BANÜ 2. TIP ÖĞRENCİ SEMPOZYUMU

Tıpta Yapay Zeka: Koruma, Tanı, Tedavi ve Etik Boyut

8 MAYIS 2026 CUMA

SAAT 09.00

NAZIM HİKMET KONFERANS SALONU (MERKEZİ DERSLİK BİNASI)



TAM METİN KİTABI

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ

TIP FAKÜLTESİ

www.tipsempozyum2026.bandirma.edu.tr

BANÜ 2.TIP ÖĞRENCİ SEMPOZYUMU

Tıpta Yapay Zeka:

Koruma, Tanı, Tedavi ve Etik Boyutu

08 MAYIS 2026 Bandırma/Balıkesir/Türkiye

Editör

YAKUP BAYKUŞ

AYŞE GÜLDEM KİLCİLER

Editör Yardımcıları

RULİN DENİZ

SEFER ÜSTEBAY

M.BORA UZUNER

ALİHAN TIĞLI

Bu kitabın tüm hakları Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi Dekanlığına aittir.

Yazarlar etik ve hukuki olarak eserlerinden sorumludurlar.

Yayın Tarihi

24.06.2026

ISBN

978-625-94286-9-7

SEMPOZYUM DÜZENLEME KURULU

- Dr. Ayşe Güldem KİLCİLER
- Dr. Alihan TIĞLI
- Dr. Muhammet Bora UZUNER
- Dr. Rulin DENİZ
- Dr. Sefer ÜSTEBAY
- Dr. Yakup BAYKUŞ
- Stj. Dr. Behiye YILDIZ
- Stj. Dr. Berivan TAYANAK

SEMPOZYUM BİLİMSEL KURULU

- Dr. Ahmet BALUN
- Dr. Ali Haldun ÖZCAN
- Dr. Alihan TIĞLI
- Dr. Alkame AKGÜMÜŞ
- Dr. Ayfer ASLAN
- Dr. Aykut BAŞER
- Dr. Ayşe Güldem KİLCİLER
- Dr. Ayşegül KÜÇÜK
- Dr. Begüm BARIŞ ÇETİNKAYA
- Dr. Çağdaş AKTAN
- Dr. Damla ŞAHİN
- Dr. Didem AYHAN
- Dr. Doğukan DEMİR
- Dr. Döndü ÜLKER ÜSTEBAY
- Dr. Duygu DURMAZ
- Dr. Duygu KESEBİ ISGANDAROV
- Dr. Erdal KARAVAŞ
- Dr. Filiz ÖZYİĞİT
- Dr. Fulden KÜÇÜK
- Dr. Gülseren YILMAZ
- Dr. Hakan KARDAŞ
- Dr. Hülya YILMAZ BAŞER
- Dr. Hüseyin ESECELİ
- Dr. Kader ŞAHİN
- Dr. Kadir KABAHASANOĞLU
- Dr. Mehmet KIRDAR
- Dr. Merve DİLLİ GÜRKAN
- Dr. Muammer Hayri BEKTAŞ
- Dr. Muhammet Bora UZUNER
- Dr. Mustafa ÖRMECİ
- Dr. Mustafa Talha GÜNEŞ
- Dr. Mümtaz Taner TORUN
- Dr. Nart GÖRGÜ
- Dr. Nazlı ŞENER
- Dr. Oğuz KÜÇÜKYILMAZ
- Dr. Oktay ERAY
- Dr. Onur FURUNDAOTURAN
- Dr. Ozan TÜRKMEN
- Dr. Özgür KUŞ
- Dr. Özge TANIŞMAN
- Dr. Perihan ERKAN ALKAN
- Dr. Rulin DENİZ
- Dr. Safiye Bilge GÜÇLÜ KAYTA
- Dr. Sefer ÜSTEBAY
- Dr. Sümeyra SAVAŞ
- Dr. Tilbe ERTEN ALMAK
- Dr. Toros TAŞKIN
- Dr. Yağmur Simge AKTUNA
- Dr. Yakup BAYKUŞ
- Dr. Yasemin ERCAN DEĞİRMENCİ
- Dr. Yasemin ÜNAL
- Dr. Yasin Selçuk YARDİBİ
- Dr. Yılda Arzu ABA
- Dr. Zülfiye KÖKTAŞ

Sempozyum düzenleme kurulu ve sempozyum bilimsel kurulu isim sıralaması, alfabetik sıralamaya göre düzenlenmiştir.

İÇİNDEKİLER

Radyolojide yapay zeka destekli görüntü analizi: tanıya yardımcı sistemler	1
Dijital patolojide yapay zeka: nerelerde kullanıyoruz?	8
Kardiyoloji pratiğinde yapay zeka kullanımı	13
Dahiliye Pratiğinde Yapay Zekâ Destekli Karar Sistemleri	21
Acil Tıpta Yapay Zekâ: Risk Stratifikasyonu ve Müdahale Kararı	28
Nörolojik hastalıklarda yapay zekâ: iyileşme potansiyeli ve fonksiyonel prognoz	33
Çocuk hastalıklarında yapay zekâ: erken tanı ve prognoz	42
Enfeksiyöz ajanların tanısında yapay zeka ile mikroorganizma tanımlama: güncel yaklaşımlar üzerine bir derleme	45
Cerrahiye karar: Yapay zeka ile hasta seçimi ve risk tahmini	52
Kadın hastalıklarında yapay zeka: jinekoloji ve obstetrik uygulamaları	55
Ürolojide Uygulamalarında Yapay Zeka: Tanı ve Tedavi Planlama	68
Beyin ve sinir cerrahisinde yapay zekâ: cerrahi planlama ve nöronavigasyon	74
Vücut Haritası ve 3D modelleme: Yapay Zeka ile Anatomik Simulasyon (Bir Diz Eklemi Modeli)	78
Biyokimyasal parametreler ve yapay zekâ ile biyobelirteç keşfi ve erken tanı	82
İlaç Seçimi ve Doz Optimizasyonu: Yapay Zekâ ile Personalize Farmakoterapi	86
Genomik verilerde yapay zeka: Kalıtsal hastalıkların tanısı ve risk tahmini	93
Kulak Burun Boğazda Yapay Zeka: Görüntüleme ve Erken Tanı Uygulamaları	100
Körlüğü önlemek: yapay zeka ile retina hastalıklarının erken tanısı	105
Çocuk Ruh Sağlığında Yapay Zekâ: Davranış Analizi ve Erken Müdahale	117
Beslenme Uygulamalarında Yapay Zeka: Kişiselleştirilmiş Beslenme Planlaması ve Hasta Takibi	125
Tıpta Yapay Zekâ: Veri Güvenliği, Etik ve Hukuki Sorumluluklar	133
Postmenopozal Osteoporozda Gastrointestinal Mikrobiyota: Patofizyoloji, Kanıtlar ve Tedaviye Yansımalar	141
Yoğun Bakım Ünitelerinde Karar Destek Sistemlerinde Yapay Zekânın Rolü: Anestezist Perspektifi	150
Brakial arter kanülasyonunda kanül ucu kopması: Nadir bir komplikasyon	154
Eş zamanlı ön çapraz bağ rekonstrüksiyonu menisküs onarımının klinik sonuçlarını ve başarısızlık oranlarını etkiliyor mu?	157
Osteoporotik Vertebra Kompresyon Kiriklarinda Vertebroplasti ve Kifoplastinin Klinik ve Radyolojik Sonuçlarinin Karşilaştirilmasi	158
Hidroklorotiyazid başlanmasını izleyen ağır semptomatik hipotonik hiponatremi: yoğun bakımda yönetilen yaşlı kadın olgu	160
Empagliflozin kullanan tip 2 diyabetli hastada üriner sistem enfeksiyonu ve azalmış oral alım sonrası gelişen öglisemik diyabetik ketoasidoz: olgu sunumu	164
Adölesan idiopatik skolyoz hastalarında anterior vertebral body tetherıng (avbt) ve posterior spinal füzyon (psf) cerahilerinin klinik ve fonksiyonel sonuçlarının karşılaştırılması	169
Fiziksel tıp ve rehabilitasyonda yapay zekâ uygulamaları: son 10 yıldaki gelişmeler ve gelecek perspektifleri	170
İş sağlığı uygulamalarında yapay zeka kullanımı: kullanım alanları, fırsatlar, sınırlılıklar ve etik boyutlar	178
Beyin morfolojisinde yapay zekânın rolü: literatür derlemesi	186
Uterusun mezenkimal tümörü; Leiomyosarkom olgu tanısında yaşanan zorluklar	192
Toplumda yapay zekânın sağlık hizmetlerinde faydalı olacağına ilişkin görüşler ve ilişkili faktörler	198
Makine öğrenmesi modellerinde hata profili analizi: diyabet verisi üzerinden tanımlayıcı bir analiz	202
Sağlık Yönetiminde Yapay Zeka Uygulamaları: Bir Sağlık Yönetimi Perspektifinden İnceleme	212
Menopozal ve perimenopozal dönemde hormon tedavisi: biyoeşdeğer formlar, uygulama yolları ve klinik yaklaşımlardaki tarihsel dönüşüm	225
İleri Yaşta Saptanan Orta Hat Yerleşimli Dev Kranial Lipom: Nadir Bir Tanı	245
Afet Tıbbında Yapay Zekâ Uygulamaları: Erken Uyarıdan Klinik Karar Desteğine Güncel Yaklaşımlar	250
Laparoskopik total histerektomide uterin arterin üreter vizualizasyonu eşliğinde erken ligasyonu: intraoperatif kanama kontrolüne yönelik güvenli bir cerrahi yaklaşım	257
Yapay zekâ destekli sohbet botlarının sigara bırakma uygulamalarında klinik kullanım potansiyelinin değerlendirilmesi	262
Yapay zeka destekli hemşirelik bakımının yaşam kalitesi üzerine etkileri: derleme çalışması	272

Radyolojide yapay zeka destekli görüntü analizi: tanıya yardımcı sistemler

Gülsüm Bige YILDIR [1], Özge TANIŞMAN [2]
[1] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi Öğrencisi
[2] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Radyoloji Ana Bilim Dalı

İletişim: glbyildir@gmail.com

Özet

Radyoloji, artan görüntüleme hacmi ve veri karmaşıklığı nedeniyle yüksek iş yüküyle karşı karşıya olan bir tıbbi disiplindir. Yapay zeka (YZ), özellikle derin öğrenme ve evrişimli sinir ağları (CNN) aracılığıyla tıbbi görüntü analizinde doğruluk, hız ve verimlilik sağlayarak bu süreci dönüştürmektedir. Bu derlemede, YZ'nin radyolojideki temel uygulamaları; bilgisayar destekli tanı sistemleri, görüntü segmentasyonu, sınıflandırma ve radyomik analiz kapsamında ele alınmıştır. YZ'nin erken tanıyı destekleme, klinik iş akışını optimize etme ve hasta sonuçlarını iyileştirme potansiyeli vurgulanmıştır. Bununla birlikte, veri gizliliği, algoritmik önyargı, açıklanabilirlik eksikliği ve genellenebilirlik sorunları, bu teknolojinin klinik uygulamalara entegrasyonunda önemli sınırlılıklar oluşturmaktadır. Mevcut bulgular, YZ'nin bağımsız bir sistemden ziyade, radyologlarla iş birliği içinde çalışan tamamlayıcı bir araç olarak en etkili şekilde kullanılabileceğini göstermektedir. Sonuç olarak, YZ'nin sürdürülebilir klinik entegrasyonu, teknik performans kadar etik ve sosyal boyutların da dikkate alınmasını gerektirmektedir.

Anahtar Kelimeler: Yapay zeka, radyoloji, derin öğrenme, görüntü analizi, tanıya yardımcı sistemler.

1. Giriş

Radyoloji, hastalıkların tanı, tedavi planlaması ve takibinde merkezi rol oynayan temel tıbbi disiplinlerden biridir. X-ışınlarının keşfi ile başlayan süreç, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG), ultrasonografi ve pozitron emisyon tomografisi (PET) gibi ileri görüntüleme tekniklerinin geliştirilmesiyle büyük bir evrim geçirmiştir. Günümüzde bu teknolojiler, anatomik ve fonksiyonel düzeyde detaylı bilgi sağlayarak klinik karar verme süreçlerinin ayrılmaz bir parçası haline gelmiştir [1].

Son yıllarda sağlık hizmetlerinde dijitalleşmenin hız kazanması, radyolojik görüntülerin sayısında ve karmaşıklığında önemli bir artışa yol açmıştır. Bu durum, radyologların değerlendirmesi gereken veri miktarını dramatik şekilde artırarak iş yükünü yükseltmiş ve insan faktörüne bağlı hataların ortaya çıkma riskini beraberinde getirmiştir.

Yapay zeka (YZ), bu ihtiyaçlara yanıt verebilecek en önemli teknolojik gelişmelerden biri olarak öne çıkmaktadır. Makine öğrenmesi ve özellikle derin öğrenme algoritmaları, büyük veri setlerinden öğrenerek karmaşık örüntüleri tanıyabilme kapasitesine sahiptir. Evrişimli sinir ağları (CNN) gibi modeller, görüntü işleme alanında yüksek başarı oranlarıyla öne çıkmakta ve tıbbi görüntülerdeki patolojik değişiklikleri otomatik olarak tespit edebilmektedir. Bu sistemler, insan gözünün algılamakta zorlandığı mikroskobik düzeydeki değişimleri analiz edebilme yeteneği sayesinde tanısal doğruluğun artırılmasına katkı sağlamaktadır [2].

YZ'nin radyolojideki kullanımı, yalnızca görüntü analizinin otomasyonu ile sınırlı kalmayıp, aynı zamanda klinik karar destek sistemlerinin geliştirilmesine de olanak tanımaktadır. Bu sistemler, hastaya ait klinik ve görüntüleme verilerini entegre ederek tanı ve tedavi süreçlerinde daha kapsamlı değerlendirmeler yapılmasını mümkün kılmaktadır.

Literatürde, YZ'nin tanı doğruluğunu artırdığı, görüntü yorumlama süresini azalttığı ve iş akışı verimliliğini iyileştirdiği bildirilmiştir [3,4]. Bununla birlikte, bu teknolojilerin radyoloğun yerini almak yerine, klinik karar verme sürecinde destekleyici bir araç olarak kullanılması gerektiği vurgulanmaktadır.

Ancak YZ'nin radyoloji pratiğine entegrasyonu çeşitli zorlukları da beraberinde getirmektedir. Algoritmaların "black box" olarak adlandırılan şeffaflık sorunları, veri gizliliği ve güvenliği, model doğruluğunun farklı hasta popülasyonlarında değişkenlik göstermesi gibi faktörler bu teknolojilerin klinik kullanımını sınırlayan önemli unsurlar arasında yer almaktadır. Ayrıca, YZ sistemlerinin gerçek klinik ortamlardaki etkinliğine ilişkin kanıtların hâlen sınırlı olması, bu sistemlerin dikkatli ve kontrollü bir şekilde uygulanmasını gerektirmektedir [3].

Bu derlemenin amacı, YZ'nin radyolojideki mevcut kullanım alanlarını, teknik altyapısını ve klinik etkilerini kapsamlı bir şekilde incelemek; aynı zamanda bu teknolojilerin sunduğu fırsatları ve karşılaşılan zorlukları güncel literatür ışığında değerlendirmektir.

2. Yapay Zekanın Radyolojideki Rolü

YZ, radyolojide görüntü analizi ve klinik karar süreçlerini destekleyen önemli bir teknoloji haline gelmiştir. Özellikle derin öğrenme ve evrişimli sinir ağları (CNN), tıbbi görüntülerdeki karmaşık örüntüleri analiz ederek tanı doğruluğunu artırabilmektedir. Yapılan çalışmalar, YZ sistemlerinin belirli görevlerde radyolog performansına yakın sonuçlar verebildiğini göstermektedir [5].

YZ uygulamaları radyolojide başlıca lezyon tespiti, görüntü segmentasyonu ve hastalık sınıflandırması alanlarında kullanılmaktadır. Bu sistemler, büyük veri setleri üzerinden öğrenerek insan gözünün fark edemeyeceği detayları tespit edebilmekte ve erken tanıya katkı sağlamaktadır [6].

Bunun yanı sıra YZ, radyolojik iş akışını optimize ederek yorumlama süresini azaltmakta ve iş yükünü hafifletmektedir. Ayrıca klinik karar destek sistemleri aracılığıyla hasta verileri entegre edilerek daha kapsamlı ve kişiselleştirilmiş değerlendirmeler yapılabilmektedir [7].

Ancak algoritmaların açıklanabilirliği, veri güvenliği ve genellenebilirlik gibi sorunlar, YZ'nin klinik kullanımını sınırlayan önemli faktörlerdir. Bu nedenle YZ, tanı sürecini destekleyen tamamlayıcı bir araç olarak değerlendirilmelidir.

3. Bilgisayar Destekli Tanı (CAD) Sistemleri

Bilgisayar destekli tanı (Computer-Aided Diagnosis, CAD) sistemleri, radyolojik görüntülerdeki anormallikleri otomatik olarak analiz eden ve radyologların tanı sürecini destekleyen algoritmik yapılardır. Bu sistemler, görüntüleri tarayarak şüpheli bölgeleri belirler ve ilgili alanları işaretleyerek radyoloğun dikkatini bu bölgelere yönlendirir. Böylece tanı sürecinde hem hız hem de doğruluk artışı sağlanmaktadır [6].

CAD sistemleri genel olarak iki ana kategoriye ayrılmaktadır:

CADe (Computer-Aided Detection): Görüntüdeki lezyon, nodül veya anormal yapıları tespit eder ve işaretler.

CADx (Computer-Aided Diagnosis): Tespit edilen lezyonların benign veya malign olma olasılığını değerlendirerek sınıflandırma yapar.

Bu sistemler, özellikle mamografi, akciğer bilgisayarlı tomografisi ve direkt grafilerde yaygın olarak kullanılmaktadır. Örneğin, meme kanseri taramalarında CAD

sistemlerinin kullanımı, küçük lezyonların tespit edilmesinde duyarlılığı artırarak erken tanıya katkı sağlamaktadır [8]. Benzer şekilde akciğer nodüllerinin tespitinde ve kemik kırıklarının değerlendirilmesinde de CAD sistemlerinin klinik faydası gösterilmiştir [5].

Bununla birlikte, CAD sistemleri radyoloğun yerini alan bağımsız sistemler olarak değil, tanı sürecini destekleyen yardımcı araçlar olarak kullanılmaktadır. Yapılan çalışmalar, bu sistemlerin özellikle ikinci okuyucu (second reader) olarak kullanıldığında tanısal performansı artırdığını ortaya koymaktadır [6].

4. Görüntü Analizinde Derin Öğrenme (Deep Learning)

Derin öğrenme, yapay zekanın en gelişmiş alt alanlarından biri olup, tıbbi görüntü analizinde yüksek doğruluk sağlayan yöntemler arasında yer almaktadır. Özellikle evrişimli sinir ağları (CNN), radyolojik görüntülerdeki karmaşık örüntüleri analiz ederek sınıflandırma, segmentasyon ve anomali tespiti gibi görevlerde yaygın olarak kullanılmaktadır [5].

Derin öğrenme tabanlı görüntü analizi süreci genel olarak dört temel aşamadan oluşmaktadır: ön işleme ve özellik çıkarımı, segmentasyon, sınıflandırma ve radyomik analiz. Ön işleme aşamasında görüntü kalitesi iyileştirilirken, CNN modelleri aracılığıyla otomatik özellik çıkarımı yapılır. Segmentasyon aşamasında ilgi alanları (örneğin tümör dokusu) ayrıştırılır ve sınıflandırma aşamasında bu yapılar klinik olarak anlamlı kategorilere ayrılır (Benign/malign gibi).

Son aşama olan radyomik analiz, görüntülerin yüksek boyutlu sayısal verilere dönüştürülmesini ve bu verilerden klinik olarak anlamlı özelliklerin çıkarılmasını içerir. Radyomik yaklaşımlar, tümörün şekli, yoğunluğu ve doku heterojenliği gibi özellikleri analiz ederek hastalığın biyolojik davranışı ve prognozu hakkında öngörüler sunabilmektedir. Güncel çalışmalar, radyomik analizlerin tanı doğruluğunu artırmanın yanı sıra tedavi yanıtının öngörülmesine de katkı sağladığını göstermektedir [9,10].

Bununla birlikte, derin öğrenme ve radyomik analiz yöntemlerinin klinik uygulamalara entegrasyonu bazı sınırlılıklar içermektedir. Özellikle veri standardizasyonu, modelin genellenebilirliği ve sonuçların tekrarlanabilirliği gibi sorunlar, bu sistemlerin güvenilirliğini etkileyen önemli faktörler arasında yer almaktadır [10].

5. Klinik Uygulamalar ve Tanısal Başarı

YZ'nın radyolojiye entegrasyonu, tanısal süreçleri yalnızca hızlandırmakla kalmamış, aynı zamanda insan kaynaklı hataları azaltarak klinik doğruluğu ve hasta sonuçlarını önemli ölçüde iyileştirmiştir. Yapılan çalışmalar, YZ destekli görüntü analizinin tanı süresini kısalttığını ve yorumlama sürecindeki hata oranlarını azalttığını göstermektedir [4]. Bu teknolojik dönüşüm; onkoloji, kardiyoloji, nöroloji ve acil tıp gibi birçok klinik alanda somut kazanımlar sağlamaktadır.

Özellikle derin öğrenme tabanlı algoritmaların, akciğer nodülleri gibi erken evre kanser bulgularının tespitinde yüksek duyarlılık ve doğruluk sağladığı gösterilmiştir [11]. Benzer şekilde, intrakraniyal kanama gibi acil durumların saptanmasında YZ sistemlerinin yüksek doğruluk oranlarına ulaşabildiği ve tanı süresini anlamlı derecede kısalttığı bildirilmektedir [12]. Bu bulgular,YZ'nin kritik klinik senaryolarda radyolog performansını destekleyici ve hızlandırıcı bir rol oynadığını göstermektedir.

Bunun yanı sıra, YZ sistemleri radyoloji iş akışını optimize ederek acil vakaların önceliklendirilmesine olanak tanımaktadır. Güncel uygulamalarda, algoritmalar şüpheli

bulguları otomatik olarak işaretleyebilmekte ve yüksek riskli vakaları öncelikli değerlendirme listesine alarak müdahale süresini kısaltmaktadır [7]. Bu yaklaşım, özellikle zamanın kritik olduğu durumlarda klinik sonuçların iyileştirilmesine katkı sağlamaktadır.

Sonuç olarak, YZ'nin radyoloji pratiğine entegrasyonu yalnızca teknik bir gelişim değil, aynı zamanda klinik karar süreçlerini yeniden şekillendiren kapsamlı bir dönüşüm olarak değerlendirilmektedir. Ancak bu sistemlerin en etkili şekilde kullanılabilmesi için insan–makine iş birliğinin sürdürülmesi ve klinik validasyon süreçlerinin dikkatle yürütülmesi gerekmektedir.

6. Etik Sorunlar ve Toplumsal Yansımalar

YZ sistemlerinin klinik karar verme süreçlerine entegrasyonu, hasta güvenliği, veri mahremiyeti ve sağlık hizmetlerinin eşitliği gibi temel etik ilkeleri doğrudan etkileyen çok boyutlu tartışmaları beraberinde getirmektedir. Son yıllarda yapılan çalışmalar, YZ'nin sağlık hizmetlerinde sunduğu potansiyele rağmen, etik ve düzenleyici çerçevelerin bu hızlı teknolojik gelişime tam olarak ayak uyduramadığını göstermektedir. Bu durum, hem sağlık profesyonelleri hem de hastalar nezdinde güven sorunlarına yol açarak YZ'nin klinik uygulamalara entegrasyon sürecini yavaşlatmaktadır [13].

6.1. Veri Gizliliği ve Güvenliği:

Tıbbi verilerin son derece hassas ve kişisel niteliği, YZ uygulamalarında veri güvenliğini en kritik konulardan biri haline getirmektedir. Özellikle büyük veri setlerinin toplanması, saklanması ve işlenmesi süreçlerinde veri ihlali, yetkisiz erişim ve yeniden kimliklendirme (re-identification) gibi riskler ortaya çıkmaktadır. Güncel literatür, hasta mahremiyetinin korunmasının yalnızca hukuki bir zorunluluk değil, aynı zamanda YZ sistemlerine duyulan güvenin sürdürülebilirliği açısından temel bir unsur olduğunu vurgulamaktadır [14]. Ayrıca, veri anonimleştirme tekniklerinin her zaman yeterli olmadığı ve gelişmiş algoritmaların anonim veriler üzerinden bile bireyleri yeniden tanımlayabildiği belirtilmektedir.

6.2. Algoritmik Önyargı ve Adalet:

YZ modelleri, eğitildikleri veri setlerinin özelliklerini doğrudan yansıttıkları için önyargı (bias) üretme potansiyeline sahiptir. Özellikle veri setlerinin belirli demografik grupları yeterince temsil etmemesi durumunda, modellerin belirli hasta gruplarında daha düşük performans göstermesi söz konusu olabilmektedir. Bu durum, mevcut sağlık eşitsizliklerini artırarak etik açıdan ciddi sorunlar doğurmaktadır [15]. Güncel çalışmalar, YZ sistemlerinin yalnızca teknik olarak değil, aynı zamanda sosyodemografik açıdan da dengeli veri setleri ile eğitilmesi gerektiğini ortaya koymaktadır [15]. Ayrıca, algoritmik önyargının fark edilmesinin zor olması, bu sorunun uzun süre fark edilmeden klinik uygulamalarda devam etmesine neden olabilmektedir.

6.3. Sorumluluk ve Hesap Verebilirlik:

YZ sistemlerinin klinik karar süreçlerinde kullanılması, hata durumunda sorumluluğun kimde olduğu sorusunu gündeme getirmektedir. Bir tanı hatası durumunda sorumluluğun geliştiriciye mi, yazılım sağlayıcısına mı yoksa klinik kararı veren hekime mi ait olduğu konusu henüz netlik kazanmamıştır. Bu belirsizlik, hukuki düzenlemelerin yetersiz kaldığı alanlardan biri olarak öne çıkmaktadır. Güncel etik yaklaşımlar, YZ'nin bağımsız bir karar verici olarak değil, insan denetimi altında çalışan bir destek sistemi olarak konumlandırılması gerektiğini vurgulamaktadır [14]. Bu bağlamda "human-in-the-loop" yaklaşımı, klinik güvenliği artıran önemli bir model olarak önerilmektedir.

6.4. Şeffaflık Eksikliği (Kara Kutu Problemi):

Derin öğrenme tabanlı YZ sistemlerinin en önemli sınırlılıklarından biri, karar verme süreçlerinin çoğu zaman açıklanamamasıdır. "Kara kutu" olarak tanımlanan bu durum, hem hekimlerin hem de hastaların YZ'ye duyduğu güveni olumsuz etkileyebilmektedir. Özellikle klinik kararların gerekçelendirilmesinin zor olması, hata analizini ve sistemin doğrulanmasını güçleştirmektedir. Bu nedenle, açıklanabilir YZ (Explainable AI) yaklaşımlarının geliştirilmesi ve klinik ortamlarda uygulanabilir hale getirilmesi büyük önem taşımaktadır [16]. Açıklanabilirlik, yalnızca teknik bir gereklilik değil, aynı zamanda etik ve hukuki sorumluluğun da temel bileşenlerinden biri olarak değerlendirilmektedir.

6.5. Yanlış Pozitiflerin Artma Riski:

YZ sistemleri genellikle yüksek duyarlılık ile çalışacak şekilde optimize edildiğinden, bazı durumlarda yanlış pozitif sonuç oranlarında artış gözlemlenebilmektedir. Bu durum, gereksiz ileri tetkiklere, artan sağlık maliyetlerine ve hastalarda anksiyete gibi psikolojik etkilere yol açabilmektedir. Güncel çalışmalar, YZ sistemlerinin klinik karar destek aracı olarak kullanılması gerektiğini ve sonuçların mutlaka uzman hekim tarafından değerlendirilmesi gerektiğini vurgulamaktadır [17].

6.6. Yüksek Teknik Gereksinim ve Maliyet:

YZ sistemlerinin klinik uygulamalarda etkin bir şekilde kullanılabilmesi için yüksek işlem gücüne sahip donanımlar, geniş veri altyapıları ve uzman teknik ekipler gerekmektedir. Bu durum, özellikle düşük ve orta gelirli ülkelerde sağlık sistemleri için önemli bir uygulama bariyeri oluşturmaktadır. Ayrıca, sistemlerin kurulumu, bakımı ve güncellenmesi de ek maliyetler doğurmaktadır. Güncel literatür, YZ'nin sağlık sistemlerinde eşitsizlikleri azaltmak yerine bazı durumlarda artırabileceğine dikkat çekmektedir [13].

6.7. İnsan Bağlantısının Zayıflaması:

YZ sistemlerinin yaygınlaşması, hasta-hekim ilişkisinde insan faktörünün azalması riskini beraberinde getirmektedir. Empati, iletişim ve klinik sezgi gibi insan odaklı becerilerin YZ tarafından ikame edilememesi, sağlık hizmetlerinde "insan dokunuşunun" önemini koruduğunu göstermektedir. Ayrıca, sağlık profesyonellerinin YZ sistemlerine aşırı güven duyması sonucunda otomasyon yanlılığı (automation bias) gelişebileceği ve bu durumun klinik karar kalitesini olumsuz etkileyebileceği belirtilmektedir [18].

7. Tartışma

Yapay zekanın radyoloji pratiğine entegrasyonu, son yıllarda tanısal doğruluk, hız ve klinik verimlilik açısından önemli kazanımlar sağlamış olsa da bu teknolojinin gerçek klinik ortamlardaki etkisi hâlen çok boyutlu bir değerlendirme gerektirmektedir. Literatürde, yapay zeka destekli sistemlerin özellikle görüntü analizinde yüksek doğruluk oranlarına ulaştığı ve bazı spesifik görevlerde radyolog performansına yakın sonuçlar verebildiği gösterilmiştir [5]. Bununla birlikte, bu başarıların büyük ölçüde kontrollü veri setleri üzerinde elde edildiği ve gerçek dünya koşullarında performansın değişkenlik gösterebildiği vurgulanmaktadır [19,20].

YZ'nin en belirgin katkılarından biri, radyolojik iş akışını optimize ederek yorumlama sürelerini azaltması ve yüksek hacimli veri yönetimini kolaylaştırmasıdır. Özellikle acil vakaların önceliklendirilmesi, triyaj sistemleri ve otomatik raporlama süreçleri, klinik karar verme sürecini hızlandırarak hasta sonuçlarını olumlu yönde etkileyebilmektedir [7]. Ancak bazı çalışmalar, yapay zeka kullanımının iş yükünü tamamen ortadan kaldırmadığını, aksine yanlış pozitif bulguların artması durumunda ek

değerlendirme gereksinimi doğurarak iş yükünü farklı bir biçimde yeniden şekillendirebileceğini göstermektedir.

Bunun yanı sıra, yapay zeka sistemlerinin genellenebilirliği önemli bir tartışma konusudur. Bir modelin belirli bir veri seti üzerinde yüksek performans göstermesi, farklı hasta popülasyonlarında veya farklı görüntüleme cihazlarında aynı başarıyı göstereceği anlamına gelmemektedir. Veri heterojenliği, görüntü kalitesi farklılıkları ve demografik çeşitlilik, model performansını doğrudan etkileyen faktörlerdir. Bu nedenle, modellerin çok merkezli ve çeşitli veri setleri üzerinde test edilmesi gerektiği vurgulanmaktadır [20].

Etik ve hukuki boyutlar da yapay zekanın klinik uygulamalara entegrasyonunda önemli sınırlılıklar oluşturmaktadır. Algoritmik önyargı, veri gizliliği ve sorumluluk paylaşımı gibi konular, hem klinik güven hem de hasta kabulü açısından kritik öneme sahiptir. Özellikle açıklanabilirlik eksikliği (kara kutu problemi), klinisyenlerin sistem çıktılarının arkasındaki mantığı anlamasını zorlaştırmakta ve bu durum klinik karar süreçlerinde yapay zekaya olan güveni sınırlamaktadır.

Tüm bu sınırlılıklara rağmen, yapay zekanın radyolojideki geleceği oldukça umut vericidir. Güncel eğilimler, yapay zekanın bağımsız bir karar verici sistem olarak değil, insan uzmanlarla birlikte çalışan hibrit bir model çerçevesinde en etkili sonuçları verdiğini göstermektedir. “Human-in-the-loop” yaklaşımı, hem tanısal doğruluğu artırmakta hem de etik ve güvenlik sorunlarını azaltmaktadır [7].

Sonuç olarak, yapay zeka radyolojide devrim niteliğinde bir potansiyele sahip olmakla birlikte, bu teknolojinin sürdürülebilir ve güvenilir bir şekilde kullanılabilmesi için teknik performansın yanı sıra etik, klinik ve sosyodemografik faktörlerin bütüncül bir şekilde ele alınması gerekmektedir. Gelecekte yapılacak çalışmaların, gerçek dünya verileri, uzun dönem klinik sonuçlar ve sistemlerin sağlık hizmetlerine entegrasyonu üzerine odaklanması büyük önem taşımaktadır.

Sonuç

Yapay zeka (YZ), radyolojide tanısal doğruluğu artıran, iş akışlarını optimize eden ve kişiselleştirilmiş tıbbı destekleyen dönüştürücü bir teknoloji olarak öne çıkmaktadır. Görüntü analizi ve bilgisayar destekli tanı sistemleri aracılığıyla klinik süreçlere önemli katkılar sunmaktadır. Bununla birlikte, YZ’nin etkin ve güvenilir bir şekilde klinik uygulamalara entegrasyonu; veri gizliliği, algoritmik önyargı ve açıklanabilirlik gibi temel etik ve teknik sorunların çözümüne bağlıdır.

Bu bağlamda, disiplinler arası iş birliğinin güçlendirilmesi ve sağlık profesyonellerinin dijital yetkinliklerinin artırılması kritik önem taşımaktadır. Sonuç olarak, YZ’nin radyolojide sürdürülebilir bir dönüşüm yaratabilmesi, yalnızca teknolojik gelişmelerle değil, aynı zamanda etik ilkelere dayalı sorumlu kullanım ile mümkün olacaktır.

Kaynakça

1. Najjar, R. (2023). Redefining radiology with artificial intelligence. Diagnostics, 13(17), 2760. https://doi.org/10.3390/diagnostics13172760
2. Obuchowicz, R., et al. (2025). Artificial intelligence in radiology: Current applications and future directions. European Radiology. https://doi.org/10.1007/s00330-025-XXXXX
3. Lawrence, K., et al. (2025). Artificial intelligence in radiology workflow optimization. Journal of Medical Imaging.

4. Khalifa, M., & Albadawy, M. (2024). Artificial intelligence in radiology: Applications and challenges. Diagnostics, 14(3), 312. https://doi.org/10.3390/diagnostics14030312
5. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. Medical Image Analysis, 42, 60–88. https://doi.org/10.1016/j.media.2017.07.005
6. Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdzal, M., Turcotte, S., Pal, C. J., Kadoury, S., & Tang, A. (2017). Deep learning: A primer for radiologists. Radiographics, 37(7), 2113–2131. https://doi.org/10.1148/rg.2017170077
7. Topol, E. (2019). Deep medicine: How artificial intelligence can make healthcare human again. Basic Books.
8. Doi, K. (2007). Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. Radiology, 243(3), 611–632. https://doi.org/10.1148/radiol.2433052099
9. Gillies, R. J., Kinahan, P. E., & Hricak, H. (2016). Radiomics: Images are more than pictures, they are data. Radiology, 278(2), 563–577. https://doi.org/10.1148/radiol.2015151169
10. Mayerhoefer, M. E., Materka, A., Langs, G., Häggström, I., Szczypiński, P., Gibbs, P., & Cook, G. (2020). Introduction to radiomics. Journal of Nuclear Medicine, 61(4), 488–495. https://doi.org/10.2967/jnumed.118.222893
11. Abadia, A. F., et al. (2022). Deep learning for lung nodule detection and classification in CT imaging. Radiology: Artificial Intelligence, 4(2), e210123. https://doi.org/10.1148/ryai.210123
12. Wismüller, A. (2020). A deep learning approach for detection of intracranial hemorrhage in CT images. arXiv. https://doi.org/10.48550/arXiv.2002.12515
13. Aldhafeeri, F., et al. (2025). Ethical challenges of artificial intelligence in healthcare. Healthcare Analytics.
14. Herington, J. (2023). Ethical challenges of artificial intelligence in healthcare. Bioethics, 37(1), 45–54. https://doi.org/10.1111/bioe.13055
15. Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2021). A survey on bias and fairness in machine learning. ACM Computing Surveys, 54(6), 1–35. https://doi.org/10.1145/3457607
16. Haupt, C. E., et al. (2026). Explainable artificial intelligence in healthcare: Challenges and opportunities. Nature Medicine.
17. Goisauf, M., Cano Abadía, M., et al. (2022). Ethics of AI in healthcare: A systematic review. BMC Medical Ethics, 23, 1–14. https://doi.org/10.1186/s12910-022-00752-2
18. Romeo, A. (2025). Automation bias in clinical decision-making: Implications for AI adoption. Journal of Medical Ethics.
19. Kelly, C. J., Karthikesalingam, A., Suleyman, M., Corrado, G., & King, D. (2019). Key challenges for delivering clinical impact with artificial intelligence. BMC Medicine, 17(1), 195. https://doi.org/10.1186/s12916-019-1426-2
20. Ghassemi, M., Oakden-Rayner, L., & Beam, A. L. (2021). The false hope of current approaches to explainable artificial intelligence in healthcare. Lancet Digital Health, 3(11), e745–e750. https://doi.org/10.1016/S2589-7500(21)00208-9

Dijital patolojide yapay zeka: nerelerde kullanıyoruz?

Yasemin DOĞAN, Dönem 3 Öğrencisi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Türkiye, yaseminyd44@gmail.com

Toros TAŞKIN, Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Tıbbi Patoloji Anabilim Dalı, Türkiye, tttaskin@bandirma.edu.tr

Özet

Dijital patoloji, histopatolojik preparatların dijital ortama aktarılması ile birlikte gelişen ve modern tıpta önemli bir yer edinen bir alandır. Son yıllarda yapay zekâ teknolojilerinin bu alana entegrasyonu ile tanı süreçlerinde önemli ilerlemeler kaydedilmiştir. Bu derlemede, dijital patolojide yapay zekânın kullanım alanları, avantajları, sınırlamaları ve gelecekteki potansiyel uygulamaları güncel literatür eşliğinde ele alınmıştır. Güncel çalışmalar, yapay zekâ sistemlerinin özellikle tanı doğruluğunu artırma, iş akışını hızlandırma ve prognostik değerlendirmelerde önemli katkılar sağladığını göstermektedir.

Anahtar kelimeler: Dijital patoloji, yapay zekâ, derin öğrenme, tanı destek sistemleri

Giriş

Dijital patoloji, histopatolojik preparatların yüksek çözünürlüklü tarayıcılar aracılığıyla dijital ortama aktarılması ve bu görüntülerin bilgisayar destekli sistemler ile analiz edilmesini kapsayan modern bir tıp disiplinidir. Geleneksel mikroskobik inceleme yöntemlerine alternatif olarak gelişen bu yaklaşım, özellikle son yıllarda teknolojik ilerlemeler sayesinde hızla yaygınlaşmıştır. Dijitalleşmenin patoloji pratiğine entegrasyonu, yalnızca görüntülerin saklanması ve paylaşılmasını kolaylaştırmakla kalmamış, aynı zamanda ileri analiz yöntemlerinin uygulanmasına da olanak sağlamıştır.

Bu dönüşümün en önemli bileşenlerinden biri yapay zekâ teknolojileridir. Yapay zekâ, büyük veri setlerini analiz edebilme kapasitesi sayesinde özellikle görüntüye dayalı tıbbi alanlarda güçlü bir araç haline gelmiştir. Patoloji, hücresel ve doku düzeyindeki morfolojik değişikliklerin değerlendirilmesine dayandığı için yapay zekâ uygulamalarına son derece uygun bir alandır. Bu bağlamda, derin öğrenme ve özellikle konvolüsyonel sinir ağları gibi yöntemler, histopatolojik görüntülerin analizinde yaygın olarak kullanılmaktadır.

Son yıllarda yapılan çalışmalar, yapay zekâ destekli sistemlerin birçok patolojik durumda yüksek tanısal doğruluk oranlarına ulaştığını göstermektedir. Özellikle tümör tespiti, sınıflandırılması ve prognoz tahmini gibi alanlarda bu sistemlerin performansı dikkat çekicidir. Nitekim güncel meta-analizlerde, yapay zekâ algoritmalarının yüksek sensitivite ve spesifite değerlerine sahip olduğu ve patologlara önemli ölçüde destek sağladığı bildirilmiştir [1].

Bununla birlikte, dijital patolojide yapay zekâ kullanımı yalnızca tanı süreçleri ile sınırlı değildir. Aynı zamanda iş akışının optimize edilmesi, kantitatif analizlerin standardize edilmesi ve araştırma süreçlerinin hızlandırılması gibi pek çok alanda katkı sağlamaktadır. Klinik uygulamalara entegrasyonunun artmasıyla birlikte, yapay zekâ sistemlerinin patoloji pratiğinde giderek daha merkezi bir rol üstlenmesi beklenmektedir [2].

Ancak tüm bu gelişmelere rağmen, yapay zekânın dijital patolojide kullanımı bazı sınırlamaları da beraberinde getirmektedir. Veri standardizasyonu, etik sorunlar, regülasyon eksiklikleri ve klinik validasyon gereksinimi bu alandaki önemli tartışma konuları arasında yer almaktadır [3].

Bu derlemede, dijital patolojide yapay zekânın kullanım alanları güncel literatür ışığında ele alınarak, mevcut uygulamalar, avantajlar, sınırlamalar ve gelecekteki potansiyel gelişmeler kapsamlı bir şekilde incelenmiştir.

1. Dijital Patolojide Yapay Zekâ Teknolojileri

Dijital patolojide yapay zekâ uygulamaları, temel olarak yüksek çözünürlüklü histopatolojik görüntülerin analizine dayanır. Bu görüntüler genellikle "Whole Slide Imaging (WSI)" teknolojisi ile elde edilmekte olup, klasik mikroskopik incelemelerin dijital karşılığı olarak değerlendirilmektedir. WSI sistemleri, preparatların tamamını tarayarak gigapiksel boyutunda görüntüler üretir ve bu sayede detaylı analiz yapılmasına olanak sağlar.

Bu büyük veri setlerinin işlenmesinde en yaygın kullanılan yöntem derin öğrenme tabanlı algoritmalardır. Derin öğrenme, çok katmanlı sinir ağları aracılığıyla veriden otomatik olarak özellik çıkarımı yapabilen bir yapay zekâ alt alanıdır. Özellikle görüntü analizi söz konusu olduğunda, bu yöntemler manuel özellik belirleme ihtiyacını ortadan kaldırarak daha esnek ve güçlü analizler sunmaktadır.

Dijital patolojide en sık kullanılan model türlerinden biri konvolüsyonel sinir ağlarıdır (CNN). Bu ağlar, görüntü içerisindeki hücresel yapıları, doku organizasyonunu ve patolojik değişiklikleri tanımlayabilme yeteneğine sahiptir. CNN tabanlı modeller, özellikle tümör tespiti, hücre sınıflandırması ve doku segmentasyonu gibi görevlerde yüksek performans göstermektedir.

Bunun yanı sıra, son yıllarda daha gelişmiş yapay zekâ yaklaşımları da kullanılmaya başlanmıştır. Özellikle generative adversarial networks (GAN) gibi modeller, veri artırma (data augmentation) ve sentetik görüntü üretimi için kullanılmaktadır. Bu sayede sınırlı veri setlerine sahip çalışmalarda model performansı artırılabilmektedir [4].

Güncel literatürde ayrıca multimodal yapay zekâ sistemlerinin önemi giderek artmaktadır. Bu sistemler, yalnızca histopatolojik görüntüleri değil, aynı zamanda genetik, moleküler ve klinik verileri de entegre ederek daha kapsamlı analizler yapılmasına olanak tanımaktadır. Bu yaklaşım, özellikle kişiselleştirilmiş tıp uygulamaları açısından büyük potansiyel taşımaktadır.

Dijital patolojide yapay zekâ uygulamalarının başarısı, büyük ölçüde kullanılan veri setlerinin kalitesine ve çeşitliliğine bağlıdır. Model eğitimi için geniş ve iyi etiketlenmiş veri setlerine ihtiyaç duyulmaktadır. Bu durum, veri paylaşımı ve standardizasyon konularını önemli hale getirmektedir.

Sonuç olarak, dijital patolojide kullanılan yapay zekâ teknolojileri, görüntü analizi alanındaki gelişmelerle paralel olarak hızla ilerlemekte ve patoloji pratiğinde daha doğru, hızlı ve objektif değerlendirmelerin yapılmasına katkı sağlamaktadır.

2. Kullanım Alanları

2.1 Tanı ve Tanı Destek Sistemleri

Yapay zekânın dijital patolojide en yaygın kullanım alanı, tanı ve tanı destek sistemleridir. Bu sistemler, histopatolojik kesitlerde anormal alanları tespit ederek patologlara yardımcı olmaktadır.

Güncel meta-analizlerde, yapay zekâ algoritmalarının yüksek sensitivite ve spesifite değerlerine ulaştığı ve özellikle kanser tanısında güvenilir sonuçlar verdiği bildirilmiştir [1]. Bu durum, yapay zekânın klinik karar süreçlerinde destekleyici bir araç olarak önemini artırmaktadır.

2.2 Meme Kanserinde Kullanım

Meme kanseri, dijital patolojide yapay zekâ uygulamalarının en yoğun çalışıldığı alanlardan biridir. Özellikle lenf nodu metastazlarının tespiti, bu alandaki en önemli kullanım örneklerinden biridir.

Bejnordi ve arkadaşlarının çalışmasında, derin öğrenme algoritmalarının lenf nodu metastazlarını saptamada yüksek doğruluk gösterdiği ve özellikle mikrometastazların tespitinde patologlara destek sağladığı bildirilmiştir [5].

CAMELYON16 kapsamında geliştirilen modeller de meme kanseri metastazlarının otomatik tespitinde yapay zekânın klinik olarak uygulanabilir olduğunu göstermiştir.

Sonuç olarak, yapay zekâ meme kanserinde hem tanısal doğruluğu artırmakta hem de küçük metastatik odakların gözden kaçma riskini azaltmaktadır.

2.3 Prostat Kanserinde Kullanım

Prostat biyopsilerinin değerlendirilmesi, gözlemciye bağlı değişkenliğin yüksek olduğu alanlardan biridir. Yapay zekâ, bu değişkenliği azaltarak daha tutarlı sonuçlar elde edilmesini sağlamaktadır.

Özellikle Gleason skorlama sisteminde yapay zekâ destekli analizler, düşük ve yüksek dereceli tümörlerin ayrımında yüksek doğruluk oranlarına ulaşmıştır [6]. Ayrıca geniş veri setleri üzerinde eğitilen modeller, küçük tümör odaklarını dahi tespit edebilme kapasitesine sahiptir.

2.4 Akciğer ve Kolorektal Kanserlerde Kullanım

Yapay zekâ uygulamaları, akciğer ve kolorektal kanserlerde de etkin şekilde kullanılmaktadır. Bu alanlarda: tümör tespiti, histolojik alt tip sınıflandırması, tümör mikroçevresinin analizi gibi birçok görev başarıyla gerçekleştirilmektedir.

Özellikle tümör infiltratif hücrelerin dağılımı analiz edilerek hastalığın biyolojik davranışı hakkında bilgi elde edilebilmektedir.

2.5 Prognostik ve Prediktif Analiz

Yapay zekâ yalnızca tanı koymakla kalmayıp, hastalığın prognozunu ve tedaviye yanıtını da öngörebilmektedir. Tümör mikroçevresi, immün hücre infiltrasyonu ve hücresel heterojenlik gibi faktörler analiz edilerek sağkalım tahmini yapılabilmektedir [7].

Bu yaklaşım, kişiselleştirilmiş tıp uygulamaları açısından büyük önem taşımaktadır.

2.6 Kantitatif Analiz ve Otomasyon

Dijital patolojide yapay zekâ, kantitatif ölçümlerin standardizasyonunda önemli rol oynamaktadır. Özellikle; mitotik indeks hesaplama, Ki-67 proliferasyon indeksi, immünohistokimyasal boyanma oranları gibi ölçümler yapay zekâ sayesinde daha hızlı ve objektif şekilde yapılabilmektedir.

2.7 Klinik İş Akışına Katkı

Yapay zekâ sistemleri, patoloji laboratuvarlarında iş akışını optimize etmektedir. Ön tarama yaparak normal vakaları ayıklamakta ve patologların daha kritik vakalara odaklanmasını sağlamaktadır [8].

Bu durum, hem zaman tasarrufu sağlamakta hem de tanısal verimliliği artırmaktadır.

3. Avantajlar ve Sınırlamalar

3.1 Avantajlar

Yapay zekânın en önemli avantajlarından biri, tanısal doğruluğu artırması ve gözlemciye bağlı değişkenliği azaltmasıdır. Özellikle büyük veri setleri üzerinde eğitilen algoritmalar, patologlar arasında görülebilen yorum farklılıklarını minimize edebilmektedir.

Buna ek olarak, yapay zekâ sistemleri iş akışını hızlandırarak patologların zamanını daha kritik vakalara yönlendirmesine olanak sağlar. Ön tarama algoritmaları sayesinde normal örnekler hızlıca ayıklanabilir ve patolojik olabilecek vakalar önceliklendirilebilir [2].

Ayrıca, kantitatif analizlerde yüksek tekrarlanabilirlik sağlaması, özellikle Ki-67 ve mitotik indeks gibi ölçümlerde objektif sonuçlar elde edilmesine katkı sunmaktadır.

3.2 Sınırlamalar

Yapay zekânın en önemli sınırlamalarından biri, yüksek kaliteli ve büyük ölçekli veri setlerine ihtiyaç duymasıdır. Veri eksikliği veya dengesiz veri dağılımı, model performansını olumsuz etkileyebilmektedir.

Bunun yanında, klinik validasyon süreçlerinin tamamlanmamış olması, birçok algoritmanın rutin klinik kullanıma tam olarak entegre edilmesini sınırlamaktadır. Ayrıca regülasyon eksiklikleri ve etik sorunlar (veri gizliliği, sorumluluk paylaşımı gibi) önemli tartışma konularıdır [3].

Son olarak, yapay zekâ sistemlerinin “kara kutu” (black box) yapısı, karar süreçlerinin tam olarak açıklanamaması nedeniyle klinisyenler arasında güven sorununa yol açabilmektedir.

4. Gelecek Perspektifleri

2026 yılına ait güncel çalışmalar, dijital patolojide yapay zekânın daha gelişmiş hale geleceğini ve multimodal veri entegrasyonu ile daha kapsamlı analizler yapılabileceğini göstermektedir [8]. Histopatolojik görüntülerin yanında genomik, proteomik ve klinik verilerin birlikte analiz edilmesiyle daha kapsamlı ve kişiselleştirilmiş tanı ve tedavi yaklaşımları geliştirilebilecektir. Bu yaklaşım, özellikle onkoloji alanında bireyselleştirilmiş tıp uygulamalarını güçlendirecektir.

Bunun yanı sıra, büyük dil modelleri ve üretken yapay zekâ sistemlerinin dijital patolojiye entegrasyonu giderek önem kazanmaktadır. Bu sistemler, patoloji raporlarının otomatik oluşturulması, görüntü yorumlama desteği ve eğitim süreçlerinde yardımcı araç olarak kullanılabilir hale gelmektedir.

Ayrıca gelecekte yapay zekâ sistemlerinin daha şeffaf ve açıklanabilir hale gelmesi (explainable AI), klinik güvenin artması açısından kritik bir gelişme olacaktır. Bu sayede “kara kutu” problemine yönelik sınırlamalar azaltılabilecektir.

5. Sonuç

Dijital patoloji, histopatolojik preparatların dijital ortama aktarılmasıyla tanı süreçlerini daha hızlı ve standart hale getiren modern bir yaklaşımdır. Bu alanda yapay zekâ ve derin öğrenme tabanlı sistemler; özellikle meme ve prostat kanseri gibi hastalıklarda tanı, sınıflandırma ve değerlendirme süreçlerinde patologlara destek sağlamaktadır. Yapay zekâ, iş yükünü azaltarak ve objektif analiz imkânı sunarak patoloji pratiğine katkı verirken, nihai klinik kararın yine patologlar tarafından verilmesi temel prensip olmaya devam etmektedir. Bu nedenle yapay zekâ, patoloğun yerini alan bir sistemden ziyade onunla iş birliği içinde çalışan bir destek aracı olarak değerlendirilmektedir. Genel olarak bu teknolojilerin gelişimi, tanısal doğruluğu artırırken aynı zamanda patoloji pratiğinde daha verimli ve entegre bir çalışma modeline geçişi mümkün kılmaktadır.

Kaynakça

1. McGenity, C., Clarke, E. L., Jennings, C., Matthews, G., Cartlidge, C., Freduah-Agyemang, H., & Treanor, D. (2024).Artificial intelligence in digital pathology: A systematic review and meta-analysis of diagnostic test accuracy. npj Digital Medicine, 7, 114. https://doi.org/10.1038/s41746-024-01106-8
2. Zhang, D. Y., Venkat, A., Khasawneh, H., Sali, R., Zhang, V., & Pei, Z. (2024).Implementation of digital pathology and artificial intelligence in routine pathology practice. Laboratory Investigation, 104(9), 102111. https://doi.org/10.1016/j.labinv.2024.102111
3. van Diest, P. J., Flach, R. N., van Dooijeweert, C., Makineli, S., Breimer, G. E., Stathonikos, N., & Veta, M. (2024).Pros and cons of artificial intelligence implementation in diagnostic pathology. Histopathology, 84(6), 924–934. https://doi.org/10.1111/his.15153
4. Alajaji, S. A., Khoury, Z. H., Elgharib, M., Saeed, M., Ahmed, A. R. H., Khan, M. B., & Sultan, A. S. (2024).Generative adversarial networks in digital histopathology: Current applications, limitations, ethical considerations, and future directions. Modern Pathology, 37(1), 100369. https://doi.org/10.1016/j.modpat.2023.
5. Bejnordi, B. E., Veta, M., van Diest, P. J., van Ginneken, B., Karssemeijer, N., Litjens, G., … & Ciompi, F. (2017).Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. JAMA, 318(22), 2199–2210. https://doi.org/100369.10.1001/jama.2017.14585
6. Ström, P., Kartasalo, K., Olsson, H., Solorzano, L., Delahunt, B., Berney, D. M., … & Egevad, L. (2020).Artificial intelligence for diagnosis and grading of prostate cancer in biopsies: A population-based, diagnostic study. The Lancet Oncology, 21(2), 222–232. https://doi.org/10.1016/S1470-2045(19)30738-7.
7. Tucci, F., Laurinavicius, A., Kather, J. N., & Eloy, C. (2024).The digital revolution in pathology: Towards a smarter approach to research and treatment. Pathology, 110(4), 241–251. https://doi.org/10.1177/03008916241231035
8. Zhang, X. M., Li, Q., Wang, Y., & Chen, Z. (2026).Artificial intelligence in digital pathology diagnosis and analysis: Technologies, challenges, and future prospects. Military Medical Research, 12(1), 93. https://doi.org/10.1186/s40779-025-00680-6
9. Türkmen, İ. (2021). Dijital patoloji ve yapay zekâ. SD Sağlık Düşüncesi ve Tıp Kültürü Dergisi, İlkbahar, 72–75.

Kardiyoloji pratiğinde yapay zeka kullanımı[1,2]

[1]*Dr. Mustafa Talha Güneş, Bandırma On Yedi Eylül Üniversitesi Kardiyoloji A.D.*

ORCID ID: 0009-0004-3084-368X

[2]*Dr. Ruveyda Zeynep Yıldız, Bandırma On Yedi Eylül Üniversitesi Tıp Fakültesi*

Kardiyovasküler hastalıklar (KVH) yaşam süresinin uzamasına paralel olarak mortalite nedenleri arasında giderek daha üst sıralarda yer almaktadır. Dünya Sağlık Örgütü'nün 2022 verilerine göre tüm dünyadaki ölümlerin yaklaşık %32'si (19,8 milyon kişi) kardiyovasküler hastalıklara bağlı olarak gerçekleşmiş ve bunun %85'i miyokard enfarktüsü ve inmeye sekonder gelişmiştir.(1) Yine aynı verilere göre KVH'ye bağlı ölümlerin yaklaşık dörtte üçünün düşük ve orta gelir seviyesindeki ülkelerde görülmesi ülkemizde bu etyoloji için erken tanı ve tedavinin önem arz etmesini gerektirmektedir.

Yapay zeka (YZ), bilgisayar ve makinelerin öğrenme, tekrar etme, neden-sonuç ilişkisi kurma, algılama ve karar verme gibi bazı görevleri gerçekleştirmekte insan zekasını simüle etmesi için geliştirilen ve teknolojik gelişmelerin yardımıyla son yıllarda popülerliği giderek artan sanal bir sistemdir. YZ'nin her alanda olduğu gibi sağlık ve tıp bilimlerinde de kullanım sıklığı ve çeşitliliği giderek artmaktadır. Kardiyoloji alanında da farklı görüntüleme ve tanı yöntemleriyle erken, hızlı ve doğru bir şekilde KVH tanısı konulabilmesi ve tedavi planlaması amacıyla çalışmalar devam etmektedir.

1. EKG Analizinde YZ Kullanımı

KVH tanısının konulmasında EKG önemli bir tanı aracıdır ve hem acil hem de elektif koşullarda doğru yorumlanması önem arz etmektedir. Operatör farklılıkları ve erken dönemde EKG'deki değişimlerin insan gözünün algılayamayacağı kadar minimal olması gibi faktörler nedeniyle EKG yorumlama süreçlerinde zorluklar yaşanabilmektedir.

1.1. Atrial Fibrilasyon (AF) Tespiti

AF, dünya çapında özellikle inme etyolojisinde rol oynaması nedeniyle KVH'ye bağlı morbidite ve mortalitenin azaltılabilmesi için erken tespitin önemli olduğu bir tanıdır. Attia ve ark. tarafından yapılan bir araştırmada, 650 binden fazla EKG ile eğitilen bir YZ aracılığıyla sinüs ritmindeki hastalarda paroksismal AF tanısı konulmasında %80'in üstünde hassasiyet ve özgüllük gösterilmiştir.(2) Giyilebilir teknolojilerin ilerlemesiyle birlikte AF'nin erken tespitinde majör sıçramalar yaşanmıştır. Örneğin, Shahid ve ark. tarafından yapılan bir meta-analizde Apple Watch'un AF tanısı için yüksek oranda hassasiyet ve özgüllük gösterdiği saptanmıştır.(3)

1.2. Miyokard Enfarktüsü (MI) Tespiti

MI'da hızlı ve doğru tanı koymak için EKG ilk tetkik olarak kullanılmaktadır. Fakat son yıllarda oklüziv MI'ların yaklaşık %56'sında ST-segment elevasyonu görülmeyebileceği gösterilmiştir.(4) Bu nedenle farklı modalitelerin bir arada kullanılarak akut koroner oklüzyonların doğru teşhisi, YZ uygulamaları için kullanım alanı olarak değerlendirilmektedir.

Sadece EKG analizi ile oluşabilecek yanlış tanıları engellemek için Xiao ve ark. tarafından yapılan bir çalışmada hastanın yaşı ve cinsiyetini de kapsayan bir YZ modellemesiyle STEMI tanısının konulmasında spesifitede anlamlı azalma olmadan sensitivitede artış gösterilmiştir.(5) Yu ve ark. tarafından yapılan bir başka çalışmada ise YZ-destekli algoritmalar ile EKG üzerindeki gürültü sinyalleri temizlenmiş ve minimal değişimler daha kolay ve doğru bir şekilde saptanabilir hale getirilmiştir.(6) Bunlara ek olarak; ekokardiyografi parametrelerinin, magnetokardiyografinin ve vücut yüzey

haritalamanın EKG analizi modellemesine ek olarak kullanımıyla iskemik süreçlerinin tanısının hızlı ve doğru bir şekilde yapılabildiğini gösteren çalışmalar son yıllarda yayımlanmıştır.(7–9)

1.3. Kalp Yetersizliği Teşhisi

Dünya çapında önemli bir morbidite ve mortalite nedeni olan kalp yetersizliğinin tanısı standart olarak ekokardiyografik ölçümler ile konulmaktadır. YZ-destekli modellerin gelişmesiyle EKG üzerinden yapılan analizlerle de yüksek doğruluk oranlarıyla bu tanının desteklenebileceği gösterilmiştir. Örneğin; Cho ve ark. tarafından yapılan bir çalışmada yaklaşık 40 bin EKG ile eğitilen bir YZ modellemesi aracılığıyla tek derivasyonlu EKG kaydı ile bile tanı doğruluğu oranı %87-92 olarak saptanmıştır.(10) Ek olarak; Attia ve ark. tarafından yapılan bir başka çalışmada akıllı saatlerden elde edilen EKG kayıtları kullanılarak düşük EF'li kalp yetersizliği tanısı %88 doğruluk oranı ile tahmin edilebilmiştir.(11)

2. Ekokardiyografide YZ Kullanımı

Ekokardiyografi, günlük kardiyoloji pratiğinde en sık kullanılan tanı yöntemlerinden biri olmakla birlikte subjektif yorumlamaya açık olduğu için operatör eğitiminin en çok önem arz ettiği tekniklerdendir. Operatör farklılığına bağlı olarak oluşabilecek yorum farklılıklarını minimize etmek ve ölçüm hassasiyetini artırmak için YZ kullanımı ekokardiyografi pratiğinde son yıllarda önemi giderek artan bir şekilde kullanılmaya başlanmıştır.

2.1. Otomatik ölçüm

Günümüzde yaygın kullanılan ekokardiyografi cihazları tarafından iki boyutlu (2D) ve üç boyutlu (3D) ölçümler için otomatik ölçüm yapılabilmektedir. Bu ölçümler tetkikin tekrarlanabilirliğini artırmakla birlikte endokard sınırlarının ölçümünün insan emeğine bağlı olması nedeniyle operatör tecrübesiyle korele bir hassasiyete sahiptir.(12)

İntrakardiyak boşluk çapları ve hacimleri, atım hacmi, ejeksiyon fraksiyonu (EF) ve duvar kalınlıklarının ölçümünde diyastol sonu ve sistol sonu zamanlarının eş zamanlı EKG ölçümleriyle tanınması ve endokard sınırlarının otomatik belirlenebilmesi neticesinde YZ kullanımı günlük pratiğe entegre edilmeye başlanmıştır. Yapılan farklı çalışmalarda YZ aracılığıyla yapılan sol ventrikül EF ölçümlerinin geleneksel yöntemlerle %90 ve üzerinde korelasyon gösterdiği bulunmuştur.(12)

Kalp yetersizliğinin tanısında son yıllarda önemli bir yere sahip olan global longitudinal strain (GLS) ölçümü de YZ'nin kullanım alanlarından biri haline gelmektedir. YZ, miyokard hareketlerinin otomatik tanınmasında, standart görüntülerin hızlı bir şekilde taranmasında ve GLS ölçümlerinde giderek artan bir sıklıkta kullanılmaktadır. Yapılan çalışmalarda YZ-destekli cihazlar ile EF ve GLS ölçüm süresi 8 saniye civarına düşürülebilmiştir.(13)

2.2. Tanı Aracı

YZ, bazı hastalıklarda spesifik olarak görülebilecek ekokardiyografik özelliklerin tanınmasında eğitimli profesyoneller ile benzer doğrulukta sonuçlar vermektedir. Hipertrofik kardiyomiyopati - atlet kalbi ayrımı, kardiyak amiloidoz ve pulmoner hipertansiyon gibi hastalıklar için %85 ve üzeri doğrulukla çalışabilen YZ tanı algoritmaları üretilmiş durumdadır.(14)

2.3. Kapak Patolojileri

YZ algoritması ile Moghaddasi ve Nourian tarafından 137 hasta üzerinde yapılan bir çalışmada normal mitral kapak ve hafif/orta/ciddi mitral yetersizlik ayrımında %99 doğruluk ve %99 hassasiyet ve özgüllükle tanı konulabilmiştir.(15) Ciddi aort darlığı tanısı için Playford ve ark. tarafından yapılan bir çalışmada ise sol ventrikül çıkış yolu (LVOT) çapı ve aort kapak üzerindeki maksimum kan akım hızı ile geleneksel ölçüm tekniğinden daha yüksek doğrulukta (%95 vs %73) tanıya ulaşılabilmiştir.(16)

3. Bilgisayarlı Tomografide (BT) YZ Kullanımı

BT, kardiyoloji pratiğinde farklı kullanım alanlarına sahiptir.(17) Ayaktan polikliniğe göğüs ağrısıyla başvuran hastaların ilk değerlendirmesinde kullanılabildiği gibi, transkateter aort kapak implantasyonu (TAVI) öncesinde girişim tercihlerinin ve kapak çapının belirlenmesinde de önemli bir yere sahiptir.(18,19) Koroner Anjiyografi Bilgisayarlı Tomografi (KABT) özellikle düşük riskli olarak değerlendirilen göğüs ağrısıyla acil servis başvurularında girişimsel görüntüleme kararı verebilmek için son yıllarda giderek artan sıklıkta kullanılmaktadır.(20)

3.1. Otomatik Kalsiyum Skoru Ölçümü

Koroner arter kalsiyum (CAC ya da Agatston) skoru, BT görüntüleri üzerinden cihaz modaliteleri yardımıyla ölçülebilmekte ve aterosklerotik olaylar için belirteç olarak kullanılmaktadır.(21) YZ algoritmalarının hız ve doğruluğunu test etmek için yapılan farklı çalışmalarda manuel ölçümlerle kıyaslandığında yüksek hassasiyet ve doğrulukla Agatston skorunun hesaplanabildiği saptanmıştır.(22,23) Radyasyon maruziyetini azaltmak adına başka bir endikasyonla çekilen toraks BT görüntüleri üzerinden YZ aracılığıyla CAC skorunun hesaplanabileceğini gösteren çalışmalar olmakla birlikte, eş-zamanlı EKG kaydı olmaması nedeniyle CAC skorunun koroner arterler içinde bölgesel dağılımının belirlenmesinde zorluklar olabileceğini belirten yayınlar mevcuttur.(24)

3.2. Plak Karakterizasyonu

Geçmiş yıllarda ateroskleroza yönelik tedavi algoritmalarında koroner arter lezyon ciddiyeti yaygın kabul gören ölçüm olmasına rağmen son yıllarda yapılan çalışmalarda koroner plakların morfolojik özelliklerinin aterosklerotik risk değerlendirmesinde önemli bir yere sahip olduğu gösterilmiştir. KABT ile koroner plakların morfolojik özellikleri hassas bir şekilde değerlendirilebilmektedir.(25)

Jávorszky ve ark. tarafından 894 hasta üzerinde gerçekleştirilen bir çalışmada YZ aracılı ölçümlerin toplam/kalsifiye/non-kalsifiye plakların tespitinde manuel ölçümlerle yüksek korelasyon gösterilmiştir (ICC sırasıyla 0,88, 0,84 ve 0,99).(26) Lin ve ark. tarafından 921 hasta üzerinde yapılan bir başka çalışmada ise YZ algoritmalarının toplam plak yükünü belirlemede manuel IVUS ölçümleriyle belirgin korelasyon gösterdiği (ICC: 0,95) ve analiz süresini anlamlı ölçüde kısalttığı bulunmuştur.(27) Anılan YZ algoritmaları görüntüleme işlemi öncesinde bazı manuel ayarlamalara ihtiyaç duymakla birlikte yeni ve tam otomatik algoritmalar geliştirilmektedir.(28)

3.3. Lezyon Ciddiyetinin Değerlendirilmesi

KABT görüntüleri üzerinden koroner arter lezyon ciddiyetinin kantitatif değerlendirilmesi mümkün olmakla birlikte, bu değerlendirmelerin altın standart yöntem olan koroner anjiyografi ile korelasyonu operatör tecrübesine bağlı olarak değişkenlik göstermekte, zaman ve maliyet kayıplarına neden olabilmektedir. Kerl ve ark. tarafından yapılan bir çalışmada KABT görüntülerini raporlayan deneyimli (8 yıl ve üstü) operatörlerin yorumlarının koroner anjiyografi ile korelasyon oranlarının, deneyimsiz operatörlere kıyasla belirgin şekilde daha yüksek olduğu gösterilmiştir (r değeri sırasıyla 0,75 ve 0,39).(29) Bir

başka çalışmada ise kalsifik plakların yanlış pozitif ve yanlış negatif sonuçlara yol açabileceği belirtilmiştir.(30)

Bu amaçla, koroner arter lezyonlarının ve kalsifik plakların YZ algoritmaları ile değerlendirilmesi hakkındaki bir meta-analizde, hem lezyonların hem kalsifik plakların karakterizasyonunda YZ algoritmalarının yüksek doğruluk, hassasiyet ve özgüllük ile sonuç verebildiği gösterilmiştir.(31)

Girişimsel anjiyografide lezyon ciddiyetinin belirlenmesinde son yıllarda sıkça kullanılan BT-FFR (BT-fractional flow reserve) yönteminin makine öğrenmesi (ML) ile kombine edilmesini araştıran Yang ve ark. tarafından yapılan bir çalışmada, KABT görüntülerine göre orta ciddiyetteki koroner arter lezyonlarına sahip hastaların YZ-aracılı BT-FFR veya standart yönetim ile takibi kaydedilmiştir. BT-FFR kolundaki grupta koroner anjiyografide non-obstruktif lezyonlar saptanan veya obstruktif lezyon saptansa bile revaskülarizasyon yapılmayan hasta sayısının standart yönetim koluna göre belirgin oranda düşük olduğu izlenmiştir (%28 vs %46). Ek olarak, BT-FFR kolundaki hasta grubundan koroner anjiyografi sonucunda revaskülarizasyon yapılanların oranı diğer kola oranla anlamlı şekilde yüksek saptanmış ve bir yıllık izlemde MACE oranlarında anlamlı fark izlenmemiştir.(32)

3.4. Aterosklerotik Riskin Belirlenmesi

KVH dünya genelinde yaygın bir mortalite nedeni olduğundan dolayı erken tanı amacıyla çeşitli risk skorları geliştirilmiştir. Framingham veya SCORE2 gibi risk hesaplama algoritmaları klasik risk faktörlerini (yaşam tarzı, kan basıncı ve kolesterol değerleri, diyabet, hipertansiyon vb.) kullanmaktadır.(33,34)

YZ-temelli KABT görüntüleri son yıllarda aterosklerotik riski belirlemek için kullanılmakta olup "AI-Risk Model" adı ile bir hesaplama modeli geliştirilmiştir. Bu model koroner arterlerdeki plak ve lezyon karakteristikleri ile klasik risk faktörlerini bir araya getirmiştir. AI-Risk modelinin major advers kardiyak olayları (MACE) öngördürücülüğünün değerlendirildiği yakın tarihli bir çalışmada, klasik risk skorlarına AI-Risk skorunun eklenmesiyle (koroner ateroskleroz olsun ya da olmasın) 10 yıllık MACE tahmininde doğruluk oranının arttığı gösterilmiştir.(35)

4. Kardiyak Manyetik Rezonans Görüntülemede (CMR) YZ

CMR, son yıllarda özellikle kardiyomiyopatilerin ve diğer yapısal kalp hastalıklarının teşhisinde altın standart yöntem olarak kabul edilmektedir. Ayrıca, miyokard dokusunda iskemi ve fibrozis tespitinde geç gadolinyum tutulumu (LGE) paterni analizi yaygın olarak kullanılmaktadır. Fakat tetkik esnasında hastanın aralıklarla nefesini tutmasının gerekmesi ve işlemin uzun sürmesi optimal görüntü elde edilmesini engelleyebilmektedir. Bu nedenle işlemin daha kısa sürede ve daha az görüntü ile yapılabilmesini sağlayabilecek YZ uygulamaları geliştirilmektedir.

4.1. Miyokard Segmentasyonu ve Karakterizasyonu

Assadi ve ark. tarafından yapılan bir çalışmada 814 hastanın görüntüleriyle eğitilen YZ ile 101 hastada tekrarlanabilirlik ve mortalite analizi yapılmış ve diyastol- ve sistol-sonu hacmi, atım hacmi, EF için yapılan manuel ölçümlerle yüksek oranda korelasyon gösterilmiştir.(36) Yine benzer şekilde Xue ve ark. tarafından yapılan başka bir çalışmada 1034 hastanın CMR görüntüleri üzerinden eğitilen YZ ile 200 görüntü üzerinde segmentasyon analizi yapılmış ve hem 1,5 T hem de 3 T görüntülerde manuel ölçümlerle yüksek korelasyon yakalanabilmiştir.(37)

Schwab ve ark. tarafından yapılan çalışmada ise LGE analizi yapılmış ve YZ-temelli algoritmaların hem infarkt hem de mikrovasküler obstrüksiyon segmentasyonunda manuel ölçümlerle yeterli ölçüde korele olduğu saptanmıştır.(38)

4.2. Yapısal Kalp Hastalıklarında Tanı

Wang ve ark. tarafından yayımlanan bir çalışmada 7900 hastadan alınan CMR görüntüleriyle eğitilen YZ modeli, 6650 KVH hastasının tanısının konmasında test edilmiştir. Hipertrofik kardiyomiyopati, aritmojenik sağ ventrikül kardiyomiyopatisi, Ebstein anomalisi ve restriktif kardiyomiyopati dahil olmak üzere 11 farklı tanı üzerinden sonuçlar incelendiğinde YZ modelinin deneyimli operatörlerle kıyaslandığında benzer doğruluk oranlarıyla tanı koyabildiği, bazı tanılar için aynı operatörlerden daha yüksek doğrulukta tanı koyabildiği gösterilmiştir.(39)

5. Sonuç

YZ, tıbbın her alanında olduğu gibi kardiyak görüntülemede de son yıllarda kullanıma hızlı bir şekilde entegre edilmiştir. Veri setlerinin çoğalması, makinelerin işlem güçlerinin artması ve YZ-destekli tıbbi cihazların daha yaygın bir şekilde kullanıma girmesiyle önümüzdeki yıllarda daha da artan bir sıklıkta ve doğruluk oranıyla kullanılacağı beklenmektedir.

Referanslar

1. Cardiovascular diseases (CVDs) [Internet]. [cited 2026 May 1]. Available from: https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)
2. Attia ZI, Noseworthy PA, Lopez-Jimenez F, Asirvatham SJ, Deshmukh AJ, Gersh BJ, et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. The Lancet. 2019 Sep 7;394(10201):861–7. doi:10.1016/S0140-6736(19)31721-0 PubMed PMID: 31378392.
3. Shahid S, Iqbal M, Saeed H, Hira S, Batool A, Khalid S, et al. Diagnostic Accuracy of Apple Watch Electrocardiogram for Atrial Fibrillation: A Systematic Review and Meta-Analysis. JACC: Advances. 2025 Feb 1;4(2). doi:10.1016/J.JACADV.2024.101538
4. de Alencar Neto JN, Scheffer MK, Correia BP, Franchini KG, Felicioni SP, De Marchi MFN. Systematic review and meta-analysis of diagnostic test accuracy of ST-segment elevation for acute coronary occlusion. Int J Cardiol. 2024 May 1;402:131889. doi:10.1016/J.IJCARD.2024.131889 PubMed PMID: 38382857.
5. Xiao R, Ding C, Hu X, Clifford GD, Wright DW, Shah AJ, et al. Integrating multimodal information in machine learning for classifying acute myocardial infarction. Physiol Meas. 2023 Apr 18;44(4):044002. doi:10.1088/1361-6579/acc77f PubMed PMID: 36963114.
6. Yu K, Feng L, Chen Y, Wu M, Zhang Y, Zhu P, et al. Accurate wavelet thresholding method for ECG signals. Comput Biol Med. 2024 Feb 1;169:107835. doi:10.1016/J.COMPBIOMED.2023.107835 PubMed PMID: 38096762.
7. Elvas LB, Nunes M, Ferreira JC, Dias MS, Rosário LB. AI-Driven Decision Support for Early Detection of Cardiac Events: Unveiling Patterns and Predicting Myocardial Ischemia. J Pers Med. 2023, Vol 13, Page 1421. 2023 Sep 21;13(9):1421. doi:10.3390/JPM13091421
8. Tao R, Zhang S, Zhang R, Shen C, Ma J, Cui J, et al. AI-enabled diagnosis and localization of myocardial ischemia and coronary artery stenosis from

magnetocardiographic recordings. Scientific Reports 2025 15:1. 2025 Feb 19;15(1):6094-. doi:10.1038/s41598-025-90615-x PubMed PMID: 39972046.

9. Lefebvre C, Hoekstra J. Early detection and diagnosis of acute myocardial infarction: the potential for improved care with next-generation, user-friendly electrocardiographic body surface mapping. Am J Emerg Med. 2007 Nov 1;25(9):1063–72. doi:10.1016/J.AJEM.2007.06.011 PubMed PMID: 18022503.

10. Cho J, Lee BT, Kwon JM, Lee Y, Park H, Oh BH, et al. Artificial Intelligence Algorithm for Screening Heart Failure with Reduced Ejection Fraction Using Electrocardiography. ASAIO Journal. 2021 Mar 1;67(3):314–21. doi:10.1097/MAT.0000000000001218 PubMed PMID: 33627606.

11. Attia ZI, Harmon DM, Dugan J, Manka L, Lopez-Jimenez F, Lerman A, et al. Prospective evaluation of smartwatch-enabled detection of left ventricular dysfunction. Nature Medicine 2022 28:12. 2022 Nov 14;28(12):2497–503. doi:10.1038/s41591-022-02053-1 PubMed PMID: 36376461.

12. Asch FM, Poilvert N, Abraham T, Jankowski M, Cleve J, Adams M, et al. Automated Echocardiographic Quantification of Left Ventricular Ejection Fraction Without Volume Measurements Using a Machine Learning Algorithm Mimicking a Human Expert. Circ Cardiovasc Imaging. 2019 Sep 1;12(9):e009303. doi:10.1161/CIRCIMAGING.119.009303 PubMed PMID: 31522550.

13. Knackstedt C, Bekkers SCAM, Schummers G, Schreckenberg M, Muraru D, Badano LP, et al. Fully Automated Versus Standard Tracking of Left Ventricular Ejection Fraction and Longitudinal Strain the FAST-EFs Multicenter Study. J Am Coll Cardiol. 2015 Sep 29;66(13):1456–66. doi:10.1016/J.JACC.2015.07.052 PubMed PMID: 26403342.

14. Zhang J, Gajjala S, Agrawal P, Tison GH, Hallock LA, Beussink-Nelson L, et al. Fully Automated Echocardiogram Interpretation in Clinical Practice. Circulation. 2018;138(16):1623–35. doi:10.1161/CIRCULATIONAHA.118.034338 PubMed PMID: 30354459.

15. Moghaddasi H, Nourian S. Automatic assessment of mitral regurgitation severity based on extensive textural features on 2D echocardiography videos. Comput Biol Med. 2016 Jun 1;73:47–55. doi:10.1016/j.compbiomed.2016.03.026 PubMed PMID: 27082766.

16. Playford D, Bordin E, Mohamad R, Stewart S, Strange G. Enhanced Diagnosis of Severe Aortic Stenosis Using Artificial Intelligence: A Proof-of-Concept Study of 530,871 Echocardiograms. JACC Cardiovasc Imaging. 2020 Apr 1;13(4):1087–90. doi:10.1016/J.JCMG.2019.10.013 PubMed PMID: 31864981.

17. Nicol ED, Norgaard BL, Blanke P, Ahmadi A, Weir-McCall J, Horvat PM, et al. The Future of Cardiovascular Computed Tomography: Advanced Analytics and Clinical Insights. JACC Cardiovasc Imaging. 2019 Jun 1;12(6):1058–72. doi:10.1016/J.JCMG.2018.11.037 PubMed PMID: 31171259.

18. Ybarra LF, Piazza N. Expanding the Role of Coronary Computed Tomography Angiography in Interventional Cardiology. Circulation. 2022 Jan 4;145(1):5–7. doi:10.1161/CIRCULATIONAHA.121.053038 PubMed PMID: 34965167.

19. Vrints C, Andreotti F, Koskinas KC, Rossello X, Adamo M, Ainslie J, et al. 2024 ESC Guidelines for the management of chronic coronary syndromes: Developed by the task force for the management of chronic coronary syndromes of the European Society of Cardiology (ESC) Endorsed by the European Association for Cardio-Thoracic Surgery

(EACTS). Eur Heart J. 2024 Sep 29;45(36):3415–537. doi:10.1093/EURHEARTJ/EHAE177 PubMed PMID: 39210710.

20. Byrne RA, Rossello X, Coughlan JJ, Barbato E, Berry C, Chieffo A, et al. 2023 ESC Guidelines for the management of acute coronary syndromes: Developed by the task force on the management of acute coronary syndromes of the European Society of Cardiology (ESC). Eur Heart J. 2023 Oct 12;44(38):3720–826. doi:10.1093/EURHEARTJ/EHAD191 PubMed PMID: 37622654.

21. Budoff MJ, Young R, Burke G, Carr JJ, Detrano RC, Folsom AR, et al. Ten-year association of coronary artery calcium with atherosclerotic cardiovascular disease (ASCVD) events: the multi-ethnic study of atherosclerosis (MESA). Eur Heart J. 2018 Jul 1;39(25):2401. doi:10.1093/EURHEARTJ/EHY217 PubMed PMID: 29688297.

22. Eng D, Chute C, Khandwala N, Rajpurkar P, Long J, Shleifer S, et al. Automated coronary calcium scoring using deep learning with multicenter external validation. NPJ Digit Med. 2021 Dec 1;4(1):88. doi:10.1038/S41746-021-00460-1 PubMed PMID: 34075194.

23. Hong JS, Tzeng YH, Yin WH, Wu KT, Hsu HY, Lu CF, et al. Automated coronary artery calcium scoring using nested U-Net and focal loss. Comput Struct Biotechnol J. 2022 Jan 1;20:1681. doi:10.1016/J.CSBJ.2022.03.025 PubMed PMID: 35465160.

24. Yu J, Qian L, Sun W, Nie Z, Zheng DD, Han P, et al. Automated total and vessel-specific coronary artery calcium (CAC) quantification on chest CT: direct comparison with CAC scoring on non-contrast cardiac CT. BMC Med Imaging. 2022 Dec 1;22(1):177. doi:10.1186/S12880-022-00907-1 PubMed PMID: 36241978.

25. Cau R, Flanders A, Mannelli L, Politi C, Faa G, Suri JS, et al. Artificial intelligence in computed tomography plaque characterization: A review. Eur J Radiol. 2021 Jul 1;140:109767. doi:10.1016/j.ejrad.2021.109767 PubMed PMID: 34000598.

26. Jávorszky N, Homonnay B, Gerstenblith G, Bluemke D, Kiss P, Török M, et al. Deep learning–based atherosclerotic coronary plaque segmentation on coronary CT angiography. Eur Radiol. 2022 Oct 1;32(10):7217–26. doi:10.1007/S00330-022-08801-8 PubMed PMID: 35524783.

27. Lin A, Kolossváry M, Cadet S, McElhinney P, Goeller M, Han D, et al. Radiomics-based precision phenotyping identifies unstable coronary plaques from computed tomography angiography. JACC Cardiovasc Imaging. 2022 May 1;15(5):859. doi:10.1016/J.JCMG.2021.11.016 PubMed PMID: 35512957.

28. Griffin WF, Choi AD, Riess JS, Marques H, Chang HJ, Choi JH, et al. AI Evaluation of Stenosis on Coronary CTA, Comparison With Quantitative Coronary Angiography and Fractional Flow Reserve: A CREDENCE Trial Substudy. JACC Cardiovasc Imaging. 2023 Feb 1;16(2):193–205. doi:10.1016/J.JCMG.2021.10.020 PubMed PMID: 35183478.

29. Kerl JM, Schoepf UJ, Bauer RW, Tekin T, Costello P, Vogl TJ, et al. 64-Slice Multidetector-row Computed Tomography in the Diagnosis of Coronary Artery Disease Interobserver Agreement Among Radiologists With Varied Levels of Experience on a Per-patient and Per-segment Basis. 2012 Jan. doi:10.1097/RTI.0b013e3181f82805

30. Andrew M, John H. The challenge of coronary calcium on coronary computed tomographic angiography (CCTA) scans: effect on interpretation and possible solutions. International Journal of Cardiovascular Imaging. 2015 Dec 1;31(2):145–57. doi:10.1007/S10554-015-0773-0 PubMed PMID: 26408105.

31. Du M, He S, Liu J, Yuan L. Artificial Intelligence in CT Angiography for the Detection of Coronary Artery Stenosis and Calcified Plaque: A Systematic Review and Meta-analysis. Acad Radiol. 2025 Jul 1;32(7):3776–87. doi:10.1016/j.acra.2025.03.054 PubMed PMID: 40234162.

32. Yang J, Shan D, Wang X, Sun X, Shao M, Wang K, et al. On-Site Computed Tomography-Derived Fractional Flow Reserve to Guide Management of Patients with Stable Coronary Artery Disease: The TARGET Randomized Trial. Circulation. 2023 May 2;147(18):1369–81. doi:10.1161/CIRCULATIONAHA.123.063996 PubMed PMID: 36870065.

33. Wilson PWF, D'Agostino RB, Levy D, Belanger AM, Silbershatz H, Kannel WB. Prediction of coronary heart disease using risk factor categories. Circulation. 1998 May 12;97(18):1837–47. doi:10.1161/01.CIR.97.18.1837 PubMed PMID: 9603539.

34. SCORE2 working group and ESC Cardiovascular risk collaboration. SCORE2 risk prediction algorithms: new models to estimate 10-year risk of cardiovascular disease in Europe. Eur Heart J. 2021 Jul 1;42(25):2439–54. doi:10.1093/EURHEARTJ/EHAB309 PubMed PMID: 34120177.

35. Chan K, Wahome E, Tsiachristas A, Antonopoulos AS, Patel P, Lyasheva M, et al. Inflammatory risk and cardiovascular events in patients without obstructive coronary artery disease: the ORFAN multicentre, longitudinal cohort study. The Lancet. 2024 Jun 15;403(10444):2606–18. doi:10.1016/S0140-6736(24)00596-8 PubMed PMID: 38823406.

36. Assadi H, Alabed S, Li R, Matthews G, Karunasaagarar K, Kasmai B, et al. Development and validation of AI-derived segmentation of four-chamber cine cardiac magnetic resonance. Eur Radiol Exp. 2024 Dec 1;8(1):77. doi:10.1186/S41747-024-00477-7 PubMed PMID: 38992116.

37. Xue H, Davies RH, Brown LAE, Knott KD, Kotecha T, Fontana M, et al. Automated Inline Analysis of Myocardial Perfusion MRI with Deep Learning. Radiol Artif Intell. 2020 Oct 21;2(6):1–8. doi:10.1148/RYAI.2020200009

38. Schwab M, Pamminger M, Kremser C, Haltmeier M, Mayr A. Deep Learning Pipeline for Fully Automated Myocardial Infarct Segmentation from Clinical Cardiac MR Scans. Radiology Advances. 2025 Feb 5;2(4). doi:10.1093/radadv/umaf023

39. Wang YR, Yang K, Wen Y, Wang P, Hu Y, Lai Y, et al. Screening and diagnosis of cardiovascular disease using artificial intelligence-enabled cardiac magnetic resonance imaging. Nat Med. 2024 May 1;30(5):1471. doi:10.1038/S41591-024-02971-2 PubMed PMID: 38740996.

Dahiliye Pratiğinde Yapay Zekâ Destekli Karar Sistemleri

Muhammet Can Boydak, Dönem II Öğrencisi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi

Email: muhammetboydak@ogr.bandirma.edu.tr

Duygu Kesebi Isgandarov, İç Hastalıkları Ana Bilim Dalı Doktor Öğretim Üyesi, Bandırma Onyedi Eylül Üniversitesi

Email: dkesebi@bandirma.edu.tr

Özet

Yapay zekâ, sağlık hizmetlerinde giderek artan bir şekilde kullanılmaktadır. Özellikle yoğun veri akışı olan alanlarda klinik karar verme sürecini güçlendiren yardımcı bir sistemdir. Hasta yükünün fazla olduğu dahiliye gibi kliniklerde, karar verme süresini kısaltarak zamanın daha etkin kullanılmasına katkı sağlar. Dahiliye pratiği; çok sayıda laboratuvar parametresi, vital bulgu ve klinik değişkenin eş zamanlı değerlendirilmesini gerektirdiğinden yapay zekâ ve makine öğrenmesi (ML) destekli sistemlere olan ihtiyacı artırmaktadır. Yapay zekâ tabanlı karar sistemleri; erken tanı, risk tahmini ve tedavi optimizasyonu gibi süreçlerde klinik uygulamaları destekleyerek sağlık hizmetlerinin kalitesini iyileştirmektedir. Bu derleme, yapay zekâ destekli klinik karar sistemlerinin dahiliye pratiğindeki kullanım alanlarını klinik örnekler üzerinden değerlendirerek pratik uygulamaya yönelik bir çerçeve sunmayı amaçlamaktadır. Özellikle sepsis, akut böbrek hasarı ve kalp yetmezliği gibi durumlarda erken tanı ve komplikasyonların önlenmesi açısından önemli avantajlar sağladığı görülmektedir; bunlara bağlı olarak mortalite ve morbidite oranları azalmaktadır. Sonuç olarak yapay zekâ, klinik karar süreçlerini güçlendirerek daha hızlı, doğru ve etkin bir klinik değerlendirmeye katkı sağlamaktadır ancak beraberinde getirebileceği etik sorunlar göz ardı edilmemeli ve nihai kararın her zaman klinisyene ait olduğu unutulmamalıdır.

Anahtar kelimeler: dahiliye, yapay zekâ, klinik karar destek sistemi

Giriş

Günümüzde tıp pratiği giderek artan veri yükü ile karakterizedir. Bilhassa dahiliye pratiği, çok sayıda klinik verinin eş zamanlı değerlendirilmesini gerektiren en kompleks tıp alanlarından biridir. Hastaların değerlendirilmesi sırasında laboratuvar parametreleri, vital bulgular, görüntüleme sonuçları ve anamnez birlikte ele alınmaktadır. Bu durum klinik karar verme sürecini zorlaştırarak hata olasılığını artırmaktadır (Beam & Kohane, 2018; Rajkomar ve ark., 2019; Obermeyer & Emanuel, 2016).

Dahiliye pratiğinde sepsis, kalp yetmezliği, akut böbrek hasarı (AKI), KOAH ve diyabet gibi birçok hastalıkta tek bir parametre yeterli olmayıp çok sayıda klinik verinin birlikte değerlendirilmesi gerekir (Komorowski ve ark., 2018; Tomašev ve ark., 2019). Bu çok boyutlu veri yapısı, klinisyenler için önemli bir zorluk oluşturmaktadır.

Yapay zekâ ve makine öğrenmesi algoritmaları aracılığıyla büyük veri setlerini analiz ederek tanı ve tedavi süreçlerine katkı sağlayan önemli bir teknoloji olarak ortaya çıkmıştır. Bu sistemler, erken tanı, risk tahmini, prognoz ve tedavi planlaması gibi alanlarda klinisyene önemli katkılar sunmaktadır ve klinik karar doğruluğunu artırmaktadır (Topol, 2019; Sutton ve ark., 2020).

Bu derlemenin amacı, yapay zekâ destekli karar sistemlerinin dahiliye pratiğindeki kullanım alanlarını, klinik katkılarını ve sınırlamalarını güncel literatürü tarayıp incelemektir.

Yapay Zekâ Nedir?

Yapay zekâ, makinelerin öğrenme, düşünme, sınıflandırma ve problem çözme gibi insana özgü bazı becerileri gerçekleştirebilmesini sağlayan algoritmalar bütünüdür. Bu sistemler, özellikle makine öğrenmesi ve derin öğrenme yöntemleri sayesinde insan zekasını taklit etmeye çalışmaktadır.

Sağlık alanında veri miktarının artması ve bu verilere daha kolay erişilebilmesi, son yıllarda yapay zekâ uygulamalarının gelişmesini mümkün kılmıştır. Yapay zekâ, büyük ve karmaşık veri setleri içinde yer alan klinik bilgileri analiz ederek klinisyenlerin karar verme süreçlerine katkı sağlayabilmektedir. Özellikle yüksek veri yoğunluğuna sahip klinik alanlarda daha etkin olduğu düşünülmektedir. Her ne kadar klinikte yaygın kullanımı henüz sınırlı olsa da mevcut çalışmalar yapay zekânın hastalıkların tanı, tedavi ve izleminde, ayrıca riskli durumların belirlenmesinde etkili bir şekilde kullanılabileceğini göstermektedir (Keleş, 2022).

Yapay Zekâ Dahiliye Pratiğinde Nerelerde Kullanılır?

- **Tanı Koyma ve Erken Tanıda Yapay Zekâ**

Belirli bir hastalığın tanı sürecinde yapay zekâdan yararlanılması, tanıya ulaşma süresini anlamlı ölçüde kısaltmakta ve tanısal verimliliği artırmaktadır. Klinik muayene bulguları, biyokimyasal analizler ve diğer klinik test verileri ile birlikte radyolojik görüntüler, endoskopik incelemeler ve patolojik bulgular, yapay zekâ destekli sistemler aracılığıyla hızlı ve kapsamlı bir şekilde değerlendirilebilmekte; bu sayede multidisipliner veri entegrasyonu sağlanmaktadır. Bu durum, özellikle karmaşık vakalarda daha kısa sürede ve daha yüksek doğruluk oranıyla tanı konulmasına olanak tanımaktadır. Ayrıca elde edilen verilerin bütüncül bir biçimde analiz edilmesi, hekimlerin daha bilinçli, rasyonel ve hasta odaklı tedavi planları oluşturmasına katkı sağlamakta; kişiselleştirilmiş tıp yaklaşımını desteklemektedir (Keleş, 2022).

- ❖ **Sepsis**

  Her yıl ölümlerin yaklaşık %20'sini oluturan sepsis, sinsi semptomları sebebiyle tanısı zor konan bir hastalıktır. Fizik muayene bulguları, laboratuvar testleri de dahil olmak üzere mevcut tanı yöntemleri zamanında müdahale için gereken hızdan yoksundur. Ayrıca bu tanı yöntemleri sepsisi diğer durumlardan ayırt edecek yeterli doğruluğa sahip değildir. Yaşlılar, yoğun bakımdaki hastalar ve immun sistemi zayıf kişiler için zamanla yarışılır. Bakteri kültürleri elzem olsa da zaman alıcı doğaları ve yanlış negatifliklere yatkınlıkları etkinliklerini sınırlamaktadır.

  Yapay zekâ destekli bir klinik karar sistemi, kapsamlı klinik parametrelere ihtiyaç duymadan hemogram (CBC) ve lökosit dağılımı (DIFF) verilerini kullanarak basit tahminler sunmuştur. Bu bulgular, söz konusu sistemlerin klinik iş akışına entegre edilebilirliğine işaret etmekte; sepsis tanısının daha hızlı ve doğru konulmasına ve hasta bakımının zamanlamasının iyileştirilmesine katkı sağlayabileceğini düşündürmektedir (Lin ve ark., 2025).

- **Risk Tahmininde Yapay Zekâ**

Yapay zekâ, bazı hastalıkların nüksünü öngörebilme yeteneğine sahiptir. Geçmiş verilerden öğrenerek karmaşık, doğrusal olmayan ve farklı patofizyolojik mekanizmalara sahip hastalıkların anlaşılmasına ve yönetimine katkı sağlamaktadır. Bu noktada elektronik sağlık kayıtları (ESK) büyük önem taşımaktadır. Yapay zekâ sistemleri bu verilere erişerek, hastanede yatan bir hastada gelişebilecek akut alevlenmeleri önceden tahmin edebilmektedir (Loftus ve ark., 2022).

- ❖ **Nefrolojide Yapay Zekânın Kullanımı**

Bir yapay zekâ programının, biyokimyasal değişiklikler ortaya çıkmadan önce akut böbrek hasarının başlangıcını öngörebildiği ve erken müdahale imkânı sağlayabildiği gösterilmiştir. Modelin, hastalığın farklı evrelerinde yapılan izlemde erken tahminlerde yüksek doğruluk sağladığı bildirilmiştir (Tomašev ve ark., 2019). Bununla birlikte, bu tür izlem genellikle hastaneye yatış gerektirdiğinden, yatışı olmayan hastalar serviste izlenen hastalar kadar yakından takip edilememekte ve erken tanı açısından dezavantajlı kalabilmektedir.

❖ **Diyabet Komplikasyonları**

Diyabet, küresel ölçekte erken mortalite ve engelliliğe uyarlanmış yaşam yılları açısından önde gelen nedenlerden biridir. Hastalığa bağlı morbidite, büyük ölçüde gelişen komplikasyonlardan kaynaklanmaktadır (Scheideman ve ark., 2025). Başlıca komplikasyonlar arasında diyabetik nöropati, diyabetik nefropati, periferik nöropati, otonom nöropati, diyabetik ayak yaraları ve diğer sistemik komplikasyonlar yer almaktadır.

Komplikasyonların önleyici yönetimi, klinik sonuçların iyileştirilmesi açısından kritik öneme sahiptir. Yapay zekâ ve makine öğrenmesi temelli modeller, bu komplikasyonları öngörebilme yetenekleri sayesinde uygun tedavi süreçlerinin planlanmasına katkı sağlamakta ve komplikasyonların erken dönemde önlenmesini desteklemektedir (Scheideman ve ark., 2025).

Mevcut çalışmalar, yapay zekâ uygulamalarının bu komplikasyonların tespitinde güvenilir doğruluk oranları sağlayabildiğini göstermektedir. Klinik biyokimya parametreleri, fizik muayene bulguları ve görüntüleme sonuçları gibi çok boyutlu veriler, yapay zekâ sistemleri tarafından kısa sürede analiz edilebilmekte; elde edilen çıktılar klinisyene karar sürecinde destek sunmaktadır
(Scheideman ve ark., 2025).

- **Tedavi Optimizasyonu ve Prognozda Yapay Zekâ**

Yapay zekâ destekli klinik karar destek sistemleri, yalnızca tanı ve risk tahmini ile sınırlı kalmayıp tedavi süreçlerinin optimize edilmesinde de kritik bir işlev üstlenmektedir ve bireyselleştirilmesini sağlamaktadır (Rajkomar ve ark.,2019; Sutton ve ark., 2020). Bu sistemler, hastaya özgü klinik verileri analiz ederek uygun ilaç seçimi, doz ayarlaması ve olası ilaç etkileşimlerinin önlenmesi konusunda klinisyene destek sağlar (Tolley ve ark., 2018; Jia ve ark., 2016). Özellikle çoklu hastalığa sahip bireylerde tedavi planının bireyselleştirilmesine katkıda bulunarak klinik sonuçların iyileştirilmesine yardımcı olmaktadır (Topol, 2019).

Sepsisin en iyi tedavi stratejisi belirsizliğini sürdürmektedir. Hatta bazı tedavi uygulama yöntemleri hastaya zarara yol açabileceği yönünde kanıtlar vardır. Klinik değişkenlik oldukça fazladır. Geliştirilen bir yapay zekâ modeli, sepsis hastalarının tedavi yönetimine ilişkin klinisyene sunduğu öneriler doğrultusunda mortalite oranında sınırlı ancak anlamlı bir azalma ile ilişkilendirilmiştir; bu etkinin, yıllık bazda önemli sayıda yaşamın kurtarılmasına katkı sağlayabileceği öngörülmektedir (Komorowski ve ark.,2018).

Kalp yetmezliği, klinik seyri değişken olan ve tedavi yönetimi kişiselleştirilmesi gereken kompleks bir hastalıktır. Yapay zekâ destekli klinik karar destek sistemleri, hastaya ait elektronik sağlık kayıtlarını analiz ederek tedavi sürecinin optimize edilmesine geleneksel tekniklerden daha iyi katkı sağlamaktadır (Golas ve ark., 2018). Bu sistemler özellikle diüretik ve kardiyovasküler ilaçların doz ayarlaması, hastanın klinik durumuna göre ilaç seçimi ve riskli durumların erken belirlenmesi konusunda klinisyene destek sunmaktadır. Ayrıca yeniden hastaneye yatış riskinin azaltılmasında ve klinik sonuçların iyileştirilmesinde önemli potansiyele sahip olduğu bildirilmektedir (Bozyel ve ark., 2024).

Yapay zekâ destekli klinik karar destek sistemleri, diyabet hastalığının takibinde kan şekeri kontrolü, ilaç seçimi ve insülin dozunun ayarlanması gibi süreçlerde doktora yardımcı olmaktadır. Bu sistemler hastanın kan şekeri değerlerini, yaşam tarzını ve eşlik eden hastalıklarını değerlendirerek daha kişiye özel tedavi planlarının yapılmasına katkı sağlar. Ayrıca kan şekerinin çok düşmesi ya da çok yükselmesi gibi durumları önceden fark edip uyarı verebilir ve böylece tedavinin daha güvenli yapılmasına yardımcı olur. Genel olarak bu sistemlerin diyabet yönetiminde doktorların karar verme sürecini destekleyerek tedavi başarısını artırabileceği düşünülmektedir (Ying ve ark., 2025).

- **Polifarmasiyi Önlemede Yapay Zekâ**

Çoklu ilaç kullanımı hem epidemiyolojik olarak hem ekonomik olarak bir sorun teşkil eder. Özellikle geriatrik hastalar ilaç hatalarına ve advers ilaç olaylarına daha duyarlıdır (Ng ve ark., 2025) İlaç değerlendirme süreçlerinin zaman alıcı ve pratikte zor uygulanabilir olması, bu yükü hafifletecek sistemlere olan ihtiyacı artırmaktadır (Mouazer ve ark., 2025). Yapay zekâ temelli modellerin reçeteleme süreçlerini iyileştirdiği, uygunsuz ilaç kullanımını azalttığı ve yaşlı hastalarda olumsuz sonuçların azaltılmasına katkı sağladığı gösterilmiştir. (Mouazer ve ark., 2025; Ng ve ark, 2025).

Etik Sıkıntılar ve Sınırlılıklar

Yapay zekâ sistemleri sağlık alanında kullanılmasına rağmen çeşitli etik ve teknik riskleri de beraberinde getirmektedir. Bu sistemler, eğitim verilerinden ve algoritma tasarımlarından kaynaklanan önyargıları öğrenerek karar süreçlerine yansıtabilmektedir. Özellikle veri setlerinde belirli grupların yeterince temsil edilmemesi, cinsiyet, yaş, etnik köken ve sosyoekonomik durum gibi değişkenler açısından dengesizliklerin bulunması, bazı hasta gruplarında hatalı veya düşük doğrulukta sonuçlara yol açabilmektedir (Güvercin, 2020; Sağıroğlu & Tosun, 2023). Bu durum, zaten dezavantajlı grupların sağlık hizmetlerine erişimini daha da zorlaştırmakta ve eşitsizlikleri artırmaktadır (Kaplan & Bingöl, 2024; Uzun, 2020). Ayrıca yapay zekâ sistemlerinin karmaşık yapısı nedeniyle karar verme süreçlerinin şeffaf olmaması "kara kutu" problemi olarak ifade edilmekte, bu da hekimlerin sisteme olan güvenini azaltmakta ve hatalı bir karar durumunda sorumluluğun kimde olduğu sorusunu belirsiz hale getirmektedir (Alpkoçak, 2024; Keskinbora, 2019; Güvercin, 2020). Bununla birlikte hasta özerkliğinin zedelenmesi de önemli bir sorun olarak ortaya çıkmakta; hastaların karar süreçlerine yeterince dahil olamaması ve bilgilendirilmiş onamın zayıflaması etik açıdan tartışmalara neden olmaktadır (Uzun, 2020; Keleş, 2022).

Bunlara ek olarak yapay zekâ uygulamaları büyük miktarda sağlık verisine ihtiyaç duyduğu için mahremiyet ve veri güvenliği risklerini de artırmaktadır. Veri sızıntıları, siber saldırılar veya verilerin kötüye kullanımı hasta mahremiyetini tehdit ederken sağlık sistemine duyulan güveni de zedeleyebilmektedir (Özdemir & Bilgin, 2021; Kaplan & Bingöl, 2024). Bu nedenle verilerin anonimleştirilmesi, güçlü şifreleme yöntemleri ve erişim kontrol sistemlerinin kullanılması büyük önem taşımaktadır (Alpkoçak, 2024; Koç ve ark., 2023). Öte yandan yapay zekâ destekli sağlık hizmetlerinde olası hatalarda sorumluluğun kimde olduğu konusu netleşmemiştir; hekim, yazılımcı veya sağlık kuruluşu arasında oluşan bu belirsizlik hem etik hem de hukuki sorunlara yol açmaktadır (Güvercin, 2020; Alpaydın, 2020). Ayrıca birçok ülkede bu teknolojilerin kullanımını düzenleyen yasal çerçevenin yetersiz olması, hasta hakları ve veri güvenliği açısından önemli boşluklar oluşturmaktadır (Yorgancıoğlu ve ark., 2024; İlkılıç, 2021). Bu nedenle yapay zekânın sağlık alanında güvenli, adil ve etkili bir şekilde kullanılabilmesi için hem etik ilkelere hem de kapsamlı yasal düzenlemelere ihtiyaç duyulmaktadır.

Sonuç

Sonuç olarak, yapay zekâ destekli klinik karar destek sistemleri dahiliye pratiğinde tanı, risk değerlendirmesi, tedavi planlaması ve hasta takibi gibi birçok aşamada önemli katkılar sunmaktadır. Özellikle çok boyutlu, karmaşık ve yoğun klinik verilerin hızlı ve doğru bir şekilde analiz edilmesi, hekimlerin karar verme süreçlerini güçlendirerek daha etkin ve güvenli bir sağlık hizmeti sunulmasına olanak sağlamaktadır ve bu sistemlerin klinik pratikte giderek daha önemli bir araç haline geldiğini göstermektedir. Erken tanı ve komplikasyonların önlenmesi açısından sağladığı avantajlar, bu teknolojilerin klinik pratiğe entegrasyonunun önemini ortaya koymaktadır. Bununla birlikte, etik sorunlar, veri güvenliği, algoritmik önyargılar ve hukuki sorumluluk gibi sınırlılıklar göz ardı edilmemelidir. Gelecekte yapay zekâ sistemlerinin daha şeffaf, güvenilir ve klinik olarak doğrulanmış hale gelmesi; aynı zamanda güçlü yasal düzenlemeler ve etik çerçeveler ile desteklenmesi, bu teknolojilerin sağlık hizmetlerinde sürdürülebilir ve yaygın kullanımını mümkün kılacaktır. Bu bağlamda yapay zekâ, hekimin yerini alan bir unsurdan ziyade, klinik karar süreçlerini destekleyen tamamlayıcı bir araç olarak değerlendirilmelidir.

Kaynakça

1. Alpaydın, E. (2020). Makine öğrenmesi. İstanbul: Boğaziçi Üniversitesi Yayınları.
2. Alpkoçak, A. (2024). Sağlıkta açıklanabilir yapay zekâ. TOTBİD Dergisi S, 23, 18-19. https://doi.org/10.5578/totbid.dergisi.2024.04
3. Beam, A. L., & Kohane, I. S. (2018). Big data and machine learning in health care. JAMA, 319(13), 1317–1318.
4. Bozyel, S., Şimşek, E., Koçyiğit Burunkaya, D., Güler, A., Korkmaz, Y., Şeker, M., Ertürk, M. ve Keser, N. (2024). Kalp ve Damar Hastalıklarında Yapay Zeka Tabanlı Klinik Karar Destek Sistemleri. Anadolu Kardiyoloji Dergisi , 28 (2), 74-86. https://doi.org/10.14744/AnatolJCardiol.2023.3685
5. Golas, S. B., Shibahara, T., Agboola, S., Otaki, H., Sato, J., Nakae, T., Hisamitsu, T., Kojima, G., Felsted, J., Kakarmath, S., Kvedar, J., & Jethwani, K. (2018). A machine learning model to predict the risk of 30-day readmissions in patients with heart failure: a retrospective analysis of electronic medical records data. *BMC medical informatics and decision making*, *18*(1), 44. https://doi.org/10.1186/s12911-018-0620-z
6. Güvercin,C.H.(2020). Tıpta yapay zekâ ve etik. Yapay zekâ ve tıp etiği, 1,7-13
7. İlkılıç, İ. (2021). Tıpta yapay zekâ kullanımının etik açıdan değerlendirilmesi. Medipol 18-21.
8. Jia, P., Zhang, L., Chen, J., Zhao, P., & Zhang, M. (2016). The Effects of Clinical Decision Support Systems on Medication Safety: An Overview. *PloS one*, *11*(12), e0167683. https://doi.org/10.1371/journal.pone.0167683
9. Kaplan, M., Çakar, F., & Bingöl, H. (2024). Sağlık alanında yapay zekânın kullanımı: Derleme. Muş Alparslan Üniversitesi Sağlık Bilimleri Dergisi, 4(3), 75-85.
10. Keleş, H. (2022). TIPTA YAPAY ZEKA UYGULAMALARI. The Journal of Kırıkkale University Faculty of Medicine, 24(3), 604-613. https://doi.org/10.24938/kutfd.1214512
11. Keskinbora, K. H. (2019). Medical ethics considerations on artificial intelligence. Journal of Clinical Neuroscience, 64, 277–282.
12. Koç, A.M., Bakiu, E., Gülas, G.E., & Koç, E.M. (2023). Sağlık için yapay zekâ teknolojilerinin etik tasarımı, uygulanması ve kullanımı için dikkat edilecek hususlar. Sağlık Bilimlerinde Yapay Zekâ Dergisi, 3(2), 14-21. DOI:10.52309/jaihs.2023.18 D

13. Komorowski, M., Celi, L. A., Badawi, O., et al. (2018). The Artificial Intelligence Clinician learns optimal treatment strategies for sepsis. Nature Medicine, 24(11), 1716–1720.

14. Lin, T. H., Chung, H. Y., Jian, M. J., Chang, C. K., Lin, H. H., Yen, C. T., Tang, S. H., Pan, P. C., Perng, C. L., Chang, F. Y., Chen, C. W., & Shang, H. S. (2025). AI-Driven Innovations for Early Sepsis Detection by Combining Predictive Accuracy With Blood Count Analysis in an Emergency Setting: Retrospective Study. *Journal of medical Internet research*, *27*, e56155. https://doi.org/10.2196/56155

15. Loftus, T. J., Shickel, B., Ozrazgat-Baslanti, T., Ren, Y., Glicksberg, B. S., Cao, J., Singh, K., Chan, L., Nadkarni, G. N., & Bihorac, A. (2022). Artificial intelligence-enabled decision support in nephrology. *Nature reviews. Nephrology*, *18*(7), 452–465. https://doi.org/10.1038/s41581-022-00562-3

16. Mouazer, A., Léguillon, R., Boudegzdame, N., Levrard, T., Le Bars, Y., Simon, C., Séroussi, B., Grosjean, J., Lelong, R., Letord, C., Darmoni, S., Schuers, M., Belmin, J., Sedki, K., Dubois, S., Falcoff, H., Tsopra, R., & Lamy, J. B. (2025). ABiMed: An intelligent and visual clinical decision support system for medication reviews and polypharmacy management. *BMC medical informatics and decision making*, *25*(1), 173. https://doi.org/10.1186/s12911-025-03002-x

17. Ng, Y., Hsu, J. T. Y., Ng, N. N. E., Ong, J. Z. E., Hsu, J. L. J., Sulaimi, F., Tan, H. K., Tang, A. S. P., & Ng, Q. X. (2025). Evaluating the role of clinical decision support systems in medication safety for older people: a systematic review. *Age and ageing*, *54*(7), afaf206. https://doi.org/10.1093/ageing/afaf206

18. Obermeyer, Z., & Emanuel, E. J. (2016). Predicting the future — Big data, machine learning, and clinical medicine. New England Journal of Medicine, 375(13), 1216–1219.

19. Özdemir, L., & Bilgin, A. (2021). Sağlıkta yapay zekânın kullanımı ve etik sorunlar. Sağlık ve Hemşirelik Yönetimi Dergisi, 8(3), 439-445. DOI:10.54304/SHYD.2021.63325

20. Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. New England Journal of Medicine, 380(14), 1347–1358.

21. Sağıroğlu, E., & Tosun, H. (2023). Yapay zekânın sağlık uygulamalarındaki kullanımı Ve etik açıdan tartışılması: Geleneksel derleme. Turkiye Klinikleri Journal of Medical Ethics-Law & History/Türkiye klinikleri tıp Etiği, Hukuku ve Tarihi Dergisi, 31(2), 140-8. DOI: 10.5336/mdethic.2022-92760

22. Scheideman, A. F., Shao, M. M., Zelada, H., Cuadros, J., Foreman, J., Sarder, P., Ho, C., Ejskjaer, N., Fleischer, J., Cichosz, S. L., Armstrong, D. G., Mathioudakis, N., Wang, T., Tham, Y. C., & Klonoff, D. C. (2025). Machine Learning to Diagnose Complications of Diabetes. *Journal of diabetes science and technology*, *19*(6), 1650–1670. https://doi.org/10.1177/19322968251365245

23. Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N., & Kroeker, K. I. (2020). An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ digital medicine*, *3*, 17. https://doi.org/10.1038/s41746-020-0221-y

24. Tolley, C. L., Slight, S. P., Husband, A. K., Watson, N., & Bates, D. W. (2018). Improving medication-related clinical decision support. *American journal of health-system pharmacy : AJHP : official journal of the American Society of Health-System Pharmacists*, *75*(4), 239–246. https://doi.org/10.2146/ajhp160830

25. Tomašev, N., Glorot, X., Rae, J. W., et al. (2019). A clinically applicable approach to continuous prediction of future acute kidney injury. Nature, 572(7767), 116–119.

26. Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. Nature Medicine, 25(1), 44–56.

27. Uzun, T. (2020). Yapay zeka Ve Sağlik Uygulamalari. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 3(1), 80-92.

28. Ying, Z., Fan, Y., Chen, C., Liu, Y., Tang, Q., Chen, Z., Yang, Q., Yan, H., Wu, L., Lu, J., Liu, Z., Liu, J., Li, X., & Chen, Y. (2025). Real-Time AI-Assisted Insulin Titration System for Glucose Control in Patients With Type 2 Diabetes: A Randomized Clinical Trial. *JAMA network open*, *8*(5), e258910. https://doi.org/10.1001/jamanetworkopen.2025.8910

29. Yorgancıoğlu, G.T., Balçık, Y.P., & Sebik, N.B. (2024). Türkiye ve dünyada sağlık hizmetlerinde yapay zekâ. Mersin Üniversitesi Tıp Fakültesi Lokman Hekim Tıp Tarihi ve Folklorik Tıp Dergisi, 14(1), 50-60. https://doi.org/10.31020/mutftd.1278529

Acil Tıpta Yapay Zekâ: Risk Stratifikasyonu ve Müdahale Kararı

Dr.Öğr.Üyesi Oğuz KÜÇÜKYILMAZ[1], Firdevs SARIGÖL[2]
[1] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Acil Tıp ABD
[2] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Tıp Fakültesi Dönem1

Özet

Acil tıp, yüksek hasta yükü, zamana duyarlı kararlar ve sınırlı kaynaklar nedeniyle hata payına en az tolerans gösteren klinik alanlardan biridir. Bu karmaşık ve hızlı tempolu ortamda yapay zekâ (YZ) ve makine öğrenimi (MÖ) destekli sistemler, hekimin karar sürecine hız ve doğruluk kazandırmada büyük potansiyel taşımaktadır. Günümüzde acil servislerde triyaj, tanısal görüntüleme, yoğun bakım risk analizleri ve mortalite tahmininde aktif olarak YZ-tabanlı sistemler kullanılmaktadır. Ancak YZ'nin hekime kararı "olasılık temelli" mi yoksa "direktif odaklı" mı sunması gerektiği, etik ve yasal tartışmaların odağını oluşturmaktadır. Bu makalede, acil tıpta YZ'nin tarihsel gelişim süreci, mevcut uygulamaları, entegrasyon modelleri ve global politika yaklaşımları incelenmekte; vaka örnekleri, akademik bulgular ve düzenleyici çerçeveler üzerinden eleştirel bir değerlendirme sunulmaktadır. Ayrıca, YZ'nin gelecekte acil tıbbın farklı alt alanlarına genişletilebilmesi için geçmesi gereken aşamalar ve olası engeller özgün bir biçimde tartışılmaktadır.

Anahtar kelimeler: Acil tıp, yapay zekâ, risk stratifikasyonu, karar destek sistemleri, makine öğrenimi, etik

1. Giriş

Acil tıpta karar verme, sınırlı bilgi, yüksek stres ve zaman baskısı altında gerçekleşir. Ortalama bir acil servis hekiminin vardiya başına 100'den fazla klinik karar aldığı hesaplanmıştır (1). Bu yoğun akışta hataların çoğu bilişsel yük, veri sınırlılığı ve hızlı değerlendirme baskısından kaynaklanmaktadır (2). Bu bağlamda, yapay zekâya duyulan ihtiyaç, yalnızca hız değil, *karar kalitesinde standardizasyon* gerekliliğinden doğmuştur (3).

YZ'nin tıptaki yolculuğu 1970'lerde MYCIN adlı antibiyotik öneri sistemiyle başlamış, 2010'larla birlikte derin öğrenme (deep learning) algoritmaları sayesinde sağlık verisi analizinde devrim yaratmıştır (4). Acil tıpta ilk uygulamalar, EKG yorumlayıcı sistemler ve sepsis erken uyarı modelleridir (5).

Son yıllarda ise acil tıp departmanlarında ChatGPT-4o, PaLM-Med ve Ed-CoPilot gibi doğal dil işleme (Natural Language Processing, NLP) tabanlı sistemler triyaj süreçlerinde aktif olarak kullanılmaktadır. Pamukkale Üniversitesi'nde 2025 yılında yapılan bir pilot çalışmada, ChatGPT-4o tabanlı triyaj asistanı kırmızı öncelikli hastaları %92,4 doğrulukla belirlemiştir (6). Benzer şekilde ABD'de Johns Hopkins Üniversitesi Hastanesi, Machine Learning for Triage (ML-Triage) modelini kullanarak mortalite tahmininde %91 duyarlılığa ulaşmıştır (7).

Acil tıpta YZ kullanımının büyümesi, yalnız teknolojik değil; etik, yasal ve mesleki kimlik açısından da dönüşüm yaratmaktadır (8).

2. Acil Tıpta YZ ve Makine Öğrenimi Kullanım Süreçleri

2.1 Triyaj ve Hasta Önceliklendirme

YZ, hasta kayıtları, vital bulgular ve semptom tekstlerini analiz ederek triyaj kategorisini tahmin edebilmektedir (9). Türkiye'de yürütülen bir çalışmada, acil triyajda YZ kullanan sistemlerin insan kaynaklı hata oranını %18 azalttığı saptanmıştır (10).

ABD'nin New York şehrinde 2024 itibarıyla kullanılan "ED-SmartFlow" algoritması, triyaj verilerini anlık işlemekte ve nöbet yoğunluğunu optimize etmektedir (11).

2.2 Görüntüleme ve Tanısal Destek

YZ destekli radyoloji sistemleri travma sonrası kafatası kırığı, iç kanama ve inme gibi durumları 5 dakika içinde yorumlayabilmektedir. "DeepMind Eye" ve "Aidoc" platformları, acil görüntüleme analizinde yaygınlaşmıştır (12).

2.3 Prognostik Modelleme ve Müdahale Kararı

PanAI projesi (Türkiye, 2026), akut pankreatitte mortalite tahmininde Ranson skoruna göre daha yüksek performans göstermiştir (AUC = 0.91) (13).
Benzer şekilde, Massachusetts General Hospital (ABD) geliştirdiği e-Sepsis Alert modeliyle, sepsis gelişimini 6 saat öncesinden tahmin etmektedir (14).

3. YZ'nin Etkin Entegrasyonu: Klinik Karar Sürecinde Konumlandırma

YZ'nin acil servise entegrasyonu yalnız teknik değil, iş akışı ve sorumluluk paylaşımı açısından yeniden tasarım gerektirir.
Üç ana karar sunum biçimi bulunmaktadır:

1. Olasılık temelli sistemler: Tahmini olasılık sunar (örnek: "pulmoner emboli olasılığı %78"), hekim kararı yönlendirir.
2. Öneri-odaklı sistemler: Karar alternatifleri oluşturur (örnek: "BT taraması önerilir, EKG tekrarı değerlendirilebilir").
3. Direktif sistemler: Otomatik emir veya tedavi protokolü başlatır; günümüzde etik kaygılar nedeniyle yaygın kullanımı yoktur (15).

Dünya Sağlık Örgütü (WHO-AI4H) ve Avrupa Birliği Tıbbi Cihaz Yönetmeliği (MDR 2017/745), YZ sistemlerinin "hekim kararını destekleyen araç" statüsünde sınırlanması gerektiğini belirtmektedir (16, 17). Türkiye'de de 2025 yılında yayımlanan "Sağlıkta Yapay Zekâ Etik ve Hukuki Rehberi", benzer çizgide düzenlenmiştir (18).

4. Örnek Vaka: Yapay Zekâ Destekli Karar Süreci

Vaka: Acil servise göğüs ağrısı ile başvuran 62 yaşında erkek hasta.
Vital bulgular stabil, EKG'de hafif ST depresyonu izleniyor.

YZ sistemi (CardioNet-AI) verileri analiz ederek şu çıktıları oluşturdu:

- NSTEMI olasılığı %77,
- Kardiyoloji konsültasyonu önerisi (1. öncelik),
- Troponin tekrar testi (2. öncelik),
- Taburculuk (düşük olasılık %7).

Hekim, sistem önerisini dikkate alarak erken konsültasyon yaptı; NSTEMI tanısı doğrulandı. Bu vaka, YZ'nin karar sürecinde zaman kazandırdığını, ancak nihai kararın insanda kaldığını göstermektedir (19).

5. Tartışma

Akademik literatür, YZ'nin acil tıpta mortaliteyi öngörme, kaynak kullanımını azaltma ve hata oranını düşürme potansiyelini desteklemektedir (20, 21).
Bununla birlikte, veri önyargısı (data bias) ve açıklanabilirlik eksikliği, klinik güveni zedelemektedir (22).

ABD FDA (2023) ve Avrupa EMA (2024) "Yapay Zekâ Tabanlı Yazılım Tıbbi Cihaz Rehberleri" yayımlayarak algoritmik güncelleme süreçlerinin şeffaflaştırılmasını zorunlu kılmıştır (23).
OECD'nin 2024 tarihli raporu, etik yapay zekâ politikalarının ulusal standart haline getirilmesi gerektiğini vurgulamıştır (24).

Türkiye'de TİTCK tarafından 2025'te yayımlanan "Dijital Sağlık Teknolojilerinde Klinik Değerlendirme Kılavuzu", YZ sistemlerinin klinik doğrulamasında hekim gözetimi zorunluluğunu getirmiştir (25).

Olumlu yayınlar, yapay zekânın zamandan tasarruf ve doğruluk avantajlarını öne çıkarırken (26), olumsuz yayınlar aşırı güven, etik kaygı ve veri gizliliği risklerine dikkat çekmektedir (27).
Bu nedenle multidisipliner ekip, hasta rızası yönetimi ve sürekli etik izleme mekanizmaları YZ'nin güvenli entegrasyonu için gereklidir.

6. Sonuç

Yapay zekâ, acil tıpta risk stratifikasyonu ve müdahale kararlarının doğasını dönüştürmektedir. Ancak bu dönüşüm, yalnızca teknolojik değil, ekolojik bir değişimdir: veri yönetim kültüründen klinik sorumluluk paylaşımına kadar uzanır. Kişisel verilerin korunması ve alınan kararların sorumluluğu konusunda detaylı daha ayrıntılı düzenlemeler gerekmektedir. Yine kullanılacak risk skorlama sistemleri gibi klinik karar kaynaklarının güncel ve tüm acil tıp camiasında kabul görmüş olması ayrıntılı olarak değerlendirmek gerecek başka bir husutur. Anak tüm bunlar gelişimin önünde engel olacak büyük sorunlar değildir. Acil Tıp gelişime en hızlı ayak uyduran bölümlerden biri olmaya devam edecektir.

Gelecekte YZ, travma yönetiminde kanama kontrol tahmini, toksikoloji olgularında madde sınıflandırmasından çocuk acilde febril hasta değerlendirmesine kadar pek çok yeni alanlarda kullanılmaya başlanaaktır.
Ancak şu sorular hâlâ netleşmemiştir:
YZ'nin önerdiği kararlar, hekimin sezgisiyle çeliştiğinde kimin sözü geçecektir?
Hatalı bir algoritmik yönlendirmede yasal sorumluluk kimdedir?
Ve en önemlisi — acil servisin kaotik doğasında YZ gerçekten bir "yardımcı asistan" mı, yoksa "karar ortağı" mı olacaktır?

Bu sorulara verilecek en uygun yanıtlar ve atılacak doğru adımlar, gelecekte acil tıbbın dijital dönüşümünü yönlendirecektir.

Kaynaklar

1. Croskerry P. Diagnostic failure: A cognitive and affective approach. *BMJ Qual Saf.* 2020;29(11):933-938.
2. Redpath C, Taylor S. Cognitive overload in emergency medicine. *Emerg Med J.* 2019;36(6):331-335.
3. Berikol GB, Sarbay İ. Acil tıpta yapay zekânın gerekliliği. *Anadolu J Emerg Med.* 2022;4(3):114-117.

4. Shortliffe EH, Buchanan BG. A model of inexact reasoning in medicine. *Math Biosci.* 1975;23(3):351-379.
5. Shashikumar SP, Stanley MD, et al. Early sepsis detection using blood pressure dynamics. *J Electrocardiol.* 2017;50(6):739-743.
6. Pamukkale Üniversitesi. *Acil Servis Triyajında Yapay Zekâ Kullanımı.* Denizli; 2025.
7. Levin S et al. Machine-Learning-Based Electronic Triage. *Ann Emerg Med.* 2018;71(5):565-574.
8. Grant K et al. Artificial Intelligence in Emergency Medicine. *Ann Emerg Med.* 2020;75(6):721-726.
9. Sarbay İ, Berikol GB, Özturan İU. Performance of ChatGPT in emergency triage. *Turk J Emerg Med.* 2023;23(3):150-158.
10. Adıyaman S, Azizoğlu F. Digital and AI-supported triage system. *J Original Stud.* 2025;6:e2857.
11. New York City Health+Hospitals. *ED-SmartFlow Pilot Report.* NYC; 2024.
12. Aidoc Radiology AI Suite. Clinical validation summary. Tel Aviv; 2023.
13. Çaltekin İ et al. PanAI: Prognosis and mortality prediction in acute pancreatitis. *Arch Curr Med Res.* 2026;7(1):70-80.
14. Nemati S et al. Real-time Sepsis Prediction in ICU. *Crit Care Med.* 2021;49(8):1377-1384.
15. Naylor CD. On the prospects for deep learning in health care. *JAMA.* 2018;320(11):1099-1100.
16. WHO. *Artificial Intelligence for Health (AI4H) Ethics Framework.* Geneva; 2023.
17. European Commission. *Medical Device Regulation (MDR 2017/745).* Brussels; 2021.
18. T.C. Sağlık Bakanlığı. *Sağlıkta Yapay Zekâ Etik ve Hukuki Rehberi.* Ankara; 2025.
19. Massachusetts General Hospital. *Clinical AI Integration Case Studies.* Boston; 2024.
20. Cabitza F, Campagner A. The unintended consequences of AI in clinical decision-making. *Clin Chem Lab Med.* 2022;60(8):1220-1229.
21. Hinton G. Deep learning in health. *Nature.* 2021;596(7872):482-483.
22. Jobin A, Ienca M, Vayena E. The global landscape of AI ethics guidelines. *Nat Mach Intell.* 2019;1(9):389-399.
23. U.S. FDA. *AI/ML-Based Software as a Medical Device Action Plan.* Silver Spring MD; 2023.
24. OECD. *AI in Health: Regulatory and Ethical Considerations.* Paris; 2024.
25. TİTCK. *Dijital Sağlık Teknolojilerinde Klinik Değerlendirme Kılavuzu.* Ankara; 2025.
26. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019;25(1):44-56.

27. Chenais G. Artificial intelligence in emergency medicine: Viewpoint. *J Med Internet Res.* 2023;25:e40031.

Nörolojik hastalıklarda yapay zekâ: iyileşme potansiyeli ve fonksiyonel prognoz

Behiye Yıldız[1], Yağmur Simge Sever Aktuna[2*]

[1]Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Lisans Öğrencisi

[2]Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Nöroloji Anabilim Dalı, Öğretim Üyesi

[*]Sorumlu yazar: yamirsever@gmail.com

Özet

Bu çalışma, nörolojik hastalıklarda yapay zekânın iyileşme potansiyeli ve fonksiyonel prognoz üzerindeki rolünü analitik ve eleştirel bir bakış açısıyla değerlendiren yapılandırılmış bir anlatı derlemesidir. Son on yılı kapsayan literatür çerçevesinde; inme, Alzheimer hastalığı, Parkinson hastalığı, multiple skleroz, epilepsi, travmatik beyin hasarı ve amyotrofik lateral skleroz alanlarında makine öğrenimi, derin öğrenme, konvolüsyonel ve yinelemeli sinir ağları, transformer tabanlı mimarileri, federe öğrenme ve açıklanabilir yapay zekâ yaklaşımlarının klinik kullanımları incelenmiştir. Genel eğilim, klinik, görüntüleme, laboratuvar ve dijital biyobelirteçleri bir araya getiren çok modlu modellerin; tanı, fonksiyonel prognoz ve tedavi yanıtı öngörüsünde tek veri türüne dayalı modellere kıyasla daha yüksek ayırt edici güce sahip olduğunu göstermektedir. Bununla birlikte çalışmaların önemli bir bölümü tek merkezli ve retrospektif olup; genellenebilirlik, prospektif etki değerlendirmesi ve gerçek yaşam klinik iş akışına entegrasyon açısından sınırlılıklar taşımaktadır. TRIPOD+AI ve PROBAST+AI çerçeveleri ile FDA (Amerika Birleşik Devletleri Gıda ve İlaç İdaresi), EMA (Avrupa İlaç Ajansı), Avrupa Birliği AI Act ve ulusal veri koruma düzenlemeleri, metodolojik kalite, yanlılık değerlendirmesi, veri yönetişimi, mahremiyet ve güvenlik başlıklarında asgari standartları tanımlamaktadır. Sonuç olarak yapay zekâ, nörolojide hekimin yerini alan otonom bir sistemden çok, çok boyutlu klinik belirsizliği azaltan ve karar sürecini destekleyen bir araç olarak konumlanmakta; bu potansiyelin güvenli ve etkili biçimde hayata geçirilebilmesi için çok merkezli, prospektif, açıklanabilir ve hasta sonlanımlarını merkeze alan çalışmalara gereksinim bulunmaktadır.

Anahtar Kelimeler: Yapay zekâ; nörolojik hastalıklar; fonksiyonel prognoz; iyileşme potansiyeli; makine öğrenimi; derin öğrenme.

Giriş

Nörolojik hastalıklar, yalnızca tanısal açıdan karmaşık olmaları nedeniyle değil; bireyler arasında belirgin farklılık gösteren iyileşme örüntüleri, uzun dönem işlev kaybı ve yüksek bakım yükü nedeniyle de yapay zekâ uygulamaları için son derece uygun bir alan oluşturmaktadır (World Health Organization [WHO], 2024). Günlük klinik pratikte çoğu zaman asıl soru, hastalığın varlığından çok, hastanın ne ölçüde toparlanabileceği, fonksiyonel bağımsızlığını hangi düzeyde koruyabileceği ve hangi tedavi yaklaşımından daha fazla yarar görebileceğidir. Bu nedenle güncel literatürde yapay zekânın en dikkat çekici katkısı, yalnızca tanıya yardımcı olması değil; prognozun öngörülmesi, tedavi kararlarının kişiselleştirilmesi ve rehabilitasyon hedeflerinin belirlenmesinde kullanılabilmesidir (Kalani ve Anjankar, 2024).

Nörolojide yapay zekâ uygulamalarını diğer tıbbi alanlardan ayıran temel özellik, verinin son derece heterojen yapıda olmasıdır. Aynı hastaya ait yapısal MRG (manyetik rezonans görüntüleme), difüzyon görüntüleme, FLAIR (fluid-atenuated inversion recovery) sekansları, PET (pozitron emisyon tomografisi) verileri, EEG (elektroensefalografi) kayıtları, klinik ölçekler, yürüme sensörleri, konuşma örnekleri, laboratuvar parametreleri ve uzunlamasına izlem verileri birlikte değerlendirilebilmektedir (Acien vd., 2024; Al-Shammri vd., 2026; Cejudo vd., 2026; Olsson vd., 2026). Bu nedenle nörolojik

uygulamalarda başarının belirleyicisi çoğu zaman yalnızca kullanılan algoritma değildir. Veri standardizasyonu, eksik verinin uygun biçimde yönetilmesi, zaman boyutunun modele yansıtılması ve sonuçların klinik olarak yorumlanabilir olması, model performansı kadar belirleyici unsurlardır (Campagnini vd., 2022). Özellikle prognoz odaklı çalışmalarda, zaman boyutunu ve değişkenler arası karmaşık ilişkileri modelleyebilen transformer tabanlı mimariler ile yapılandırılmış klinik verilerde güçlü performans gösteren topluluk öğrenmesi ve artırım (boosting/güçlendirme) temelli yöntemlerin öne çıkması bu gereksinimle ilişkilidir (Cejudo vd., 2026; Olsson vd., 2026).

Literatür incelendiğinde, yapay zekâ temelli nörolojik çalışmaların var olduğu; ancak bunların önemli bir bölümünün derleme niteliğinde, mühendislik prototipi düzeyinde ya da karar destek/veri tabanı geliştirme ekseninde kaldığı görülmektedir. Klinik sonlanımları merkeze alan, çok merkezli ve dış doğrulamalı yerli çalışmaların sayısı daha sınırlıdır. Bu doğrultuda, bu çalışmanın amacı nörolojik hastalıklarda yapay zekânın iyileşme potansiyeli ve fonksiyonel prognoz üzerindeki etkisini mevcut literatür ışığında değerlendirmektir.

Yöntem

Literatür taramasında ağırlıklı olarak 2016–2026 yılları arasındaki çalışmalar dikkate alınmış, daha eski tarihli ancak alanın gelişimini anlamak açısından önem taşıyan sınırlı sayıdaki yayın ise tarihsel bağlam sağlamak amacıyla dâhil edilmiştir. Tarama sürecinde PubMed öncelikli olmak üzere uluslararası literatür, Nature ve Science ailesi dergilerde yayımlanan ilgili çalışmalar, yeni eğilimleri yansıtan ön baskılar, açık erişimli tam metinler, resmi düzenleyici belgeler ve Türkçe kaynaklar incelenmiştir. Türkçe literatürde özellikle DergiPark ve TR Dizin'de yer alan çalışmalar ile Türkiye'de veri koruma ve düzenleyici çerçeveyi belirleyen kurumsal metinlere öncelik verilmiştir.

Bu çalışma sistematik derleme niteliği taşımamakla birlikte, yapılandırılmış ve eleştirel bir anlatı incelemesi gerçekleştirme amacına uygun olarak, seçilen yayınların belirlenmesinde belirli nitelikler esas alınmıştır. Bunlar; son on yıla ait olma, orijinal araştırma makalesi olma ya da sistematik derleme/meta-analiz niteliği taşıma, klinik uygulanabilirlik, performans ölçütleri gibi ölçütlerin açık biçimde raporlanmış olması veya iyileşme potansiyeli ya da fonksiyonel prognozla doğrudan ilişkili sonuçlar içermesidir. Ön baskı niteliğindeki çalışmalar yönelim gösterici bilgi sağlamak amacıyla gözden geçirilmiş; ancak temel sonuçlar oluşturulurken hakemli yayınlara öncelik verilmiştir.

Bulgular

Yöntemler, modeller ve hastalık alanları

Nörolojide kullanılan yapay zekâ yöntemlerinin genel olarak iki ana grupta ele alınabileceği değerlendirilmiştir. Birinci grupta, yapılandırılmış klinik veriler üzerinde güçlü performans gösteren klasik makine öğrenimi yöntemleri yer alır; bu grupta lojistik regresyon, destek vektör makineleri, rassal orman (random forest), gradyan artırma (gradient boosting) ve XGBoost gibi modeller öne çıkmaktadır (Campagnini vd., 2022; Zhao vd., 2024). İkinci grupta ise ham görüntü ve sinyal verilerinden otomatik olarak özellik öğrenebilen derin öğrenme yaklaşımları bulunmaktadır. Özellikle 2D ve 3D konvolüsyonel sinir ağları, U-Net türevleri, RNN (yinelemeli sinir ağı - recurrent neural network), LSTM (uzun-kısa süreli bellek), BLSTM (çift yönlü LSTM), görüntü dönüştürme (ViT-vision transformer) ve multimodal dönüştürücü mimarileri bu alanda dikkat çekmektedir. Federe öğrenme, verinin merkezileştirilemediği çok merkezli nörogörüntüleme araştırmalarında önemli bir çözüm olarak öne çıkarken; açıklanabilir yapay zekâ yaklaşımları ise SHAP, LIME ve Grad-CAM gibi araçlarla model kararlarının klinik olarak anlaşılabilir hale getirilmesine katkı sunmaktadır (Zhao vd., 2024).

Bu yöntemlerin hangi hastalık alanında öne çıktığı, büyük ölçüde kullanılan veri tipine ve hedeflenen klinik soruya bağlıdır. Örneğin klasik makine öğrenimi yöntemleri; inme, Parkinson Hastalığı (PH), epilepsi, Multipl Skleroz (MS), travmatik beyin hasarı ve Amiyotrofik Lateral Skleroz (ALS) gibi alanlarda klinik skorlar, laboratuvar verileri, EEG özellikleri ve demografik değişkenler üzerinden risk sınıflaması ve kısa dönem prognoz tahmini amacıyla sıklıkla kullanılmaktadır (Al-Shammri vd., 2026; Zhao vd., 2024). Buna karşılık derin öğrenme temelli yaklaşımlar; özellikle Alzheimer hastalığı, epilepsi, inme ve multipl skleroz gibi alanlarda MRG, BT (bilgisayarlı tomografi) ve EEG verileri üzerinden tanı desteği, lezyon segmentasyonu ve fonksiyonel sonuç öngörüsünde daha belirgin bir kullanım alanı bulmuştur (Cejudo vd., 2026; Koska vd., 2024). Zaman serisi tabanlı derin öğrenme modelleri ise Alzheimer progresyonu, ALS seyri ve epileptik nöbet öngörüsü gibi uzunlamasına veri gerektiren durumlarda önem kazanmaktadır (Cejudo vd., 2026).

Türkiye'den bildirilen çalışmalar da genel olarak bu uluslararası eğilimle uyumludur. Özellikle rehabilitasyon teknolojileri, EEG işleme, multipl skleroz için veri tabanı ve karar destek sistemleri ile Alzheimer ve epilepside radyolojik görüntü ya da sinyal temelli sınıflandırma çalışmaları dikkat çekmektedir (Koska vd., 2024). Bununla birlikte ulusal literatürdeki çalışmaların önemli bir bölümünün mühendislik prototipi ya da yöntem geliştirme aşamasında kaldığı, gerçek yaşam hasta sonlanımlarına dayanan prospektif klinik etki çalışmalarının ise henüz sınırlı olduğu görülmektedir. Bu durum, Türkiye'de teknik kapasitenin bulunduğunu; ancak klinik doğrulama ve çok merkezli uygulama boyutunun henüz yeterince gelişmediğini düşündürmektedir.

Klinik uygulamalar

Tanı

Tanı alanında yapay zekânın en güçlü uygulamalarından biri demans ve Alzheimer hastalığı spektrumunda görülmektedir (Cejudo vd., 2026). Çok modlu veri kullanan yeni kuşak modeller, yalnızca görüntüleme verisine değil; klinik öykü, nöropsikolojik değerlendirme ve yapısal MRG gibi birden fazla veri kaynağına dayandıklarında belirgin ölçüde daha yüksek performans göstermektedir. Örneğin multimodal transformer tabanlı çalışmalarda, dış doğrulama kohortlarında yüksek AUROC (Area Under the Receiver Operating Characteristic Curve) ve AUPR (Area Under the Precision-Recall Curve) değerleri bildirilmiş; ayrıca nörolog ve nöroradyologların yapay zekâ desteğiyle daha yüksek tanısal doğruluk sergilediği gösterilmiştir (Kalani ve Anjankar, 2024). Benzer biçimde, yapısal MRG verileri üzerinde geliştirilen açıklanabilir ViT tabanlı Alzheimer modelleri, hem Alzheimer hastalığını sağlıklı bireylerden ayırmada hem de hafif bilişsel bozulmanın ilerleyici alt tiplerini belirlemede yüksek doğruluk oranları bildirmiştir (Trasca vd., 2025).

Epilepsi alanında da tanısal amaçlı yapay zekâ uygulamaları dikkat çekici sonuçlar vermektedir (Kalani ve Anjankar, 2024). Özellikle PET görüntüleri ve EEG verilerine dayalı modeller, temporal lob epilepsisi gibi seçilmiş klinik alt gruplarda yüksek ayırt edici performans bildirmiştir (Trasca vd., 2025). Bununla birlikte burada önemli olan nokta, bu yüksek performansın çoğu zaman seçilmiş hasta gruplarında ve sınırlı örneklemler üzerinde elde edilmiş olmasıdır. Dolayısıyla tanıda bildirilen yüksek doğruluk oranları umut verici olmakla birlikte, bunların gerçek yaşam klinik çeşitliliğinde aynı düzeyde sürdürülebilir olup olmadığı hâlen net değildir.

Prognoz

Fonksiyonel prognoz açısından yapay zekânın en olgunlaştığı alanın inme olduğu söylenebilir (T.C. Sağlık Bakanlığı, 2019). Akut iskemik inmede geliştirilen modeller, özellikle üç aylık fonksiyonel sonlanımın öngörülmesinde dikkat çekici sonuçlar üretmiştir

(Campagnini vd., 2022; Zhao vd., 2024). Kararların nasıl alındığını şeffaf bir şekilde gösteren bir araç olan SHAP aracı destekli gradyan artırım modeliyle yapılan bir çalışmada, doğrulama setinde yüksek AUC ve duyarlılık değerleri bildirilmiş; modelin klasik lojistik regresyona göre daha iyi performans gösterdiği vurgulanmıştır (Olsson vd., 2026). Bununla birlikte inme rehabilitasyonuna ilişkin sistematik derlemeler, alandaki performansın heterojen olduğunu ve bildirilen sonuçların önemli bir bölümünde yanlılık riskinin yüksek veya belirsiz kaldığını göstermektedir (Campagnini vd., 2022). Bu nedenle inme alanı yapay zekâ açısından en ileri örnekleri sunsa da klinik uygulamaya geçiş açısından hâlen metodolojik güçlendirmeye ihtiyaç vardır.

Alzheimer hastalığında prognoz, daha çok hafif bilişsel bozulmadan demansa dönüşümün öngörülmesi çerçevesinde incelenmektedir. Bu alanda çok modlu RNN tabanlı yaklaşımlar, tek veri kaynağına dayanan modellere göre daha yüksek performans göstermiştir (Cejudo vd., 2026). Multipl sklerozda ise klinik, immünolojik ve radyolojik MRG verilerinin makine öğrenimi ile bütünleşik değerlendirilmesi, hastalık progresyonu ve engellilik artışı gibi sonuçların tahmininde umut verici bulunmuştur (Al-Shammri vd., 2026). ALS'de klinik verilerin görüntüleme ile birleştirilmesi sağkalım sınıflamasını anlamlı şekilde iyileştirmiştir (Acien vd., 2024). Travmatik beyin hasarında ise özellikle hematom progresyonu ve kısa dönem prognoz için geliştirilen açıklanabilir radyomik modeller dikkat çekmektedir (Kalani ve Anjankar, 2024).

Bu bulguların ortak yönü, prognoz sorusunun tek bir biyobelirteç ya da tek bir klinik değişken üzerinden yanıtlanamayacağını göstermektedir (Trasca vd., 2025). Hastanın klinik durumu, görüntüleme özellikleri, laboratuvar verileri ve izlem sürecindeki değişkenlik birlikte ele alındığında daha güçlü tahmin modelleri elde edilmektedir (Al-Shammri vd., 2026; Olsson vd., 2026). Dolayısıyla yapay zekânın nörolojide prognoza en büyük katkısı, farklı veri türlerini aynı çerçevede birleştirerek belirsizliği azaltabilmesidir.

Tedavi planlama

Tedavi planlaması, yapay zekânın klinik açıdan en dikkat çekici vaatlerinden birini oluşturmaktadır (Kalani ve Anjankar, 2024). Bu alanın en belirgin örnekleri epilepside görülmektedir. Özellikle ilaç direnci ve nöromodülasyon yanıtı gibi, hasta bazında kritik klinik kararları etkileyebilecek sonuçların önceden tahmin edilebilmesi, kişiselleştirilmiş tedavi yaklaşımı açısından büyük önem taşımaktadır (Trasca vd., 2025). Dirençli epilepside nöromodülasyon yanıtını değerlendiren çalışmalar ve meta-analitik veriler, yapay zekâ modellerinin anlamlı bir ayırt edici güce sahip olduğunu göstermektedir (Ervin ve Arya, 2025). Ancak burada da temel sorun, çalışmaların çoğunun küçük örneklemler ve sınırlı dış doğrulama ile yürütülmüş olmasıdır (Ervin ve Arya, 2025).

Tedavi planlaması açısından önemli bir nokta, yapay zekânın yalnızca "hangi hastada hangi tedavi işe yarar?" sorusuna değil, aynı zamanda "hangi hastada hangi tedavinin yararı sınırlı olabilir?" sorusuna da katkı sağlayabilmesidir. Bu yönüyle yapay zekâ, gereksiz tedavi yükünün azaltılması, hasta seçiminin daha rasyonel yapılması ve kaynakların daha verimli kullanılması bakımından da potansiyel taşımaktadır. Bununla birlikte klinik kararların doğrudan algoritmaya devredilmesi değil, algoritmik çıktının klinik bağlam içinde yorumlanması gereklidir (WHO, 2024).

Rehabilitasyon

Rehabilitasyon alanında yapay zekâ uygulamaları giderek daha görünür hale gelmektedir. Burada öne çıkan temel kullanım alanları şunlardır: Birincisi, hangi hastanın daha yoğun ya da daha erken rehabilitasyondan yarar görebileceğinin belirlenmesi; ikincisi, rehabilitasyon sürecinin kişiselleştirilmesi; üçüncüsü ise telerehabilitasyon, sanal gerçeklik ve giyilebilir

teknolojiler aracılığıyla izlem yapılması (Sharma vd., 2026); dördüncüsü ise özellikle inme hastalarında motor fonksiyonların geri kazanımı için EEG tabanlı beyin-bilgisayar arayüzü (BCI) ve robotik rehabilitasyon uygulamalarının kullanılmasıdır (Ang vd., 2015; Cantillo-Negrete vd., 2025). İnme rehabilitasyonuna ilişkin sistematik derlemeler ve makine öğrenimi temelli tahmin modelleri, bu yaklaşımların klinik açıdan anlamlı bir potansiyel taşıdığını göstermektedir (Campagnini vd., 2022, 2025; Zhao vd., 2024). Ancak veri kaynaklarındaki heterojenlik, farklı sonlanım ölçütleri ve sınırlı metodolojik kalite nedeniyle genellenebilir sonuçlara ulaşmak güçtür (Campagnini vd., 2022).

Nörorehabilitasyon alanındaki daha geniş kapsamlı derlemeler de benzer bir tablo ortaya koymaktadır. Yapay zekâ ve makine öğrenimi yöntemlerinin tanı ve tedavi süreçlerinde giderek daha fazla yer bulduğu; ancak uygulamaların henüz standart klinik yaklaşımın yerini alacak düzeyde olmadığı görülmektedir (Sharma vd., 2026). Türkiye'den bildirilen yayınlar da özellikle kişiselleştirilmiş bakım, mobil izlem, sanal gerçeklik destekli rehabilitasyon ve hasta takibinin dijitalleştirilmesi gibi başlıklarda yapay zekânın önemli fırsatlar sunduğunu göstermektedir (Koska vd., 2024). Buna karşın bu yayınların çoğunda klinik etkinlikten çok uygulama potansiyeli ön plandadır.

İzlem

İzlem sürecinde yapay zekâ özellikle Parkinson hastalığı ve ALS gibi ilerleyici nörolojik hastalıklarda önem kazanmaktadır. Parkinson hastalığında yürüme analizi, çift görev performansı, dijital hareket verileri ve klinik bulguların birlikte kullanıldığı modeller, bilişsel bozulmanın erken dönem tahmininde umut verici bulunmuştur (Cejudo vd., 2026). Bazı çalışmalarda klasik klinik ve yürüme verilerinin, ileri görüntüleme yöntemlerinden daha fazla katkı sunduğu gösterilmiştir. Bu durum, her zaman daha karmaşık veri türlerinin daha yüksek klinik yarar sağlamadığını; bazen iyi yapılandırılmış klinik verinin daha güçlü olabileceğini göstermektedir.

ALS'de ise dijital biyobelirteçler giderek daha fazla önem kazanmaktadır. Okülometrik ölçümler, klavye kullanım dinamikleri ve diğer dijital davranışsal göstergeler, hastalık seyrinin izlenmesinde potansiyel araçlar olarak değerlendirilmektedir (Acien vd., 2024). Bu yaklaşımların en önemli avantajı, hastalık gidişinin yalnızca poliklinik ziyaretleri sırasında değil, daha sürekli ve daha nesnel biçimde izlenebilme olanağı sunmasıdır. Bununla birlikte bu alandaki çalışmaların çoğu henüz doğrulama ve klinik entegrasyon aşamasındadır (Acien vd., 2024; Trasca vd., 2025).

İyileşme potansiyeli ve fonksiyonel prognoz üzerine kanıtların değerlendirilmesi

Mevcut literatür incelendiğinde, doğrudan "iyileşme potansiyeli"ni ölçen çalışmaların sayısının tanı odaklı çalışmalara kıyasla daha az olduğu görülmektedir. Bu nedenle araştırmaların büyük bölümü, iyileşme potansiyelini doğrudan değil; modifiye Rankin Skalası, GOSE, EDSS, ALSFRS-R, nöbetsizlik oranı, bilişsel bozulma derecesi ya da işe dönüş gibi dolaylı fonksiyonel sonlanımlar üzerinden değerlendirmektedir (Acien vd., 2024; Al-Shammri vd., 2026; Campagnini vd., 2022; Olsson vd., 2026). Bu yaklaşım anlaşılır olmakla birlikte, çalışmalar arası karşılaştırmayı güçleştirmektedir; zira her sonlanım ölçeği farklı bir işlevsel boyutu temsil etmekte ve bu ölçeklerin aynı kavramsal çerçevede değerlendirilmesi her zaman mümkün olmamaktadır.

Alanlar arası karşılaştırma yapıldığında, en güçlü kanıtın inmede kısa dönem fonksiyonel sonuç öngörüsü (Olsson vd., 2026; Zhao vd., 2024) ile Alzheimer hastalığında tanı ve progresyon öngörüsü alanlarında (Cejudo vd., 2026) toplandığı söylenebilir. ALS'de sağkalım sınıflaması da görece güçlü bir kanıt alanı oluşturmaktadır (Acien vd., 2024). Parkinson hastalığında bilişsel bozulma ve yürüme temelli tahminler, epilepside tedavi

yanıtı (Ervin ve Arya, 2025) ve multipl sklerozda progresyon öngörüsü ise orta düzeyde kanıt sunmaktadır (Al-Shammri vd., 2026). Travmatik beyin hasarında geniş hasta gruplarına genellenebilir fonksiyonel prognoz modelleri ve federe öğrenme temelli gerçek yaşam uygulamaları henüz daha sınırlı olmakla birlikte, gelecek açısından umut verici bir çerçeve oluşturmaktadır.

Burada dikkat edilmesi gereken temel nokta, "en iyi performans değeri" ile "en güçlü klinik kanıt"ın aynı şey olmadığıdır. Bir model küçük, seçilmiş ve homojen bir örneklemde çok yüksek doğruluk gösterebilir; ancak dış geçerlilik olmaksızın bu başarının klinik değeri sınırlı kalır. Bu nedenle iyileşme potansiyeli ve fonksiyonel prognoz alanındaki değerlendirme yapılırken yalnızca AUC ya da doğruluk değil; çalışmanın tasarımı, dış geçerlilik durumu, örneklemin temsiliyet gücü ve modelin klinik yorumlanabilirliği birlikte dikkate alınmalıdır (Campagnini vd., 2022; Trasca vd., 2025).

Etik, düzenleyici çerçeve ve veri yönetişimi

Nörolojide yapay zekâ kullanımına ilişkin etik tartışmaların merkezinde yalnızca hatalı tahmin riski yer almamaktadır. Asıl mesele, bu hataların hangi hasta gruplarında yoğunlaştığı ve bunun klinik eşitsizlikleri artırıp artırmadığıdır. Yaş, cinsiyet, etnik köken, kullanılan görüntüleme cihazı, başvuru merkezi ya da hastalık alt tipi bakımından dengesiz örneklemlerle geliştirilen modeller, genel ortalamada yüksek performans gösterse bile bazı alt gruplarda belirgin biçimde zayıf kalabilir. Bu nedenle yapay zekâ modellerinin değerlendirilmesinde yalnızca ortalama performans ölçütlerine değil, alt grup düzeyinde kararlılık ve adalet göstergelerine de bakılması gereklidir (WHO, 2021).

Bu alanda metodolojik kaliteyi artırmak üzere geliştirilen TRIPOD+AI ve PROBAST+AI çerçeveleri büyük önem taşımaktadır. TRIPOD+AI, yapay zekâ temelli tahmin modellerinin daha eksiksiz ve şeffaf biçimde raporlanmasını amaçlarken; PROBAST aracı (Wolff vd., 2019) ve bu aracın yapay zekâ uzantısı olan PROBAST+AI, geliştirilen modellerin yanlılık, kalite ve uygulanabilirlik açısından sistematik olarak değerlendirilmesini sağlamaktadır. Nörolojide geliştirilen modeller açısından bu kılavuzların önemi büyüktür; zira klinik değeri olan bir model yalnızca yüksek AUC üreten model değildir. Aynı zamanda veri kaynağını açık biçimde tanımlayan, eksik veriyi nasıl yönettiğini belirten, kalibrasyonu gösteren, dış doğrulama içeren ve klinik karar sürecine nasıl entegre edileceğini açıklayan modeldir (Collins vd., 2024).

Düzenleyici açıdan bakıldığında FDA, EMA ve Avrupa Birliği kurumları, yapay zekâ temelli tıbbi yazılımların yaşam döngüsü yaklaşımıyla ele alınması gerektiğini vurgulamaktadır. Buna göre bir modelin yalnızca geliştirilmesi değil; eğitim verisinin niteliği, kullanım sırasında insan gözetimi, gerçek yaşam performans izlemi, güvenlik güncellemeleri ve risk yönetimi birlikte değerlendirilmelidir. Avrupa Birliği AI Act kapsamında tıbbi amaçlı yapay zekâ sistemlerinin yüksek riskli kategoride değerlendirilmesi, bu teknolojilerin sıradan yazılımlar olarak değil, hasta güvenliğini etkileyebilecek klinik araçlar olarak görüldüğünü göstermektedir. Türkiye'de de KVKK çerçevesinde veri minimizasyonu, anonimleştirme, tasarımdan itibaren veri koruma ve ayrımcılık riskinin azaltılması ilkeleri özellikle önem kazanmaktadır (Trasca vd., 2025).

Bu bağlamda federe öğrenme önemli bir ara çözüm sunmaktadır. Özellikle çok merkezli nörolojik çalışmalarda hasta verisini fiziksel olarak tek bir merkezde toplamadan model eğitimi yapılabilmesi, hem mahremiyet hem de veri paylaşımı kısıtları açısından avantaj sağlamaktadır. Bununla birlikte federe öğrenme tek başına genellenebilirlik sorununu çözmez. Merkezler arası veri dağılımı, tanısal dengesizlikler ve teknik heterojenlik devam ettiği sürece bu yaklaşımın da dış doğrulama, kalibrasyon ve önyargı değerlendirmesi ile desteklenmesi gerekir.

Tartışma

Mevcut literatürün ortak biçimde gösterdiği nokta, yapay zekânın nörolojide en değerli katkısının yalnızca görünmeyen örüntüleri bulmak değil, çok boyutlu klinik belirsizliği daha ölçülebilir hale getirmek olduğudur. İnmede klinik skorlar, laboratuvar bulguları ve görüntüleme özelliklerinin (Olsson vd., 2026; Zhao vd., 2024); Alzheimer hastalığında MRG, bilişsel testler ve klinik öykünün (Cejudo vd., 2026); Parkinson hastalığında yürüme parametreleri ile klinik bulguların; epilepside EEG, PET ve ilaç öyküsünün (Trasca vd., 2025); ALS'de ise klinik ve görüntüleme verilerinin birlikte değerlendirilmesi (Acien vd., 2024), en güçlü sonuçların çoğunlukla çok modlu modellerden elde edildiğini göstermektedir (Al-Shammri vd., 2026). Bu durum, nörolojik hastalıkların tek bir belirteç üzerinden değil, karmaşık ve çok bileşenli biyolojik süreçler üzerinden ilerlediğini bir kez daha ortaya koymaktadır.

Bununla birlikte fonksiyonel prognoz alanında hâlen önemli metodolojik sorunlar bulunmaktadır. İlk olarak sonlanım ölçütleri arasında belirgin bir heterojenlik vardır. mRS, GOSE, EDSS, ALSFRS-R, nöbetsizlik ya da işe dönüş gibi sonuçlar, işlevselliğin farklı boyutlarını temsil etmekte ve bunların aynı başlık altında karşılaştırılması her zaman doğru olmamaktadır (Acien vd., 2024; Campagnini vd., 2022). İkinci olarak zaman pencereleri farklılık göstermektedir; üç aylık, bir yıllık ya da daha uzun dönemli tahminlerin aynı model sınıfı altında doğrudan karşılaştırılması metodolojik açıdan sorunludur. Üçüncü olarak veri kayması önemli bir problemdir. Cihaz farklılıkları, merkezler arası uygulama değişkenliği, hasta profillerinin farklılığı ve zaman içinde değişen klinik pratikler, model performansını belirgin biçimde etkileyebilmektedir (Koska vd., 2024). Son olarak, yapay zekânın klinik kararı gerçekten iyileştirip iyileştirmediğini gösteren prospektif etki çalışmalarının sayısı henüz sınırlıdır (Sharma vd., 2026).

Bu nedenle en dengeli sonuç, yapay zekânın nörolojide hekimin yerini alan bir karar verici değil, klinik belirsizliği azaltan ve karar sürecini destekleyen bir araç olduğudur (Kalani ve Anjankar, 2024). Özellikle demans alanında yapay zekâ desteğiyle nörolog ve nöroradyolog performansının artmış olması, bu yaklaşımın somut örneklerinden biridir (Trasca vd., 2025). Burada açıklanabilirlik ayrıca özel bir önem taşımaktadır (Olsson vd., 2026). Klinik pratikte yüksek riskli bir prognoz tahmini sunulduğunda, bu sonucun hangi değişkenlere dayanarak üretildiğinin bilinmesi gerekir; aksi hâlde yanlış bir olumsuz tahmin, tedavi çabasının erken kesilmesine ya da rehabilitasyon hedeflerinin gereksiz biçimde daraltılmasına yol açabilir. Bu nedenle nörolojide ideal yapay zekâ modeli, yalnızca yüksek doğruluk gösteren değil; aynı zamanda açıklanabilir, dış geçerliliği gösterilmiş ve klinik iş akışına uyumlu olan modeldir (Collins vd., 2024; Olsson vd., 2026).

Sonuç ve öneriler

Sonuç olarak nörolojik hastalıklarda yapay zekânın en güçlü kullanım alanları kısa vadede tanı desteği, orta vadede fonksiyonel prognoz ve tedavi kişiselleştirmesi, uzun vadede ise sürekli dijital izlem ve yeniden kalibrasyona dayalı karar desteği olarak görünmektedir. Güncel literatür, inme, Alzheimer hastalığı, epilepsi ve ALS alanlarında daha olgun örnekler sunarken; Parkinson hastalığı, multipl skleroz ve travmatik beyin hasarında hızla gelişen fakat henüz tam olgunlaşmamış bir uygulama alanına işaret etmektedir. Bununla birlikte mevcut kanıt düzeyi, yapay zekânın nörolojide bağımsız ve otonom bir karar verici olarak kullanılmasını değil, nitelikli bir klinik karar desteği aracı olarak değerlendirilmesini desteklemektedir.

Araştırma ve uygulama açısından birkaç temel öneri öne çıkmaktadır. İlk olarak, sonlanım ölçütlerinin daha standardize biçimde raporlanması gereklidir. İnmede mRS ve rehabilitasyon hedefleri, multipl sklerozda EDSS ve uzunlamasına MRG aktivitesi, ALS'de

ALSFRS-R ve sağkalım, epilepside ise nöbetsizlik ile yaşam kalitesinin birlikte değerlendirilmesi önemlidir. İkinci olarak alanın tek merkezli ve retrospektif çalışmalardan, çok merkezli ve prospektif etki çalışmalarına yönelmesi gerekir. Üçüncü olarak veri paylaşımının mümkün olmadığı koşullarda federe öğrenme gibi yöntemler kullanılabilir; ancak bu yaklaşımlar mutlaka dış geçerlilik, kalibrasyon ve önyargı denetimiyle desteklenmelidir. Dördüncü olarak, geliştirilen tüm klinik modeller TRIPOD+AI ve PROBAST+AI ilkelerine uygun biçimde raporlanmalı; açıklanabilirlik, model geliştirme sürecinin sonradan eklenen bir unsuru değil, baştan planlanan temel bir bileşeni olmalıdır. Son olarak Türkiye'de teknik düzeyde başlayan üretimin, nöroloji, radyoloji, biyomedikal mühendislik ve veri yönetişimi ekiplerinin birlikte çalıştığı çok merkezli klinik araştırma ağlarıyla güçlendirilmesi gerekmektedir.

En genel çerçevede ifade etmek gerekirse, yapay zekânın nörolojideki asıl değeri, hekimin yerine geçmesinde değil; karmaşık ve çok boyutlu hasta verisini anlamlı, yorumlanabilir ve klinik olarak kullanılabilir hale getirmesindedir. Bu nedenle gelecek dönemde başarı ölçütü yalnızca modelin doğruluğu değil; hasta yararı, klinik karar üzerindeki etkisi, güvenliği, eşitsizlikleri azaltma kapasitesi ve gerçek yaşam koşullarındaki sürdürülebilirliği olacaktır.

Kaynakça

Acien, A., Calcagno, N., Burke, K. M., Mondesire-Crump, I., Holmes, A. A., Mruthik, S., ... Berry, J. D. (2024). A novel digital tool for detection and monitoring of amyotrophic lateral sclerosis motor impairment and progression via keystroke dynamics. Scientific Reports, 14, 67940.

Al-Shammri, S., Özdil, A., Aboukoura, A., Azizieh, F., Yilmaz, B. ve Raghupathy, R. (2026). Predicting multiple sclerosis prognosis using AI and machine learning: Integrating clinical, immunological, and radiological variables. Frontiers in Neurology, 16, 1712953.

Ang, K. K., Chua, K. S. G., Phua, K. S., Wang, C., Chen, Z. Y., Kuah, C. W. K., ... Guan, C. (2015). A randomized controlled trial of EEG-based motor imagery brain-computer interface robotic rehabilitation for stroke. Frontiers in Neuroengineering, 7, 30.

Campagnini, S., Arienti, C., Patrini, M., Liuzzi, P., Mannini, A. ve Carrozza, M. C. (2022). Machine learning methods for functional recovery prediction and prognosis in post-stroke rehabilitation: A systematic review. Journal of NeuroEngineering and Rehabilitation, 19, 54.

Campagnini, S., Sodero, A., Baccini, M., Hakiki, B., Grippo, A., Macchi, C., ... Cecchi, F. (2025). Prediction of the functional outcome of intensive inpatient rehabilitation after stroke using machine learning methods. Scientific Reports, 15, 781.

Cantillo-Negrete, J., Rodríguez-García, M. E., Carrillo-Mora, P., Arias-Carrión, O., Ortega-Robles, E., Galicia-Alvarado, M. A., ... Carino-Escobar, R. I. (2025). The ReHand-BCI trial: A randomized controlled trial of a brain-computer interface for upper extremity stroke neurorehabilitation. Frontiers in Neuroscience, 19, 1579988.

Cejudo, A., Arrojo, M., Martín, C. ve Almeida, A. (2026). AI and wearables for early detection of cognitive impairment and dementia: Systematic review. Journal of Medical Internet Research, 28(1), e86262.

Collins, G. S., Moons, K. G. M., Dhiman, P., Riley, R. D., Beam, A. L., Van Calster, B., ... Mateen, B. A. (2024). TRIPOD+AI statement: Updated guidance for reporting clinical prediction models that use regression or machine learning methods. BMJ, 385, e078378.

Ervin, B. ve Arya, R. (2025). Artificial intelligence and machine learning in neuromodulation for epilepsy. Journal of Clinical Neurophysiology, 42(6), 493-504.

Kalani, M. ve Anjankar, A. (2024). Revolutionizing neurology: The role of artificial intelligence in advancing diagnosis and treatment. Cureus, 16(6), e61706.

Koska, I. O., Selver, A., Gelal, F., Uluc, M. E., Çetinoğlu, Y. K., Yurttutan, N., ... Dicle, O. (2024). Deep learning classification of ischemic stroke territory on diffusion-weighted MRI: Added value of augmenting the input with image transformations. Journal of Imaging Informatics in Medicine, 38, 1374-1387.

Olsson, J., Stanne, T. M., Andersson, B. ve Jern, C. (2026). Predicting post-stroke functional outcome using explainable machine learning and integrated data. Scientific Reports, 16, 47814.

Sharma, A., Ateyeh, R. ve Waqas, M. (2026). Digital and intelligent rehabilitation technologies in stroke and neurological disorders: A systematic review of artificial intelligence, virtual reality, gamification, and emerging therapeutic platforms in neurorehabilitation. Bioengineering, 13(2), 195.

T.C. Sağlık Bakanlığı. (2019). Akut iskemik inme tanı ve tedavi rehberi (Versiyon 1.0). Ankara: T.C. Sağlık Bakanlığı.

Trasca, D.-M., Dorin, P. I., Carmen, S., Varut, R.-M., Singer, C. E., Radivojevic, K. ve Stoica, G. A. (2025). Artificial intelligence in biomedicine: A systematic review from nanomedicine to neurology and hepatology. Pharmaceutics, 17(12), 1564.

Wolff, R. F., Moons, K. G. M., Riley, R. D., Whiting, P. F., Westwood, M., Collins, G. S., ... PROBAST Group. (2019). PROBAST: A tool to assess the risk of bias and applicability of prediction model studies. Annals of Internal Medicine, 170(1), 51-58.

World Health Organization. (2021). Ethics and governance of artificial intelligence for health: WHO guidance. Geneva: World Health Organization.

World Health Organization. (2024). Over 1 in 3 people affected by neurological conditions, the leading cause of illness and disability worldwide. Erişim adresi: https://www.who.int/news/item/14-03-2024-over-1-in-3-people-affected-by-neurological-conditions--the-leading-cause-of-illness-and-disability-worldwide

Zhao, Z., Zhang, Y., Su, J., Yang, L., Pang, L., Gao, Y. ve Wang, H. (2024). A comprehensive review for artificial intelligence on neuroimaging in rehabilitation of ischemic stroke. Frontiers in Neurology, 15, 1367854.

Çocuk hastalıklarında yapay zekâ: erken tanı ve prognoz

Halil Bal[1], Begüm Barış Çetinkaya[2]

[1] Tıp Fakültesi Öğrencisi, Bandırma Onyedi Eylül Üniversitesi

[2] Dr. Öğr. Üyesi, Çocuk Sağlığı ve Hastalıkları AD, Bandırma Onyedi Eylül Üniversitesi,

bcetinkaya@bandirma.edu.tr

Özet

Yapay zekâ (YZ), sağlık hizmetlerinde tanı, tedavi planlama ve prognoz tahmini gibi alanlarda giderek artan bir şekilde kullanılmaktadır. Pediatrik hastalarda fizyolojik parametrelerin yaşa bağlı değişkenlik göstermesi, klinik değerlendirmeyi daha karmaşık hale getirmekte ve erken tanı süreçlerini zorlaştırmaktadır. Bu derlemede, pediatrik hastalıklarda YZ uygulamalarının erken tanı ve prognoz üzerindeki etkileri güncel literatür ışığında incelenmiştir.

Mevcut çalışmalar, YZ sistemlerinin sepsis erken tanısında, prematürelerde bronkopulmoner displazi (BPD) öngörüsünde, diyabet yönetiminde, doğuştan kalp hastalıklarının değerlendirilmesinde, akut lenfoblastik lösemi (ALL) tanısında ve çoklu organ yetmezliği risk tahmininde yüksek doğruluk oranları ile etkin olduğunu göstermektedir. Özellikle yoğun bakım ortamında erken uyarı sistemlerinin kullanımı, mortalite ve morbiditeyi azaltma potansiyeline sahiptir.

Sonuç olarak, yapay zekâ pediatrik hastalıklarda erken tanı ve prognoz tahmininde önemli bir araç olup, klinik karar verme sürecinde destekleyici bir rol üstlenmelidir.

Anahtar Kelimeler: Yapay zekâ, pediatri, erken tanı, prognoz

Giriş

Yapay zekâ (YZ), bilgisayar sistemlerinin veri analizi yoluyla öğrenme, örüntü tanıma ve karar verme süreçlerini gerçekleştirmesini sağlayan bir teknolojidir. Son yıllarda sağlık alanında YZ kullanımında önemli bir artış gözlenmiş olup, bu sistemler özellikle büyük veri setlerinin analizinde klinik karar süreçlerini desteklemektedir. (Kim et al., 2019)

Pediatrik hasta grubunda fizyolojik parametrelerin yaşa göre değişkenlik göstermesi, tanı ve prognoz süreçlerini erişkin popülasyona göre daha karmaşık hale getirmektedir. Bu nedenle pediatride erken tanı ve risk belirleme kritik öneme sahiptir. Yapay zekâ, çok sayıda klinik değişkeni eş zamanlı analiz edebilme kapasitesi ile bu alanda önemli bir çözüm sunmaktadır. (Kim et al., 2019)

Pediatride Yapay Zekâ Uygulamaları

Sepsis Tanısında Yapay Zekâ

Sepsis, pediatrik hastalarda hızlı ilerleyen ve yüksek mortalite ile ilişkili bir klinik durumdur. Yapay zekâ algoritmaları, yaşa özgü vital bulgular ve laboratuvar verilerini analiz ederek sepsis riskini erken dönemde tahmin edebilmektedir. Bu sistemlerin AUC değerinin yaklaşık 0.75 olduğu bildirilmektedir. (Spaeder et al., 2019).

Diyabet Yönetiminde Yapay Zekâ

Pediatrik diyabet takibinde kullanılan YZ sistemleri, sürekli glukoz izleme cihazlarından elde edilen verileri analiz ederek kan şekeri değişimlerini önceden tahmin edebilmektedir. Hipoglisemi ve hiperglisemi tahmininde yüksek doğruluk oranları (%99.8 ve %98.9)

bildirilmiştir. Ayrıca bu sistemler bireyselleştirilmiş tedavi önerileri sunarak hasta yönetimini optimize etmektedir. (Duckworth et al., 2022).

Prematüre Bebeklerde BPD Tahmini

Bronkopulmoner displazi, prematüre bebeklerde önemli bir morbidite nedenidir. Yapay zekâ modelleri, perinatal ve postnatal verileri analiz ederek BPD gelişim riskini yüksek doğrulukla tahmin edebilmektedir. Literatürde bu sistemlerin AUC değerinin 0.899 olduğu bildirilmiştir . (Leigh et al., 2022).

Doğuştan Kalp Hastalıklarında Yapay Zekâ

YZ uygulamaları, ekokardiyografi, manyetik rezonans ve bilgisayarlı tomografi görüntülerini analiz ederek anatomik yapıların değerlendirilmesini kolaylaştırmaktadır. Bu sistemler, tanı doğruluğunu artırmanın yanı sıra cerrahi planlama sürecinde simülasyon imkânı sunarak klinik karar süreçlerine katkı sağlamaktadır. (Holt et al., 2025).

Akut Lenfoblastik Lösemi Tanısında Yapay Zekâ

ALL, çocukluk çağı kanserlerinin önemli bir bölümünü oluşturmaktadır. Derin öğrenme algoritmaları, mikroskobik görüntüler üzerinden blast hücrelerini ayırt ederek erken tanıya katkı sağlamaktadır. Bu sistemlerin doğruluk oranı %94.3 olarak bildirilmektedir. (Papaioannou et al., 2024).

Çoklu Organ Yetmezliği Öngörüsü

YZ sistemleri, henüz organ yetmezliği gelişmemiş hastalarda ilerleyen süreçte çoklu organ yetmezliği gelişimini öngörebilmektedir. Bu sistemlerin doğruluk oranının yaklaşık %91 olduğu bildirilmiştir. Bu durum, erken müdahale ile klinik sonuçların iyileştirilmesine olanak sağlamaktadır. (Bose et al., 2021).

Tartışma

Yapay zekâ uygulamaları pediatrik hastalıklarda erken tanı ve prognoz tahmini açısından önemli avantajlar sunmaktadır. Özellikle yoğun bakım ünitelerinde erken uyarı sistemlerinin kullanımı, hasta sonuçlarını iyileştirme potansiyeline sahiptir.

Bununla birlikte, YZ sistemlerinin klinik uygulamaya entegrasyonunda bazı sınırlılıklar bulunmaktadır. Veri kalitesi ve veri çeşitliliği, model performansını doğrudan etkilemektedir. Ayrıca pediatrik hastalarda yaşa bağlı fizyolojik farklılıklar, modellerin genellenebilirliğini sınırlayabilir. Bunun yanında etik, veri güvenliği ve klinik sorumluluk gibi konular da dikkatle ele alınmalıdır.

Sonuç

Yapay zekâ, pediatrik hastalıklarda erken tanı ve prognoz tahmininde önemli bir potansiyele sahiptir. Ancak bu sistemler klinik kararların yerine geçmemeli, hekimlere destek sağlayan yardımcı araçlar olarak kullanılmalıdır. Gelecekte daha geniş veri setleri ve gelişmiş algoritmalar ile pediatride YZ kullanımının artması beklenmektedir

Kaynaklar

1. Kim, S. Y., Kim, S., Cho, J., et al. (2019). A deep learning model for real-time mortality prediction in critically ill children. *Critical Care*.
2. Spaeder, M., Moorman, J., Tran, C., et al. (2019). Predictive analytics in the pediatric intensive care unit for early identification of sepsis. *Pediatric Research*.
3. Duckworth, C., Guy, M., Kumaran, A., et al. (2022). Explainable machine learning for real-time hypoglycemia and hyperglycemia prediction and personalized control recommendations. *Journal of Diabetes Science and Technology*.

4. Leigh, R. M., Pham, A. B., Rao, S. S., et al. (2022). Machine learning for prediction of bronchopulmonary dysplasia-free survival among very preterm infants. *BMC Pediatrics*.
5. Holt, D. B., El-Bokl, A., Stromberg, D., & Taylor, M. D. (2025). Role of artificial intelligence in congenital heart disease and interventions. *Journal of the Society for Cardiovascular Angiography & Interventions*.
6. Papaioannou, D., Christou, I. T., Anagnou, N., & Chatziioannou, A. (2024). Deep learning algorithms for early diagnosis of acute lymphoblastic leukemia.
7. Bose, S. N., Greenstein, J., Fackler, J., et al. (2021). Early prediction of multiple organ dysfunction in the pediatric intensive care unit. *Frontiers in Pediatrics*.

Enfeksiyöz ajanların tanısında yapay zeka ile mikroorganizma tanımlama: güncel yaklaşımlar üzerine bir derleme

Safiye Bilge GÜÇLÜ KAYTA [1], Doktor Öğretim Üyesi, Bandırma Onyedi Eylül Üniversitesi, skayta@bandirma.edu.tr

Zeynep Betül EREN [2], Tıp Fakültesi Öğrencisi, Bandırma Onyedi Eylül Üniversitesi, zeynepbetulerenn@gmail.com

Özet

Enfeksiyon hastalıklarında etken mikroorganizmanın doğru ve hızlı biçimde tanımlanması, uygun tedavinin zamanında başlanması ve hasta yönetiminin etkin şekilde planlanması açısından temel öneme sahiptir. Geleneksel mikrobiyolojik yöntemler klinik uygulamada halen vazgeçilmez olmakla birlikte, kültür süresinin uzunluğu, uzman yorumuna bağımlılık ve bazı patojenlerde sınırlı duyarlılık gibi nedenlerle yeni teknolojilere ihtiyaç duyulmaktadır. Son yıllarda yapay zeka temelli yaklaşımlar, klinik mikrobiyoloji laboratuvarında giderek daha fazla ilgi çekmektedir. Özellikle makine öğrenmesi ve derin öğrenme yöntemleri; dijital mikroskopi görüntülerinin analizi, Gram boyama preparatlarının yorumlanması, koloni morfolojisinin değerlendirilmesi, MALDI-TOF kütle spektrometrisi verilerinin işlenmesi ve metagenomik dizileme sonuçlarının yorumlanması gibi alanlarda kullanılmaktadır. Bu yöntemler, tanı süresini kısaltma, gözlemci bağımlılığını azaltma, yüksek hacimli verilerin daha standart biçimde değerlendirilmesini sağlama ve klinik karar sürecine destek olma potansiyeli taşımaktadır. Bununla birlikte veri seti farklılıkları, genellenebilirlik sorunu, algoritmaların açıklanabilirliği, etik ve düzenleyici engeller gibi çeşitli sınırlılıklar da mevcuttur. Bu derlemede, enfeksiyöz ajanların tanısında yapay zeka destekli mikroorganizma tanımlama yöntemleri güncel literatür ışığında ele alınmış; başlıca kullanım alanları, güçlü yönleri, sınırlılıkları ve gelecekteki olası katkıları değerlendirilmiştir. Mevcut veriler, yapay zekanın klinik mikrobiyoloji uzmanının yerini alan bağımsız bir sistemden çok, laboratuvar süreçlerini hızlandıran ve standartlaştıran yardımcı bir karar destek aracı olarak değerlendirilmesi gerektiğini düşündürmektedir.

Anahtar kelimeler: yapay zeka, klinik mikrobiyoloji, mikroorganizma tanımlama, derin öğrenme

Giriş

Enfeksiyöz hastalıkların yönetiminde en önemli basamaklardan biri etken mikroorganizmanın hızlı ve doğru biçimde tanımlanmasıdır. Bu tanımlama yalnızca tanı koydurmakla kalmaz; ampirik tedavinin hedefe yönelik tedaviye dönüştürülmesini, izolasyon önlemlerinin düzenlenmesini, antimikrobiyal direnç riskinin değerlendirilmesini ve bazı durumlarda salgın kontrolünü de doğrudan etkiler. Klasik mikrobiyolojik yöntemler arasında mikroskobik inceleme, kültür, biyokimyasal testler, serolojik yöntemler ve moleküler tanı testleri yer almakla birlikte bu yöntemlerin bazı kısıtlılıkları mevcuttur. Moleküler testler hızlı sonuç verse de her ajan için uygulanabilir olmamaları, maliyet ve teknik altyapı gereksinimi gibi nedenlerle her merkezde erişimi mümkün olmamaktadır. Kültür yöntemiyle tanı canlı etken gerektirmesi ve saatler-günler süren inkübasyon süreçleri nedeniyle zaman kaybına yol açabilir, ayrıca bazı durumlarda etken üretilemeyebilir. Mikroskobik inceleme ise deneyimli göz gerektirir ve gözlemciye bağlı değişkenlik gösterebilir (Benoit et al., 2024). Özellikle sepsis, menenjit, endokardit ve nozokomiyal enfeksiyonlar gibi ciddi tablolarda, tanıdaki gecikme hasta prognozunu olumsuz etkilemekte ve mortalitede artışa neden olabilmektedir (Komorowski et al., 2018; Prescott et al., 2026; Singer et al., 2016) .

Yapay zeka (YZ) kullanımının artmasıyla enfeksiyöz ajanların laboratuvar tanısında da kullanım alanı geliştirilmiştir. YZ, büyük hacimli verilerde insan gözüyle zor fark edilen ayrıntıları saptayabilmekte ve sınıflandırma, tahmin gibi görevlerde kullanılabilmektedir. Ayrıca kişi ve laboratuvar kaynaklı yorum farklılıklarını azaltarak daha standart ve objektif bir sonuç sunmaktadır. Klinik mikrobiyolojide bu yaklaşım özellikle görüntü temelli tanı, spektral veri analizi ve genomik/metagenomik veri yorumlama alanlarında ön plana çıkmaktadır (Burns et al., 2023; Dien Bard et al., 2025). Bununla birlikte bu sistemlerin güvenilirliği, farklı popülasyonlara uygulanabilirliği ve gerçek yaşam koşullarındaki başarısı halen araştırılmakta ve tartışılmaktadır.

Bu derlemenin amacı, enfeksiyöz ajanların tanısında YZ ile mikroorganizma tanımlama konusundaki güncel yaklaşımları gözden geçirmek; mevcut kullanım alanlarını, sağladığı avantajları, karşılaşılan temel sorunları ve klinik uygulamadaki olası geleceğini değerlendirmektir.

Derleme

1. Yapay zeka ve klinik mikrobiyolojide temel kavramlar

Yapay zeka, bilgisayar sistemlerinin insan zekâsını taklit eden görevleri yerine getirebilmesini sağlayan yöntemlerin genel adıdır. YZ uygulamaları içerisinde makine öğrenmesi ve derin öğrenme yöntemleri, klinik mikrobiyoloji alanında en sık kullanılan yaklaşımlar arasında yer almaktadır. Makine öğrenmesi, sistemin belirli veriler üzerinden örüntüleri öğrenmesine ve yeni verileri sınıflandırmasına olanak sağlar. Derin öğrenme ise çok katmanlı yapay sinir ağları aracılığıyla daha karmaşık veri yapılarını, özellikle görüntü ve yüksek boyutlu sinyal verilerini analiz edebilir (Dien Bard et al., 2025).

Klinik mikrobiyoloji laboratuvarında üretilen veriler oldukça çeşitlidir. Direk mikroskopi görüntüleri, kültür plak fotoğrafları, MALDI-TOF kütle spektrometrisi çıktıları, PCR amplifikasyon eğrileri bunlar arasında sayılabilir. Bu veri tiplerinin büyük bir kısmı, insan uzman tarafından yorumlandığında zaman ve deneyim gerektirir. YZ ise bu verileri belli kural dahilinde tanıyarak sınıflama yapabilir, şüpheli örnekleri öne çıkarabilir ve tanı sürecini hızlandırabilir.

Bununla birlikte YZ modellerinin etkinliği büyük ölçüde kullanılan eğitim verisinin kalitesine bağlıdır. Hatalı etiketlenmiş veri, dengesiz örnek dağılımı veya az sayıda ve belli merkezlerden toplanmış sınırlı veri kümeleri, model performansını olumsuz etkileyebilir. Bu nedenle klinik mikrobiyolojide YZ kullanımının iyi planlanmış veri yönetimi, kalite kontrol ve klinik doğrulama gerektiren bir süreç olduğu unutulmamalıdır.

2. Dijital mikroskopi ve görüntü analizi ile mikroorganizma tanımlama

Klinik mikrobiyoloji laboratuvarında mikroskobik inceleme, birçok enfeksiyon etkeninin ilk değerlendirilmesinde önemli bir basamaktır. Özellikle sepsis, bakteremi, endokardit, menenjit gibi ciddi enfeksiyonlarda ampirik tedavi seçiminin erken belirlenmesinde Gram boyama yönlendirici olmaktadır. Gram boyama, aside dirençli boyama, mantar elemanlarının gösterilmesi ve parazitlerin mikroskobik tanısı, günümüzde rutin uygulamada sıkça kullanılmaktadır. Ancak bu değerlendirmeler, örnek kalitesi ve gözlemci deneyimine bağlı olarak değişkenlik gösterebilir.

Derin öğrenme tabanlı görüntü analiz sistemleri, mikroskopik incelemede elde edilen görüntüler üzerinden mikroorganizma tanımlamasına katkıda bulunabilir. Özellikle Gram boyalı preparatlarda kok, basil, maya gibi görüntü ayrımında YZ modellerinin oldukça işlevsel olduğu görülmüştür. Smith ve arkadaşlarının geliştirdiği otomatik görüntü elde etme ve evrimsel sinir ağı (CNN) tabanlı yaklaşımda; kan kültürlerinden elde edilen on

binlerce görüntü kullanılarak, Gram preparatlarında mikroorganizma paternlerinin otomatik sınıflandırılması için yüksek duyarlılık ve özgüllükte uygulanabilirliği gösterilmiştir (Smith et al., 2018).

Son yıllarda görüntü tabanlı YZ uygulamaları yalnızca klasik boyalı preparatların değerlendirilmesi ile sınırlı kalmamış, aynı zamanda boyasız (label-free) mikroskopik görüntüler üzerinden mikroorganizma sınıflandırmasına da yönelmiştir. Hallström ve ark. çalışmasında, herhangi bir kimyasal boyama uygulanmaksızın elde edilen faz-kontrast görüntülerden bakteriyel tür sınıflandırmasının mümkün olabildiği gösterilmiştir (Hallström et al., 2023; Işıl et al., 2025). Bu yaklaşım, örnek hazırlık süresini azaltması ve boyama işlemlerine bağlı değişkenliği sınırlaması açısından dikkat çekicidir. Bu yöntemlerin yaygın kullanımı ile laboratuvardaki ön inceleme sürecinin kısaltılabileceği, iş yükü ve zamandan kazanç sağlanabileceği belirtilmiştir. YZ sistemlerinin mikroskopide kullanımı, sıtma gibi paraziter hastalıkların tanısında da katkı sağlayabilir. Sıtma tanısı periferik yayma preparatlarının deneyimli uzman tarafından değerlendirilerek eritrosit içinde parazitin gösterilmesine dayanmaktadır. YZ sistemlerin periferik yayma preparatlarında hem tarama hem de parazitin varlığında tür tayininde etkili olabileceği gösterilmiştir (Martín-Ramírez et al., 2026; Nagendra et al., 2025).

Geleneksel mikroskobik değerlendirmede laboratuvar uzmanı preparatın farklı alanlarını manuel olarak tarayarak mikroorganizma varlığını araştırır. YZ ile geliştirilen whole slide analiz yaklaşımında ise tek tek seçilmiş görüntü alanları yerine, preparatın tamamına ait geniş dijital görüntü verisi işlenebilmektedir. Bu yöntem, mikroorganizmanın yoğun bulunduğu alanların otomatik biçimde saptanmasına, tanısal açıdan anlamlı bölgelerin önceliklendirilmesine ve gözden kaçabilecek odakların belirlenmesine katkı sağlar. Bu yaklaşım yalnızca sınırlı görüntü kesitlerinin değil, tüm preparatın değerlendirilmesini hedeflediğinden, yapay zeka destekli mikroskopinin klinik güvenilirliğini artırabilecek önemli bir adımdır(McMahon et al., 2025).

Bununla birlikte görüntü tabanlı sistemlerde temel sorunlar bulunmaktadır. Boyama kalitesindeki değişiklikler, preparat artefaktları, ışık farklılıkları, kamera çözünürlüğü ve görüntü standardizasyonundaki yetersizlikler model performansını etkileyebilir. Ayrıca gerçek laboratuvar örneklerinde karışık enfeksiyonlar, debris, hücresel artıklar ve nadir etkenler gibi unsurlar, kontrollü çalışma koşullarına göre daha karmaşık bir tablo oluşturur. Bu nedenle dijital mikroskopi temelli YZ uygulamaları klinik kullanım öncesinde mutlaka çok merkezli ve gerçek yaşam verileriyle doğrulanmalıdır.

Bununla birlikte görüntü tabanlı sistemlerde temel sorunlar bulunmaktadır. Boyama kalitesindeki değişiklikler, preparat artefaktları, ışık farklılıkları, kamera çözünürlüğü ve görüntü standardizasyonundaki yetersizlikler model performansını etkileyebilir. Ayrıca gerçek laboratuvar örneklerinde çoklu etkenler, hücresel artıklar ve nadir etkenler gibi unsurlar daha karmaşık bir tablo oluşturur. Bu nedenle dijital mikroskopi temelli YZ uygulamaları geliştirilmeli ve klinik kullanım öncesinde mutlaka çok merkezli ve gerçek yaşam verileriyle doğrulanmalıdır.

3. Koloni morfolojisinin ve kültür plaklarının değerlendirilmesi

Kültür, enfeksiyon etkenlerinin birçoğunun tanısında altın standart yöntemdir. Kültür plaklarında üreyen kolonilerin büyüklüğü, şekli, rengi, hemoliz durumu ve besiyerindeki yayılımı, mikroorganizmanın ön tanısında önemli ipuçları sağlar. Ancak bu değerlendirme, deneyim gerektiren ve gözlemciye bağlı değişkenlik gösterebilen bir süreçtir.

Son yıllarda kültür plaklarının dijital olarak görüntülenmesi ve bu görüntülerin YZ ile değerlendirilmesi üzerine önemli çalışmalar yapılmıştır. YZ destekli görüntü analiz

sistemleri, negatif plakların hızlı elenmesi, koloni varlığının saptanması ve belirli morfolojik paternlerin sınıflandırılması gibi görevlerde kullanılabilmektedir. Dijital görüntüleme ile birlikte bu morfolojik veriler YZ tarafından analiz edilebilir hale gelmiştir. Yapılan çalışmalarda, kültür plaklarında steril olan plakların erken tespit edilebileceği gösterilmiştir. Böylece YZ plakların taranmasında kullanılmasıyla üreme olmayan plaklar ön işlemde erken tespit edilebilir, laboratuvar uzmanının zamanını daha karmaşık ve pozitif örneklere ayırması sağlanabilir (Jacot et al., 2024).

Ancak kültür plaklarında görüntü standardizasyonu önemli bir sorundur. Işık düzeyi, inkübasyon süresi, kamera açısı, kullanılan besiyeri ve laboratuvar içi farklılıklar, aynı mikroorganizmanın farklı şekillerde görünmesine neden olabilir. Bu nedenle kültür plaklarının YZ ile değerlendirilmesi, günümüzde kesin tanı koyma yerine ön tarama ve iş akışında verim amacıyla daha gerçekçi bir kullanım alanı sunmaktadır.

4. Maldi-tof verilerinin yapay zeka ile işlenmesi

MALDI-TOF kütle spektrometrisi, son yıllarda klinik mikrobiyolojide miikroorganizma tanımlamasında oldukça büyük bir gelişmedir. Bu yöntemle mikroorganizmalara ait protein yapılar kısa sürede analiz edilerek tür düzeyinde yüksek doğrulukla tespit yapılabilmektedir. Geleneksel MALDI-TOF sistemlerinde elde edilen spektrumlar, cihazın referans veritabanı ile karşılaştırılır. MALDI-TOF MS verilerinin YZ tabanlı yöntemlerle yeniden analiz edilmesi, mevcut laboratuvar altyapısına ek bir yazılımsal değerlendirme katmanı kazandırarak tanısal kapasiteyi artırabilir. Bu sayede yalnızca mikroorganizmaların tür düzeyinde tanımlanması değil, aynı zamanda alt tür ayrımı, epidemiyolojik ilişkilerin ortaya konması ve bazı antimikrobiyal direnç paternlerinin öngörülmesi de mümkün hâle gelebilir (Weis et al., 2020).

5. Genomik ve metagenomik verilerin değerlendirilmesi

Kültür bağımlı olmayan yöntemlerin gelişmesi ile enfeksiyon hastalıklarının tanısında büyük gelişme yaşanmıştır. Metagenomik yeni nesil dizileme, örnekte bulunan bakteri, virüs, mantar ve parazit nükleik asitlerini önceden belirlenmiş bir hedefe gereksinim duyulmaksızın saptayabilme potansiyeline sahiptir. Bu yaklaşımlar örnekte bulunan mikrobiyal genetik materyalin geniş kapsamlı incelenmesine olanak tanımakla birlikte özellikle alışılmadık patojen olasılığı bulunan veya kültürde üremeyen enfeksiyonlarda değerlidir. Benoit ve ark. tarafından yapılan bir çalışmada merkezi sinir sistemi enfeksiyonlarında BOS metagenomik yeni nesil sekanslama testinin geniş örneklemde yüksek özgüllük gösterdiği ve geleneksel bazı yöntemlere göre daha yüksek duyarlılık sağlayabildiği bildirilmiştir (Benoit et al., 2024). Genomik verilerin YZ ile işlenmesi yalnızca etken tanımlamayı değil, direnç genlerinin varlığı ve olası virülans özelliklerinin öngörülmesini de mümkün kılabilir (Ahmad et al., 2023; Hu et al., 2023; Street et al., 2022).

Bununla birlikte bu alandaki en büyük sorunlardan biri, tespit edilen nükleik asidin her zaman aktif enfeksiyon anlamına gelmemesidir. Kolonizasyon, kontaminasyon veya çevresel DNA varlığı yanlış klinik yorumlara yol açabilir. Ayrıca dizileme maliyeti, veri depolama ihtiyacı, teknik uzman gereksinimi ve analiz standardizasyonundaki eksiklikler, bu teknolojilerin yaygın kullanımını sınırlandırmaktadır.

6. Yapay zekanın sağladığı avantajlar

Yapay zeka tabanlı sistemlerin en önemli avantajı hız ve standardizasyondur. Görsel yorum gerektiren işlemlerde kişiler arası farklılıklar bulunabilir. İnsan gözünde yorgunluğa bağlı performans değişebilirken, algoritma aynı veri yapısına tutarlı şekilde yaklaşabilir. Mikroskopi görüntülerinin, kültür plaklarının veya spektral verilerin kısa sürede ön

değerlendirilmesi, laboratuvarın toplam çalışma süresini azaltabilir. Özellikle acil klinik karar gereken durumlarda bu kazanım önemlidir. Diğer bir avantaj ise büyük veri kümelerinin işlenebilmesidir. İnsan uzman için zaman alıcı olan binlerce görüntü veya spektrum, algoritmalar tarafından daha kısa sürede değerlendirilebilir. Bu özellik, yüksek hacimli laboratuvarlarda iş gücü planlamasına katkı sağlayabilir (Dien Bard et al., 2025; Jacot et al., 2024).

7. Sınırlılıklar, etik sorunlar ve klinik uygulamadaki güçlükler

Yapay zeka uygulamalarının klinik mikrobiyolojide yaygın kullanıma girmesi önünde önemli engeller bulunmaktadır. Bunların başında veri seti yanlılığı gelir. Modelin eğitildiği veri, gerçek hasta popülasyonunu yeterince temsil etmiyorsa sistem farklı ortamlarda başarısız olabilir. Örneğin tek merkezde, belirli bir cihazla ve belirli sayıda örnek üzerinden geliştirilen bir model başka merkezde aynı doğruluğu göstermeyebilir (Sounderajah et al., 2025).

Etik açıdan veri gizliliği, algoritmik önyargı ve hata durumunda sorumluluğun kime ait olacağı da önemli tartışma başlıklarıdır. YZ yanlış sınıflama yaptığında bunun klinik sonuçları ciddi olabilir. Bu nedenle bu tür sistemlerin doğrudan klinik karar verici olarak değil, uzman denetiminde yardımcı araç olarak kullanılması daha güvenli görünmektedir.

Klinik uygulamadaki bir başka güçlük de maliyet ve altyapı gereksinimidir. Dijital görüntüleme sistemleri, veri depolama altyapısı, yazılım entegrasyonu ve teknik destek gereksinimi, özellikle kaynakları sınırlı merkezlerde yaygın kullanımın önünde engel oluşturabilir (Han et al., 2024).

Sonuç

Enfeksiyöz ajanların tanısında YZ ile mikroorganizma tanımlama, klinik mikrobiyoloji alanında hızlı gelişen ve gelecek vadeden bir çalışma alanıdır. Özellikle dijital mikroskopi, Gram boyama değerlendirmesi, kültür plak analizi, MALDI-TOF verilerinin yorumlanması ve metagenomik dizileme gibi alanlarda YZ destekli sistemlerin tanısal sürece önemli katkılar sunabileceği görülmektedir. Bu sistemler, tanı süresini azaltma, iş yükünü hafifletme, standartizasyon sağlama ve uzman değerlendirmesine destek olma açısından değer taşımaktadır.

Bununla birlikte mevcut veriler, yapay zekanın tek başına kesin tanı koyan bağımsız bir yöntem olarak değerlendirilmemesi gerektiğini göstermektedir. Veri kalitesi, genellenebilirlik, açıklanabilirlik, etik sorunlar ve klinik doğrulama eksiklikleri, bu teknolojilerin halen dikkatli yaklaşılması gereken araçlar olduğunu ortaya koymaktadır. Bu nedenle en uygun yaklaşım, yapay zekayı klinik mikrobiyoloji uzmanının yerini alan değil; onun karar sürecini destekleyen, laboratuvarın hızını ve verimliliğini artıran yardımcı bir sistem olarak konumlandırmaktır.

Gelecekte daha büyük, çok merkezli ve standardize çalışmalarla desteklenen YZ uygulamaları, enfeksiyon tanısında daha güçlü bir yer edinebilir. Ancak klinik yarar ancak teknoloji ile uzman yorumunun dengeli biçimde birleştirilmesiyle sağlanabilir.

Kaynakça

Ahmad, A., Hettiarachchi, R., Khezri, A., Singh Ahluwalia, B., Wadduwage, D. N., & Ahmad, R. (2023). Highly sensitive quantitative phase microscopy and deep learning aided with whole genome sequencing for rapid detection of infection and antimicrobial resistance. *Frontiers in Microbiology*, *14*, 1154620. https://doi.org/10.3389/fmicb.2023.1154620

Benoit, P., Brazer, N., de Lorenzi-Tognon, M., Kelly, E., Servellita, V., Oseguera, M., Nguyen, J., Tang, J., Omura, C., Streithorst, J., Hillberg, M., Ingebrigtsen, D., Zorn, K., Wilson, M. R., Blicharz, T., Wong, A. P., O'Donovan, B., Murray, B., Miller, S., & Chiu, C. Y. (2024). Seven-year performance of a clinical metagenomic next-generation sequencing test for diagnosis of central nervous system infections. *Nature Medicine*, *30*(12), 3522–3533. https://doi.org/10.1038/s41591-024-03275-1

Burns, B. L., Rhoads, D. D., & Misra, A. (2023). The Use of Machine Learning for Image Analysis Artificial Intelligence in Clinical Microbiology. *Journal of Clinical Microbiology*, *61*(9), e0233621. https://doi.org/10.1128/jcm.02336-21

Dien Bard, J., Prinzi, A. M., Larkin, P. M. K., Peaper, D. R., & Rhoads, D. D. (2025). Proceedings of the Clinical Microbiology Open 2024: artificial intelligence applications in clinical microbiology. In *Journal of clinical microbiology* (Vol. 63, Issue 4, p. e0180424). https://doi.org/10.1128/jcm.01804-24

Hallström, E., Kandavalli, V., Ranefall, P., Elf, J., & Wählby, C. (2023). Label-free deep learning-based species classification of bacteria imaged by phase-contrast microscopy. *PLoS Computational Biology*, *19*(11), e1011181. https://doi.org/10.1371/journal.pcbi.1011181

Han, R., Acosta, J. N., Shakeri, Z., Ioannidis, J. P. A., Topol, E. J., & Rajpurkar, P. (2024). Randomised controlled trials evaluating artificial intelligence in clinical practice: a scoping review. *The Lancet. Digital Health*, *6*(5), e367–e373. https://doi.org/10.1016/S2589-7500(24)00047-5

Hu, X., Zhao, Y., Han, P., Liu, S., Liu, W., Mai, C., Deng, Q., Ren, J., Luo, J., Chen, F., Jia, X., Zhang, J., Rao, G., & Gu, B. (2023). Novel Clinical mNGS-Based Machine Learning Model for Rapid Antimicrobial Susceptibility Testing of Acinetobacter baumannii. *Journal of Clinical Microbiology*, *61*(5), e0180522. https://doi.org/10.1128/jcm.01805-22

Işıl, Ç., Koydemir, H. C., Eryilmaz, M., de Haan, K., Pillar, N., Mentesoglu, K., Unal, A. F., Rivenson, Y., Chandrasekaran, S., Garner, O. B., & Ozcan, A. (2025). Virtual Gram staining of label-free bacteria using dark-field microscopy and deep learning. *Science Advances*, *11*(2), eads2757. https://doi.org/10.1126/sciadv.ads2757

Jacot, D., Gizha, S., Orny, C., Fernandes, M., Tricoli, C., Marcelpoil, R., Prod'hom, G., Volle, J.-M., Greub, G., & Croxatto, A. (2024). Development and evaluation of an artificial intelligence for bacterial growth monitoring in clinical bacteriology. *Journal of Clinical Microbiology*, *62*(5), e0165123. https://doi.org/10.1128/jcm.01651-23

Komorowski, M., Celi, L. A., Badawi, O., Gordon, A. C., & Faisal, A. A. (2018). The Artificial Intelligence Clinician learns optimal treatment strategies for sepsis in intensive care. *Nature Medicine*, *24*(11), 1716–1720. https://doi.org/10.1038/s41591-018-0213-5

Martín-Ramírez, A., Lanza-Suárez, M., Berzosa Díaz, P., Benito, A., Antón-Berenguer, V., & Rubio, J. M. (2026). Automated microscopy for malaria diagnosis in a reference laboratory in nonendemic settings. *Parasites & Vectors*, *19*(1), 67. https://doi.org/10.1186/s13071-025-07215-x

McMahon, J., Tomita, N., Tatishev, E. S., Workman, A. A., Costales, C. R., Banaei, N., Martin, I. W., & Hassanpour, S. (2025). A novel framework for the automated characterization of Gram-stained blood culture slides using a large-scale vision transformer. *Journal of Clinical Microbiology*, *63*(3), e0151424.

https://doi.org/10.1128/jcm.01514-24

Nagendra, S., Hayes, R., Bae, D., & Dodge, K. (2025). Diagnosis of Plasmodium infections using artificial intelligence techniques versus standard microscopy in a reference laboratory. *Journal of Clinical Microbiology*, *63*(1), e0077524. https://doi.org/10.1128/jcm.00775-24

Prescott, H. C., Antonelli, M., Alhazzani, W., Møller, M. H., Alshamsi, F., Azevedo, L. C. P., Belley-Cote, E., De Waele, J., Derde, L., Dionne, J. C., Evans, L., Gershengorn, H. B., Hodgson, C. L., Honarmand, K., Kesecioglu, J., McIntyre, L., Mer, M., Nunnally, M. E., Oczkowski, S. J. W., … Coopersmith, C. M. (2026). Surviving Sepsis Campaign: International Guidelines for Management of Sepsis and Septic Shock 2026. *Critical Care Medicine*. https://doi.org/10.1097/CCM.0000000000007075

Singer, M., Deutschman, C. S., Seymour, C. W., Shankar-Hari, M., Annane, D., Bauer, M., Bellomo, R., Bernard, G. R., Chiche, J.-D., Coopersmith, C. M., Hotchkiss, R. S., Levy, M. M., Marshall, J. C., Martin, G. S., Opal, S. M., Rubenfeld, G. D., van der Poll, T., Vincent, J.-L., & Angus, D. C. (2016). The Third International Consensus Definitions for Sepsis and Septic Shock (Sepsis-3). *JAMA*, *315*(8), 801–810. https://doi.org/10.1001/jama.2016.0287

Smith, K. P., Kang, A. D., & Kirby, J. E. (2018). Automated Interpretation of Blood Culture Gram Stains by Use of a Deep Convolutional Neural Network. *Journal of Clinical Microbiology*, *56*(3). https://doi.org/10.1128/JCM.01521-17

Sounderajah, V., Guni, A., Liu, X., Collins, G. S., Karthikesalingam, A., Markar, S. R., Golub, R. M., Denniston, A. K., Shetty, S., Moher, D., Bossuyt, P. M., Darzi, A., & Ashrafian, H. (2025). The STARD-AI reporting guideline for diagnostic accuracy studies using artificial intelligence. *Nature Medicine*, *31*(10), 3283–3289. https://doi.org/10.1038/s41591-025-03953-8

Street, T. L., Sanderson, N. D., Kolenda, C., Kavanagh, J., Pickford, H., Hoosdally, S., Cregan, J., Taunt, C., Jones, E., Oakley, S., Atkins, B. L., Dudareva, M., McNally, M. A., O'Grady, J., Crook, D. W., & Eyre, D. W. (2022). Clinical Metagenomic Sequencing for Species Identification and Antimicrobial Resistance Prediction in Orthopedic Device Infection. *Journal of Clinical Microbiology*, *60*(4), e0215621. https://doi.org/10.1128/jcm.02156-21

Weis, C. V, Jutzeler, C. R., & Borgwardt, K. (2020). Machine learning for microbial identification and antimicrobial susceptibility testing on MALDI-TOF mass spectra: a systematic review. *Clinical Microbiology and Infection : The Official Publication of the European Society of Clinical Microbiology and Infectious Diseases*, *26*(10), 1310–1317. https://doi.org/10.1016/j.cmi.2020.03.014

Cerrahiye karar: Yapay zeka ile hasta seçimi ve risk tahmini

Tuğrul Melik KUŞ, Stj. Dr., Bandırma 17 Eylül Üniversitesi Tıp Fakültesi, tugrulmelik@gmail.com

Özet

Dünya genelinde yılda yaklaşık 310 milyon cerrahi prosedür gerçekleştirilmekte ve bu operasyonların ardından %4,2 oranında majör komplikasyon insidansı gözlenmektedir (Weiser ve ark., 2015). Bu komplikasyonlar, yalnızca önlenebilir olanları bakımından değerlendirildiğinde dahi önemli ekonomik yükler oluşturmaktadır (Ludbrook, 2022). Geleneksel klinik değerlendirme yöntemleri, öznel yargılar ve sınırlı veri işleme kapasitesi nedeniyle yetersiz kalabilmektedir. Bu derleme, yapay zeka (YZ) modellerinin preoperatif hasta seçimi ve risk tahminindeki performansını literatür verileri ışığında incelemektedir. Bulgular, makine öğrenimi modellerinin geleneksel ACS-NSQIP hesaplayıcılarına kıyasla (AUC: 0,90 vs. 0,83) daha yüksek doğruluk sağladığını göstermektedir (Bihorac ve ark., 2019). Açıklanabilir Yapay Zeka (XAI) araçlarının klinik karar destek süreçlerine entegrasyonu, cerrah güveni ve paylaşımlı karar verme açısından kritik önem taşımaktadır (Brandenburg ve ark., 2025).

Anahtar Kelimeler: Yapay zeka, cerrahi risk tahmini, makine öğrenimi, hasta seçimi, açıklanabilir yapay zeka.

1. Giriş

Cerrahi karar verme süreci, hastanın preoperatif durumunun doğru analiz edilmesi ve olası risklerin öngörülmesine dayanır. Günümüzde dünya genelinde yapılan yıllık 310 milyon cerrahi prosedürün önemli bir kısmı majör komplikasyonlarla sonuçlanmakta; bu durum hem hasta güvenliği hem de sağlık sistemi maliyetleri açısından ciddi sorunlar doğurmaktadır (Weiser ve ark., 2015). Postoperatif komplikasyonların ekonomik yükü giderek büyümekte olup bu durum cerrahi bakımın sürdürülebilirliğini tehdit etmektedir (Ludbrook, 2022). Geleneksel yöntemler, hekimin deneyimine ve sınırlı sayıda değişkene dayanan statik risk skorlama sistemlerini kullanmaktadır. Oysa yapay zeka modelleri, büyük veri kümelerinden örüntü öğrenerek her hasta için bireyselleştirilmiş ve gerçek zamanlı karar desteği sunma kapasitesine sahiptir (Bihorac ve ark., 2019).

Bu derleme; yapay zeka destekli hasta seçimi ve risk tahmininin klinik kanıt tabanını, açıklanabilirlik boyutunu, etik ve hukuki sınırlılıklarını ile Türkiye bağlamındaki uygulama olanaklarını sistematik biçimde ele almayı amaçlamaktadır.

2. Geleneksel Yöntemler ve Sınırlamaları

Klinik pratikte yaygın olarak kullanılan ASA Fiziksel Durum Skoru, ACS-NSQIP Kalkulatörü ve POSSUM gibi sistemler genellikle lojistik regresyon temellidir. Geniş hasta popülasyonlarından elde edilen verilerle geliştirilmiş olsalar da bu araçların temel kısıtları şunlardır:

- Değişken sayısının 20-30 faktörle sınırlı olması.
- Sabit eşik değerleri kullanmaları ve kişiselleştirilmemiş olmaları.
- Klinisyen bağımlı hatalı veri girişi riskine açık olmaları.
- Yeni verilerle kendilerini güncelleyemeyen statik yapıda olmaları.

Bu sınırlılıklar, özellikle multimorbid ve kompleks hastalarda yetersiz risk öngörüsüne yol açarak hem aşırı hem de yetersiz müdahale riskini artırmaktadır (Graeßner ve ark., 2023).

3. Yapay Zeka Modelleri ve Klinik Performans

Makine öğrenimi (ML), derin öğrenme (DL) ve büyük dil modelleri (LLM), cerrahi risk tahmininde yeni bir dönem başlatmıştır. Yüzlerce değişkeni eş zamanlı işleyebilen bu modeller, statik değil sürekli öğrenen bir yapıdadır (Graeßner ve ark., 2023). Başlıca klinik bulgular şöyle özetlenebilir:

• MySurgeryRisk Platformu: 51.457 hasta üzerinde yürütülen çalışmada, 8 farklı komplikasyon tipi için AUC 0,77-0,94 arasında değerler elde edilmiştir (Bihorac ve ark., 2019).

• Karşılaştırmalı Analiz: YZ modelleri majör komplikasyon tahmininde AUC 0,90'a ulaşırken geleneksel ACS-NSQIP hesaplayıcıları 0,82-0,83 bandında kalmıştır (Ruiz ve ark., 2025).

• LLM Katkısı: Klinik notları analiz eden büyük dil modelleri, preoperatif tahmin doğruluğunda %38,3 oranında iyileşme sağlamıştır (Hyder ve ark., 2020).

4. Açıklanabilir Yapay Zeka (XAI) ve Karar Akışı

YZ modellerinin "kara kutu" olarak nitelendirilmesi cerrahlar arasında güven sorunu yaratmaktadır. XAI araçları, modelin hangi değişkenleri ön plana çıkardığını görselleştirerek kararı insan diline çevirmektedir (Brandenburg ve ark., 2025). Örneğin, 72 yaşında diyabetik ve böbrek fonksiyonu sınırda olan bir hastada YZ "yüksek risk" uyarısı verdiğinde, XAI bu riskin temel nedenlerini —düşük eGFR ve yetersiz beslenme durumu— cerraha ayrıntılı biçimde raporlamaktadır.

Bu şeffaflık; cerrahın operasyon öncesi hastayı optimize etmesine ya da konservatif yönetime yönelmesine olanak tanır. SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-Agnostic Explanations) bu alanda en yaygın kullanılan XAI yöntemleri olup sırasıyla değişken katkılarının nicel analizi ve bireysel örneklem düzeyinde açıklama üretimi için tercih edilmektedir (Lundberg ve ark., 2018).

5. Zorluklar ve Etik Boyutlar

Teknolojik başarıya rağmen klinik entegrasyonun önünde ciddi engeller bulunmaktadır:

• Veri Kalitesi: Farklı hastanelerdeki eksik veya standart dışı veri girişleri model performansını olumsuz etkilemektedir (Ruiz ve ark., 2025).

• Algoritma Önyargısı: Eğitim verilerindeki demografik dengesizlikler, azınlık ve dezavantajlı gruplarda hatalı tahminlere yol açabilmektedir (Graeßner ve ark., 2023).

• Yasal Sorumluluk: Hatalı bir YZ kararı sonucu gelişen komplikasyonlarda sorumluluğun kime ait olduğu hukuki belirsizliğini korumaktadır (Brandenburg ve ark., 2025).

• Türkiye Bağlamı: Modellerin büyük çoğunluğu Batılı hasta verileriyle eğitilmiştir. Türkiye'ye özgü komorbidite örüntüleri ve geç başvuru alışkanlıkları bu modellere yansımamakta; bu durum yerel uygulanabilirliği kısıtlamaktadır.

6. Sonuç ve Öneriler

YZ modelleri, cerrahi risk tahmini ve hasta seçiminde geleneksel yöntemlere göre belirgin üstünlük sergilemektedir. Klinik başarı için XAI tekniklerinin entegrasyonu ve gerçek zamanlı risk güncellemeleri vazgeçilmezdir (Brandenburg ve ark., 2025). Bu doğrultuda üç temel öneri öne çıkmaktadır:

• Çok merkezli prospektif çalışmaların artırılması ve Türkiye hastalarını kapsayan yerel veri setlerinin oluşturulması.

• NHIS altyapısının standardizasyonu yoluyla Türkiye'ye özgü YZ modellerinin geliştirilmesi.

• YZ okuryazarlığının tıp müfredatına dahil edilerek mezuniyet öncesi dönemde temel yetkinlik olarak tanımlanması.

Yapay zeka, cerrahın karar verme sürecini ortadan kaldırmaz; ancak bu süreci veri odaklı, şeffaf ve kişiselleştirilmiş bir zemine taşır.

Kaynakça

Bihorac, A., Ozrazgat-Baslanti, T., Ebadi, A., Motaei, A., Madkour, M., Pardalos, P. M., ... & Rashidi, P. (2019). MySurgeryRisk: Development and validation of a machine-learning risk algorithm for major complications and death after surgery. Annals of Surgery, 269(4), 652–662.

Brandenburg, J. M., Müller-Stich, B. P., & Wagner, M. (2025). Can surgeons trust AI? Perspectives on machine learning in surgery and the importance of eXplainable Artificial Intelligence (XAI). Langenbeck's Archives of Surgery, 410, 53. https://doi.org/10.1007/s00423-025-03626-7

Graeßner, M., Jungwirth, B., Frank, E., Schaller, S. J., Kochs, E., Ulm, K., ... & Kagerbauer, S. M. (2023). Enabling personalized perioperative risk prediction by using a machine-learning model based on preoperative data. Scientific Reports, 13, 7128. https://doi.org/10.1038/s41598-023-33981-8

Hyder, J. A., Wakeam, E., Habermann, E. B., & Ghaferi, A. A. (2020). Utilizing machine learning methods for preoperative prediction of postsurgical mortality and morbidity. Annals of Surgery, 271(4), 614–621.

Ludbrook, G. L. (2022). The hidden pandemic: The cost of postoperative complications. Current Anesthesiology Reports, 12, 1–9. https://doi.org/10.1007/s40140-021-00493-y

Lundberg, S. M., Nair, B., Vavilala, M. S., Horibe, M., & Lee, S. I. (2018). Explainable machine-learning predictions for the prevention of hypoxaemia during surgery. Nature Biomedical Engineering, 2(10), 749–760.

Ruiz, N., Cardona Salazar, I., Naranjo Palacio, L., et al. (2025). Accuracy and reliability of artificial intelligence in surgical decision-making: A literature review. Cureus, 17(10). https://doi.org/10.7759/cureus.77617

Weiser, T. G., Haynes, A. B., Molina, G., Lipsitz, S. R., Esquivel, M. M., Uribe-Leitz, T., ... & Gawande, A. A. (2015). Estimate of the global volume of surgery in 2012: an assessment supporting improved health outcomes. The Lancet, 385(Suppl 2), S11. https://doi.org/10.1016/S0140-6736(15)60806-6

Kadın hastalıklarında yapay zeka: jinekoloji ve obstetrik uygulamaları

Berru Hazal Tunç[1], Yasemin Ercan Değirmenci *[2]

[1] Dönem III Öğrencisi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, email: berrutunc@ogr.bandirma.edu.tr

[2] Dr. Öğr. Üyesi. Bandırma 17 Eylül Üniversitesi Tıp Kadın Hastalıkları ve Doğum Bölümü, email: ydegirmenci@bandirma.edu.tr. https://orcid.org/ 0009-0001-5591-7997

*corresponding author

Özet

Yapay zeka temelli uygulamalar ve cihazlar gündelik hayatta sık kullanılmaya başlamıştır.

Yapay zeka, bilgisayarların büyük veri setlerinden örüntüler çıkararak insan benzeri düşünme, öğrenme ve karar verme süreçlerini taklit etmeye çalışan bir uygulamadır. Digital tıbbi uygulamalar da temel taşıyıcı olmaya başlayan yapay zeka, sağlıkta önemli dönüşümlerin habercisidir. Sağlık alanında erken tanı, tedavi, takip ve bakım aşamalarında önemli roller almaya başlamıştır. Jinekoloji ve obstetrik alanında sık kullanılmaya başlanan yapay zeka teknolojisi ile, gebelikte hastalıkların taranması ve yönetimi, uzaktan gebelik takibi, fetüs gelişimi, elektronik izleme, genetik tarama ve postpartum dönemde kullanılmış ve olumlu sonuçlar alınmıştır. Ancak bu çalışmalar çoğunlukla tek merkezli, küçük ölçekli olmaları sebebiyle entegrasyon sürecinin başlaması, klinisyenlerin sürece adaptasyonu ve uygulamanın yaygınlaşması zorlaşmaktadır. Bu çalışmada yapay zekanın kadın sağlığında geldiği noktalar anlatılmaya çalışılacaktır.

Anahtar kelimeler: Yapay zeka, kadın sağlığı, obstetri, jinekoloji

Giriş

Yapay zekanın son yıllarda sağlık sistemine entegrasyonu klinik karar süreçlerini kolaylaştırmak, hata oranlarını azaltmak ve hasta güvenliğini güçlendirmek amacı taşımaktadır ve giderek daha fazla önem kazanmaktadır (Aftab,2025; Patel et al.,2024). Özellikle kadın hastalıkları ve doğum gibi çok karmaşık ilişkileri içeren alanlarda tanısal doğruluğu arttırmak, süreçleri hızlandırmak, hastalıkların doğasını yeniden keşfetmek ve yeni tedavi seçenekleri oluşturmak ve klinik bakımın kalitesini geliştirmek amacıyla yaygın olarak kullanılmaya başlanmıştır. Yapay zeka, bilgisayarların insan benzeri düşünme, karar verme, öğrenme ve problem çözme becerilerini taklit etmeye çalışmaktadır (Jeong et al,2023). Yapay zeka, minimum insan müdahalesi ile akıllı davranışı modellemek için bir makinenin kullanımını tanımlayan genel bir terimdir (Delanerolle et al.,2021). Yapay zeka kavramı, ilk defa John McCharty tarafından ‘zeki makineler ve zeki bilgisayar programları yapma bilimi ve mühendisliği’ olarak tanımlanmıştır (Demirhan et al.,2010). 1970’ li yıllardan itibaren yapay zekanın sağlık sistemine entegrasyonu başlamış erken tanı ve tedavi, görüntüleme yöntemleri ve tıbbi verilerin saklanması alanlarında önemli gelişmeler yaşanmıştır (Uzun et al,2020). 2020’li yılların ortalarından itibaren, obstetri ve jinekolojide klinik karar süreçlerini ve hasta sonuçlarını iyileştirmek amacıyla yapay zeka entegrasyonlu yapılan çalışmaların sayısında belirgin bir artış gözlenmektedir (Restaino et al.,2025). Yapay zeka uygulamalarının kadın hastalıkları ve doğumda kullanılması 2010 yıllarında başlamıştır. Obstetrik alanda makine öğrenimi kullanılmaya başlanmıştır. Yapay zeka teknolojisi gebelik süreci, fetal gelişim ve doğum komplikasyonları gibi birçok alanda daha güvenilir tahminler yapılabilmesini desteklemektedir (Horgan et al.,2023).

Yapay zeka: temel kavramlar

Yapay zeka, büyük veri setlerinden örüntüler çıkararak insanın düşünme, öğrenme ve karar verme süreçlerini taklit etmek üzere geliştirilmiş sistemlerin genel adı olmakla beraber sağlık alanında köklü bir dönüşüm yaratmaktadır (Patel et al.,2024) Yapay zeka, temel olarak veri bilimi alanına girer ve makine öğrenimini ve klasik programlamayı içerir. Yapay zeka, temelde insanlar tarafından gerçekleştirilen entelektüel görevleri otomatikleştirmeye odaklanan bir alandır, makine öğrenimi ve derin öğrenme bu hedefe ulaşmanın yöntemleridir. Makine öğrenimi, bir veri kümesini en iyi şekilde temsil eden algoritmalar oluşturarak yapay zekanın öğrenme yönüne odaklanmaktadır. Klasik bilgisayar programlarında ise veriler ve algoritma bilgisayara yüklenir ve çıktı elde edilir. Makine öğreniminde ise veri setleri ve çıktılar yapay zekaya yüklenir ve buna uyan algoritma yani işleyiş tespit edilir. Ortaya çıkan algoritma bazı hastalıkların bilinmez işleyiş mekanizmalarına açıklık sağlayabilecektir. Az sayıda değişkene odaklanan geleneksel istatiksel modellerden farklı olarak makine öğrenimi daha büyük veri kümelerinde çok değişkenli karmaşık yapıları daha hızlı bir şekilde analiz yapabilmektedir (Rajula HSR et al.,2020). Makine öğreniminde, her biri farklı görevleri çözmek için yararlı olan dört öğrenme yöntemi vardır. Bunlar denetimli, denetimsiz, yarı denetimli ve pekiştirmeli öğrenme yöntemleridir (James J et al.,2013). Denetimli öğrenme, etiketlenmiş verilerden yararlanarak modelin belirli sonuçları tahmin etmeyi öğrenmesini sağlamaktadır. Preeklampsi, Gestasyonel Diabet veya Preterm doğum gibi obstetrik sonuçları öngörmeye yönelik modeller geliştirmede sıkça kullanılmaktadır. Denetimsiz öğrenme, veriler arasındaki gizli kalıpları ve ilişkileri keşfetmeyi amaçlamaktadır. Geniş ölçekli benzer klinik özelliklere sahip hasta gruplarını ve sonuçlarını değerlendirerek elde ettiği sonuçlarla kişiselleştirilmiş yaklaşımlar geliştirmeye katkı sağlamaktadır (Giaxi et al.,2025). Pekiştirmeli öğrenmede, çevreden alınan geri bildirimlerle modelin sürekli olarak kendini geliştirmesini sağlamaktadır. Jinekolojik cerrahide robotik sistemlerin hareket optimizasyonunu arttırmak, hata oranlarını azaltmak ve operasyon sürelerini kısaltmak için kullanımı yaygınlaşmaya başlamıştır.

Derin öğrenme, makine öğreniminin alt alanıdır ve yapay sinir ağları (artificial neural networks) üzerine kuruludur. Derin ifadesi, ağın çok katmanlı yapısını (girdi ve çıktı katmanları) ifade eder. Yapay sinir ağı (ANN), biyolojik sinir ağlarını taklit eden makine öğrenim algoritmasıdır (Hastie T et al.,2005). Sinir ağlarında girişler, ağırlıklar, eşik ve çıktı vardır. Sinir ağı bir eğitim veri kümesi kullanacak, ardından bu veri kümelerindeki kalıpları tanıyacak ve veri kümesinin çıktısın tahmin etmek için kullanılabilecek algoritmalar formüle edecek. Derin öğrenme, görüntü, ses, sinyal ve zaman serisi gibi karmaşık verilerden anlam çıkarmaya olanak tanımaktadır. Özellikle CNN temelli modeller, MRI, Ultrasonografi ve kardiyotokografi verilerinin analizinde yüksek doğruluk oranları elde etmeye yardımcı olmaktadır (Bashir et al.,2025).

OBSTETRİK ALANINDA YAPAY ZEKA

Obstetrik alanında yapay zeka özellikle yüksek riskli gebeliklerin erken tespitinde bu sayede maternal ve fetal sağlığın korunmasında rol oynamaktadır. Bu uygulamalar maternal-fetal gelişebilecek olumsuz durumların önceden tespit edilebilmesine odaklanmıştır (Shabani et al.,2025). Makine öğrenmesi modelleri özellikle Random Forest, Gradient Boosting ve Multilayer Perceptron gebelik komplikasyonlarını öngörmede başarılı sonuçlar verdiği belirtilmektedir. Anne yaşı, gestasyonel yaş, gebelik sayısı, antenatal bakım sıklığı, vital bulgular ve doğum şekli gibi değişkenleri değerlendirerek riskli gebeliklerin erken tanınması sağlanmaktadır (Sylvain et al.,2025). Bu tür uygulamalar özellikle sağlık çalışanı sayısının az olduğu bölgelerde gebelik komplikasyonlarını erken dönemde saptayarak otomatik uyarı üretmekte ve gerekli yönlendirmeleri yapmaktadır (Patel et al.,2024).

Obstetrik mortalite ve mobiditeye yol açan en önemli hastalıklardan biri olan preeklampsinin erken dönemde tespit edilmesini sağlayan yapay zeka modelleri kullanılabilmektedir. Modeller klinik bulgular, laboratuar sonuçları, vital bulgular ve demografik verilerle erken dönemde riskli hastaların yakalanmasıyla maternal fetal mortalitenin azalmasına katkı sağlayabilmektedir. Bu sayede komplikasyonlar klinik belirtiler ortaya çıkmadan önce öngörülebilmekte ve önleyici müdahalelerin yapılabilmesine olanak tanımaktadır (Feduniw et al.,2022). Son yıllarda yapılan bir çalışmada preeklampsi, doğum sonrası kanama ve erken doğum gibi komplikasyonların tahmininde makine öğrenimi ve sinir ağı tabanlı modellerin yüksek doğrulukta sonuçlar verdiği belirtilmektedir (Dos Santos et al., 2025). Sağlık sistemi veri kayıtlarındaki elde edilen verilerle geliştirilen bu sistemler, serum kreatinin, ürik asit ve PLGF düzeyleri gibi biyokimyasal göstergeleri değerlendirerek risk skorlaması yapmaktadırlar

(Patel et al.,2024). Preeklampside, maternal mortalite ve morbiditeyi tahmin etmede %86 doğrulukla tahmin edilebildiği Vasudeva'nın geliştirdiği yapay zeka modeli ile daha başarılı sonuçlar elde edilmiştir (Vasudevan et al.,2025). Konvolüsyonel sinir ağı (CNN) modelleri ile fetal kalp hızı sinyallerini analiz ederek hipoksiye eğilimli fetüsleri insan algısının farkedemeyeceği düzeyde tespit edilebilmekte olduğu gösterilmiştir. Bu uygulamalar sağlık çalışanlarına doğum öncesi ve doğum sırasında fetal hipoksi erken yakalayabilme olanağı tanır (Lin et al.,2024). Preterm doğum öngörüsünde derin öğrenme algoritmaları önemli sonuçlar vermektedir. Günümüzde geliştirilen mobil uygulamaların, antenatal dönemde kan basıncı, nabız ve glikoz düzeyi gibi ölçümleri analiz ederek riskli gebeliklerin uzaktan izlenmesi mümkündür (Feduniw et al.,2022).

Sensörlerden mobil uygulamaya kayıt, AI risk analizi sonrası, AI'ın hasta uyarısı (düşük,orta,yüksek risk şeklinde) / AI'ın aynı zamanda klinik bildirim yapması gibi işlem algoritması modelleri ile klinik süreçler içinde etkin kullanılabilecek modeller üzerinde çalışılmaktadır.

Doğum şeklinin öngörülmesi birçok faktörü içeren kompleks bir süreç olup, yapay zeka modellerinin bu süreci etkileyen çok sayıda değişkeni aynı anda analiz ederek doğum şeklinin öngörülmesinde klinisyenlere önemli destek sağlamaktadır. Yapılan araştırmalar, makine öğrenmesi algoritmalarının doğum şekli tahmininde geleneksel istatiksel yöntemlerden daha yüksek doğruluk oranlarına ulaştığını göstermektedir. Özellikle XGBoost, Random Forest ve Support Vector Machine gibi algoritmaların, klasik lojistik regresyon modellerine göre daha başarılı sonuçlar verdiği bildirilmiştir (Michalist et al., 2024). Pelvik ölçümler, body mass index, gebelik haftası, fetal pozisyon ve önceki doğum hikayesi gibi çok sayıda değişkeni içeren veriler analiz edilerek öngörülmektedir. Bazı sistemlerde, geri dönütler yoluyla model kendi modellemesini güncelleyerek doğruluk oranlarını arttırabilmektedir. Bu özellik, doğum eyleminin yönetiminde dinamik, güvenilir ve sürekli öğrenen klinik karar destek sistemlerinin geliştirilmesini mümkün kılmaktadır (Schmauder et al.,2025). Fetal sağlık ve gelişim süreçlerinin izlenmesi obstetri pratiğinin en önemli konusudur. Bu süreçlerin takibi CNN temelli derin öğrenme modelleri ile objektif ve hızlı bir şekilde yapılabilmektedir.

JİNEKOLOJİ ALANINDA YAPAY ZEKA

Endometrial patolojilerde yapay zeka

Endometrial patolojiler genellikle anormal uterin kanama ve infertilite nedeniyle başvuran hastalarda gözlenir. Endometriyal patolojilerin tanısı klinik değerlendirme, görüntüleme yöntemleri ve histopatolojik örnekleme yöntemiyle konulabilir. Son dönemde yapay zeka destekli sistemler, özellikle görüntünün değerlendirilmesi ile dijital patolojide tanısal doğruluğu arttırmaktadır. Postmenapozal dönemde vajinal kanama ile kendisini erken

evrede gösteren endometrial kanser, gelişmiş ülkelerde en sık görülen jinekolojik malignite olarak yaygınlığı artmaktadır (Crosbie et al., 2022). Endometriyal sitolojinin yanlış negatif sonuç oranlarının yüksekliği düşünüldüğünde, maliyet-etkinlik açısından yapay zeka algoritmalarının endometrial kanserin tanısı için histereskopi ve histopatolojik görüntülerin değerlendirilmesinde MRG tabanlı görüntüleme araçlarından daha etkin ve daha az maliyetli olmaktadır. Renk- doku incelemesi temelli histereskopi görüntülerinin, olasılıksal sinir ağı (PNN) ve SVM modeli uygulamalarla %79 yüzde ile normal ve anormal endometrial doku ayrımı yapabilmektedirler (Neofytou et al.,2006). Endometrial kanser tanısı, histereskopi sırasında elde edilen histopatolojik materyalin değerlendirilmesinden sonra netlik kazanır. Yapay zekanın buradaki gözlemciler arasındaki değişkenlik sorununu azaltacağı düşünülmektedir. Sun ve ark. histopatolojik endometrial görüntülerin taranması için CNN ve dikkate dayalı CAD yaklaşımı geliştirerek, modelleri ise normal endometrium, endometriyal polip, endometrial hiperplazi ve endometrial adenokarsinom olmak üzere dört endometrial doku sınıfı arasında ayrım yapmak üzere tasarladılar (Sun et al.,2020). Bu çalışmayla çapraz doğrulama seti %76,9 doğruluk göstermiş, 200 hemotoksilen eozin görüntüsünden oluşan doğrulama seti %84,5 doğruluk elde etmiştir. Bu modelin endometriyal dokunun morfolojik özellikleriyle histopatolojilerinin korele olması patologlara tanı koymada yardımcı olabilecektir. Li ve ark. Tarafından yapılan bir başka çalışmada yapay zeka entegre MRG ile myometrial invazyon prognoz belirlemede yapay zeka entegre modellerin daha başarılı olduğunu gözlemlemişlerdir (X. Li et al.,2023).

Servikal patolojilerde yapay zeka

Servikal patolojiler, kadınlarda ciddi morbidite ve mortaliteye neden olabilen benign enflamatuar hastalıklar, premalign lezyonlar, ve invaziv servikal kansere kadar geniş bir spektrumdaki tüm hastalıkları kapsar. Özellikle Servikal intraepitelyal neoplazi (CIN) ve adenokarsinoma in situ (AIS) gibi premalign lezyonların erken ve doğru tespiti için bu lezyonların invaziv servikal kansere ilerlemesini önlemek için kritik öneme sahiptir (Hristamyan et al.,2025). Serviks kanseri, dünya çapında kadınları etkileyen en yaygın kanserlerden biri olmakla beraber özellikle düşük ve orta gelirli ülkelerde önemli bir halk sağlığı problemidir (Özbilgeç et al.,2025). Günümüzde servikal lezyonları servikal sitoloji (pap smear), servikal HPV testi ve kolposkopi yöntemleri ile değerlendirmekteyiz (Whitlock et al.,2011). Yüksek riskli HPV tiplerinin tarama testi CIN gibi lezyonların tespiti ile invaziv serviks kanserine dönüşüm öncesinde erken teşhis için oldukça faydalıdır (Huh et al.,2015). Kolposkopi önemli bir tanı yöntemidir serviks premalign lezyonlarının tespit etme konusunda oldukça güvenilirdir (cervical cancer screening, 2022). Bu tür değerlendirmelerin gözlemciye bağlı değişkenlik içermektedir. Yapay zeka entegrasyonu ile servikal sitoloji, HPV ile ilişkili risk değerlendirmesi ve kolposkopik görüntü analizi ile değerlendirilmesi gibi yeni değerlendirme süreçleri başlamıştır. Bazı çalışmalar derin öğrenme modelleri ile servikal kanser taraması ve sitopatologların hassasiyetini arttırdığı ve okuma sürelerini belirgin azalttığını göstermektedir (Xue et al.,2025). Bazı modellerle tele-servikografi görüntülerinde yüksek riskli lezyonlar için %98 hassasiyet ve %95,5 özgüllük göstermiştir (Ouh et al.,2024). AI destekli sistemlerin, kolposkopik değerlendirmede kişiye bağlı değişkenliği azalttığı ve klinik karar verme süreçlerini desteklediği bildirilmektedir (Aquilina&Papagiannakis,2024).

Derin öğrenme tabanlı algoritmalar servikal sitoloji değerlendirmelerinde, yüksek çözünürlüklü digital sitoloji görüntülerini analiz ederek hücresel anormallikleri tespit edebilir ve emek ağırlıklı ve hataya açık geleneksel manuel değerlendirmeye göre tanı doğruluğunu ve verimliliği arttırabilir (William, Ware, Basaza -Ejiri&Obungoloch,2018). Sıvı bazlı sitoloji örnekleri, otomatik analiz için hücre dağılımını eşit yayan sisteme sahip olması AI ları eğitmek için avantaj sağlar. AI destekli sitoloji sistemleri, çekirdek boyutu,

çekirdek sitoplazma oranı, kromatin yapısı ve hücresel düzensizlikler olmak üzere hücrenin morfolojik yapısını analiz edebilirler (Sood, Khandor, &Bhatia,2024).

Atipik skuamöz hücreleri (ASC-US) düşük dereceli (LSIL) ve yüksek dereceli skuamöz intraepitelyal lezyonlardan (HSIL) ayırt etmek, sitolojik tanıda önemli bir zorluk teşkil etmektedir (Sornapudi et al.,2020). AI tabanlı modeller, bu lezyonlar arasındaki ince morfolojik farklılıkları öğrenerek sınıflandırma doğruluğunu arttırır (Takahashi et al.,2022). Algoritmalar HSIL gibi lezyonlar için yüksek hassasiyet göstererek erken tanı ve tedaviye yardımcı olmaktadır. Yapay zeka destekli algoritmalar tanı hassasiyetini %20,2' ye kadar ve özgüllüğü %22,3'e kadar arttırabilir (Z. Ye et al.,2025). Güncel yaklaşımlar, serviks sitolojisinde patologların yerini AI'ın alması yerine, insan uzmanlığını yapay zeka ile birleştiren hibrit modelleri vurgulamaktadır (Vaccaro, Almaatoug,& Malone,2024).

HPV genotiplemesi HR-HPV tiplerin tanımlanması ile serviks kanseri riskinin daha doğru bir şekilde belirlenmesini sağlar (Demarco et al., 2020). Yapay zeka algoritmaları, çeşitli HPV genotipleri ile sitolojik ve klinik sonuçlar arasındaki ilişkiyi analiz ederek risk düzeylerini daha başarılı olarak değerlendirebilir (Shie et al.,2025). Özellikle HPV 16- 18 pozitif hastaların yakından izlenmesi ek etkenler varlığında risk değerlendirilmesi daha güçlenebilir. AI tabanlı risk modelleri, HPV genotipi, enfeksiyon süresi, sitolojik bulgular ve hasta özelliklerini birleştirerek premalign lezyonların ilerleme olasılığını tahmininde başarılı sonuçlar alınmaktadır (Farzaneh, Soltani, Dastyar, Mohammadi, &Hosseini,2025). Bu modeller hangi hastaların yakından izlenmesi gerektiği konusunda başarılı yönlendiricilikleri olabilir.

Kolposkopik muayene, büyük ölçüde klinisyenin deneyimine ve öznel yorumuna dayanmaktadır. Gözlemciye bağlı bu değişkenlik, lezyonların gözden kaçması veya yanlış yorumlanması gibi sorunlara yol açabilir ve bu da standardizasyon zorunluluğu ve iyileşme ihtiyacını gösterir. Digital kolposkopi sistemleri, serviksin yüksek çözünürlüklü görüntülerin elde edilmesini arşivlenmesini ve analizini sağlar. Yapay zeka algoritmaları kullanarak digital görüntüleri analiz etme, kolposkopinin tanı performansını arttırmaktadır (Phiri et al.,2026). Bu modeller kolposkopik görüntülerdeki vasküler paternler, epitel yüzey özellikleri ve aseto beyaz alanların morfolojik bulgularını otomatik olarak değerlendirebilir (Thomas et al.,2025). Özellikle CNN modelleri malign premalign lezyonları ayırt edilmesine yardımcı olurlar. Kolposkopide biyopsi bölgesinin doğru tespit edilmesi tanı açısından hayati önem taşımaktadır. Çalışmalar, AI sistemlerinin servikal sitopatoloji için duyarlılık ve özgüllük açısından desteksiz modlardan daha iyi sonuçlar vermiştir (Z.Ye et al.,2025).

AI destekli sistemler, servikal sitoloji, HPV test sonuçları, kolposkopik görüntüler ve hasta klinik bilgileri dahil olmak üzere tanı girdilerini eş zamanlı analiz edebilmektedirler. Bu tür modeller risk profilinden tanıya ve oradan tedaviye kadar tüm klinik süreçleri kapsayabilir (Wentzensen et al.,2024). AI destekli modeller, hasta verilerinden yararlanarak, kişiye özgü risk skoru oluşturabilirler.

Adneksiyel kitlelerde yapay zeka uygulamaları

Adneksiyel kitleler, jinekolojide sık görülen ve tedavi yönetimi tartışma yaratan konulardan biridir. Reprodüktif dönemde olduğu gibi peri/postmenapozal dönemdeki hastalarda, benign ve malign lezyonların ayırt edilmesi ve doğru tedavi büyük önem taşımaktadır. Çoğu adneksiyel kitle iyi huylu olmakla beraber maling kitlelerden gözden kaçırılmamalıdır (Vazquez-Manjarrez et al.,2020). Geleneksel jinekoloji pratiğinde klinik bulgular, tümör belirteçlerinin ölçülmesi, transvajinal ultrason ve ihtiyaç dahilinde MRG veya BT ile tanıya ulaşılmaya çalışılmaktadır. Tedavi kararında gereksiz cerrahiden kaçınmaya çalışılırken maligniteyi atlama riskinide bertaraf etmek gerekmektedir. Yapay zeka algoritmaları; ultrason, bilgisayarlı tomografi ve magnetik rezonans görüntüleri üzerinden karmaşık

morfolojik ve fonksiyonel özellikleri, insan gözünün ötesinde ayrıntılı bir şekilde analiz edebilme potansiyeline sahiptir. Bu sayede malignite risk tahmini, kitlelerin sınıflandırılması ve cerrahi planlamaya yönelik karar destek sistemleri oluşturalabilir (Ardakani et al.,2025).

Adneksiyel kitlelerde en temel yaklaşım, basit (uniloküler) kistler, komplex kistler, solid lezyonlar ve solid-kistik lezyonlar şeklinde sınıflandırlmaktadır. Basit kistler çoğunlukla benign lezyonlardır. Kompleks yapılar ise septasyon, papiller oluşum veya ekojenik kompanentler içerdiğinden daha dikkatli değerlendirilmelidirler (Moro, Vagni, et al.,2025). Uluslararası sınıflandırmada IOTA grubunun tanımladığı terminaloji ve tanısal kriterler kullanılmaktadır. Bu kriterler: duvar yapısı, iç yüzey düzensizlikleri, solid alanlar, Doppler akımı ve ek bulgular gibi çok sayıda parametrenin sistematik değerlendirilmesi ile konur (Timmerman et al.,2010). Adneksiyel kitleler reprodüktif dönemde sık görülmekle beraber bu dönemde genellikle benign kitlelerdir. Perimenapozal ve postmenapozal dönemde ise malignite olasılığı artmaktadır. Ovaryan kanser insidansı genel popülasyonda düşük olmasına rağmen mortalitesi yüksek bir hastalıktır. Bu nedenle adneksiyel kitlelerin doğru değerlendirilmesi hayati önem taşımaktadır.

Tıbbi görüntülemede en sık kullanılan derin öğrenme modeli olan konvolüsyonel sinir ağlarıdır (CNN). CNN' ler görüntüdeki kenar, doku, yapı ve morfolojik detayları otomatik olarak tespit edebilmektedir. Bu modellerin ultrason, BT ve MRG yöntemlerine entegrasyonu görüntülerin analizinde yüksek doğruluk ve hızlı sonuç almaya yardım eder (X. Liu et al.,2019). CNN tabanlı modeller; kitle morfolojisini tanıma, malignite riskini tahmin etme ve görüntüdeki kritik alanları belirleme gibi görevlerde geleneksel yöntemlere göre daha başarılı bulunmuştur. Tıbbi görüntüleme alanında kullanılan veri setleri genellikle ultrason, BT veya MRG görüntülerinden oluşur ve her bir görüntünün doğru etiketlenmesi model performansının temel belirleyicisidir. Etiketleme; kitle sınırının belirlenmesi, morfolojik özelliklerin tanımlanması veya malignite belirteçlerinin doğrulanmasını içerir. Bu süreçte radyologlar ve jinekologlar etiketlemeyi doğru yaparak modelin tüm öğrenme sürecini doğru tamamlamasına yardım eder, yanlış etiketleme tüm süreci olumsuz etkilemektedir (Zhang&Nie,2022). Veri büyüklüğü modelin genelleştirebilme gücünü yükseltir. Farklı cihazlardan, farklı merkezlerden gelen görüntüler modelin gücünü azaltabilir. Bu nedenle geniş, heterojen ve çok merkezli veri setleri ile oluşturulan yapay zeka modelleri daha güvenilir hale gelmektedir. Klinik verilere entegre edilen yapay zeka modelleri yaş, menapoz durumu, tümör belirteçleri ve görüntü verilerini kombine ederek daha kapsamlı risk skorları oluşturulabilmektedir. Risk tahmini tek başına tanı koydurucu olmamakla beraber klinisyenlerin karar verme sürecini kolaylaştırabilmektedir. Günümüzde CNN tabanlı modeller, özellikle ultrason görüntülerinde morfolojik özelliklerin tanınması ve malignite risk sınıflamasında iyi sonuçlar izlenmektedir. Bazı modellerde %90' a yaklaşan başarı oranları ve kompleks morfolojiye sahip kitlelerde klinisyenlere yakın performans göstermektedirler. Hibrit modellerde ise hem görüntü verisi, yaş, menapoz durumu, CA- 125 düzeyi gibi klinik parametreleri bir arada değerlendiren modellerde daha yüksek başarı oranları tespit edilmektedir.

İntraoperatif görüntü destekli yapay zeka uygulamaları, cerrahi sırasında gerçek zamanlı veri analizi yaparak cerrahın karar sürecine anlık destek olabilmektedir. Özellikle Laparoskopik operasyonlarda görüntüler CNN modelli sistemlerle doku sınırlarının tanınması, şüpheli alanların işaretlenmesi ve anatomik yapıların otomatik tanınması sağlanabilir (Reily et al.,2023).

İvf tedavisinde yapay zeka uygulamaları

Son yıllarda teknolojinin gelişmesi ile birlikte, İVF tedavisinde büyük değişiklikler olmasına rağmen gebelik elde etme oranları %30 ve canlı doğum elde etme oranlarıda düşük oranlarda

seyretmektedir. Embiryo seçimi ve morfolojisinin şimdiye kadar olan geleneksel yaklaşımlar kişi ve deneyim bağımlı olmuştur, bu da başarı oranlarında değişkenliği beraberinde getirmiştir.

İnfertil hastalarda İVF tedavisi tek ve son seçenek olması ve başarı oranlarının belirli bir seviyede kalması yeni çözüm arayışlarına yol açmaktadır. İVF süreçlerinde elde edilen oosit kalitesini yükselttikleri için over stimülasyon protokolleri büyük önem taşımaktadır (Alper M et al.,2017). Over stimülasyonunun yaş, over rezervi, hormon profili, vücut kitle indeksi, amh verileri gibi hasta özelliklerine bağlı düzenlenmesi başarı oranlarını arttırabilmektedir. Yaş ve over rezervlerine göre hastalar farklı stimülasyon protokollerine ihtiyaç duyabilirler. Over stimülasyon protokolleri overin aşırı hiperstimülasyonu, düşük oosit kalitesi ve daha düşük İVF başarı oranları gibi zorlukları vardır. Bu zorluklar daha önce yapılmış geniş ölçekli veri setlerinin yapay zeka modelleri ile analiz sonrası kişiye özel stimülasyon protokolleri oluşturulabilir. Modellerin geri dönütlerle beslenmesi ile daha dinamik modeller geliştirilerek OHSS riski azaltılabilir ve başarı oranları yükseltilebilir (Hariton E et al.,2023)

Embiryo implantasyonu ve canlı gebelik gelişimi için oosit kalitesi kritik önem taşımaktadır. Geleneksel mikroskobik görüntüde sitoplazmayı çevreleyen zona pellusida, sitoplazmik yapı, vakuoller, izole ilk kutup gövdesi ve perivitellin alan varlığı incelenir. İlk kutup gövdesi bu aşamaya özgüdür. Döllenme için bu oositler seçilir. Birçok merkezde bu değerlendirme embiryolog tarafından yapılmaktadır ve kişiye bağlı bir değerlendirmedir. Yapay zeka modelleri, oositlerin yüksek çözünürlüklü görüntülerine dayalı analizler yaparak oosit kalitesi değerlendirmesinde daha güçlü olanaklar sağlayabilir (Letterie G. Et al.,2022). Yapay zeka modelli görüntü analiz teknikleri ile insan gözünün yakalayamayabileceği ayrıntılı görüntüleme ile kaliteli oosit seçimi başarısı arttırılabilmektedir. Yapay zeka modelleri ile objektiviteden uzaklaşmış standardize edilmiş uygulamalar oluşturulabilir (Si K. Et al.,2023). Hızlandırılmış görüntüleme yoluyla oosit gelişinin sürekli izlenmesi ve dinamik bilgiler elde etmemizi sağlar (Bhide P. et al.,2024).

Sperm seçiminde geleneksel yöntemin verimliliğini arttırmaya yönelik modeller geliştirilebilir. Semen analiz yirmi beş yıldır öznellikten uzaklaştırılabilmesi açısından bilgisayar destekli semen analizi (CASA) ile yapılmaktadır. Ancak CASA yöntemi sperm konsantrasyonu ve morfolojideki çeşitlilikten dolayı kullanımı kısıtlı kalmıştır (Finelli R. et al,2021). Son dönemlerde CASA yöntemine AI modelleri entegre edilmiştir (Goodson SG. et al,2017). Son yıllarda yapılan AI destekli semen analizi ile yapılan İVF uygulamalarının başarı oranı daha yüksek bulunmuştur (Ottle S.et al.,2022). Sperm görüntülerindeki küçük farklar yakalanabilir başarılı sonuçlara olumlu katkı sağlayabilir. Yüksek çözünürlüklü video görüntüleri sperm hareketliliği ve morfolojisindeki farklılıkları belirlemede daha etkili olabilmektedir (Shahali S. et al., 2024).

Embiryo seçimi sırasında, morfolojik görsel değerlendirme, hücre sayısı, simetrisi, bölünmesi statik görüntülerle CNN ile yapılabilir. Geleneksel yöntemde embiryo gelişim aşamaları takip edilmektedir. Geleneksel yöntemde en iyi embiryoyu seçerken embiryoyu inkübatörden birden fazla çıkartılması gerekebilmektedir. Bu işlemde embiryo kalitesinde düşmeye yol açmaktadır. Zaman aralıklı görüntüleme sistemi entegre yapay zeka modelleri (Embryoscope, Eeva gibi) ile embiryo gelişim aşamaları inkübatörden çıkarmadan takip edilebilir. Bu modellere geri dönüt eklenerek daha dinamik modeller geliştirilebilir.

Embiryonun implantasyonu sırasında aneuploidi, implantasyon başarısızlığının, gebelik kayıplarının ve konjenital anomalilerin başlıca nedenidir (Schaeffer et al., 2018). Başarısız İVF uygulamaları olan hastalarda embiryoların genetik yapısını ve transfer sırasında euploid embiryoyu belirleyebilmek için preimplantasyon genetik testi (PGT-A) kullanılır (Greco et al.,2020). PGT- işleminin biyopsi olması, travmatik olması nedeni ile embiryoya hasar

verme riski vardır. Statik görüntülerle CNN modelleri ile PGT-A yapmadan euploid embiryo seçimi yapılabilir (Chavez- Badiola et al.,2020). Jiang ve ark. Embiryo plöidi durumunu hasta özellikleri, anne yaşı, amh değeri, baba sperm özellikleri ile oluşturulmuş modellerle başarı oranlarını öngörebilmektedirler (Jiang V.S. et al.,2023). Transfer embiryosu seçiminde AI entegre uygulamalarda başarı oranlarında %11,1 artış izlenmiştir (Fitz et al.,2021).

Sonuç

Yapay zeka uygulamaları Kadın hastalıkları ve Doğum alanında veriye dayalı, objektif ve standardize edilmiş uygulamalarla önemli katkılar sunabilme kapasitesine sahiptir. Yüksek riskli gebeliklerin tanınması, preeklampsi riskinin belirlenmesi, ultrason değerlendirmesi sırasında yapay zeka entegre cihazlarla tanının güçlendirilmesi sağlanabilir. Aynı zamanda endometriyal, servikal ve adneksiyal patolojilerin tespitinde yardımcı olabilir. Ovum, sperm, embiryo seçimi daha kaliteli yapılarak İVF tedavisindeki başarı oranları arttırılabilir.

Yapay zeka uygulamalarını hekim alternatifi olarak düşünmekten ziyade, klinisyene destek sağlayan tamamlayıcı bir araç olarak değerlendirilmelidir. İnsan ve AI entegre modeller, mevcut klinik hizmetlerin güçlendirilmesine yardım eder ve tanı tedavi sürecini güçlendirebilir.

AI uygulamalarının rutin klinik kullanımına girmesi için geniş ölçekli, prospektif ve çok merkezli çalışmalara ihtiyaç duyulmaktadır. Etik ve hukuki çerçevenin netleştirilmesi ve farklı popülasyonlarda genellenebilirliğin gelecekte netleştirilmesi gerekmektedir.

Kaynakça

Aftab, N. (2025). Artificial intelligence in obstetrics and Gynaecology: advancing precision and personalised care. *Cureus*, *17*(6).

Alper, M. M., & Fauser, B. C. (2017). Ovarian stimulation protocols for IVF: is more better than less?. *Reproductive biomedicine online*, *34*(4), 345-353.

Ardakani, A. A., Mohammadi, A., Mohebbi, A., Vijayananthan, A., Leong, S. S., Ting, L. Y., ... & Hatamikia, S. (2025). From ACR O-RADS 2022 to Explainable Deep Learning: Comparative Performance of Expert Radiologists, Convolutional Neural Networks, Vision Transformers, and Fusion Models in Ovarian Masses. *arXiv preprint arXiv:2511.06282*.

Aquilina, A., & Papagiannakis, E. (2024). Deep learning diagnostic classification of cervical images to augment colposcopic impression. *Journal of lower genital tract disease*, *28*(3), 224-230.

Bankhead, P., Loughrey, M. B., Fernández, J. A., Dombrowski, Y., McArt, D. G., Dunne, P. D., ... & Hamilton, P. W. (2017). QuPath: Open source software for digital pathology image analysis. *Scientific reports*, *7*(1), 1-7.

Bashir, Z., Lin, M., Feragen, A., Mikolaj, K., Taksøe-Vester, C., Christensen, A. N., ... & Tolsgaard, M. G. (2025). Clinical validation of explainable AI for fetal growth scans through multi-level, cross-institutional prospective end-user evaluation. *Scientific Reports*, *15*(1), 2074.

Bhide, P., Chan, D. Y., Lanz, D., Alqawasmeh, O., Barry, E., Baxter, D., ... & Thangaratinam, S. (2024). Clinical effectiveness and safety of time-lapse imaging systems for embryo incubation and selection in in-vitro fertilisation treatment (TILT): a multicentre, three-parallel-group, double-blind, randomised controlled trial. *The Lancet*, *404*(10449), 256-265.

Chavez-Badiola, A., Flores-Saiffe-Farías, A., Mendizabal-Ruiz, G., Drakeley, A. J., & Cohen, J. (2020). Embryo Ranking Intelligent Classification Algorithm (ERICA): artificial intelligence clinical assistant predicting embryo ploidy and implantation. *Reproductive biomedicine online*, *41*(4), 585-593.

Crosbie, E. J., Kitson, S. J., McAlpine, J. N., Mukhopadhyay, A., Powell, M. E., & Singh, N. (2022). Endometrial cancer. *The Lancet*, *399*(10333), 1412-1428.

Jeong, G. H. (2020). Artificial intelligence, machine learning, and deep learning in women's health nursing. *Korean Journal of Women Health Nursing*, *26*(1), 5-9.

Jiang, V. S., Kandula, H., Thirumalaraju, P., Kanakasabapathy, M. K., Cherouveim, P., Souter, I., ... & Shafiee, H. (2023). The use of voting ensembles to improve the accuracy of deep neural networks as a non-invasive method to predict embryo ploidy status. *Journal of assisted reproduction and genetics*, *40*(2), 301-308.

Delanerolle, G., Yang, X., Shetty, S., Raymont, V., Shetty, A., Phiri, P., ... & Shi, J. Q. (2021). Artificial intelligence: a rapid case for advancement in the personalization of gynaecology/obstetric and mental health care. *Women's Health*, *17*, 17455065211018111.

Demarco, M., Egemen, D., Raine-Bennett, T. R., Cheung, L. C., Befano, B., Poitras, N. E., ... & Schiffman, M. (2020). A study of partial human papillomavirus genotyping in support of the 2019 ASCCP risk-based management consensus guidelines. *Journal of lower genital tract disease*, *24*(2), 144-147.

Demirhan, A., Kılıç, Y. A., & İnan, G. (2010). Tıpta yapay zeka uygulamaları.

Uzun, T. (2020). Yapay zeka Ve Sağlik Uygulamalari. *İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, *3*(1), 80-92.

Dos Santos, G. G. (2026). Using artificial intelligence as a technological tool in gynecologic and obstetric health: A narrative literature review. *International Journal of Gynecology & Obstetrics*, *172*(2), 850-865.

Farzaneh, F., Soltani, A., Dastyar, F., Mohammadi, M., & Hosseini, M. S. (2025). AI-Driven predictive modeling of cervical intraepithelial neoplasia severity: a comprehensive analysis with clinical adoption frameworks. *BMC cancer*, *25*(1), 1521.

Feduniw, S., Golik, D., Kajdy, A., Pruc, M., Modzelewski, J., Sys, D., ... & Rabijewski, M. (2022, October). Application of artificial intelligence in screening for adverse perinatal outcomes—a systematic review. In *Healthcare* (Vol. 10, No. 11, p. 2164). MDPI.

Finelli, R., Leisegang, K., Tumallapalli, S., Henkel, R., & Agarwal, A. (2021). The validity and reliability of computer-aided semen analyzers in performing semen analysis: a systematic review. *Translational andrology and urology*, *10*(7), 3069.

Fitz, V. W., Kanakasabapathy, M. K., Thirumalaraju, P., Kandula, H., Ramirez, L. B., Boehnlein, L., ... & Shafiee, H. (2021). Should there be an "AI" in TEAM? Embryologists selection of high implantation potential embryos improves with the aid of an artificial intelligence algorithm. *Journal of Assisted Reproduction and Genetics*, *38*(10), 2663-2670.

Goodson, S. G., White, S., Stevans, A. M., Bhat, S., Kao, C. Y., Jaworski, S., ... & O'Brien, D. A. (2017). CASAnova: a multiclass support vector machine model for the classification of human sperm motility patterns. *Biology of reproduction*, *97*(5), 698-708.

Greco, E., Litwicka, K., Minasi, M. G., Cursio, E., Greco, P. F., & Barillari, P. (2020). Preimplantation genetic testing: where we are today. *International journal of molecular sciences*, *21*(12), 4381.

Hariton, E., Pavlovic, Z., Fanton, M., & Jiang, V. S. (2023). Applications of artificial intelligence in ovarian stimulation: a tool for improving efficiency and outcomes. *Fertility and sterility*, *120*(1), 8-16.

Hristamyan, M. A. (2025). Primary and Secondary Prophylaxis for Diseases Caused by Human Papillomavirus Infections. *Journal of Cancer Prevention*, *30*(3), 146.

Huh, W. K., Ault, K. A., Chelmow, D., Davey, D. D., Goulart, R. A., Garcia, F. A., ... & Einstein, M. H. (2015). Use of primary high-risk human papillomavirus testing for cervical cancer screening: interim clinical guidance. *Journal of lower genital tract disease*, *19*(2), 91-96.

Letterie, G., MacDonald, A., & Shi, Z. (2022). An artificial intelligence platform to optimize workflow during ovarian stimulation and IVF: process improvement and outcome-based predictions. *Reproductive biomedicine online*, *44*(2), 254-260.

Li, X., Dessi, M., Marcus, D., Russell, J., Aboagye, E. O., Ellis, L. B., ... & Rockall, A. G. (2023). Prediction of deep myometrial infiltration, clinical risk category, histological type, and lymphovascular space invasion in women with endometrial cancer based on clinical and T2-

Liu, X., Faes, L., Kale, A. U., Wagner, S. K., Fu, D. J., Bruynseels, A., ... & Denniston, A. K. (2019). A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *The lancet digital health*, *1*(6), e271-e297.

Lin, Z., Liu, X., Wang, N., Li, R., Liu, Q., Ma, J., ... & Hong, S. (2024). Deep learning with information fusion and model interpretation for health monitoring of fetus based on long-term prenatal electronic fetal heart rate monitoring data. *arXiv preprint arXiv:2401.15337*.

Michalitsi, K., Metallinou, D., Diamanti, A., Georgakopoulou, V. E., Kagkouras, I., Tsoukala, E., & Sarantaki, A. (2024). Artificial intelligence in predicting the mode of delivery: a systematic review. *Cureus*, *16*(9).

Moro, F., Momi, M., Ledger, A., Barreñada, L., Ceusters, J., Sturla, D., ... & Mazzocco, A. (2025). External validation of ultrasound-based models for differentiating between benign and malignant adnexal masses: a nationwide prospective multicenter study (IOTA phase 6). *American Journal of Obstetrics and Gynecology*.

Neofytou, M. S., Pattichis, M. S., Pattichis, C. S., Tanos, V., Kyriacou, E. C., & Koutsouris, D. D. (2006, August). Texture-based classification of hysteroscopy images of the endometrium. In *2006 International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 3005-3008). IEEE.

Ottl, S., Amiriparian, S., Gerczuk, M., & Schuller, B. W. (2022). motilitAI: A machine learning framework for automatic prediction of human sperm motility. *iscience*, *25*(8).

Schaeffer, E., Porchia, L., López-Luna, A., Hernández-Melchor, D., & López-Bayghen, E. (2018). Aneuploidy rates inversely correlate with implantation during in vitro fertilization procedures: In Favor of PGT. In *Modern medical genetics and genomics*. IntechOpen.

Schmauder, S., Sandström, A., Boman, M., Martin, C., & Stephansson, O. (2025). Machine learning prediction models for mode of delivery in prolonged pregnancies in Sweden. *Scientific Reports*, *15*(1), 32487.

Shabani, F., Jodeiri, A., Mohammad-Alizadeh-Charandabi, S., Abbasalizadeh, F., Tanha, J., & Mirghafourvand, M. (2025). Developing and validating an artificial intelligence-based

application for predicting some pregnancy outcomes: a multi-phase study protocol. *Reproductive Health*, *22*(1), 99.

Shahali, S., Murshed, M., Spencer, L., Tunc, O., Pisarevski, L., Conceicao, J., ... & Nosrati, R. (2024). Morphology classification of live unstained human sperm using ensemble deep learning. *Advanced Intelligent Systems*, *6*(11), 2400141.

Shi, L., Chen, H., Zhang, Z., Wang, Y., Ren, W., & Huang, J. (2025). Evolving HPV diagnostics: current practice and future frontiers. *Frontiers in Cellular and Infection Microbiology*, *15*, 1681779.

Sood, T., Khandnor, P., & Bhatia, R. (2024). Enhancing pap smear image classification: Integrating transfer learning and attention mechanisms for improved detection of cervical abnormalities. *Biomedical Physics & Engineering Express*, *10*(6), 065031.

Sornapudi, S., Stanley, R. J., Stoecker, W. V., Long, R., Xue, Z., Zuna, R., ... & Antani, S. (2020). DeepCIN: attention-based cervical histology image classification with sequential feature modeling for pathologist-level accuracy. *Journal of Pathology Informatics*, *11*(1), 40.

Sun, H., Zeng, X., Xu, T., Peng, G., & Ma, Y. (2019). Computer-aided diagnosis in histopathological images of the endometrium using a convolutional neural network and attention mechanisms. *IEEE journal of biomedical and health informatics*, *24*(6), 1664-1676.

Si, K., Huang, B., & Jin, L. (2023). Application of artificial intelligence in gametes and embryos selection. *Human Fertility*, *26*(4), 757-777.

Sylvain, M. H., Nyabyenda, E. C., Uwase, M., Komezusenge, I., Ndikumana, F., & Ngaruye, I. (2025). Prediction of adverse pregnancy outcomes using machine learning techniques: evidence from analysis of electronic medical records data in Rwanda. *BMC Medical Informatics and Decision Making*, *25*(1), 76.

Takahashi, T., Matsuoka, H., Sakurai, R., Akatsuka, J., Kobayashi, Y., Nakamura, M., ... & Tamiya, G. (2022). Development of a prognostic prediction support system for cervical intraepithelial neoplasia using artificial intelligence-based diagnosis. *Journal of gynecologic oncology*, *33*(5), e57.

Thomas, A., Brar, S., Weitoschova, A., Yerra, S., Gutierrez, C., & Vinagolu-Baur, J. (2025). Artificial Intelligence Enhanced Colposcopy Supports Early Detection of High Grade Cervical Intraepithelial Neoplasia in HPV Positive Individuals. *International Journal of Research*, *10*(1), 28-35.

Timmerman, D., Ameye, L., Fischerova, D., Epstein, E., Melis, G. B., Guerriero, S., ... & Valentin, L. (2010). Simple ultrasound rules to distinguish between benign and malignant adnexal masses before surgery: prospective validation by IOTA group. *Bmj*, *341*.

Restaino, S., De Giorgio, M. R., Pellecchia, G., Arcieri, M., Vasta, F. M., Fedele, C., ... & Giannone, G. (2025). Artificial intelligence in gynecological oncology from diagnosis to surgery. *Cancers*, *17*(7), 1060.

Giaxi, P., Vivilaki, V., Sarella, A., Harizopoulou, V., & Gourounti, K. (2025). Artificial intelligence and machine learning: An updated systematic review of their role in obstetrics and midwifery. *Cureus*, *17*(3).

Ngo, T. N., & Hastie, D. (2025). Artificial Intelligence for Academic Purposes (AIAP): Integrating AI literacy into an EAP module. *English for Specific Purposes*, *77*, 20-38.

Horgan, R., Nehme, L., & Abuhamad, A. (2023). Artificial intelligence in obstetric ultrasound: A scoping review. *Prenatal Diagnosis*, *43*(9), 1176-1219.

Patel, D. J., Chaudhari, K., Acharya, N., Shrivastava, D., & Muneeba, S. (2024). Artificial intelligence in obstetrics and gynecology: transforming care and outcomes. *Cureus*, *16*(7).

Rajula, H. S. R., Verlato, G., Manchia, M., Antonucci, N., & Fanos, V. (2020). Comparison of conventional statistical methods with machine learning in medicine: diagnosis, drug development, and treatment. *Medicina*, *56*(9), 455.

Reilly, G. P., Dunton, C. J., Bullock, R. G., Ure, D. R., Fritsche, H., Ghosh, S., ... & Phan, R. T. (2023). Validation of a deep neural network-based algorithm supporting clinical management of adnexal mass. *Frontiers in Medicine*, *10*, 1102437.

Ouh, Y. T., Kim, T. J., Ju, W., Kim, S. W., Jeon, S., Kim, S. N., ... & Lee, J. K. (2024). Development and validation of artificial intelligence-based analysis software to support screening system of cervical intraepithelial neoplasia. *Scientific reports*, *14*(1), 1957.

Özbilgeç, S., Akkuş, F., Şener, R., Dönmez, E. E., Serin, E. C., & Acar, A. (2025). HPV status and colposcopy: key predictors in cervical cancer and precancerous lesion diagnosis. *Northwestern Medical Journal*, *5*(4), 201-208.

Phiri, H., Uwinkindi, F., Diop, M., Mwanahamuntu, M., Gondongwe, L., Guzha, B. T., ... & Parham, G. (2026). Performance of an artificial intelligence-based tool for cervical precancer screening in five countries in Africa: a prospective, observational, diagnostic accuracy study. *The Lancet Global Health*, *14*(1), e49-e60.

Vaccaro, M., Almaatouq, A., & Malone, T. (2024). When combinations of humans and AI are useful: A systematic review and meta-analysis. *Nature Human Behaviour*, *8*(12), 2293-2303.

Vasudevan, L., Kibria, M. G., Kucirka, L. M., Shieh, K., Wei, M., Masoumi, S., ... & Page, D. (2025). Machine learning models to predict risk of maternal morbidity and mortality from electronic medical record data: scoping review. *Journal of medical Internet research*, *27*, e68225.

Vázquez-Manjarrez, S. E., Rico-Rodriguez, O. C., Guzman-Martinez, N., Espinoza-Cruz, V., & Lara-Nuñez, D. (2020). Imaging and diagnostic approach of the adnexal mass: what the oncologist should know. *Chinese Clinical Oncology*, *9*(5), 69-69.

Wentzensen, N., Garcia, F., Clarke, M. A., Massad, L. S., Cheung, L. C., Egemen, D., ... & Enduring Consensus Cervical Cancer Screening and Management Guidelines Committee. (2024). Enduring consensus guidelines for cervical cancer screening and management: introduction to the scope and process. *Journal of lower genital tract disease*, *28*(2), 117-123.

Whitlock, E. P., Vesco, K. K., Eder, M., Lin, J. S., Senger, C. A., & Burda, B. U. (2011). Liquid-based cytology and human papillomavirus testing to screen for cervical cancer: a systematic review for the US Preventive Services Task Force. *Annals of internal medicine*, *155*(10), 687-697.

William, W., Ware, A., Basaza-Ejiri, A. H., & Obungoloch, J. (2018). A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images. *Computer methods and programs in biomedicine*, *164*, 15-22.

Xue, P., Dang, L., Kong, L. H., Tang, H. P., Xu, H. M., Weng, H. Y., ... & Zhao, F. H. (2025). Deep learning enabled liquid-based cytology model for cervical precancer and cancer detection. *Nature Communications*, *16*(1), 3506.

Ye, Z. C., Yang, Y. H., Xu, L., Wei, R. G., Ruan, X. L., Xue, P., ... & Qiao, Y. L. (2025). Diagnostic performance evaluation of artificial intelligence-assisted diagnostic systems in cervical cytopathological examination. *Zhonghua liu xing bing xue za zhi= Zhonghua liuxingbingxue zazhi*, *46*(3), 499-505.

Zhang, Y., & Nie, H. (2022). Design and Implementation of Obstetric Central Monitoring System Based on Medical Image Segmentation Algorithm. *Journal of Healthcare Engineering*, *2022*(1), 3545831.

Ürolojide Uygulamalarında Yapay Zeka: Tanı ve Tedavi Planlama

Mehmet KIRDAR[1], dr.mhmtkrdr89@gmail.com

Ümit OLCAY[2], umitolcay@ogr.bandirma.edu.tr

1. Üroloji Uzmanı, Bandırma Eğitim ve Araştırma Hastanesi, Bandırma, Türkiye

2. Dönem 2 Öğrencisi, Bandırma Onyedi Eylül Üniversitesi

Özet

Yapay zeka (YZ), makine öğrenmesi ve derin öğrenme alt dalları aracılığıyla ürolojinin radyolojik tanı, patoloji, robotik cerrahi ve hasta takibi gibi tüm alt alanlarını dönüştürme potansiyeli taşımaktadır. Konvolüsyonel sinir ağları (CNN) tabanlı modeller; multiparametrik MRI yorumlama, sistoskopik lezyon tespiti ve Gleason derecelendirmesi başta olmak üzere pek çok tanısal görevde uzman hekim performansına eşit ya da üstün sonuçlar sergilemiştir. Robot yardımlı cerrahide gerçek zamanlı anatomik rehberlik ve nesnel beceri değerlendirmesi sağlayan YZ sistemleri klinik pratiğe girmekte; federe öğrenme ve çok-modal füzyon modelleri ise yakın gelecekte kişiselleştirilmiş tedaviyi mümkün kılacaktır. Bununla birlikte algoritmik önyargı, kara kutu sorunu ve regülatif belirsizlikler klinik benimsemenin önündeki başlıca engellerdir. Bu derleme, güncel kanıtlar ve gelecek perspektifleri çerçevesinde ürolojide YZ uygulamalarını eleştirel bir bakış açısıyla sunmayı amaçlamaktadır.

Anahtar kelimeler: Yapay zeka, üroloji, prostat kanseri, robotik cerrahi, dijital patoloji,

1. Giriş

Yapay zeka (YZ), özellikle makine öğrenmesi (ML) ve derin öğrenme (DL) alt dalları aracılığıyla son on yılda tıbbın neredeyse tüm branşlarını etkilemeye başlamıştır. Üroloji, görüntü yoğunluklu yapısı, biyomarker çeşitliliği ve robotik cerrahiye olan yatkınlığı nedeniyle bu dönüşümden en fazla yararlanan alanların başında gelmektedir (Goldenberg ve ark., 2019).

Konvolüsyonel sinir ağları (CNN), radyomik analiz, doğal dil işleme (NLP) ve pekiştirmeli öğrenme gibi farklı YZ paradigmaları; prostat, mesane ve böbrek kanserlerinin tanısından robota entegre cerrahi rehberliğe, hasta risk sınıflandırmasından kişiselleştirilmiş tedavi planlamasına uzanan geniş bir yelpazede klinik pratiğe girmektedir (Erickson ve ark., 2017; Syed ve ark., 2017).

Bu derleme, güncel literatür ışığında ürolojide YZ uygulamalarını altı temel başlıkta ele almakta; mevcut kanıtları, sınırlılıkları ve gelecek perspektiflerini bilimsel bir çerçevede sunmayı amaçlamaktadır.

> Temel Kavramlar: Makine Öğrenmesi (ML) · Derin Öğrenme (DL) · Konvolüsyonel Sinir Ağı (CNN) · Radyomik · Doğal Dil İşleme (NLP) · Robotik YZ · Dijital Patoloji · Federe Öğrenme

2. Tanısal Yapay Zeka Uygulamaları

2.1. Prostat Kanseri

Prostat kanseri tanısında YZ'nin en çok araştırılan alanı, multiparametrik manyetik rezonans görüntüleme (mpMRI) yorumlama sürecidir. PI-RADS (Prostate Imaging Reporting and Data System) skorlamasını otomatikleştiren CNN modelleri, gözlemciler arası değişkenliği anlamlı düzeyde azaltmakta ve tanısal özgüllüğü artırmaktadır (Litjens ve ark., 2017).

Litjens ve ark. geliştirdiği model, periferik zonda klinik olarak anlamlı prostat kanserini tespit etmede AUC 0,89 değerine ulaşmıştır. Yeterlilik testlerine tabi tutulan uzman ürologlarla kıyaslandığında, en iyi performanslı CNN modellerinin deneyimli okuyucuların performansına yaklaştığı ya da eşit düzeye geldiği gözlenmiştir (Litjens ve ark., 2017).

2.2. Mesane Kanseri

Sistoskopik YZ, mesane kanseri tanısında devrim niteliğinde bir adım olarak değerlendirilmektedir. DETECT1 randomize kontrollü çalışması, yapay zeka destekli sistoskopinin özellikle yassı ve küçük lezyonlarda %94 duyarlılık ile deneyimli sistoskopistleri geride bıraktığını ortaya koymuştur (Bryan ve ark., 2021).

BT sistografi görüntülerinin derin öğrenme ile analizi, ürotelyal karsinom tespitinde yüksek performans sergilemekte; bu yöntem özellikle böbrek fonksiyon bozukluğu nedeniyle geleneksel sistoskopinin uygulanamadığı hastalarda umut verici bir alternatif sunmaktadır (Coudray ve ark., 2018).

2.3. Böbrek Tümörleri

BT radyomik analizi, solid böbrek kitlelerinde onkositom ve anjiomyolipom gibi benign lezyonların malign tümörlerden ayrımında kritik bir rol üstlenebilir. Yayımlanan çalışmalarda AUC değerleri 0,88–0,93 aralığında raporlanmış olup bu yaklaşım küçük renal kitlelerde gereksiz cerrahiyi azaltma potansiyeli taşımaktadır (Kocak ve ark., 2020).

Üreter ve böbrek pelvisindeki taş hastalığında da YZ'den yararlanılmaktadır. NCCT (kontrastsız BT) görüntülerinde taş tespitine yönelik modeller %97 özgüllük değerine ulaşmış; taş bileşimini radyomik parametrelerle tahmin eden algoritmalar ise ESWL endikasyon seçiminde karar desteği sunmaktadır (Hameed ve ark., 2021).

3. Dijital Patoloji ve Biyopsi Yorumlama

Tam kesit dijital görüntüleme (whole slide imaging, WSI) teknolojisinin yaygınlaşması, patolojide derin öğrenme uygulamalarının önünü açmıştır. Bulten ve ark. tarafından yürütülen çok merkezli çalışmada, WSI üzerinde eğitilen CNN modeli Gleason derecesini AUC 0,98 ile belirleyerek uzman patologlarla karşılaştırılabilir performans göstermiştir (Bulten ve ark., 2022).

Otomatik Gleason skorlamanın ötesinde, YZ tabanlı dijital patoloji sistemleri aşağıdaki biyobelirteçleri ve yapısal özellikleri de ölçebilmektedir:

- Ki-67 proliferasyon indeksi (hücre düzeyinde otomatik sayım)
- Perinöral invazyon (PNI) tespiti
- Lenfovasküler invazyon (LVI) tespiti
- Tümör/stroma oranı hesaplaması
- AR (androjen reseptör) ve ERG ekspresyon skorlaması

Bu yaklaşımlar, patoloji iş yükü yüksek merkezlerde anlamlı zaman tasarrufu sağlamakta ve prognostik bilginin standartlaşmasına katkıda bulunmaktadır (Bulten ve ark., 2022).

> Temel Referans: Bulten W, et al. Automated deep-learning system for Gleason grading of prostate cancer using biopsies. Lancet Oncology. 2022;23(2):233-241.

4. Yapay Zeka Destekli Robotik Cerrahi

4.1.Gerçek Zamanlı Anatomik Rehberlik

Robot yardımlı radikal prostatektomi (RARP) sırasında nörovasküler demet ve üretral sfinkter gibi kritik yapıların korunması, onkolojik sonuçlar kadar fonksiyonel sonuçları da belirlemektedir. Derin öğrenme tabanlı segmentasyon algoritmalarının cerrahi görüntüye gerçek zamanlı bindirme (overlay) olarak entegrasyonu, bu yapıların operasyon sırasında işaretlenmesine olanak tanımaktadır (Hashimoto ve ark., 2018).

4.2 Otonom ve Yarı-Otonom Cerrahi Sistemler

Smart Tissue Autonomous Robot (STAR), sert doku bağlantısı olmaksızın yumuşak doku anastomozu gerçekleştiren ilk yarı-otonom robotik platform olarak 2022 yılında literatüre girmiştir. Her ne kadar klinik öncesi aşamada olsa da bu çalışma, cerrahi otomasyonun somut bir ufku olduğunu kanıtlamaktadır (Saeidi ve ark., 2022). Da Vinci 5 (Intuitive Surgical, 2024) ise kuvvet-geri bildirim sensörleri ve YZ destekli hareket skalalaması ile piyasaya sunulan ilk ticari robotik platformdur.

4.3 Cerrahi Beceri Değerlendirmesi ve Eğitim

Cerrahın el hareketi, alet titreşimi ve güç uygulama verileri üzerinden YZ ile üretilen nesnel performans skorları, rezidanlık eğitiminde standart bir değerlendirme aracına dönüşmektedir. Bu yaklaşım, sübjektif mentöre dayalı değerlendirmenin sınırlılıklarını aşma potansiyeli taşımaktadır (Fard ve ark., 2018).

5. Hasta Takibi, Risk Tahmini ve Kişiselleştirilmiş Tedavi

5.1. PSA Kinetik Modelleme ve Aktif Gözetim

Düşük riskli prostat kanserinde aktif gözetim (active surveillance) protokollerini optimize etmek amacıyla ML modelleri geliştirilmektedir. Görüntü, biyopsi ve seri PSA ölçümlerini birleştiren multivariable algoritmalar, gereksiz tekrar biyopsisi gereksinimini azaltırken kanserin progresyonunu erken tespit etme kapasitesi sunmaktadır (Loeb ve ark., 2015).

5.2. Radyoterapi Planlama

Radyasyon onkolojisinde YZ'nin en olgun uygulaması organ-at-risk (OAR) otomatik segmentasyonudur. Derin öğrenme tabanlı OAR segmentasyonu, manuel konturlama sürecini 45–90 dakikadan birkaç dakikaya indirmekte; IMRT ve SBRT dozimetrisinde hem çalışma verimliliğini artırmakta hem de radyasyon toksisitesini azaltmaktadır (Cardenas ve ark., 2019).

5.3. İlaç Yanıt Tahmini

Metastatik kastrasyona dirençli prostat kanseri (mKHPK) ve ürotelyal kanser tedavisinde hormonal ya da immünoterapi yanıtını öngören genomik + klinik veri modelleri, klinisyenlere kişiselleştirilmiş bir karar desteği sunmaktadır (Shim ve ark., 2021).

6. Zorluklar, Sınırlamalar ve Etik Boyutlar

6.1. Veri Kalitesi ve Algoritmik Önyargı

YZ modellerinin eğitim veri setlerindeki demografik dengesizlik, farklı hasta popülasyonlarında (etnik azınlıklar, yaşlılar, düşük gelirli ülkeler) model performansını ciddi ölçüde düşürmektedir. Çok merkezli, prospektif veri toplama altyapılarının kurulması bu sorunun çözümünde kritik önem taşımaktadır (Obermeyer ve ark., 2019).

6.2. Yorumlanabilirlik (Explainability)

Derin öğrenme modellerinin "kara kutu" niteliği, klinisyen güveni ve yasal sorumluluk açısından önemli sorular doğurmaktadır. Grad-CAM (Gradient-weighted Class Activation Mapping) ve SHAP (SHapley Additive exPlanations) gibi yorumlanabilir YZ yöntemleri

bu açığı kapatmayı hedeflemekte; ancak klinik onay süreçlerinde hâlâ yetersiz kalmaktadır (Selvaraju ve ark., 2017).

6.3. Regülasyon ve Onay

Tıbbi YZ yazılımları FDA (510k/De Novo) ve CE sertifikasyon süreçlerine tabidir. Adaptif algoritmalar (continuously learning AI) için post-market gözetim ve yazılım versiyon yönetimi regülatörler açısından yeni bir çerçeve gerektirmektedir (FDA, 2021).

6.4. Etik Çerçeve

Hasta özerkliği açısından değerlendirildiğinde:

- Hastanın YZ destekli karar hakkında bilgilendirilmesi ve aydınlatılmış onam süreçlerinin yeniden tanımlanması
- YZ hatası durumunda klinisyen, yazılım geliştiricisi ve kurum arasındaki yasal sorumluluk paylaşımı
- Düşük kaynaklı sağlık sistemlerinde YZ erişim eşitsizliğinin derinleşmemesi için politika geliştirme

> Önemli uyarı: YZ sistemleri hiçbir zaman klinisyenin yerini almamalıdır. Mevcut kılavuzlar YZ'yi klinisyeni destekleyen bir karar destek aracı olarak konumlandırmakta; nihai klinik sorumluluk her zaman hekime aittir.

7. Geleceğe Bakış: 2025–2030 Yol Haritası

7.1. Çok-modal Füzyon Modelleri

Görüntü, genomik, proteomik ve elektronik sağlık kaydı (EHR) verilerini birleştiren "foundation" modeller, ürolojik onkoloji staging ve prognozunda önümüzdeki yıllarda belirleyici olacaktır (Bommasani ve ark., 2021).

7.2. Federe Öğrenme

Hasta mahremiyetini koruyarak çok merkezli veri paylaşımına olanak tanıyan federe öğrenme (federated learning) yaklaşımı, GDPR ve KVKK gibi yasal düzenlemelerle uyumlu küresel YZ model geliştirme altyapısını mümkün kılmaktadır (Li ve ark., 2020).

7.3. Dijital İkiz Teknolojisi

2030 itibarıyla hastanın patoloji-anatomi-fizyoloji verilerini birleştiren kişiselleştirilmiş sanal modeller (dijital ikizler), cerrahi planlama simülasyonu ve tedavi yanıt tahmini için kullanılabilir hale gelmesi beklenmektedir (Corral-Acero ve ark., 2020).

> "Yapay zeka üroloğun yerini almayacak — ancak yapay zekayı kullanan ürolog, kullanmayan üroloğun yerini alacak." — EAU Annual Congress, 2024

8. Sonuç

Yapay zeka, üroloji pratiğinin radyolojik tanıdan patolojik değerlendirmeye, robotik cerrahiden hasta takibine uzanan tüm boyutlarını dönüştürme potansiyeli taşımaktadır. Mevcut klinik kanıtlar, özellikle prostat ve mesane kanseri tanısında, Gleason skorlamasında ve radyoterapi planlamasında derin öğrenme modellerinin uzman hekim performansını yakaladığını ya da geride bıraktığını göstermektedir.

Bununla birlikte, algoritmik önyargı, kara kutu sorunu, regülatif belirsizlikler ve etik çerçevenin netleştirilmesi, klinik benimseme sürecinin önündeki başlıca engellerdir. Önümüzdeki dönemde prospektif randomize çalışmalar, yorumlanabilir YZ metodolojileri ve çok merkezli federe öğrenme altyapıları, ürolojide YZ'nin standart bakımın bir bileşeni olarak yerleşmesini hızlandıracaktır.

Kaynakça

1. Amin MB, et al. (eds.) AJCC Cancer Staging Manual, 8th ed. Springer; 2017.
2. Bommasani R, Hudson DA, Aditi E, et al. On the opportunities and risks of foundation models. arXiv. 2021:2108.07258.
3. Bryan RT, Liu W, Pirrie SJ, et al. Comparing an optical-based cystoscopy system with white-light cystoscopy for the detection of urothelial cancer: a prospective, randomised, controlled trial (DETECT1). Eur Urol Oncol. 2021;4(4):565-573.
4. Bulten W, Kartasalo K, Chen PC, et al. Artificial intelligence for diagnosis and Gleason grading of prostate cancer: the PANDA challenge. Nat Med. 2022;28(1):154-163.
5. Cardenas CE, Yang J, Anderson BM, Court LE, Brock KB. Advances in auto-segmentation. Semin Radiat Oncol. 2019;29(3):185-197.
6. Corral-Acero J, Margara F, Marciniak M, et al. The 'digital twin' to enable the vision of precision cardiology. Eur Heart J. 2020;41(48):4556-4564.
7. Coudray N, Ocampo PS, Sakellaropoulos T, et al. Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. Nat Med. 2018;24(10):1559-1567.
8. EAU Guidelines. Edn. presented at the EAU Annual Congress Milan 2024. European Association of Urology; 2024.
9. Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine learning for medical imaging. Radiographics. 2017;37(2):505-515.
10. Fard MJ, Ameri S, Ellis RD, Chinnam RB, Pandya AK, Klein MD. Automated robot-assisted surgical skill evaluation: predictive analytics approach. Int J Med Robot. 2018;14(1):e1850.
11. FDA. Artificial intelligence/machine learning (AI/ML)-based software as a medical device (SaMD) action plan. U.S. Food and Drug Administration; 2021.
12. Goldenberg SL, Nir G, Salcudean SE. A new era: artificial intelligence and machine learning in prostate cancer. Nat Rev Urol. 2019;16(7):391-403.
13. Hameed BMZ, Bukavina L, Misra S, et al. Artificial intelligence in urolithiasis: current perspectives and future directions. Minerals. 2021;11(8):786.
14. Hashimoto DA, Rosman G, Rus D, Meireles OR. Artificial intelligence in surgery: promises and perils. Ann Surg. 2018;268(1):70-76.
15. Kocak B, Ates E, Durmaz ES, Ulusan MB, Kilickesmez O. Influence of segmentation margin on machine learning-based high-dimensional quantitative CT texture analysis. Eur Radiol. 2020;30(4):2303-2313.
16. Li T, Sahu AK, Talwalkar A, Smith V. Federated learning: challenges, methods, and future directions. IEEE Signal Process Mag. 2020;37(3):50-60.
17. Litjens G, Sánchez CI, Timofeeva N, et al. Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. Sci Rep. 2016;6:26286.
18. Loeb S, Carter HB, Schwartz M, et al. Heterogeneity in active surveillance protocols worldwide. Rev Urol. 2015;17(4):209-215.
19. Meskó B, Görög M. A short guide for medical professionals in the era of artificial intelligence. NPJ Digit Med. 2020;3:126.
20. NCCN Clinical Practice Guidelines in Oncology: Prostate Cancer. Version 4.2024. National Comprehensive Cancer Network; 2024.
21. Obermeyer Z, Powers B, Vogeli C, Mullainathan S. Dissecting racial bias in an algorithm used to manage the health of populations. Science. 2019;366(6464):447-453.

22. Saeidi H, Opfermann JD, Kam M, et al. Autonomous robotic laparoscopic surgery for intestinal anastomosis. Sci Robot. 2022;7(62):eabj2908.
23. Selvaraju RR, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization. Proc IEEE Int Conf Comput Vis. 2017:618-626.
24. Shim SR, Kim SJ, Lee J, Rücker G. Network meta-analysis for comparing treatment effects of multiple interventions: an introduction. Epidemiol Health. 2019;41:e2019013.
25. Syed JS, Bhatt M, Bhatt JR. Artificial intelligence and its application in urology. Curr Urol Rep. 2017;18(8):65.

Beyin ve sinir cerrahisinde yapay zekâ: cerrahi planlama ve nöronavigasyon

Birgül Aksu, Ayfer Aslan

GİRİŞ

Yapay zekâ, nöroşirurjide cerrahi planlama ve nöro-navigasyon süreçlerini dönüştürerek daha güvenli, hassas ve kişiselleştirilmiş tedavi imkanları sunmaktadır.

AMAÇ

Bu sunumda, yapay zekanın nöroşirurji alanında günümüzdeki ve gelecekteki başlıca uygulama alanlarının tanıtılması amaçlanmıştır.

GELİŞME

1. Nöroşirurjide Yapay Zekanın Başlıca Uygulama Alanları

Nöroşirurjide yapay zekanın birçok uygulama alanı mevcut. Bunlardan başlıcaları şöyle gruplandırılabilir:

1) Preoperatif (Ameliyat Öncesi) Tanı ve Planlama
2) İntraoperatif (Ameliyat İçi) Yardım
3) Robotik Cerrahi ve Simülasyon
4) Postoperatif (Ameliyat Sonrası) Yönetim ve Tedavi

1) Preoperatif (Ameliyat Öncesi) Tanı ve Planlama: Yapay zeka teşhisi koyma aşamasında tümör derecelerini ayırt etmek, cerrahi hedefleri yüksek doğrulukla belirlemek ve omurgaya ait röntgen görügntüleme parametrelerinin otomatik ölçümünü yapmak için görüntüleme yöntemlerini (magnetik rezonans görüntüleme, bilgisayarlı tomografi, X-ray) analiz eder. Örneğin, makine öğrenmesi modelleri, görüntüleme yöntemlerini kullanarak doğru tümör tanısını ve sınıflandırmasını sağlayarak hastanın prognozunu ve hayatta kalma oranlarını tahmin eder; otomatik epileptojenik bölge lokalizasyonunu ve epilepsi ameliyatı için uygun adayların seçimini sağlar; BT görüntülerini akut patolojiler (kanama, potansiyel büyük damar tıkanıklığı inmeleri vb.) açısından hızlıca raporlar. Bütün bunlar tedavi planlama aşamasını destekler, tedavi için doğru hasta seçimini ve hastaların doğru kararlar almalarını kolaylaştırır. Ancak yapay zekâ görüntülemeleri yorumlarken bazen patolojileri doğru saptıyor, ama bazı görünümleri yanlış değerlendiriyor (Resim 1 ve 2). Buradan çıkartılacak sonuç, yapay zekâ görüntüleri analiz ederken, görüntüleri kendisine yüklenen algoritmaya göre motamot analiz edince her zaman doğru sonuç veremiyor. Klinisyen doktor tarafından kontrol gerekliliği halen mevcuttur.

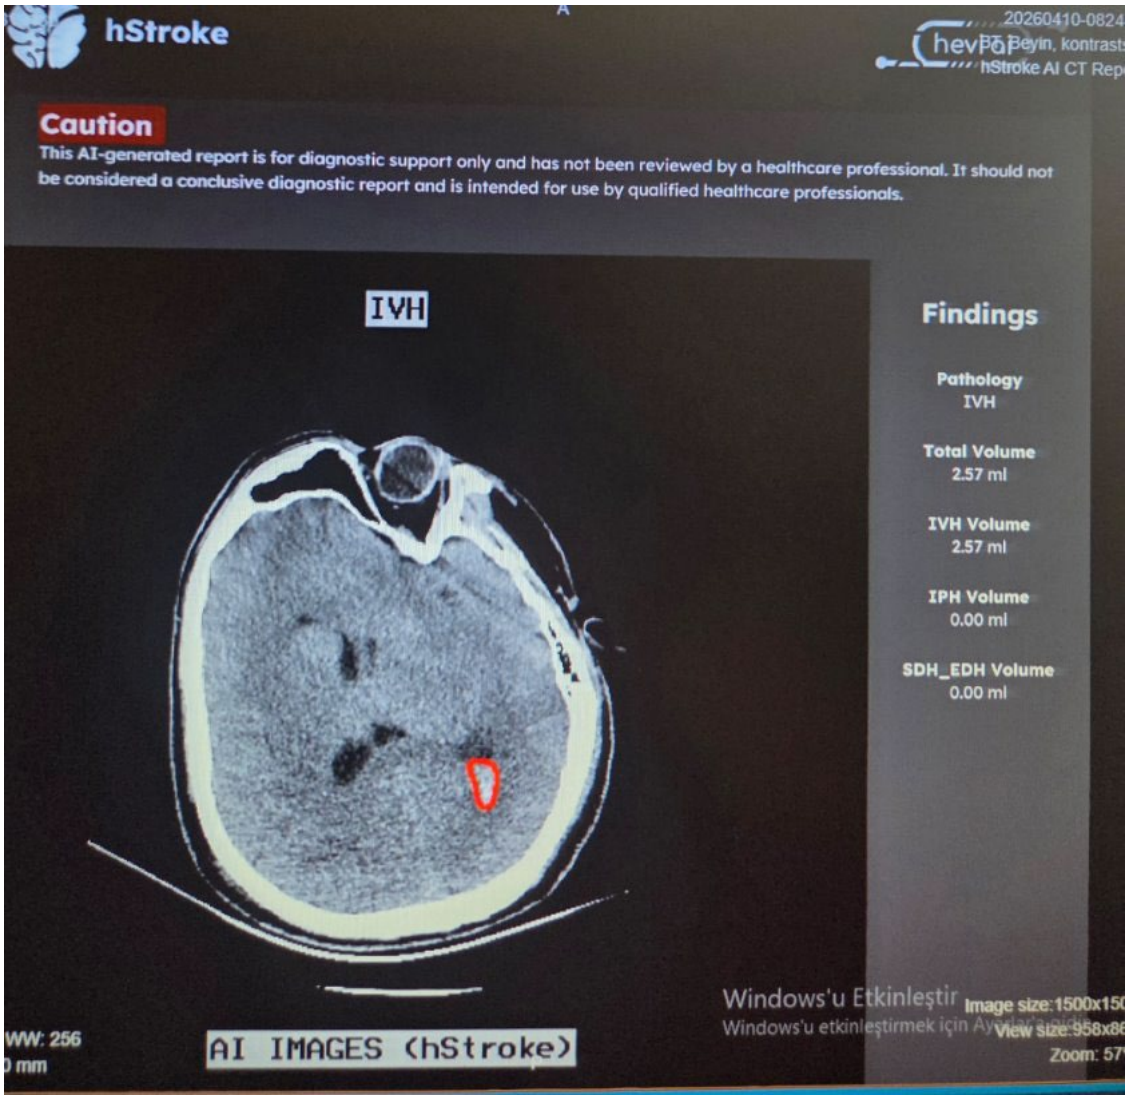

Resim 1. Yapay zekânın beyin tomografisini (BT) raporladığı bu örnekte kanamayı kırmızıyla işaretlediği kanama alanları görünüyor, bu alanları yapay zeka doğru olarak tespit etmiş.

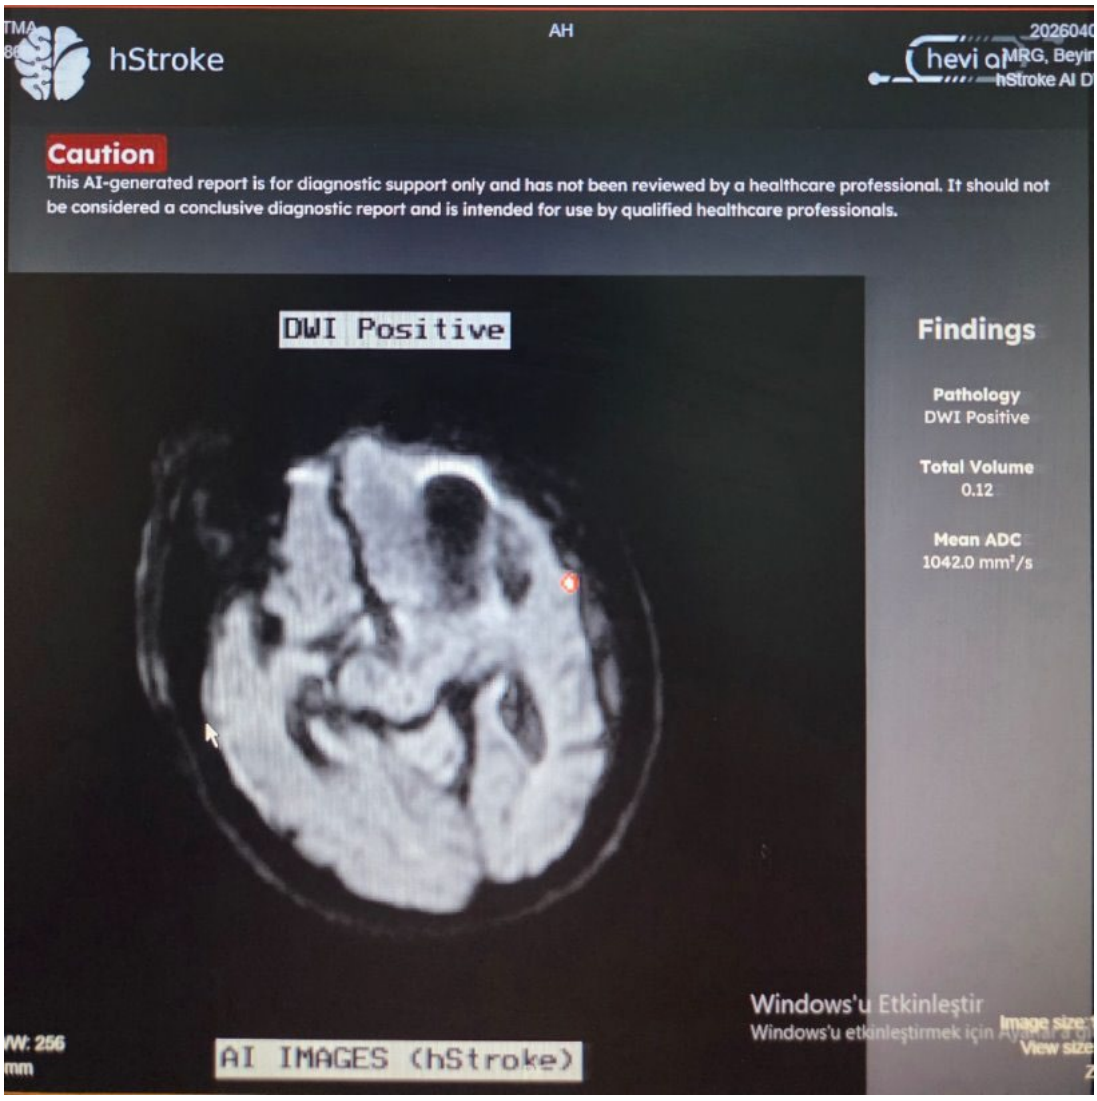

Ama

Resim 2. Örnekte görülen beyin difüzyon magnetik rezonans görüntülemede (MRG) difüzyon kısıtlamasının görüldüğü bir alanı kırmızı ile işaretlemiş ama klinik olarak işaretlediği alan iskemi ile uyumlu olarak görülmemeli, yani aslında filmi pozitif olarak raporlamış ama aslında o küçük noktasal difüzyon kısıtlamasını klinisyen doktor artefakt olarak değerlendirmeli, iskemi olarak kabul etmemektedir.

2) İntraoperatif (Ameliyat İçi) Yardım: Yapay zekâ, tümör rezeksiyonu sırasında kritik yapıları belirleme ve komplikasyon risklerini azaltma gibi konularda gerçek zamanlı navigasyon ve rehberlik sağlar. Örneğin, kendiliğinden konumlanan mikroskoplar ve endoskoplar veya otomatik görüntüleme rehberli (nöronavigasyon) cihazlar hasta sonuçlarını iyileştirmek ve nöroşirürjikal işlem hatalarını azaltmak için ameliyathanede kullanılmaktadır. Ayrıca, artırılmış gerçeklik veri gözlükleriyle cerrahi prosedürler yapilabiliyor. Bu uygulamalar, MRG görüntülerini gerçek cerrahi durumla birleştirmektedir.

3) ***Robotik cerrahi ve Simülasyon:*** Yapay zekâ, minimal invaziv prosedürler için nöro-robotik sistemleri geliştiriyor. Yapay zekâ destekli eğitmenler, cerrahların tekniklerini simülatörler üzerinde analiz ederek onları eğitiyor. Örneğin, robot destekli derin beyin stimülatörü yerleştirme, epilepsi cerrahisinde endoskopik hemisfer rezeksiyonu, omurgaya vida fiksasyonu yapılabiliyor. Robot desteği, elektrotların veya vidaların yerleştirilmesinde yüksek hassasiyet ve doğruluk sağlarken verimliliği de artırmak için kullanılabilir. Robot destekli stereotaksik fiksasyon tutarlılığı artırmayı, hataları azaltmayı, ameliyat süresini kısaltmayı ve cerrahi komplikasyonları azaltmayı başarmıştır.

4) Postoperatif (Ameliyat Sonrası) Yönetim ve Tedavi: Yapay zekâ olası komplikasyonları erken tespit etmek için yoğun bakım ünitelerindeki (YBÜ) hasta verilerini takip ediyor. Örneğin, YBÜ'deki hastaların laboratuvar sonuçlarının, radyolojik görüntülerinin, elektroensefalografi (EEG) sonuçlarının veya kafa içi basınç monitörizasyon değerlerinin analizini yapabiliyor; travmatik beyin hasarı sonrası mortalite tahminini veya subaraknoid kanama sonrası vazospazm ve geç dönem serebral iskemi olasılığının tahminini sağlıyor; böylece YBÜ'deki hasta bakımını iyileştiriyor.

2. Nöroşirurjinin Gelecekteki Yapay Zekâ Uygulamaları

1) ***Telenöroşirurji:*** Dünya genelinde otuz dokuz ülkede tek bir aktif nöroşirurjiyen bile bulunmadığı tahmin edilmektedir. Bazı düşük ve orta gelirli ülkelerde hastaların acil nöroşirurji bakımı almak için 2 saatten fazla yolculuk yapmaları gerekmektedir. Yapay zekâ yardımıyla gerçekleştirilen telenöroşirurji, yüksek kaliteli sağlık hizmetlerine erişimdeki mevcut eşitsizliklerin bazılarını giderebilir. Akıllı telefon uygulamaları, hastalara sağlık hizmeti sağlayıcılarına kolay erişim imkanı sunabilir. Yapay zekâ, sinir sisteminin hastalıklarının erken teşhisi için mobil telefon uygulamaları geliştirmek amacıyla da kullanılabilir.

2) ***"Zihin kontrolü" ve "Nöral bypass":*** Yapay zekâ, felçli hastaların bazı duyusal ve motor fonksiyonlarını geri kazandırmak, sağlıklı insanların motor yeteneklerini geliştirmek ve yeni nesil robotların geliştirilmesini kolaylaştırmak için kullanılabilir. Yapay zekâ, beyin korteksinin aktivasyonunu anlayabilir ve beyin motor korteksinden felçli bir kişinin kaslarına sinyaller göndererek motor kontrolünü geri kazandırabilir.

3) ***"Kişiselleştirilmiş tıp" ve "Hassas tıp":*** Büyük miktarda klinik verinin elde edilmesinin artmasıyla birlikte, "kişiselleştirilmiş tıp" ve "hassas tıp", sağlık sonuçlarını tahmin etmek, hastalık seyrini öngörmek, hastalıkları önlemek ve cerrahi komplikasyonları en aza indirmek için nicel modeller oluşturmayı hedeflemektedir. Hem "kişiselleştirilmiş tıp" hem de "hassas tıp" yapay zekadan faydalanabilir.

SONUÇ

Sonuç olarak yapay zeka, nöroşirurjide daha güvenli ve etkili uygulamaların önünü açarken, gelecekte sağlık hizmetlerinde önemli bir dönüşüm sağlayacaktır.

KAYNAKÇA

1) Noh SH, Cho PG, Kim KN, Kim SH, Shin DA. Artificial Intelligence for Neurosurgery : Current State and Future Directions. J Korean Neurosurg Soc. 2023 Mar;66(2):113-120. doi: 10.3340/jkns.2022.0130. Epub 2022 Sep 20. PMID: 36124365; PMCID: PMC10009243.

2) Mofatteh M. Neurosurgery and artificial intelligence. AIMS Neurosci. 2021 Aug 6;8(4):477-495. doi: 10.3934/Neuroscience.2021025. PMID: 34877400; PMCID: PMC8611194.

3) Yılmaz, A., & Ölçer, İ. (2021). YAPAY ZEKANIN CERRAHİ UYGULAMALARA ENTEGRASYONU. Beykent Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 13(2), 21-27. https://doi.org/10.20854/bujse.873770

Vücut Haritası ve 3D modelleme: Yapay Zeka ile Anatomik Simulasyon (Bir Diz Eklemi Modeli)

Ece Özbayram[1], Damla Şahin[2]

[1] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Lisans Öğrencisi, email:

[2] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi Anatomi Anabilim Dalı, Öğr. Gör. Dr., dsahin@bandirma.edu.tr

Özet

Bu derleme çalışmasında üç boyutlu (3D) baskı teknolojisinin diz eklem anatomisi eğitimindeki yeri incelenmiştir. Geleneksel anatomi eğitim yöntemlerinin sınırlılıkları göz önünde bulundurularak, 3D baskılı modellerin eğitimdeki katkıları literatür eşliğinde değerlendirilmiştir. Diz eklemi gibi kompleks anatomik bölgelerde üç boyutlu düşünmenin geliştirilmesi büyük önem taşımaktadır. Bu bağlamda katmanlı ve fonksiyonel bir diz eklem modelinin oluşturulma süreci de tanımlanmıştır. Literatür bulguları, 3D baskı modellerinin özellikle mekânsal algı ve yapısal ilişkilerin anlaşılmasında önemli katkı sağladığını, ancak tek başına yeterli bir eğitim yöntemi olmadığını göstermektedir. Bu nedenle bu modellerin geleneksel anatomi eğitimi yöntemleri ile birlikte kullanılması önerilmektedir.

Anahtar kelimeler: 3D baskı, anatomi eğitimi, diz eklemi, modelleme, eğitim teknolojisi

1. Giriş

Anatomi eğitimi, insan vücudunun üç boyutlu yapısının ve anatomik ilişkilerinin doğru şekilde kavranmasını gerektiren temel bir bilim dalıdır (Estai & Bunt, 2016; McLachlan et al., 2004). Özellikle diz eklemi gibi kemik, menisküs ve ligamentlerin kompleks organizasyon gösterdiği bölgelerde, üç boyutlu yapının algılanması öğrenciler için öğrenilmesi güç bir alan oluşturmaktadır (Iwanaga et al., 2021). Bu durum, öğrencilerin bu yapıların birbirleriyle olan fonksiyonel ilişkilerini anlamasını zorlaştırmaktadır.

Kadavra diseksiyonu materyalleri anatomi eğitiminde uzun yıllardır altın standart olarak kabul edilmekte ve öğrencilerin üç boyutlu anatomik ilişkileri anlamasında önemli rol oynamaktadır (McLachlan et al., 2004). Bununla birlikte, donör temini, maliyet, etik sınırlamalar ve laboratuvar gereksinimleri gibi faktörler kadavra temelli eğitimin sürdürülebilirliğini zorlaştırmaktadır (Estai & Bunt, 2016; Guimarães et al., 2017). Ayrıca kadavra sayısının sınırlı olması, öğrencilerin bireysel öğrenme fırsatlarını da kısıtlayabilmektedir.

Bu sınırlılıklar, anatomi eğitiminde alternatif ve tamamlayıcı öğretim yöntemlerine olan ilgiyi artırmıştır. Özellikle son yıllarda üç boyutlu baskı, sanal gerçeklik ve dijital modelleme teknolojileri anatomi öğretiminde önemli araçlar olarak öne çıkmaktadır (Erolin, 2019; Keenan & Ben Awadh, 2019; Moro et al., 2017; Zhao et al., 2020). Bu teknolojiler, öğrencilerin aktif öğrenme sürecine katılımını artırarak öğrenmeyi daha etkileşimli hale getirmektedir.

2. 3D Teknolojilerin Anatomi Eğitimindeki Yeri

2.1 3D Baskı Teknolojisinin Avantajları

3D baskı teknolojisi, anatomi eğitiminde düşük maliyetli, erişilebilir ve tekrarlanabilir modeller üretme imkânı sağlamaktadır (Brumpt et al., 2023; Fahrni & Sabatasso, 2025). Bu modellerin en önemli avantajlarından biri, öğrencilerin anatomik yapıları fiziksel olarak inceleyebilmesine olanak tanımasıdır. Bu durum, özellikle dokunsal öğrenme stiline sahip öğrenciler için önemli bir avantaj sağlamaktadır (Garas et al., 2018; Lim et al., 2016).

Literatürde, 3D baskılı anatomik modellerin öğrencilerin öğrenme performansında kadavra materyallerine alternatif veya tamamlayıcı olarak kullanılabileceği gösterilmiştir (Lim et al., 2016). Bunun yanı sıra, bu modellerin öğrencilerin derse aktif katılımını artırdığı ve öğrenme motivasyonunu olumlu yönde etkilediği bildirilmektedir (Smith et al., 2018). Ayrıca öğrencilerin bireysel çalışma imkânı bulabilmesi, öğrenmenin sürekliliğini desteklemektedir.

Güncel çalışmalar, 3D baskılı modellerin özellikle eğitimde değerli bir kaynak olduğunu, ancak öğretim üyelerinin bu modelleri kadavra temelli eğitimin yerine değil tamamlayıcısı olarak değerlendirdiğini göstermektedir (Paymard et al., 2025). Bu durum, 3D baskı teknolojisinin tek başına yeterli bir yöntem olmadığını, ancak uygun şekilde entegre edildiğinde güçlü bir eğitim aracı olabileceğini ortaya koymaktadır.

2.2 Dijital ve Sanal Modeller ile Karşılaştırma

Sanal gerçeklik ve 3D modelleme yazılımları anatomi eğitiminde giderek yaygınlaşmaktadır (Erolin, 2019; Moro et al., 2017). Bu teknolojiler, öğrencilerin anatomik yapıları dinamik olarak inceleyebilmesine ve farklı açılardan değerlendirebilmesine olanak tanımaktadır.

Sanal gerçeklik modellerinin bazı anatomik bölgelerde kadavra materyalleri ile benzer öğrenme çıktıları sağladığı gösterilmiştir (Ail et al., 2024). Özellikle ekstremite anatomisinde sanal modeller ile kadavra eğitimi arasında anlamlı fark bulunmaması, bu bölgelerde 3D teknolojilerin etkili bir destek aracı olabileceğini düşündürmektedir (Ail et al., 2024).

Buna karşın, 3D modelleme yazılımlarının tek başına ana öğretim yöntemi olarak kullanılması bazı durumlarda öğrencilerde bilişsel yük artışına neden olabilmektedir (Alexander et al., 2024). Öğrencilerin hem yazılımı öğrenmesi hem de anatomik bilgiyi işlemeye çalışması, öğrenme sürecini zorlaştırabilmektedir. Bu nedenle dijital modellerin uygun pedagojik yapılandırma ile ve diğer öğretim yöntemleriyle birlikte kullanılması önerilmektedir (Alexander et al., 2024; Barteit et al., 2021).

3. Diz Eklem Modeli İçin Teknik Yaklaşım

Bu çalışma kapsamında açık kaynaklı BT verileri kullanılarak 3D Slicer (version 5.6, Brigham and Women's Hospital, Boston, MA, USA) programında diz eklemine ait üç boyutlu bir model oluşturulmuştur. Model üzerinde gerçekleştirilen segmentasyon ve dijital düzenleme işlemleri ile femur ve tibia bileşenleri ayrılmıştır. Bu tür dijital modelleme süreçlerinin, anatomik doğruluğun korunması ve eğitimsel değerinin artırılması açısından kritik olduğu bildirilmektedir (Lim et al., 2016; Brumpt et al., 2023). Modelin eğitimsel değerini artırmak amacıyla diz ekleminin temel ligamentleri katmanlı olarak temsil edilmiştir. Lig. cruciatum anterius, lig. cruciatum posterius, lig. meniscofemorale anterius, lig. meniscofemorale posterius, lig. collaterale fibulare, lig. collaterale tibiale ve eklem kapsülü ilişkisi elastik materyal kullanılarak modele entegre edilmiştir. Bu sayede

model yalnızca statik bir yapı olmaktan çıkarılarak fonksiyonel bir eğitim aracına dönüştürülmüştür.

Eklem hareketine izin veren yapı sayesinde fleksiyon ve ekstansiyon sırasında ligamentlerin gerilme yönleri gözlemlenebilmekte ve bu durum öğrencilerin biyomekanik ilişkileri daha iyi anlamasına katkı sağlamaktadır. Bu tür fonksiyonel modeller, özellikle ortopedik anatominin kavranmasında önemli avantajlar sunmaktadır.

4. Sonuç ve Genel Değerlendirme

3D baskı teknolojisi, anatomi eğitiminde tamamlayıcı bir araç olarak önemli avantajlar sunmaktadır. Düşük maliyet, erişilebilirlik ve kişiselleştirilebilirlik gibi özellikleri sayesinde geniş öğrenci gruplarına hitap edebilmektedir (Brumpt et al., 2023; Paymard et al., 2025).

Literatür, 3D baskılı modellerin öğrenme çıktıları açısından kadavra materyalleri ile karşılaştırılabilir sonuçlar verdiğini ve öğrenci memnuniyetini artırdığını göstermektedir (Lim et al., 2016; Smith et al., 2018). Bununla birlikte, kadavra temelli eğitimin gerçek doku özelliklerini ve anatomik varyasyonları göstermesi nedeniyle hâlâ vazgeçilmez olduğu vurgulanmaktadır (McLachlan et al., 2004).

Dijital ve sanal modeller üzerine yapılan çalışmalar da benzer şekilde bu teknolojilerin tamamlayıcı rolünü desteklemektedir (Ail et al., 2024; Barteit et al., 2021). Bu bağlamda, 3D baskı modellerinin en etkili kullanımının hibrit bir eğitim yaklaşımı içerisinde olduğu söylenebilir.

Sonuç olarak, katmanlı ve fonksiyonel diz eklem modeli, öğrencilerin hem anatomik hem de fonksiyonel ilişkileri anlamasını kolaylaştıran etkili bir öğretim materyali olarak değerlendirilebilir. Gelecekte yapılacak çalışmaların, bu tür modellerin öğrenme çıktıları üzerindeki etkisini nicel olarak değerlendirmesi, anatomi eğitiminde teknoloji entegrasyonunun daha sistematik hale gelmesine katkı sağlayacaktır.

Kaynakça

Alexander, S. M., Pogson-Morowitz, K. B., & Johnson, C. S. (2024). Three-dimensional modeling in anatomy—Tool or terror? *Anatomical Sciences Education, 17*, 878–882. https://doi.org/10.1002/ase.2401

Ail, G., Freer, F., Chan, C. S., Jones, M., Broad, J., & Canale, G. P. (2024). A comparison of virtual reality anatomy models to prosections. *Anatomical Sciences Education, 17*, 763–769. https://doi.org/10.1002/ase.2366

Barteit, S., Lanfermann, L., Bärnighausen, T., Neuhann, F., & Beiersmann, C. (2021). Augmented, mixed, and virtual reality-based medical education. *JMIR Serious Games, 9*, e29080. https://doi.org/10.2196/29080

Brumpt, E., Bertin, E., Tatu, L., & Louvrier, A. (2023). 3D printing as a pedagogical tool for teaching anatomy. *BMC Medical Education, 23*, 783. https://doi.org/10.1186/s12909-023-04783-2

Erolin, C. (2019). Interactive 3D digital models in anatomy education. *Medical Science Educator, 29*, 1–10. https://doi.org/10.1007/s40670-019-00740-0

Estai, M., & Bunt, S. (2016). Best teaching practices in anatomy education. *Annals of Anatomy, 208*, 151–157. https://doi.org/10.1016/j.aanat.2016.08.001

Fahrni, S., & Sabatasso, S. (2025). 3D modelling in anatomy teaching: State of the art and pilot investigations for its application. *Translational Research in Anatomy, 41*, 100444. https://doi.org/10.1016/j.tria.2025.100444

Garas, M., Vaccarezza, M., Newland, G., McVay-Doornbusch, K., & Hasani, J. (2018). 3D printed anatomical models. *Annals of Anatomy, 219*, 57–64. https://doi.org/10.1016/j.aanat.2018.05.004

Guimarães, B., Santos, P., & Amador, F. (2017). Rethinking anatomy: How to overcome challenges of medical education's evolution. *Acta Medica Portuguesa, 30*, 134–140. https://doi.org/10.20344/amp.7898

Iwanaga, J., Loukas, M., Dumont, A. S., & Tubbs, R. S. (2021). A review of anatomy education during and after the COVID-19 pandemic: Revisiting traditional and modern methods. *Clinical Anatomy, 34*, 108–114. https://doi.org/10.1002/ca.23655

Keenan, I. D., & Ben Awadh, A. (2019). Integrating 3D visualisation technologies in undergraduate anatomy education. *Clinical Anatomy, 32*, 39–53. https://doi.org/10.1002/ca.23348

Lim, K. H. A., Loo, Z. Y., Goldie, S. J., Adams, J. W., & McMenamin, P. G. (2016). Use of 3D printed models in medical education: A randomized control trial comparing 3D prints versus cadaveric materials. *Anatomical Sciences Education, 9*, 213–221. https://doi.org/10.1002/ase.1573

McLachlan, J. C., Bligh, J., Bradley, P., & Searle, J. (2004). Teaching anatomy without cadavers. *Medical Education, 38*, 418–424. https://doi.org/10.1111/j.1365-2929.2004.01795.x

Moro, C., Štromberga, Z., Raikos, A., & Stirling, A. (2017). Virtual and augmented reality in anatomy education. *Anatomical Sciences Education, 10*, 549–559. https://doi.org/10.1002/ase.1696

Paymard, M., Naderian, H., Hassani Bafrani, H., Azami Tameh, A., Mirsafi Niasar, M., Rahimi, H., & et al. (2025). An evaluation of the use of 3D-printed anatomical models in anatomy education. *Surgical and Radiologic Anatomy*. https://doi.org/10.1007/s00276-025-03199-3

Smith, C. F., Tollemache, N., Covill, D., & Johnston, M. (2018). Take away body parts! An investigation into the use of 3D-printed anatomical models in undergraduate anatomy education. *Anatomical Sciences Education, 11*, 44–53. https://doi.org/10.1002/ase.1718

Ye, Z., Dun, A., Jiang, H., Nie, C., Zhao, S., Wang, T., & Zhai, J. (2020). Meta-analyzing the efficacy of 3D printed models in anatomy education. *BMC Medical Education, 20*, 335. https://doi.org/10.1186/s12909-020-02203-7

Zhao, J., Xu, X., Jiang, H., & Ding, Y. (2020). The effectiveness of virtual reality-based technology on anatomy teaching: A meta-analysis. *BMC Medical Education, 20*, 127. https://doi.org/10.1186/s12909-020-02181-w

Biyokimyasal parametreler ve yapay zekâ ile biyobelirteç keşfi ve erken tanı

Kader Şahin, Doç. Dr., Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Balıkesir, Türkiye
kadersahin@bandirma.edu.tr

Hüseyin Ali Erdoğan, Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Balıkesir, Türkiye 2513901008@ogr.bandırma.edu.tr

Özet

Biyobelirteçler, hastalıkların erken tanısı, prognozu ve tedaviye yanıtın değerlendirilmesinde kritik öneme sahiptir. Ancak geleneksel biyobelirteç keşif yöntemleri, yüksek boyutlu biyolojik verilerin analizinde sınırlı kalmaktadır. Son yıllarda yapay zekâ (YZ), özellikle makine öğrenmesi (ML) ve derin öğrenme (DL) yaklaşımları, biyobelirteç keşif süreçlerinde önemli ilerlemeler sağlamıştır (LeCun, Bengio ve Hinton, 2015). Bu derlemede, biyokimyasal parametreler temelinde yapay zekâ destekli biyobelirteç keşif süreçleri kapsamlı olarak ele alınmıştır. Klinik, genomik, proteomik ve metabolomik verilerin entegre edildiği multi-omics yaklaşımlar, hastalıkların moleküler mekanizmalarının daha iyi anlaşılmasını sağlamaktadır (Chen ve Snyder, 2013). Ayrıca özellik seçimi yöntemleri ve gelişmiş algoritmalar sayesinde daha güvenilir biyobelirteçler belirlenebilmektedir. Yapay zekâ tabanlı modeller, kanser başta olmak üzere birçok hastalıkta erken tanı ve risk tahmini süreçlerini geliştirmektedir (Topol, 2019). Bununla birlikte veri kalitesi, model açıklanabilirliği ve etik sorunlar gibi sınırlamalar da bulunmaktadır. Sonuç olarak, yapay zekâ biyobelirteç keşfinde güçlü bir araç olup hassas tıbbın gelişiminde önemli rol oynamaktadır.

Anahtar Kelimeler

biyobelirteç, yapay zekâ, multi-omics, makine öğrenmesi, erken tanı

Giriş

Biyobelirteçler, normal biyolojik süreçleri, patolojik durumları veya tedaviye verilen yanıtları yansıtan ölçülebilir parametrelerdir. Günümüzde erken tanı ve hastalık yönetimi açısından biyobelirteçlerin önemi giderek artmaktadır (Munnangi ve Satheeskumar, 2025). Özellikle kanser gibi kompleks hastalıklarda erken tanı, tedavi başarısını doğrudan etkilemektedir.

Geleneksel biyobelirteç keşif yöntemleri çoğunlukla sınırlı veri setleri ve doğrusal analiz yaklaşımlarına dayanmaktadır. Ancak modern biyoteknolojik gelişmeler ile birlikte genomik, proteomik ve metabolomik alanlarda büyük veri üretimi gerçekleşmiştir. Bu durum, klasik istatistiksel yöntemlerin yetersiz kalmasına neden olmuş ve daha güçlü analiz araçlarına ihtiyaç doğurmuştur (Libbrecht ve Noble, 2015).

Yapay zekâ, yüksek boyutlu ve karmaşık veri setlerini analiz edebilme yeteneği sayesinde biyobelirteç keşfinde önemli bir dönüşüm sağlamaktadır. Bu derlemenin amacı, yapay zekâ temelli biyobelirteç keşfi yaklaşımlarını sistematik olarak incelemek ve güncel gelişmeleri ortaya koymaktır.

Derleme

Yapay Zekâ ve Biyobelirteç Keşfi

Yapay zekâ, veri odaklı karar verme süreçlerini optimize eden algoritmalar bütünüdür. Biyomedikal alanda, özellikle büyük veri analizi gerektiren durumlarda önemli avantajlar sunmaktadır. Makine öğrenmesi algoritmaları, biyolojik verilerdeki karmaşık ilişkileri ortaya çıkararak potansiyel biyobelirteçlerin belirlenmesini sağlar (Libbrecht ve Noble, 2015).

Bu süreçte sınıflandırma, regresyon ve kümeleme yöntemleri sıklıkla kullanılmaktadır. Özellikle hastalık durumlarının tahmini ve hasta gruplarının ayrıştırılması açısından yapay zekâ modelleri yüksek doğruluk oranlarına ulaşabilmektedir (Topol, 2019).

Multi-Omics Veri Entegrasyonu

Multi-omics yaklaşımlar, farklı biyolojik veri katmanlarının birlikte analiz edilmesini içerir. Genomik, proteomik, metabolomik ve epigenomik verilerin entegrasyonu, hastalıkların moleküler düzeyde daha kapsamlı anlaşılmasını sağlar (Chen ve Snyder, 2013).

Bu süreçte veri ön işleme büyük önem taşır. Normalizasyon, eksik veri tamamlama ve gürültü giderme adımları model performansını doğrudan etkilemektedir. Ardından, özellik seçimi yöntemleri kullanılarak en anlamlı değişkenler belirlenir. LASSO ve Random Forest gibi algoritmalar bu aşamada sıklıkla tercih edilmektedir (Darbandi vd., 2024).

Multi-omics ve yapay zekâ entegrasyonu, özellikle kompleks hastalıkların heterojen yapısının anlaşılmasında kritik rol oynamaktadır.

Makine Öğrenmesi Yöntemleri

Makine öğrenmesi, biyobelirteç keşfinde en yaygın kullanılan yöntemlerden biridir. Denetimli öğrenme yöntemleri, etiketli veri üzerinden model eğitimi yaparken, denetimsiz öğrenme yöntemleri veri içindeki gizli yapıları keşfetmeye odaklanır.

Random Forest, yüksek doğruluk ve overfitting'e karşı dayanıklılığı nedeniyle yaygın olarak kullanılmaktadır. Support Vector Machine (SVM) ise özellikle sınıflandırma problemlerinde güçlü performans göstermektedir. LASSO regresyon yöntemi ise değişken seçimi açısından önemli avantajlar sunmaktadır (Libbrecht ve Noble, 2015).

Bu yöntemler sayesinde yüksek boyutlu veri setlerinde en anlamlı biyobelirteç adayları belirlenebilmektedir.

Derin Öğrenme ve Görüntü Analizi

Derin öğrenme, yapay sinir ağlarına dayalı bir yaklaşım olup özellikle büyük veri setlerinde yüksek performans göstermektedir. Tıbbi görüntüleme alanında derin öğrenme uygulamaları önemli gelişmeler sağlamıştır.

MRI, CT ve histopatolojik görüntüler üzerinden yapılan analizlerde derin öğrenme modelleri, hastalıkların erken tanısında yüksek doğruluk oranlarına ulaşmaktadır (Litjens et al., 2017). Örneğin, deri kanseri tanısında derin öğrenme modellerinin dermatolog seviyesinde performans gösterdiği bildirilmiştir (Esteva vd., 2017).

Bu durum, yapay zekânın klinik karar destek sistemlerinde kullanımını artırmaktadır.

Klinik Uygulamalar

Yapay zekâ destekli biyobelirteçler birçok hastalıkta uygulanmaktadır. Kanser tanısı ve prognoz tahmini, bu alandaki en önemli uygulamalardan biridir (Darbandi vd., 2024).

Ayrıca Alzheimer hastalığında erken tanı için görüntüleme verilerinin analizi ve kardiyovasküler hastalıklarda risk tahmini gibi alanlarda da yapay zekâ başarıyla kullanılmaktadır (Topol, 2019).

Liquid biopsy, serum protein analizi ve multi-omics veri entegrasyonu gibi yaklaşımlar, klinik uygulamalarda giderek yaygınlaşmaktadır.

Zorluklar ve Sınırlamalar

Yapay zekâ uygulamalarında karşılaşılan en önemli sorunlardan biri veri kalitesidir. Eksik veya hatalı veriler model performansını olumsuz etkileyebilir. Ayrıca model açıklanabilirliği, özellikle klinik uygulamalarda önemli bir gerekliliktir (Topol, 2019).

Overfitting problemi, modelin eğitim verisine aşırı uyum sağlaması sonucu genelleme yeteneğinin azalmasına neden olabilir. Bunun yanı sıra etik ve veri güvenliği konuları da dikkatle ele alınmalıdır.

Gelecek Perspektifi

Yapay zekâ ve biyobelirteç araştırmalarının geleceği oldukça umut vericidir. Hassas tıp uygulamaları, birey bazlı tedavi yaklaşımlarının geliştirilmesini sağlamaktadır.

Dijital ikiz teknolojileri ve gerçek zamanlı veri analizi, hastalıkların daha erken ve doğru şekilde tespit edilmesine olanak tanıyacaktır (Chen ve Snyder, 2013).

Bu gelişmeler, sağlık hizmetlerinin daha etkin ve kişiselleştirilmiş hale gelmesini sağlayacaktır.

Sonuç

Bu derleme, yapay zekâ destekli biyobelirteç keşfinin biyomedikal araştırmalarda giderek artan önemini ortaya koymaktadır. Özellikle multi-omics veri entegrasyonu ile birlikte kullanılan makine öğrenmesi ve derin öğrenme yaklaşımları, klasik yöntemlere kıyasla daha yüksek doğrulukta ve güvenilir sonuçlar sunmaktadır. Bu durum, hastalıkların erken tanısı, prognoz tahmini ve tedaviye yanıtın değerlendirilmesi açısından önemli avantajlar sağlamaktadır (Topol, 2019).

Yapay zekâ temelli modellerin, özellikle kanser, nörodejeneratif hastalıklar ve kardiyovasküler hastalıklar gibi kompleks ve heterojen yapıya sahip hastalıklarda biyobelirteç keşfini hızlandırdığı görülmektedir. Klinik veriler ile genomik ve proteomik verilerin birlikte analiz edilmesi, hastalıkların moleküler düzeyde daha iyi anlaşılmasına katkıda bulunmaktadır (Chen ve Snyder, 2013). Bu entegrasyon, kişiselleştirilmiş tedavi yaklaşımlarının geliştirilmesine de zemin hazırlamaktadır.

Bununla birlikte, yapay zekâ uygulamalarının klinik pratiğe tam olarak entegre edilebilmesi için bazı önemli zorlukların aşılması gerekmektedir. Veri kalitesinin artırılması, veri standardizasyonunun sağlanması ve farklı veri kaynaklarının uyumlu hale getirilmesi bu sürecin temel gereklilikleri arasında yer almaktadır. Ayrıca, yapay zekâ modellerinin açıklanabilirliğinin artırılması, klinik karar destek sistemlerine olan güvenin sağlanması açısından kritik öneme sahiptir.

Etik ve veri güvenliği konuları da göz ardı edilmemelidir. Hasta verilerinin gizliliği, veri paylaşım politikaları ve algoritmik önyargı gibi konular, yapay zekâ uygulamalarının sürdürülebilirliği açısından önemli riskler barındırmaktadır. Bu nedenle, multidisipliner yaklaşımlar ile hem teknik hem de etik boyutların birlikte ele alınması gerekmektedir.

Gelecek perspektifinde, yapay zekâ ve biyobelirteç araştırmalarının daha da entegre hale gelmesi beklenmektedir. Dijital ikiz modelleri, gerçek zamanlı hasta izleme sistemleri ve büyük veri analitiği gibi yenilikçi yaklaşımlar, hastalıkların daha erken ve doğru bir şekilde teşhis edilmesine olanak tanıyacaktır. Bunun yanı sıra, yapay zekâ destekli biyobelirteçlerin klinik validasyonu ve standardizasyonu, bu teknolojilerin rutin klinik uygulamalarda yer almasını hızlandıracaktır.

Sonuç olarak, yapay zekâ destekli biyobelirteç keşfi, hassas tıp uygulamalarının temel taşlarından biri haline gelmiştir. Bu alandaki teknolojik gelişmelerin, yakın gelecekte tanı ve tedavi süreçlerinde önemli dönüşümler yaratması beklenmektedir. Ancak bu dönüşümün etkin ve güvenilir bir şekilde gerçekleşebilmesi için veri kalitesi, model güvenilirliği ve etik standartların titizlikle ele alınması gerekmektedir.

Kaynakça

Chen, R., & Snyder, M. (2013). Systems biology: Personalized medicine for the future. *Current Opinion in Pharmacology, 13*(5), 623–628. https://doi.org/10.1016/j.coph.2013.05.001

Darbandi, M. R., et al. (2024). Artificial intelligence breakthroughs in breast cancer diagnosis. *European Journal of Cancer, 209*, 114227. https://doi.org/10.1016/j.ejca.2024.114227

Esteva, A., et al. (2017). Dermatologist-level classification of skin cancer. *Nature, 542*, 115–118. https://doi.org/10.1038/nature21056

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*, 436–444. https://doi.org/10.1038/nature14539

Libbrecht, M. W., & Noble, W. S. (2015). Machine learning in genomics. *Nature Reviews Genetics, 16*, 321–332. https://doi.org/10.1038/nrg3920

Litjens, G., et al. (2017). Deep learning in medical imaging. *Medical Image Analysis, 42*, 60–88. https://doi.org/10.1016/j.media.2017.07.005

Munnangi, S., & Satheeskumar, R. (2025). AI biomarker discovery. *Oral Oncology Reports, 14*, 100749. https://doi.org/10.1016/j.oor.2025.100749

Topol, E. J. (2019). High-performance medicine. *Nature Medicine, 25*, 44–56. https://doi.org/10.1038/s41591-018-0300-7

İlaç Seçimi ve Doz Optimizasyonu: Yapay Zekâ ile Personalize Farmakoterapi

Zehra DENİZ* – Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Balıkesir, Türkiye. E-posta: zehra.deniz@ogr.bandirma.edu.tr

Dr. Öğr. Üyesi Fulden KÜÇÜK – Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Balıkesir, Türkiye. E-posta: fuldenkucuk@bandirma.edu.tr

Özet

Kişiselleştirilmiş farmakoterapi; ilaç tedavilerini hastanın genetik, klinik ve çevresel özelliklerine göre uyarlanmasını hedefler. Pratikte aynı ilacın farklı hastalarda değişken yanıtlar oluşturması; standart tedavi yaklaşımlarının kullanımını sınırlandırarak yapay zekânın kullanımını –hasta verilerinin analiziyle tedavi seçimi ve doz ayarlaması noktasında- destekler. Bu derlemede yapay zekânın ilaç seçimi ve doz optimizasyonu süreçlerindeki rolü klinik açıdan ele alınmaktadır.

Yapay zekâ sistemleri, tedavi yanıtını ve advers etki riskini öngörerek; farklı tedavi seçeneklerini karşılaştırıp hasta bazında en uygun tedavi yaklaşımını belirleyebilir. Bu sistemlere farmakogenomik verilerin entegrasyonu da özellikle ilaç seçimi sürecinde belirli hasta alt gruplarında daha etkili ve güvenli tedavi seçenekleri uygulanmasını mümkün kılar. Doz optimizasyonunda ise MIPD (model-informed precision dosing) ile tedavi dinamik olarak hasta yanıtına göre düzenlenebilir. Tüm bunların kullanımına örnek olarak; warfarin, onkolojik tedaviler ve antibiyotik kullanımını verebilir ve bu örneklerle yapay zekâ destekli yaklaşımların potansiyelini görebiliriz. Bunların dışında veri gizliliği, algoritmik yanlılık ve klinik sorumluluk gibi etik konular noktasında da dikkatli olunmalıdır. Sonuç olarak yapay zekâ; hekimin yerini almadan yalnızca karar sürecini destekleyen ve kişiselleştirilmiş farmakoterapi uygulamalarını güçlendiren bir araç olarak değerlendirilmelidir.

Anahtar Kelimeler: Kişiselleştirilmiş farmakoterapi, yapay zekâ, ilaç seçimi, doz optimizasyonu, klinik karar destek sistemleri

Giriş

Klasik farmakoterapi her hastada aynı klinik rehberlere dayanarak yürütülür. Ancak hastaların tedaviye yanıtı önemli ölçüde farklılık gösterebilir (Topol, 2019). Klinik uygulamada hekimler çoğunlukla "hangi tedavi ve hangi doz?" sorularına yanıt arar. Klinik deney sonuçlarının sunduğu çerçevede bireylerin önemli bir kısmı ortalama yanıta tam olarak uymaz (Beam & Kohane, 2018). İlaç etkileşimleri ve eşlik eden hastalıklar bu karmaşıklığı ekstra artırır. Hastanın klinik durumunun zaman içinde değişmesiyle de doz gereksinimlerinin farklılaşması beklenebilir. Bu nedenle geleneksel doz ayarlamaları sıklıkla deneme-yanılma yaklaşımına dayanır ve sonuçlar her zaman beklenen düzeyde çıkmayabilir (Minichmayr et al., 2024). Tabi bu durumda yapay zekâ çözümleri büyük veri üzerinden karar desteği sunmayı hedeflese de her klinik durumda yeterli ve yüksek kaliteli veri bulunmayabilir (Khude & Shende, 2025). Bu sınırları aşabilmek için kişiselleştirilmiş farmakoterapi yaklaşımı öne çıkmıştır. Hastaya ait genetik, klinik ve çevresel verilerin birlikte değerlendirilmesiyle tedavi stratejileri daha uygun bir hale getirilebilir. Bu yaklaşımla tedavi etkinliğini artırma ve advers olay riskini azaltma hedeflenmektedir ancak veri gizliliği ve güvenliği noktalarına da dikkat edilmelidir. (Collins & Varmus, 2015). Bu noktada yapay zekâ, hekimin yerine karar veren bir araçtan ziyade çok değişkenli hasta verisini analiz eden, tedavi seçimini ve doz ayarlamasını destekleyen bir klinik karar

yardımcısı olarak düşünülmelidir. Böylece ilaç seçimi ve doz optimizasyonu daha sistematik ve veri temelli bir çerçevede ele alınabilir.

Kişiselleştirilmiş farmakoterapi

Kişiselleştirilmiş farmakoterapi hastaların özelliklerine göre ilaç tedavisinin uyarlanmasını ifade eder. Bu yaklaşımda genetik profiller (örneğin ilaç metabolizmasında rol alan enzimler), klinik bulgular (yaş, karaciğer ve böbrek fonksiyonları, eşlik eden hastalıklar) ve çevresel etkenler (diyet, eşzamanlı ilaç kullanımı) birlikte değerlendirilir (Collins & Varmus, 2015). Genomik, proteomik ve metabolomik veriler ile klinik verilerin entegrasyonuyla ilaç yanıtını öngören modeller geliştirilebilir (Wang et al., 2023). Bunlar belirli genetik varyasyonların ilaç etkinliği veya toksisite ile ilişkisini ortaya koyan modellerdir. Örneğin, CYP2C19 gen varyantları klopidogrel yanıtını etkileyebilirken, HLA-B*57:01 aleli abakavir ile ilişkili aşırı duyarlılık reaksiyonlarıyla bağlantılıdır. Benzer şekilde, DPYD genindeki varyasyonlar fluoropirimidin grubu kemoterapilere bağlı toksisite riskini artırabilir. Bu tür farmakogenomik bilgiler doğru ilacın seçilmesinde kritik rol oynar. Karar sürecinin genetik veriler, klinik parametreler ve hasta özelliklerini birlikte değerlendiren modellerle desteklenmesiyle tedavi planı tek bir değişkene değil hasta bağlamının bütününe dayalı oluşturulur.

Yapay zekânın farmakoterapide kullanımı

Yapay zekâ, farmakoterapide özellikle heterojen veri setlerinin bütüncül analizinde kullanılır. Elektronik sağlık kayıtları, genetik veri tabanları, biyobelirteç verileri ve ilaç düzeyi ölçümleri bu veri kaynakları arasında yer alır (Beam & Kohane, 2018). Bu sistemler, klinik olarak üç temel çıktıya odaklanır: belirli bir tedaviden fayda görme olasılığının tahmini (yanıt tahmini), yan etki gelişme riskinin öngörülmesi (advers etki tahmini) ve mevcut alternatiflerin karşılaştırmalı olarak sıralanması (tedavi sıralaması) (Wang et al., 2023). Bu çıktıların doğrudan klinik karar sürecine entegre edilmesi "en uygun tedavi seçeneği" nin belirlenmesine katkı sağlar. Klinik karar destek sistemleri (CDSS), bu analizlerin pratikte kullanılmasını sağlar. Bu sistemler ilaç etkileşimlerini değerlendirme, hasta özelliklerine göre doz aralığı önerme ve alternatif tedavi seçeneklerini karşılaştırma gibi işlevler üstlenir (Khude & Shende, 2025). Ancak bu öneriler, bağımsız bir karar olarak değil, klinik bağlam içinde yorumlanması gereken girdiler olarak ele alınmalıdır.

İlaç seçimi ve doz optimizasyonu

Yapay zekâ, ilaç seçimi ve doz optimizasyonunda tamamlayıcı bir rol üstlenir. İlaç seçimi aşamasında hastaya ait veriler analiz edilerek tedavi seçenekleri etkinlik ve güvenlilik açısından sıralanır. Bu süreçte yanıt tahmini, advers etki tahmini ve tedavi sıralaması birlikte çalışır: bir tedavinin beklenen faydası, potansiyel riski ve alternatiflere göre üstünlüğü aynı anda değerlendirilir. Farmakogenomik örnekler bu sürecin önemli bileşenlerinden biridir. CYP2C19 varyantı taşıyan hastalarda klopidogrel yanıtının düşük olması alternatif antiplatelet ajanların tercih edilmesini gündeme getirir. HLA-B*57:01 pozitif hastalarda abakavir kullanımından kaçınılması veya DPYD eksikliğinde fluoropirimidin dozunun azaltılması bu yaklaşımın doğrudan klinik yansımalarıdır. Bu çerçeve onkoloji alanında da daha belirgin hale gelmiştir. Örneğin, EGFR mutasyonu pozitif akciğer kanserinde tirozin kinaz inhibitörlerinin tercih edilmesi veya HER2 pozitif meme kanserinde trastuzumab gibi hedefe yönelik tedavilerin seçilmesi, tedavi kararının doğrudan moleküler belirteçlere dayandırıldığı durumlardır. Yapay zekâ modelleri bu tür biyobelirteçleri klinik verilerle entegre ederek, hangi hastada hangi tedavinin daha yüksek yanıt olasılığına sahip olduğunu ve hangi hastada toksisite riskinin artabileceğini öngörebilir. Böylece "hangi ilaç neden seçilir?" sorusu; yalnızca önerilerle değil bireysel

yanıt olasılığı ve risk profili üzerinden yanıtlanır. Doz optimizasyonu ise MIPD ile yürütülür (Minichmayr et al., 2024). Model-informed precision dosing (MIPD), hastaya ait klinik verileri popülasyon temelli farmakokinetik/farmakodinamik modellerle birleştirerek dozun kişiselleştirilmesini sağlar. Farmakokinetik model ilacın vücuttaki maruziyetini; farmakodinamik model ise bu maruziyetin klinik etki veya toksisite ile ilişkisini açıklar. Bayesyen yaklaşımda önce popülasyon verilerine ve hasta özelliklerine dayalı bir başlangıç tahmini yapılır; tedavi sürecinde ölçülen ilaç düzeyi, biyobelirteç veya klinik yanıt modele eklendikçe hastaya özgü parametreler yeniden hesaplanır. Böylece doz, tek seferlik bir karar olmaktan çıkar ve hastanın gerçek yanıtına göre güncellenen dinamik bir sürece dönüşür. Bu mekanizma özellikle dar terapötik aralıklı ilaçlarda hedef maruziyete ulaşmayı ve toksisite riskini azaltmayı amaçlar ancak klinik kullanım için modelin doğrulanmış olması ve önerilerin hekim tarafından klinik bağlam içinde değerlendirilmesi gerekir (Darwich et al., 2021; Minichmayr et al., 2024; Polasek et al., 2019)

Klinik uygulamalar

Yapay zekâ destekli farmakoterapi yaklaşımları klinikte giderek daha fazla değerlendirilmektedir. En iyi çalışılmış örneklerden biri warfarin doz optimizasyonudur. Warfarin, dar terapötik aralığı olan, hastalar arası belirgin doz değişkenliği görülen ve düzenli INR izlemi gerektiren bir ilaç olması nedeniyle yapay zekâ destekli doz optimizasyonu için güçlü bir klinik örnek oluşturmaktadır. Özellikle tedavi başlangıcında yetersiz doz tromboembolik olay riskini artırırken aşırı doz kanama riskini yükseltebilir. Bu nedenle warfarin tedavisinde amaç yalnızca belirli bir doz vermek değil hastayı mümkün olduğunca uzun süre terapötik INR aralığında tutmaktır. Bu alandaki güncel ve güçlü çalışmalardan biri Xue ve arkadaşları tarafından yürütülen randomize kontrollü çalışmadır. Çalışmada kalp cerrahisi sonrası warfarin başlanan 240 erişkin hasta değerlendirilmiş ve Bayesyen temelli NextDose hesaplayıcısı ile standart bakım karşılaştırılmıştır. İlk 28 günde terapötik aralıkta kalma süresi NextDose grubunda daha yüksek eğilim göstermiştir (%63'e karşı %56); tüm takip dönemi değerlendirildiğinde ise bu fark istatistiksel olarak anlamlı hale gelmiştir (%74'e karşı %71, $p = 0.04$). Daha önemlisi, klinik olarak anlamlı küçük kanama olayları NextDose grubunda belirgin şekilde daha düşük bulunmuştur ($HR = 0.21$, $p = 0.041$). Hekimlerin önerilen dozların %89.3'ünü kabul etmesi, sistemin klinik pratikte uygulanabilirliğini de desteklemektedir (Xue et al., 2024). Bu bulguların klinik anlamı, yapay zekâ destekli doz optimizasyonunun yalnızca INR hedeflerine ulaşmayı değil, kanama gibi hasta açısından önemli sonuçları da etkileyebileceğini göstermesidir. NextDose örneğinde sistem, hastanın ölçülen INR değerlerini ve klinik özelliklerini kullanarak doz önerisini Bayesyen biçimde günceller. Böylece doz sabit bir başlangıç kararı olmaktan çıkar; hastanın gerçek zamanlı farmakodinamik yanıtına göre yeniden şekillenen dinamik bir karar haline gelir. Bu yönüyle warfarin, MIPD yaklaşımının klinik karşılığını açık biçimde gösteren ilaçlardan biridir. Bir algoritmik çalışma olan GIFT çalışmasında, kalça veya diz artroplastisi geçiren 1650 yaşlı hastada genotip rehberli warfarin dozlaması klinik algoritma ile karşılaştırılmış ve majör kanama, INR ≥4, venöz tromboemboli veya ölümden oluşan kompozit sonlanım %14.7'den %10.8'e düşmüştür. Bu çalışma, genetik ve klinik değişkenlerin birlikte kullanıldığı algoritmik dozlamanın warfarin başlangıcında güvenliği artırabileceğini göstermesi açısından önemlidir (Gage et al., 2017). Daha yeni bir örnek olarak AI-WAR çalışmasında, Bi-LSTM tabanlı bir model ve uzaktan takip sistemi ile warfarin yönetimi değerlendirilmiştir. Bu çalışmada AI-WAR, klasik yönetime göre medyan TTR'yi %48.7'den %81.3'e yükseltmiş, hedef INR aralığında kalma oranını artırmış ve toplam advers olay oranını %19.7'den %9.6'ya düşürmüştür. Ancak bu çalışmanın çok güncel olması, belirli bir hasta popülasyonunda yürütülmesi ve dış doğrulama gereksinimi

nedeniyle sonuçlar temkinli yorumlanmalıdır (Li et al., 2026). Bunlara ek olarak; onkolojide, kapecitabin bazlı tedavi alan hastalarda CURATE.AI platformu kullanılarak yapılan çalışmalarda, hastaya özgü küçük veri setleriyle doz önerileri oluşturulmuştur (Blasiak et al., 2025). Bu yaklaşımın uygulanabilir olduğu gösterilmiş olsa da geniş ölçekli klinik doğrulama gereklidir. Kritik hasta popülasyonunda β-laktam antibiyotikler için yapılan DOLPHIN çalışmasında ise model destekli doz ayarlaması ile standart tedavi arasında primer sonlanım noktaları açısından anlamlı fark saptanmamış, ancak yöntemin uygulanabilirliği ortaya konmuştur (Ewoldt et al., 2022) Bu örnekler, yapay zekânın klinik pratikteki rolünün bağlama bağımlı olduğunu ve her uygulamanın klinik sonuçlar açısından ayrı ayrı değerlendirilmesi gerektiğini göstermektedir.

Etik ve sınırlamalar

Yapay zekâ destekli ilaç seçimi ve doz optimizasyonu, klinik karar süreçlerini güçlendirme potansiyeli taşısa da bu sistemlerin kullanımı önemli etik ve pratik sınırlamalar içerir. Bu alandaki temel sorunlardan biri, hasta verisinin niteliği ve güvenliğidir. Bu modeller genetik veriler, elektronik sağlık kayıtları, laboratuvar sonuçları, ilaç düzeyleri ve tedavi yanıtları gibi hassas sağlık verilerine dayanır. Bu nedenle veri gizliliği, anonimizasyon, hasta onamı ve veri paylaşım süreçleri dikkatle yönetilmelidir. Dünya Sağlık Örgütü, sağlıkta yapay zekâ kullanımında etik ilkelerin ve insan haklarının tasarım, geliştirme ve uygulama sürecinin merkezinde yer alması gerektiğini vurgulamaktadır (World Health Organization, 2021).

Bir diğer sınırlama algoritmik yanlılıktır. Yapay zekâ modelleri eğitildikleri veri setinin özelliklerini öğrenir. Eğer bu veri setleri belirli yaş, cinsiyet, etnik köken, komorbidite veya sosyoekonomik grupları yeterince temsil etmiyorsa model önerileri bazı hasta gruplarında daha düşük doğruluk gösterebilir. Farmakoterapi açısından bu durum özellikle kritiktir çünkü yanlış ilaç seçimi, yetersiz doz veya aşırı doz doğrudan advers olaylara yol açabilir. Bu nedenle algoritmalar yalnızca genel doğruluk oranlarıyla değil farklı hasta alt gruplarındaki performanslarıyla da değerlendirilmelidir. Modelin eğitildiği popülasyon ile gerçek klinik uygulamadaki hasta popülasyonu arasındaki uyumsuzluk özellikle kişiselleştirilmiş farmakoterapide önemli bir güvenlik sorunu oluşturabilir.

Açıklanabilirlik ve şeffaflık da klinik kullanım açısından belirleyicidir. Klinik farmakoterapide hekimin yalnızca "önerilen doz" veya "önerilen ilaç" bilgisini görmesi yeterli değildir; bu önerinin hangi hasta verilerine, hangi risk değerlendirmesine ve hangi model varsayımlarına dayandığını da anlayabilmesi gerekir. FDA, Health Canada ve MHRA tarafından yayımlanan makine öğrenmesi tabanlı etkin tıbbi cihazlara ilişkin şeffaflık ilkeleri, kullanıcıların modelin amaçlanan kullanımı, performansı ve sınırlamaları hakkında açık bilgiye sahip olması gerektiğini vurgulamaktadır (Food and Drug Administration, 2024). Açıklanamayan veya klinik gerekçesi anlaşılamayan önerilerin doğrudan uygulanması, hekim sorumluluğu ve hasta güvenliği açısından sorunludur. Kara kutu olarak tanımlanan yapay zekâ modellerinde, sistemin karar verme süreci kullanıcı tarafından şeffaf biçimde izlenemez ve önerilen sonucun hangi değişkenlere dayandığı açık şekilde açıklanamaz. Dolayısıyla bu durum özellikle sağlık hizmetlerinde önemli bir sorun oluşturur çünkü klinisyenler ve hastalar açısından tedavi kararlarının gerekçelendirilebilir olması beklenir. Açıklanabilirliğin sınırlı olduğu bu modeller; güven, doğrulama ve sorumluluk açısından tartışmalara yol açmaktadır (Raposo, 2025; Food and Drug Administration, 2024).

Klinik sorumluluk da ayrı bir tartışma alanıdır. Yapay zekâ sistemleri tedavi kararını destekleyebilir ancak nihai karar hekime aittir. FSMB tarafından yayımlanan 2024 raporunda klinik yapay zekânın uygun "koruyucu mekanizmalar" olmadan kullanılmasının

hasta güvenliğini etkileyebileceği ve insan sorumluluğunun korunması gerektiği belirtilmektedir (Federation of State Medical Boards, 2024). Bu nedenle bir yapay zekâ önerisi hekimin klinik değerlendirmesinin yerine geçmemelidir. Hekim; hastanın güncel klinik durumu, eşlik eden hastalıkları, laboratuvar bulguları, ilaç etkileşimleri ve hasta tercihleriyle uyumsuz bir öneriyi reddedebilmelidir.

Bir diğer önemli sınırlama klinik validasyondur. Yapay zekâ destekli ilaç seçimi veya doz optimizasyonu araçlarının klinik kullanıma girmeden önce yalnızca teknik doğruluk göstermesi yeterli değildir. Bu sistemlerin gerçek hasta sonuçları üzerindeki etkisi prospektif ve iyi tasarlanmış çalışmalarla değerlendirilmelidir. CONSORT-AI ve SPIRIT-AI kılavuzları, yapay zekâ içeren klinik müdahalelerin şeffaf biçimde raporlanması, insan-yapay zekâ etkileşiminin tanımlanması ve hata durumlarının analiz edilmesi gerektiğini belirtmektedir (Liu et al., 2020; Rivera et al., 2020). Bu gereklilik özellikle ilaç seçimi ve doz optimizasyonu gibi doğrudan hasta güvenliğini etkileyen alanlarda daha da önemlidir.

Sonuç

Klinik pratikte hekimler çoğu zaman aynı temel sorularla karşı karşıya kalır: Hangi ilaç seçilmeli ve hangi dozda başlanmalıdır? Geleneksel yaklaşımlar bu sorulara rehberler ve ortalama hasta verileri üzerinden yanıt vermeye çalışsa da bireyler arası farklılıklar bu yanıtların her zaman yeterli olmadığını göstermektedir. Bu noktada yapay zekâ, karmaşık ve çok boyutlu hasta verisini anlamlandırarak karar sürecine yeni bir bakış açısı kazandırmaktadır.

Bu derlemede ele alınan bulgular yapay zekânın özellikle ilaç seçimi ve doz optimizasyonu süreçlerinde anlamlı bir destek sağlayabileceğini göstermektedir. Farmakogenomik verilerin entegrasyonu ile daha uygun tedavi seçeneklerinin belirlenmesi, MIPD yaklaşımları ile dozun hastaya özgü olarak dinamik biçimde düzenlenebilmesi ve klinik karar destek sistemleri ile bu bilgilerin uygulanabilir hale gelmesi farmakoterapinin daha bireyselleştirilmiş bir yapıya evrildiğini düşündürmektedir. Ancak bu dönüşüm yalnızca teknik bir ilerleme olarak değil aynı zamanda klinik karar verme biçiminde bir değişim olarak da değerlendirilmelidir.

Bununla birlikte yapay zekâ sistemlerinin sunduğu öneriler her zaman mutlak doğrular olarak kabul edilmemelidir. Klinik bağlamdan kopuk, açıklanamayan veya yeterince doğrulanmamış öneriler hasta güvenliği açısından risk oluşturabilir. Bu nedenle hekim, yapay zekâ çıktısını bir "son karar" olarak değil, klinik değerlendirmeyi destekleyen bir araç olarak ele almalıdır. Özellikle veri kalitesi, modelin eğitildiği popülasyon ile gerçek hasta arasındaki uyum ve algoritmik sınırlılıklar göz önünde bulundurulmadan yapılan uygulamalar, beklenen faydanın aksine olumsuz sonuçlara yol açabilir.

Sonuç olarak yapay zekâ, ilaç seçimi ve doz optimizasyonunda önemli bir potansiyel sunmaktadır ancak bu potansiyelin klinik faydaya dönüşmesi; teknolojinin tek başına değil hekim deneyimi ve klinik yargı ile birlikte kullanılmasıyla mümkündür. Gelecekte en değerli yaklaşım yapay zekânın hekimin yerini alması değil onun kararlarını daha bilinçli, öngörülebilir ve hasta odaklı hale getirmesidir.

Kaynakça

Beam, A. L., & Kohane, I. S. (2018). Big data and machine learning in health care. JAMA, 319(13), 1317–1318. https://doi.org/10.1001/jama.2017.18391

Blasiak, A., Khong, J., & Kee, T. (2020). CURATE.AI: Optimizing personalized medicine with artificial intelligence. SLAS Technology, 25(2), 95–105. https://doi.org/10.1177/2472630319890323

Blasiak, A., Truong, A. T. L., Foo, N., Tan, L. W. J., Kumar, K. S., Tan, S. B., Tan, B. K. J., Tadeo, X., Tan, H. L., Chee, C. E., Yong, W. P., Ho, D., & Sundar, R. (2025). Personalized dose selection platform for patients with solid tumors in the PRECISE CURATE.AI feasibility trial. npj Precision Oncology, 9, 49. https://doi.org/10.1038/s41698-025-00835-7

Choi, H., Kang, H. J., Ahn, I., Gwon, H., Kim, Y., Seo, H., Cho, H. N., Han, J. Y., Kim, M. K., Kee, G., Park, S., Kwon, O., Roh, J. H., Kim, A. R., Kim, J. H., Jun, T. J., & Kim, Y. H. (2023). Machine learning models to predict the warfarin discharge dosage using clinical information of inpatients from South Korea. Scientific Reports, 13, 22461. https://doi.org/10.1038/s41598-023-49831-6

Darwich, A. S., Polasek, T. M., Aronson, J. K., Ogungbenro, K., Wright, D. F. B., Achour, B., Reny, J. L., Daali, Y., Eiermann, B., Cook, J., Rostami-Hodjegan, A., & Jamei, M. (2021). Model-informed precision dosing: Background, requirements, validation, implementation, and forward trajectory of individualizing drug therapy. *Annual Review of Pharmacology and Toxicology, 61*, 225–245. https://doi.org/10.1146/annurev-pharmtox-033020-113257

Ewoldt, T. M. J., Abdulla, A., Rietdijk, W. J. R., Muller, A. E., de Winter, B. C. M., Hunfeld, N. G. M., … Koch, B. C. P. (2022). Model-informed precision dosing of beta-lactam antibiotics and ciprofloxacin in critically ill patients: A multicentre randomized clinical trial. *Intensive Care Medicine, 48*(12), 1760–1771. https://doi.org/10.1007/s00134-022-06921-9

Federation of State Medical Boards (FSMB). (2024).Navigating the responsible and ethical incorporation of artificial intelligence into clinical practice. Resmi rapor, Nisan 2024. Retrieved from https://www.fsmb.org/siteassets/advocacy/policies/incorporation-of-ai-into-practice.pdf

Food and Drug Administration. (2019, August 12). Precision dosing: Defining the need and approaches to deliver individualized drug dosing in the real-world setting [Workshop announcement]. Retrieved from https://www.fda.gov

Khude, H., & Shende, P. (2025). AI-driven clinical decision support systems: Revolutionizing medication selection and personalized drug therapy. Advances in Integrative Medicine, 12(4), 100529. https://doi.org/10.1016/j.aimed.2025.100529

Liu, X., Rivera, S. C., Moher, D., Calvert, M. J., Denniston, A. K., … SPIRIT-AI and CONSORT-AI Working Group. (2020). Reporting guidelines for clinical trial reports for interventions involving artificial intelligence: The CONSORT-AI extension. *Nature Medicine, 26*(9), 1364–1374. https://doi.org/10.1038/s41591-020-1034-x

Minichmayr, I. K., Dreesen, E., Centanni, M., Wang, Z., Hoffert, Y., Friberg, L. E., & Wicha, S. G. (2024). Model-informed precision dosing: State of the art and future perspectives. Advanced Drug Delivery Reviews, 215, 115421. https://doi.org/10.1016/j.addr.2024.115421

Pai, M., Mangalore, R. A., Lee, S. J., … (2022). β-Lactam antibiotic therapeutic drug monitoring in critically ill patients: A systematic review and meta-analysis. Clinical Infectious Diseases, 75(10), 1848–1860. https://doi.org/10.1093/cid/ciac301

Polasek, T. M., Rostami-Hodjegan, A., Yim, D. S., Jamei, M., Lee, H., Kimko, H., … Shin, J. G. (2019). What does it take to make model-informed precision dosing common practice? Report from the 1st Asian Symposium on Precision Dosing. *AAPS Journal, 21*(2), 17. https://doi.org/10.1208/s12248-018-0286-6

Rivera, S. C., Liu, X., Chan, A. W., Denniston, A. K., Calvert, M. J., Ashrafian, H., … SPIRIT-AI and CONSORT-AI Working Group. (2020). Guidelines for clinical trial protocols for interventions involving artificial intelligence: The SPIRIT-AI extension. *Nature Medicine, 26*(9), 1351–1363. https://doi.org/10.1038/s41591-020-1037-7

Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. Nature Medicine, 25(1), 44–56. https://doi.org/10.1038/s41591-018-0300-7

Wang, X., Chen, Y., Wang, G., … (2023). Advanced machine learning algorithms for personalized pharmacotherapy in oncology: A scoping review. BMC Cancer, 23, 613. https://doi.org/10.1186/s12885-023-10649-1

World Health Organization. (2021). Ethics and governance of artificial intelligence for health: WHO guidance. https://www.who.int/publications/i/item/9789240029200

Xue, L., Ma, G., Holford, N., Qin, Q., Ding, Y., Hannam, J. A., Ding, X., Fan, H., Ji, Z., Yang, B., Shen, H., Shen, Z., & Miao, L. (2024). A randomized trial comparing standard of care to Bayesian warfarin dose individualization. Clinical Pharmacology & Therapeutics, 115(6), 1316–1325. https://doi.org/10.1002/cpt.3207

Genomik verilerde yapay zeka: Kalıtsal hastalıkların tanısı ve risk tahmini

Yağmur BENLİ, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Türkiye
yagmurbenli@ogr.bandirma.edu.tr

Doç. Dr. Çağdaş AKTAN, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Türkiye
caktan@bandirma.edu.tr

Özet

Genomik veriler, kalıtsal hastalıkların tanı ve risk tahmininde önemli rol oynayan DNA dizileri, RNA transkriptleri ve epigenetik modifikasyonlar gibi çok katmanlı biyolojik bilgileri içermektedir. Yeni Nesil Dizileme (NGS) teknolojilerinin gelişimiyle birlikte ortaya çıkan yüksek hacimli veriler, geleneksel istatistiksel yöntemlerle analiz edilmesi zor kompleks veri yapıları oluşturmuştur.

Bu derlemede, genomik veri analizinde yapay zeka (YZ) yaklaşımlarının rolü; makine öğrenmesi (ML), derin öğrenme (DL) ve geniş dil modelleri (LLM) perspektifinde incelenmiştir. Literatürdeki güncel çalışmalar, YZ algoritmalarının genetik varyantların sınıflandırılması, gen ekspresyon örüntülerinin analizi ve bireysel risk tahmininde yüksek doğruluk sağladığını göstermektedir. Bununla birlikte model açıklanabilirliği, veri yanlılığı ve biyolojik doğrulama gereksinimi, klinik uygulamalara entegrasyon açısından önemli sınırlılıklar oluşturmaktadır.

Bu çalışma, mevcut literatürde çoğunlukla ayrı ele alınan genomik ve transkriptomik veriler ile klinik parametreleri bütüncül bir çerçevede değerlendiren kavramsal bir yapay zeka yaklaşımı sunmaktadır. Önerilen çerçevenin, proteomik ve diğer omiks katmanları ile genişletilerek tanısal doğruluğu artırması ve kişiselleştirilmiş tıp uygulamalarına katkı sağlaması beklenmektedir.

Anahtar Kelimeler: Yapay zeka, biyoinformatik, genomik veri, multi-omiks, kalıtsal hastalıklar

Giriş

Kalıtsal hastalıklar, bireyin genetik yapısından kaynaklanan ve yaşam boyu klinik risk oluşturan önemli sağlık sorunları arasında yer almaktadır. Ancak bu hastalıkların yalnızca tek gen mutasyonları ile açıklanması çoğu zaman yetersiz kalmakta; çoklu gen etkileşimleri ve çevresel faktörlerin birlikte değerlendirilmesini gerektirmektedir. Bu durum, kalıtsal hastalıkların tanı ve risk öngörüsünde daha bütüncül ve veri odaklı yaklaşımlara olan ihtiyacı artırmaktadır (Roth & Marson, 2021).

Genomik veriler; DNA dizilimleri, RNA transkriptleri ve epigenetik modifikasyonları kapsayan çok katmanlı ve dinamik bir biyolojik bilgi sistemidir. Yeni Nesil Dizileme (NGS) teknolojilerinin yaygınlaşmasıyla birlikte bu verilerin hacmi hızla artmış ve biyoinformatik analiz süreçleri daha karmaşık hale gelmiştir. Bu yüksek boyutlu veri yapısı içerisinde anlamlı biyolojik sinyallerin gürültüden ayrıştırılması, kalıtsal hastalıkların genetik temelinin ortaya konmasında önemli bir zorluk oluşturmaktadır (Ramakrishnan, Washington, Suveena, Rani, & Oommen, 2025). Geleneksel analiz yöntemleri, bu kompleks veri yapılarındaki doğrusal olmayan ilişkileri modellemede sınırlı kalırken, yapay zeka (YZ) yöntemleri bu sınırlılıkları aşmada önemli bir avantaj sağlamaktadır. Makine öğrenmesi ve derin öğrenme algoritmaları, büyük ölçekli genomik verilerdeki karmaşık örüntüleri analiz ederek genetik varyantların daha doğru sınıflandırılmasına ve bireysel riskin daha hassas belirlenmesine olanak tanımaktadır (Celesti, Celesti, Wan, & Villari, 2018).

Bu çalışma, genomik veri analizinde yapay zeka yaklaşımlarını kalıtsal hastalıkların tanı ve risk tahmini bağlamında ele alarak, farklı omiks veri katmanlarının entegrasyonuna dayalı kavramsal bir çerçeve sunmayı amaçlamaktadır.

Kalıtsal Hastalıkların Tanısında Genomik Veri Katmanları

Kalıtsal hastalıkların tanısında kullanılan genomik veriler, yalnızca DNA dizilerinden ibaret olmayıp; RNA ekspresyonu, epigenetik düzenlemeler ve proteomik düzeydeki etkileşimleri kapsayan çok katmanlı bir yapıya sahiptir. DNA düzeyinde tek nükleotid polimorfizmleri (SNP), indeller ve yapısal varyasyonlar kalıtsal hastalıkların temel genetik belirleyicilerini oluşturur. RNA-Seq verileri gen ekspresyon profillerini ortaya koyarak hücresel aktivitenin dinamik bir yansımasını sağlar. Epigenetik modifikasyonlar, gen aktivitesinin çevresel faktörlere bağlı olarak nasıl değiştiğini gösterirken, proteomik veriler protein düzeyindeki fonksiyonel etkileşimleri ortaya koyar. Bu veri katmanlarının birlikte değerlendirilmesi, genetik varyantların yalnızca yapısal değil, fonksiyonel etkilerinin de anlaşılmasına olanak tanır (Xu et al., 2023).

Bu katmanların entegrasyonu "multi-omiks" yaklaşımını oluşturur ve hastalık mekanizmalarının daha bütüncül şekilde değerlendirilmesini sağlar. Ancak bu verilerin heterojen ve yüksek boyutlu yapısı, klasik analiz yöntemleri ile entegrasyonunu zorlaştırmaktadır. Bu nedenle, özellikle kompleks ve poligenik kalıtsal hastalıklarda, çok katmanlı veri entegrasyonuna dayalı analiz yaklaşımları tanısal doğruluğun artırılması ve bireysel riskin daha hassas belirlenmesi açısından önemli bir avantaj sunmaktadır (Xu et al., 2023).

Genomik Analizde Yapay Zeka

Genomik veri setlerinin büyüklüğü ve karmaşıklığı, klasik istatistiksel yöntemlerin sınırlarını zorlamaktadır. Bu yöntemler çoğunlukla doğrusal ilişkiler varsayarken, biyolojik sistemler çok katmanlı ve doğrusal olmayan etkileşimlerden oluşmaktadır. Bu nedenle özellikle poligenik kalıtsal hastalıklarda bireysel riskin doğru şekilde belirlenmesi, klasik yaklaşımlarla sınırlı kalmaktadır. Yapay zeka (YZ) yöntemleri, bu noktada doğrusal olmayan ilişkileri modelleyebilme kapasitesi ile öne çıkmaktadır. Özellikle derin öğrenme algoritmaları, yüksek boyutlu genomik verilerden doğrudan öğrenerek karmaşık örüntüleri ortaya çıkarabilmekte ve veri içerisindeki gürültüyü filtreleyerek nadir ancak klinik açıdan kritik varyantların tespitini kolaylaştırmaktadır. Bu özellik, nadir kalıtsal hastalıkların erken tanısında önemli bir avantaj sağlamaktadır. Bunun yanı sıra yapay zeka, farklı omiks katmanlarından elde edilen heterojen verilerin entegre analizine olanak tanımaktadır. Bu sayede yalnızca genetik varyasyonlar değil, bu varyasyonların fonksiyonel sonuçları da değerlendirilebilmekte ve daha bütüncül bir analiz yaklaşımı geliştirilebilmektedir (Yassi, Chatterjee, & Parry, 2023).

Sonuç olarak yapay zeka, genomik analizlerde yalnızca bir araç olmanın ötesinde, kalıtsal hastalıkların çok boyutlu yapısına uygun yeni nesil bir analiz paradigması sunmaktadır.

Biyoinformatik İş Akışında Yapay Zeka Entegrasyonu

Kalıtsal hastalıkların genomik analiz süreci, ham dizileme verilerinin elde edilmesinden klinik yorumlamaya kadar uzanan çok aşamalı bir biyoinformatik iş akışını içerir. Bu süreç; dizilerin referans genoma hizalanması (alignment), varyantların belirlenmesi (variant calling) ve klinik anlamlandırma (variant annotation) gibi temel adımlardan oluşmaktadır (Larson, Oberg, Adjei, & Wang, 2023). Geleneksel biyoinformatik pipeline'larda bu adımlar genellikle önceden tanımlı kurallara dayanan deterministik algoritmalar ile yürütülmektedir. Ancak bu yaklaşımlar, yüksek boyutlu ve gürültülü genomik verilerde sınırlı kalabilmektedir. Yapay zeka (YZ) yöntemleri ise bu süreçlerin

hızını ve doğruluğunu artırarak önemli avantajlar sağlamaktadır. Özellikle derin öğrenme tabanlı modeller, hizalama hatalarının azaltılması ve nadir varyantların tespiti gibi kritik aşamalarda klasik yöntemlere kıyasla daha yüksek performans göstermektedir (Junjun, Zhengqian, Ying, Jialiang, & Yongzhuang, 2024). Varyant anotasyonu aşamasında YZ sistemleri, genetik varyantların klinik etkisini tahmin ederek "benign", "likely pathogenic" ve "pathogenic" sınıflandırmalarını daha tutarlı şekilde gerçekleştirebilmektedir. Bu durum, kalıtsal hastalıkların tanısında klinik karar süreçlerinin daha güvenilir hale gelmesine katkı sağlamaktadır. Son yıllarda geliştirilen hibrit biyoinformatik yaklaşımlar, klasik pipeline'ları yapay zeka modelleri ile entegre ederek hem hesaplama maliyetini azaltmakta hem de analiz doğruluğunu artırmaktadır. Bu entegrasyon, genomik verilerin klinik pratiğe daha hızlı ve etkin bir şekilde aktarılmasını mümkün kılmakta ve yapay zekayı biyoinformatik iş akışlarının temel bir bileşeni haline getirmektedir (He, Liu, Zuo, Shi, & Jing, 2023).

Genomik Analizlerde Kullanılan Yapay Zeka Yöntemleri

Makine Öğrenmesi

Makine öğrenmesi algoritmaları, genetik varyantların hastalıklarla ilişkisini modelleyerek risk tahmini yapılmasını sağlar. Özellikle poligenik risk skorlarının oluşturulmasında yaygın olarak kullanılmakta olup, kalıtsal hastalık riskinin kantitatif olarak belirlenmesine olanak tanır. Random Forest ve Support Vector Machine (SVM) gibi yöntemler, varyant sınıflandırma ve ilişki analizlerinde sıkça tercih edilmektedir (Forrest et al., 2025).

Derin Öğrenme

Derin öğrenme modelleri, yüksek boyutlu genomik verilerde karmaşık örüntüleri tespit etmede üstün performans göstermektedir. Bu modeller, özellikle genomik dizilerin analizi ve mutasyon tespiti gibi alanlarda yüksek doğruluk oranlarına ulaşabilmektedir. Bu durum, kalıtsal hastalıklarla ilişkili kompleks genetik yapıların daha hassas şekilde analiz edilmesini mümkün kılmaktadır (Jaganathan et al., 2025).

Geniş Dil Modelleri

Geniş dil modelleri (LLM), genomik verileri biyolojik bir dil olarak ele alarak varyant yorumlama, literatür entegrasyonu ve klinik karar destek süreçlerinde kullanılmaktadır. Bununla birlikte bu modellerin doğrudan biyolojik çıkarım yapma kapasitesi sınırlı olup, daha çok karar destek ve bilgi entegrasyonu amacıyla kullanılması önerilmektedir (Li et al., 2025).

Bu yöntemler birbirinin alternatifi değil, tamamlayıcısı olup özellikle multi-omiks veri entegrasyonunda hibrit yaklaşımlar daha üstün performans sunmaktadır.

Tablo 1: Yapay Zeka Yöntemlerinin Karşılaştırmalı Analizi

Yöntem	Kullanım Alanı	Avantajlar	Sınırlılıklar	Örnek Algoritmalar

Makine Öğrenmesi (ML)	Poligenik risk skorları, varyant sınıflandırma	Yorumlanabilirlik görece yüksek, daha az veri ile çalışabilir	Karmaşık biyolojik etkileşimleri sınırlı modelleyebilir	RF, SVM
Derin Öğrenme (DL)	Genomik dizilerin analizi, mutasyon tespiti, görüntü-genomik entegrasyonu	Yüksek doğruluk, doğrusal olmayan ilişkileri modelleme kapasitesi	"Kara kutu" problemi, yüksek veri ve işlem gücü ihtiyacı	CNN, RNN
Geniş Dil Modelleri (LLM)	Yorumlama, literatür	Çoklu veri kaynaklarını entegre edebilme, esneklik	Doğrudan biyolojik doğrulama sınırlı, halüsinasyon riski	Transformer

Kalıtsal Hastalıklar İçin Yapay Zeka Tabanlı Kavramsal Model Önerisi

Bu çalışma kapsamında, kalıtsal hastalıkların tanı ve risk tahmini süreçlerine yönelik çok katmanlı bir yapay zeka yaklaşımını temel alan kavramsal bir çerçeve sunulmaktadır. Önerilen model; genomik varyant analizi, transkriptomik ekspresyon profili analizi ve klinik veri entegrasyonu olmak üzere üç temel bileşenden oluşmaktadır. Bu bileşenlerin bütüncül olarak değerlendirilmesi ile genetik varyantların fonksiyonel etkilerinin daha doğru yorumlanması, patojenik varyantların daha erken tespiti ve bireysel riskin daha hassas şekilde belirlenmesi hedeflenmektedir. Ayrıca bu yapı, poligenik risk skorlarının güvenilirliğini artırarak klinik karar destek süreçlerine katkı sağlayabilecek potansiyele sahiptir. Bu yaklaşım, literatürde çoğunlukla ayrı ayrı ele alınan veri katmanlarını entegre ederek kalıtsal hastalıkların çok boyutlu yapısının daha kapsamlı şekilde değerlendirilmesine olanak tanımaktadır. Önerilen çerçevenin, proteomik ve diğer omiks veri katmanları ile genişletilmesi, modelin klinik uygulanabilirliğini ve öngörü gücünü daha da artırabilir.

Kalıtsal Hastalıklar ve İlgili Genetik Mekanizmalarda Yapay Zeka Uygulamaları

Yapay zekanın genomik alandaki etkisi, farklı biyomedikal uygulamalarda giderek daha belirgin hale gelmektedir. Özellikle BRCA1/2 gen mutasyonları ve kistik fibrozis gibi kalıtsal hastalıklarda, yapay zeka tabanlı modeller genetik varyantları ek moleküler verilerle birlikte değerlendirerek bireysel risk tahmininin daha hassas yapılmasını sağlamaktadır. Bu durum, yalnızca tanısal doğruluğu artırmakla kalmayıp, aynı zamanda bireyselleştirilmiş risk sınıflandırmasını da geliştirmektedir.

Transkriptomik düzeyde yapılan analizler, gen ekspresyon imzalarının hastalık progresyonu ve prognostik değerlendirme ile ilişkili olduğunu göstermektedir. Benzer şekilde yapay zeka destekli modeller, gen ekspresyon verilerinden elde edilen biyobelirteçlerin klinik anlamlandırılmasında önemli katkılar sunmaktadır (Aktan et al., 2026). Görüntüleme verileri ile yapay zekanın entegrasyonu da önemli bir gelişim alanıdır. Özellikle MRI tabanlı modeller, tümör segmentasyonu ile genetik mutasyon tahminini

birleştirerek invaziv tanı yöntemlerine olan ihtiyacı azaltma potansiyeline sahiptir (Gokmen et al., 2026). Bunun yanı sıra CRISPR tabanlı gen düzenleme çalışmalarında, makine öğrenmesi algoritmaları off-target etkilerin tahmin edilmesinde kullanılarak genetik müdahalelerin güvenliğini artırmaktadır (Kose et al., 2024). Protein düzeyinde ise AlphaFold gibi yapay zeka sistemleri, protein yapı tahmininde yüksek doğruluk sağlayarak hastalıkların moleküler mekanizmalarının anlaşılmasına önemli katkılar sunmaktadır (Abramson et al., 2024).

Genel olarak bu uygulamalar, yapay zekanın kalıtsal hastalıkların tanısı, risk tahmini ve moleküler mekanizmalarının anlaşılmasında çok katmanlı ve bütüncül bir katkı sunduğunu göstermektedir.

Genomik Analizlerde Yapay Zeka Kullanımının Avantajları ve Zorlukları

Avantajlar

Yapay zeka sistemleri, yüksek hacimli genomik verileri kısa sürede analiz ederek zaman ve hesaplama verimliliği açısından önemli avantajlar sağlamaktadır. Ayrıca doğrusal olmayan ilişkileri modelleyebilme kapasitesi sayesinde yüksek boyutlu verilerde daha doğru örüntü tespiti yapılmasına olanak tanımaktadır. Bu sistemler, multi-omiks veri katmanlarının entegrasyonunu mümkün kılarak kalıtsal hastalıkların daha bütüncül şekilde değerlendirilmesine katkı sağlamaktadır.

Zorluklar

Bununla birlikte, yapay zeka modellerinde "kara kutu" problemi, elde edilen sonuçların klinik açıdan yorumlanabilirliğini sınırlamaktadır. Ayrıca veri setlerindeki yanlılık (bias), modelin genellenebilirliğini etkileyebilir ve farklı popülasyonlarda performans değişkenliği oluşturabilir. Bunun yanında, yapay zeka çıktılarının klinik olarak doğrulanması gerekliliği, bu sistemlerin rutin tıbbi uygulamalara entegrasyonunda önemli bir zorluk oluşturmaktadır.

Bütünleşik Multi-Omiks Modelleme ve Sistem Biyolojisi

Genomik bilimi, giderek tekil veri analizinden ziyade biyolojik sistemlerin bütüncül olarak modellenmesine yönelmektedir. Bu yaklaşımın temelini sistem biyolojisi oluşturmaktadır ve hastalıkların çok katmanlı yapısının daha iyi anlaşılmasına olanak tanımaktadır. Multi-omiks modelleme; genomik, transkriptomik, proteomik ve metabolomik verilerin entegre analizini mümkün kılarak hastalıkların yalnızca genetik düzeyde değil, aynı zamanda hücresel ve moleküler düzeyde de değerlendirilmesini sağlar. Bu sayede hastalık mekanizmaları daha kapsamlı bir şekilde ortaya konabilmektedir. Yapay zeka algoritmaları, bu çok katmanlı veriler arasındaki karmaşık ilişkileri modelleyerek hastalıkların mekanistik temellerinin daha derinlemesine analiz edilmesine katkı sağlamaktadır. Bu yaklaşım, özellikle yüksek heterojenite gösteren hastalıklarda bireyselleştirilmiş tedavi stratejilerinin geliştirilmesinde önemli bir potansiyele sahiptir. Bu bağlamda dijital biyolojik ikizler, bireylerin moleküler profillerine dayalı sanal modeller oluşturarak hastalık progresyonunun ve tedavi yanıtlarının simülasyonuna olanak tanımaktadır. Bu yaklaşım, tedavi etkinliği ve olası yan etkilerin öngörülmesi açısından gelecekte önemli bir araç olma potansiyeli taşımaktadır. Ayrıca kalıtsal hastalıklarda bireyler arası genetik heterojenitenin daha iyi anlaşılmasına ve kişiselleştirilmiş risk değerlendirmesine katkı sağlayabilir (Avelar et al., 2020; Laubenbacher, Mehrad, Shmulevich, & Trayanova, 2024).

Gelecek Perspektifi

Önerilen modelin gelecekte klinik uygulamalara entegre edilmesi ile genomik varyant verileri, transkriptomik ekspresyon profilleri ve klinik parametrelerin bütüncül şekilde analiz edildiği hibrit karar destek sistemlerinin geliştirilmesi mümkün olabilir. Bu tür sistemlerin, hem tanısal doğruluğu artırması hem de bireyselleştirilmiş tedavi ve risk öngörüsü süreçlerine katkı sağlaması beklenmektedir.

Sonuç

Genomik verilerin artan karmaşıklığı, yapay zekayı modern biyoinformatik ve klinik analiz süreçlerinin temel bileşeni haline getirmiştir. Makine öğrenmesi, derin öğrenme ve geniş dil modelleri; genetik varyant analizi, risk tahmini ve klinik yorumlama süreçlerinde önemli katkılar sağlamaktadır. Bununla birlikte, model açıklanabilirliği ve biyolojik doğrulama gerekliliği, klinik uygulamalara geçişte temel sınırlılıklar olarak öne çıkmaktadır.

Genel olarak yapay zeka, genomik verilerin çok katmanlı yapısını anlamlandırarak daha öngörücü, kişiselleştirilmiş ve önleyici bir tıbbi yaklaşımın geliştirilmesine olanak tanımaktadır.

Kaynaklar:

Abramson, J., Adler, J., Dunger, J., Evans, R., Green, T., Pritzel, A., . . . Jumper, J. M. (2024). Accurate structure prediction of biomolecular interactions with AlphaFold 3. *Nature, 630*(8016), 493-500. doi:10.1038/s41586-024-07487-w

Aktan, C., Breneman, C. M., Argun, O., Seeley, N., Atalar, C., Robinson, K., . . . Sayan, M. (2026). An Interferon-Response Transcriptomic Signature of Lymphovascular Invasion in Prostate Cancer. *Int J Mol Sci, 27*(5). doi:10.3390/ijms27052167

Avelar, R. A., Ortega, J. G., Tacutu, R., Tyler, E. J., Bennett, D., Binetti, P., . . . de Magalhaes, J. P. (2020). A multidimensional systems biology analysis of cellular senescence in aging and disease. *Genome Biol, 21*(1), 91. doi:10.1186/s13059-020-01990-9

Celesti, F., Celesti, A., Wan, J., & Villari, M. (2018). Why Deep Learning Is Changing the Way to Approach NGS Data Processing: A Review. *IEEE Rev Biomed Eng, 11*, 68-76. doi:10.1109/RBME.2018.2825987

Forrest, I. S., Vy, H. M. T., Rocheleau, G., Jordan, D. M., Petrazzini, B. O., Nadkarni, G. N., . . . Do, R. (2025). Machine learning-based penetrance of genetic variants. *Science, 389*(6763), eadm7066. doi:10.1126/science.adm7066

Gokmen, N., Kocadagli, O., Cevik, S., Aktan, C., Eghbali, R., & Liu, C. (2026). Enhancing AI-based decision support system with automatic brain tumor segmentation for EGFR mutation classification. *Med Biol Eng Comput, 64*(1), 197-217. doi:10.1007/s11517-025-03447-2

He, X., Liu, X., Zuo, F., Shi, H., & Jing, J. (2023). Artificial intelligence-based multi-omics analysis fuels cancer precision medicine. *Semin Cancer Biol, 88*, 187-200. doi:10.1016/j.semcancer.2022.12.009

Jaganathan, K., Ersaro, N., Novakovsky, G., Wang, Y., James, T., Schwartzentruber, J., . . . Farh, K. K. (2025). Predicting expression-altering promoter mutations with deep learning. *Science, 389*(6760), eads7373. doi:10.1126/science.ads7373

Junjun, R., Zhengqian, Z., Ying, W., Jialiang, W., & Yongzhuang, L. (2024). A comprehensive review of deep learning-based variant calling methods. *Brief Funct Genomics, 23*(4), 303-313. doi:10.1093/bfgp/elae003

Kose, A. M., Kocadagli, O., Tastan, C., Aktan, C., Unaldi, O. M., Guzenge, E., & Erdil, H. E. (2024). Unveiling Off-Target Mutations in CRISPR Guide RNAs: Implications for Gene Region Specificity. *CRISPR J, 7*(3), 168-178. doi:10.1089/crispr.2024.0002

Larson, N. B., Oberg, A. L., Adjei, A. A., & Wang, L. (2023). A Clinician's Guide to Bioinformatics for Next-Generation Sequencing. *J Thorac Oncol, 18*(2), 143-157. doi:10.1016/j.jtho.2022.11.006

Laubenbacher, R., Mehrad, B., Shmulevich, I., & Trayanova, N. (2024). Digital twins in medicine. *Nat Comput Sci, 4*(3), 184-191. doi:10.1038/s43588-024-00607-6

Li, S., Wang, Y., Liu, C. M., Huang, Y., Lam, T. W., & Luo, R. (2025). AutoPM3: enhancing variant interpretation via LLM-driven PM3 evidence extraction from scientific literature. *Bioinformatics, 41*(7). doi:10.1093/bioinformatics/btaf382

Ramakrishnan, R., Washington, A., Suveena, S., Rani, J. R., & Oommen, O. V. (2025). From DNA to Big Data: NGS Technologies and Their Applications. *Methods Mol Biol, 2952*, 459-482. doi:10.1007/978-1-0716-4690-8_25

Roth, T. L., & Marson, A. (2021). Genetic Disease and Therapy. *Annu Rev Pathol, 16*, 145-166. doi:10.1146/annurev-pathmechdis-012419-032626

Xu, Y., Ritchie, S. C., Liang, Y., Timmers, P., Pietzner, M., Lannelongue, L., . . . Inouye, M. (2023). An atlas of genetic scores to predict multi-omic traits. *Nature, 616*(7955), 123-131. doi:10.1038/s41586-023-05844-9

Yassi, M., Chatterjee, A., & Parry, M. (2023). Application of deep learning in cancer epigenetics through DNA methylation analysis. *Brief Bioinform, 24*(6). doi:10.1093/bib/bbad411

Kulak Burun Boğazda Yapay Zeka: Görüntüleme ve Erken Tanı Uygulamaları

Dr. Doğukan Demir 1 , ddemir@bandirma.edu.tr
Stj. Dr. Berivan Tayanak 2 , berivantayanak@ogr.bandirma.edu.tr
1 KBB ABD, Bandirma Onyedi Eylül Üniversitesi Tıp Fakültesi, 10200 Balıkesir, Türkiye
2 Bandirma Onyedi Eylül Üniversitesi Tıp Fakültesi, 10200 Balıkesir, Türkiye

ÖZET

Yapay zeka (YZ), özellikle görüntüleme ve erken tanı alanlarında, kulak burun boğaz (KBB) hastalıklarında dönüştürücü bir araç olarak ortaya çıkmıştır. Makine öğrenimi ve derin öğrenme algoritmalarındaki son gelişmeler, baş ve boyun kanserleri, sinüs hastalıkları ve kulak hastalıkları gibi çeşitli KBB patolojilerinin saptanmasında doğruluk ve verimliliği önemli ölçüde artırmıştır. YZ destekli görüntüleme teknikleri; gelişmiş görüntü analizi, örüntü tanıma ve klinik karar desteği sağlayarak daha erken ve daha doğru tanı konulmasına olanak tanır. Bu durum, erken teşhisin tedavi sonuçları ve hasta prognozu üzerinde doğrudan etkili olduğu hastalıklarda özellikle kritik öneme sahiptir. Ayrıca, YZ uygulamaları klinisyenlerin iş yükünü azaltmaya ve tanısal hataları en aza indirmeye katkıda bulunmaktadır. Bununla birlikte, veri kalitesi, etik konular ve klinik uygulamaya entegrasyon gibi zorluklar devam etmektedir. Bu çalışma, KBB görüntülemesinde YZ'nin güncel kullanım alanlarını gözden geçirmeyi ve erken tanı süreçlerini iyileştirmedeki rolünü ortaya koymayı amaçlamaktadır.

Sonuç olarak, yapay zekâ destekli görüntüleme sistemleri KBB alanında erken tanı süreçlerini hızlandırma ve doğruluğunu artırma potansiyeline sahiptir. Gelecekte daha geniş veri setleri ve çok merkezli çalışmalar ile bu teknolojilerin klinik uygulamalara entegrasyonunun artması beklenmektedir.

Anahtar Kelimeler: Kulak burun boğaz, erken tanı, tıbbi görüntüleme, yapay zeka

GİRİŞ

Kulak burun boğaz (KBB) hastalıkları, kulak, burun, boğaz ve baş-boyun bölgesine ait çok çeşitli patolojileri kapsamaktadır. Bu hastalıkların erken ve doğru tanısı, özellikle baş ve boyun kanserleri gibi prognozu doğrudan etkileyen durumlarda, tedavi başarısı ve hasta yaşam süresi açısından kritik öneme sahiptir. KBB pratiğinde tanı süreci; klinik muayene, endoskopik değerlendirme ve bilgisayarlı tomografi (BT) ile manyetik rezonans görüntüleme (MRG) gibi görüntüleme yöntemlerine dayanmaktadır. Ancak bu yöntemler çoğu zaman zaman alıcıdır ve büyük ölçüde klinisyenin deneyimine bağlıdır; bu da yorum farklılıklarına ve tanısal hatalara yol açabilmektedir.

Son yıllarda yapay zeka (YZ), büyük veri setlerini analiz edebilme, karmaşık örüntüleri tanıyabilme ve klinik karar süreçlerini destekleyebilme yeteneği sayesinde tıbbi görüntüleme alanında giderek daha fazla önem kazanmıştır. Özellikle makine öğrenimi ve derin öğrenme algoritmaları, çeşitli KBB hastalıklarının saptanması ve sınıflandırılmasında yüksek doğruluk oranları ile umut verici sonuçlar ortaya koymuştur.

Bununla birlikte, yapay zekanın KBB pratiğine entegrasyonu henüz istenilen düzeye ulaşmamıştır. Veri standardizasyonu eksikliği, etik sorunlar, veri güvenliği ve yüksek

kaliteli, geniş veri setlerine duyulan ihtiyaç gibi faktörler bu süreci sınırlamaktadır. Bu nedenle, yapay zekanın KBB görüntülemesindeki mevcut kullanım alanlarının ve potansiyel katkılarının değerlendirilmesi büyük önem taşımaktadır.
Bu çalışmanın amacı, kulak burun boğaz alanında görüntüleme ve erken tanı süreçlerinde yapay zekanın kullanımını incelemek ve bu teknolojinin tanısal doğruluk ile
hasta bakımına olan etkilerini ortaya koymaktır.

1-) Endoskopik Orta Kulak Cerrahisinde Chorda Tympani'nin Yapay Zeka ile Doğru Segmentasyonu ve İzlenmesi

En hassas ve karmaşık cerrahi prosedürlerden biri olan orta kulak ameliyatı; kronik otitis media, kolesteatom veya otoskleroz hastalarının tedavisinde çok önemli bir rol oynar. Kronik inflamasyona ek olarak, iletim tipi işitme kaybı ve tinnitusun karakteristik
semptomları olan hastalar için orta kulak ameliyatı gerekli olabilir. Orta kulak ameliyatları sırasında, bir cerrahın kapsamlı eğitimi ve ayrıntılı anatomik bilgisi intraoperatif komplikasyonlardan kaçınmak için gereklidir
Chorda tympani, fasiyal sinirin önemli dalıdır. Dilin anterior üçte ikisine hakim olan lifleri,
submandibular ve sublingual tükürük bezlerinin parasempatik liflerini ve fasiyal sinirin somatosensör dallarını içerir. Kronik otitis media tedavisi için yaygın bir prosedür olan timpanoplasti uygulanır, bu uygulama timpan hasarı ile ilgili postoperatif semptomlara duyarlıdır. Ne yazık ki, çalışmalar postoperatif tat bozuklukları, ağız kuruluğu, uyuşma veya dilin karıncalanması, disfaji ve disfoni, timpanoplasti sonrası hastaların önemli bir yüzdesinde meydana geldiğini göstermiştir. Endoskopik cerrahi ortamın karmaşıklığı, dar bir görüş alanı ve sınırlı bir alan olduğu için zorlukları daha da arttırır. Ek olarak; chorda tympaninin anatomik konumu, timpanoplasti sırasında traksiyon, germe ve yanlışlıkla kesmeye karşı özellikle savunmasız hale getirir. Sonuç olarak, endoskopik orta kulak ameliyatı sırasında korda timpaninin korunması zorlu bir meydan okuma sunar.
Son yıllarda, yapay zeka (AI) endoskopi alanında önemli ilerlemeler kaydetti ve önemli
başarılar elde etti.
Yapılan bir çalışmada, chorda tympani veri setlerini eğitmek için çok aşamalı transfer öğrenme teknikleri kullanıldı ve endoskopik orta kulak cerrahisi sırasında otomatik segmentasyon elde edildi. Çalışma, otologların endoskopik orta kulak prosedürleri sırasında chorda timmpaniyi tanıma ve koruma yeteneğini arttırmayı, gelecekteki translasyonel araştırmaların temelini atarak bilgisayarlı görme tabanlı gerçek zamanlı cerrahi rehberlik ve endoskopik orta kulak cerrahisinde karar desteği sağlamayı amaçlamaktadır.
Çalışmada, endoskopik orta kulak cerrahisi alanında, özellikle chorda tympaninin tanımlanması için DL tabanlı bilgisayar görüşünün potansiyeli gösterildi. Geliştirilen DL
modelleri, chorda tympaniyi yüksek bir performans seviyesiyle otomatik olarak algılama

ve segmentlere ayırma yeteneklerini sergiledi. Bu tür modeller, cerrahlara cerrahi güvenliği arttırmak ve postoperatif komplikasyonlardan kaçınmak için korda timpaniyi etkili bir şekilde tanımlama ve izleme konusunda yardımcı olacak değerli araçlar olarak

hizmet edebilir. Dahası, bu modeller yeni kursiyerler için gereken öğrenme süresini potansiyel olarak azaltarak tıp eğitiminde umut vaat ediyor.

2-) OtoMatch: Derin öğrenme kullanarak içerik tabanlı kulak zarı görüntüsü alma
Orta kulağın akut enfeksiyonları en sık tedavi edilen çocukluk hastalıklarıdır. Komplikasyonlar çocukların dil öğrenme ve bilişsel süreçlerini etkilediğinden, bu hastalıkların zamanında ve doğru bir şekilde teşhis edilmesi esastır. Yaygın literatür, bu enfeksiyonların, deneyimli kulak, burun ve boğaz hekimleri için bile doğru bir şekilde teşhis edilmesinin zor olduğunu göstermektedir. Bu amaçla, normal, orta kulak efüzyonu
ve timpanostomi tüpü koşulları için, dijital bir otoskopla çekilen kulak zarı görüntüleri üzerinde çalışan bir içerik tabanlı görüntü alma (CBIR) sistemi (OtoMatch) tasarlandı. OtoMatch, en benzer görüntüleri açıklamalı vakaların bir veritabanından alarak kulak hastalığı teşhisinde klinisyenlere yardımcı olmak için geliştirilen bir sistemdir. OtoMatch,
özellikleri ayıklamak için derin öğrenme tabanlı yaklaşımlar kullanır ve sorgu görüntülerinin çok boyutlu alanda eğitim görüntüleriyle benzerliğini karşılaştırmak için bir
arama tablosu oluşturur. El yapımı özelliklere sahip geleneksel CBIR yöntemleriyle karşılaştırıldığında OtoMatch, düşük değişkenlik ile daha yüksek doğruluk üretir ve böylece performansının genelleştirilebilirliğine daha uygun hale gelir.

3-) BT görüntülerinde kolesteatom tanısında yapay zeka ne kadar güvenilir?
Yapılan bir çalışma, bilgisayarlı tomografide (BT) kolesteatom tanısı için ana yapay zeka
(AI) modellerini analiz etti, performanslarını değerlendirdi ve birbirleriyle karşılaştırdı. Radyolojide yapay zekanın artan uygulaması, mevcut metodolojilerin sistematik bir karşılaştırmasını gerektirir.
Ana veritabanlarından ilgili makaleleri seçerek sistematik bir literatür taraması yapıldı.

Meta-analiz, MobilenetV2, Densenet201 ve Resnet50 AI modellerini değerlendiren üç çalışmayı içeriyordu. Tüm modeller BT'de kolesteatom tanısında yüksek düzeyde duyarlılık ve özgüllük gösterdi. Çeşitli modellerin performansı arasında istatistiksel olarak anlamlı bir fark bulunmadı, bu da farklı sinir ağı mimarileri arasında güçlü bir ortak teşhis yeteneği olduğunu gösteriyor.
Sonuç olarak; AI, görüntülemede hızlı bir ilerleme kaydediyor. Teknolojik gelişmenin hızı
umut verici. Bununla birlikte, klinik uygulamada güvenli ve etkili bir uygulama sağlamak
için, AI modellerini doğrulamak ve standartlaştırmak için daha fazla çalışmaya ihtiyaç vardır. Gelecekteki araştırmalar sadece teşhis doğruluğuna değil, aynı zamanda bu yeni teknolojilerin sağlamlığına, tekrarlanabilirliğine ve klinik entegrasyonuna da odaklanmalıdır.

4-) ChatGPT'nin Tükürük Bezi Hastalıkları Hakkındaki Sorulara Verdiği Cevaplar
Doğru ve Güvenilir mi?
Chat Generative Pre-Trained Transformer (ChatGPT), insan benzeri metin diyalogları oluşturabilen bir yapay zeka modelidir.

Bu çalışma, ChatGPT'nin tükürük bezi hastalıklarındaki sorulara verdiği cevapların
doğruluğunu ve güvenilirliğini değerlendirerek, kulak burun boğaz uzmanlarının eğitiminde potansiyel kullanımına odaklanmaktadır.
"Temel bilgi" ve "türük bezi tümörü" olarak sınıflandırılan altmış bir soru, ChatGPT
kullanılarak iki kez soruldu. Cevaplar 1 (tamamen doğru ve kapsamlı), 2 (kısmen doğru), 3 (doğru ve yanlış ifadeler içeren yanıltıcı bilgiler) veya 4 (tamamen yanlış) olarak sınıflandırıldı. Cevapların doğruluğu iki kulak, burun ve boğaz uzmanı tarafından
değerlendirildi.
Soruların 15'i (%24.6) temel bilgi, 46'sı (%75.4) tükürük bezi tümörleri hakkındaydı.
ChatGPT, 54 (%88.5) soruya "tamamen doğru ve kapsamlı" ve yedi (%11.5) soruya
"kısmen doğru" yanıt verdi. "Doğru ve yanlış ifadeler içeren yanıltıcı bilgiler" ve

"tamamen yanlış" cevaplar alınmadı. Birinci ve ikinci cevapların tekrarlanabilirlik oranı
%97 idi.
ChatGPT, tükürük bezi hastalıkları ile ilgili sorulara son derece doğru ve tekrarlanabilir cevaplar sağladı. ChatGPT'nin kulak burun boğaz uzmanları için önemli bir bilgi kaynağı
olduğu düşünülmektedir. Çalışmanın sonuçları ChatGPT'nin oldukça başarılı olduğunu
gösterse de, bu alanda daha fazla çalışmaya ihtiyaç vardır.

SONUÇ

Yapay zekâ destekli görüntüleme teknolojileri, KBB pratiğinde erken tanı süreçlerini geliştirme açısından önemli fırsatlar sunmaktadır. Özellikle derin öğrenme tabanlı modeller, endoskopik ve radyolojik görüntülerin analizinde yüksek doğruluk oranlarına ulaşarak klinisyenlere güçlü bir destek sağlamaktadır. Bu durum, hastalıkların daha erken evrede tespit edilmesine ve tedaviye daha hızlı başlanmasına katkıda bulunmaktadır.
Bununla birlikte, yapay zekâ uygulamalarının klinik pratiğe tam entegrasyonu için standartlaştırılmış veri setlerine, geniş ölçekli çok merkezli çalışmalara ve etik düzenlemelere ihtiyaç duyulmaktadır. Ayrıca, bu sistemlerin karar destek aracı olarak kullanılması ve hekim deneyimi ile birlikte değerlendirilmesi önem arz etmektedir.
Sonuç olarak, yapay zekâ teknolojilerinin KBB alanında kullanımı gelecekte daha da yaygınlaşacak olup, erken tanı ve hasta yönetiminde önemli bir rol üstlenecektir. Bu doğrultuda yapılacak çalışmalar, hem teknolojik gelişimi hızlandıracak hem de klinik sonuçların iyileştirilmesine katkı sağlayacaktır.

KAYNAKÇA

1. Ding X, Huang Y, Gao Z, et al. Accurate segmentation and tracking of chorda tympani
in endoscopic middle ear surgery with artificial intelligence. J Laryngol Otol. 2023. doi:10.1177/01455613231212051.

2. Camalan S, Niazi MKK, Moberly AC, Teknos T, Essig G, Elmaraghy C, et al. OtoMatch: Content-based eardrum image retrieval using deep learning. PLoS One. 2020;15(5):e0232776. doi:10.1371/journal.pone.0232776.
3. Avallone E, De Luca P, Max T, Siani A, Viola P, Ralli M, et al. How reliable is artificialintelligence in the diagnosis of cholesteatoma on CT images? Am J Otolaryngol.
2025;46(1):104519. doi:10.1016/j.amjoto.2024.104519.
4. Küçüktağ Z, Altan E, Saygı Uysal G, Özdoğan A. Are ChatGPT's answers to questions about salivary gland diseases accurate and reliable? Turk Arch Otorhinolaryngol. 2025;63(3):143-150. doi:10.4274/tao.2025.2025-1-17.

Körlüğü önlemek: yapay zeka ile retina hastalıklarının erken tanısı

Zeynep Ezgi Edikli [1]

Onur Furundaoturan[2]

[1] Bandırma Onyedi Eylül Üniversitesi

[2] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Göz Hastalıkları

Özet

Retina hastalıkları, erken evrede belirtisiz seyreden yapıları nedeniyle tanı gecikmelerine ve kalıcı görme kayıplarına yol açmaktadır. Diyabetik retinopati, yaşa bağlı makula dejeneresansı ve glokom; dünya genelinde önlenebilir körlüğün başlıca nedenleri arasında yer almakta olup artan hasta sayıları ve yetersiz tarama kapasitesi, bu hastalıkların erken dönemde tespitini güçleştirmektedir. Bu derleme, söz konusu hastalıkların erken tanısında yapay zeka temelli yaklaşımların mevcut durumunu, kullanılan mimarileri, klinik doğrulama bulgularını ve sınırlılıkları değerlendirmeyi amaçlamaktadır. Literatür incelendiğinde, konvolüsyonel sinir ağları başta olmak üzere Vision Transformer ve U-Net gibi derin öğrenme mimarilerinin fundus fotoğrafı ve optik koherens tomografi görüntüleri üzerinde yüksek tanısal doğrulukla çalışabildiği görülmektedir. Diyabetik retinopatide, yaşa bağlı makula dejeneresansında ve glokomda geliştirilen modeller; oftalmolojiye sevk kararı verme, hastalık evreleme ve progresyon tahmini görevlerinde uzman hekimlerle kıyaslanabilir performans sergilemiştir. Bununla birlikte mevcut çalışmaların büyük bölümünün retrospektif ve tek merkezli tasarıma dayanması, dış doğrulama verilerinin yetersizliği ve farklı popülasyonlara genellenebilirlik sorunları önemli metodolojik kısıtlar oluşturmaktadır. Açıklanabilir olma güçlükleri, hukuki belirsizlikler ve model performans kayması ise klinik entegrasyonun önündeki yapısal engeller arasında yer almaktadır. Sonuç olarak yapay zeka, retina hastalıklarında erken tanı kapasitesini genişletme potansiyeli taşımakla birlikte; rutin pratiğe alınması prospektif doğrulama çalışmalarına, çeşitli popülasyonları kapsayan veri altyapısına ve disiplinler arası iş birliğine olan ihtiyacı ortadan kaldırmamaktadır.

Anahtar Kelimeler: Yapay zeka, derin öğrenme, diyabetik retinopati, yaşa bağlı makula dejeneresansı, glokom, erken tanı, fundus görüntüleme, optik koherens tomografi

1. Giriş

Retina görme duyusunda, fotokimyasal reaksiyon ile görüntünün iletilebilir ve beyin tarafından algılanabilir bir hale kavuşmasında en önemli işlevlerin yerine getirildiği; yoğun vasküler ve özelleşmiş bir dokudur. Fotoreseptör adı verilen özelleşmiş reseptör hücreler ve retinanın üzerinde yerleştiği retina pigment epiteli (RPE) sayesinde bu işlevlerini yerine getirebilmektedir.(Masland, 2012)

Retinal hastalıklar ciddi görme kaybı sebep olmalarıyla önemli bir halk sağlığı sorunu olarak karşımıza çıkmaktadır. Bu hastalıklar arasında yaşa bağlı makula dejeneresansı (YBMD), diyabetik retinopati (DR), retinal ven tıkanıklığı (VT), retinal arter tıkanıklığı gibi tablolar sayılabilir.(GBD 2019 Blindness and Vision Impairment Collaborators ve Vision Loss Expert Group of the Global Burden of Disease Study, 2021)

Temel muayene biyomikroskop ya da indirekt oftalmoskop gibi cihazlar yardımıyla yapılan klinik değerlendirmedir ve bu subjektif muayeneye göre hastalıklar için evreleme, prognoz tayini gibi algoritmalar geliştirilmiştir.(Abràmoff, Garvin ve Sonka, 2010) Bu

değerlendirmelerde hem sağlıklı kayıt alınabilmesi hem de tekrarlayan muayenelerde farklılıkların değerlendirilebilmesi amaçlarıyla fundus fotoğrafları da kullanılabilmektedir.

Günümüzde ilerleyen teknoloji ile gelişen çeşitli cihazlar, özellikle retinal görüntülemede oldukça kolaylık sağlamaktadır. Bu cihazlar arasında optik koherens tomografi (OKT), optik koherens tomografi anjiografi (OKTA) gibi görüntüleme sistemleri yer almaktadır. OKT özel dalga boylu bir ışık hüzmesinin retinaya düşürülüp, çeşitli yansıtıcılıktaki iç retina katmanlarından geri dönüşünün değerlendirilmesi prensibine dayanan; birkaç saniyelik ancak bir histolojik kesit kadar detaylı görüntü sağlayan bir teknolojidir. Bu görüntüleme; tekrarlanabilir, zararsız, objektif ve kolaylıkla kayıt altına alınabilir görüntüleme sistemleri ile çekilebilmektedir.(Huang ve diğerleri, 1991)

OKTA ise konvansiyonel OKT'ye ek olarak daha fazla kesit alınması ve vasküler yapı içerisindeki kan elemanlarının hareketinin algılanması sayesinde boyalı anjiografik görüntülemelere benzer; nerdeyse tüm retinal vasküler hastalıkların patofizyolojisinde yer alan neovaskülarizasyonun görüntülemesine izin verebilmektedir.(Spaide, Klancnik ve Cooney, 2015)

Günümüzde ve ülkemizde yoğun poliklinik hacimleri, artan hasta sayıları ve retinal hastalıkların ve tedavilerinin sık değerlendirme gerektirmesi sebepleriyle, bahsedilen cihazlarla yapılan görüntüleme sayıları oldukça artmıştır. Bu görüntülerin doğru değerlendirilmesi hastalıkların prognoz tayini ve gerektiğinde tedavi endikasyonu koyma açısından oldukça önemlidir. Ayrıca DR ya da YBMD gibi hastalıkların tanısının erken konulması, gelecek görsel prognuzun en önemli belirteçlerinden biri olmaktadır.

Tıp pratiğinin birçok alanında aktif kullanma denemeleri olan yapan zeka (YZ) temelli derin öğrenme tabanlı görüntü analizi, oftalmoloji ve retina hastalıklarının değerlendirildiği günlük pratiğe entegre edilmeye çalışılmaktadır. YZ destekli programlar ile oftalmoloji pratiğinde özellikle retinal hastalıkların erkan tanısının konması, tedavi ve takip algoritmalarının belirmesi güncel literatürün konusunu ve çalışmaların hedefini oluşturmaktadır.(Ting ve diğerleri, 2019)

Bu derleme, retina hastalıklarının erken tanısında yapay zekanın mevcut durumunu; kullanılan algoritmik yaklaşımları, klinik doğrulama çalışmalarını, pratik uygulamaları ve ortaya çıkan zorlukları kapsayan kapsamlı bir değerlendirme sunmayı amaçlamaktadır.

2. Çeşitli Göz Hastalıklarında Yapay Zekanın Yeri

Diyabetik Retinopatide Yapay Zekanın Rolü

DR ve YBMD gibi hastalıklarda hastalığın erken tanısı ve tedavi başlangıcı, sonuç görme keskinliğini etkileyen en önemli parametredir.(Ferris, Davis ve Aiello, 1999) Uluslararası Diyabet Federasyonu'na göre 2045 yılında diyabet prevalansının 700 milyona ulaşacağı öngörülmektedir.(Sun ve diğerleri, 2022) Günümüzde diyabet ilişkili en önemli komplikasyonlardan olan DR taraması, ulaşılması gereken popülasyonun ancak %30-50 arasında bir kapsayıcılıktadır. Bu durum tanıda ciddi gecikmelere yol açmaktadır. Özellikle göz hekimlerinin sayıca yetersizliği tarama programlarındaki aksamalara katkı sağlamaktadır.(Scanlon, 2017) YZ algoritmalarının bu alanda kullanılması, görüntülerin yorumlanması için gereken uzman hekim gereksinimini önemli ölçüde azaltmakta; böylece mevcut insan kaynağının daha efektif kullanılmasına olanak tanımaktadır.

DR taramasında kullanılan YZ sistemleri ağırlıklı olarak fundus fotoğrafları üzerinde çalışmakta; eğitim ve doğrulama süreçleri büyük ölçekli, etiketlenmiş veri setleri üzerinden gerçekleştirilmektedir. Erken dönem çalışmalarda ağırlıklı olarak fundus fotoğrafı üzerinde

oftalmolojiye sevk gerektirir / gerektirmez ikili sınıflandırması yapan CNN tabanlı modeller kullanılmıştır. Bu alandaki ilk kapsamlı çalışmalardan biri olan Gulshan ve arkadaşlarının 2016 tarihli çalışmasında, Inception-v3 mimarisine dayanan model 128.175 fundus görüntüsü üzerinde eğitilmiş ve bağımsız bir test setinde %90,3 duyarlılık, %98,1 özgüllük ile oftalmolojiye sevk gerektiren DR'yi tespit etmiştir.(Gulshan ve diğerleri, 2016) Modelin performansı, 7-8 yıllık deneyime sahip retina uzmanlarının oluşturduğu bir panelle karşılaştırılmış ve istatistiksel olarak eşdeğer bulunmuştur. Bu çalışma, derin öğrenmenin oftalmoloji pratiğinde gerçekçi bir araç olabileceğini ilk kez büyük ölçekli biçimde kanıtlaması bakımından kritik öneme sahiptir.

Ardından gelen Ting ve arkadaşlarının 2017 tarihli çalışması, DR taramasının coğrafi ve etnik genellenebilirliğini sınamıştır. VGG-19 ve ResNet mimarilerinden ilham alan bir model, Singapur, Çin ve Hindistan'daki diyabetik hasta popülasyonlarından derlenen 494.661 retinal görüntü ile eğitilmiş; oftalmolojiye sevk gerektiren DR tespitinde AUC 0,936, diyabetik makula ödemi tespitinde ise AUC 0,931 elde edilmiştir.(Ting ve diğerleri, 2017) Aynı model eş zamanlı olarak YBMD ve glokomu da değerlendirmiş; çok hastalıklı sınıflandırma kapasitesiyle tek muayenede birden fazla patolojiyi tarayabilme potansiyelini ortaya koymuştur.

Fundus fotoğraflarının ötesinde OKT görüntüleri de DR'de YZ tabanlı analiz için giderek artan bir ilgi görmektedir. OKT ile elde edilen retinal katman kalınlık haritaları ve yapısal değişiklikler, derin öğrenme modellerinin diyabetik makula ödemini (DMÖ) tespit etmesini ve evrelemesini mümkün kılmaktadır. Bu yaklaşım, özellikle anti-VEGF tedavisi kararı verilmesi gereken olgularda klinisyene önemli bir karar destek işlevi sunmaktadır. Bu alanda literatürde özel bir yere sahip olan DeepMind çalışmasında ağırlıklı olarak üç boyutlu OKT verisi üzerinde çalışan iki aşamalı bir model geliştirilmiştir; model önce retinal dokuyu segmente etmekte, ardından bu segmentasyon haritası üzerinden hastalık sınıflandırması yapmaktadır.(De Fauw ve diğerleri, 2018) Elliden fazla retinal patolojiyi değerlendiren bu yaklaşım, oftalmolojiye sevk kararlarında kıdemli retina uzmanlarıyla kıyaslanabilir performans sergilemiş; özellikle DMÖ, YBMD ve DR gibi acil müdahale gerektiren durumlarda yanlış negatif oranı uzman hekimlerin ortalamasının altında kalmıştır.

DR evrelemesinde YZ'nin nereye kadar gidebileceğini sorgulayan çalışmalar da literatürde yer almaktadır. EfficientNet-B5 tabanlı modeller, uluslararası klinik DR derecelendirme skalasına göre beş aşamalı evrelemede deneyimli retina uzmanları arasındaki gözlemci uyumunu geçen kappa değerlerine ulaşmıştır.(Gulshan ve diğerleri, 2019) Bu sonuç, YZ'nin yalnızca sevk gerektirir / gerektirmez sınıflandırmasının ötesinde, klinik evreleme sürecine de entegre olabileceğine işaret etmektedir.

Progresyon tahmini açısından ise faz 3 klinik çalışmalardan elde edilen fundus görüntülerini kullanan bir CNN modelinin, iki yıl içinde proliferatif DR gelişme riskini baseline görüntüden tahmin edebildiği ve bu performansın geleneksel klinik risk faktörlerine dayanan modelleri istatistiksel olarak geçtiği bildirilmiştir.(Arcadu ve diğerleri, 2019) Benzer yaklaşımlar DMÖ için anti-VEGF tedavisine yanıt tahminine de uygulanmış; OKT tabanlı özelliklerden yola çıkılarak ranibizumab tedavisine morfolojik yanıtın daha ilk enjeksiyon öncesinde öngörülebildiği gösterilmiştir.(Bogunovic ve diğerleri, 2017)

Nitekim FDA tarafından onaylanan ilk otonom YZ tanı sistemi olan IDx-DR, birinci basamak sağlık ortamlarında oftalmolog müdahalesi gerektirmeksizin oftalmolojiye sevk gerektiren DR'yi tespit edebilmekte; bu özelliği ile erişim kısıtlı bölgelerde taramanın sürdürülebilirliğine doğrudan katkı sağlamaktadır.(Abràmoff, Lavin, Birch, Shah ve Folk,

2018) Teleoftalmoloji ile birleştirilmiş saha uygulamaları bağlamında ise Hindistan'daki birinci basamak merkezlerde yürütülen ve akıllı telefona monte edilebilir fundus kameralarının kullanıldığı prospektif bir çalışmada, YZ sisteminin retina uzmanı değerlendirmesiyle karşılaştırıldığında %95,8 duyarlılık ve %87,1 özgüllük ile oftalmolojiye sevk gerektiren DR'yi tespit ettiği bildirilmiştir.(Rajalakshmi, Subashini, Anjana ve Mohan, 2018) Bu çalışma, düşük kaynaklı sağlık ortamlarında mobil YZ tabanlı taramanın uygulanabilirliğini gerçek dünya koşullarında doğrulaması bakımından özel bir anlam taşımaktadır.

YZ algoritmalarının DR pratiğine entegrasyonunda karşılaşılan önemli güçlüklerden biri, farklı fundus kameraları ve görüntüleme koşullarına genellenebilirlik sorunudur. Eğitim veri setinde yer almayan kamera markası ya da görüntü kalitesiyle karşılaşıldığında model performansı düşebilmekte; bu durum klinik uygulamada standart cihaz kullanımının önemini artırmaktadır.(Aghabeigi Alooghareh, Sheikhey, Sahafi, Pirnejad ve Naemi, 2025) Öte yandan OKTA'nın DR takibine dahil edilmesiyle birlikte, vasküler perfüzyon kayıplarını ve neovaskülarizasyonu nicel olarak değerlendiren YZ modellerine yönelik çalışmalar da hız kazanmaktadır. Bu gelişmeler, YZ'nin DR'de yalnızca tarama değil; hastalık progresyonunun izlenmesi ve tedavi yanıtının değerlendirilmesi işlevlerini de üstlenebileceğine işaret etmektedir.

Yaşa Bağlı Makula Dejeneresansında Yapay Zekanın Rolü

YBMD, 50 yaş üzerindeki bireylerde kalıcı merkezi görme kaybının önde gelen nedenlerinden biri olup kuru ve yaş (neovasküler) olmak üzere iki temel formda karşımıza çıkmaktadır.(Wong ve diğerleri, 2014) Hastalığın erken ve orta evrelerinde merkezi görme büyük ölçüde korunduğundan hastalar çoğunlukla semptom geliştirmeden önce oftalmolojiye başvurmamaktadır. Oysa yaş YBMD'de anti-VEGF tedavisinin etkinliği büyük ölçüde tedavinin ne kadar erken başlandığına bağlıdır; bu durum tarama ve erken tanıyı kritik bir öncelik hâline getirmektedir.(Rosenfeld ve diğerleri, 2006)

YBMD'de YZ çalışmaları hem fundus fotoğrafı hem de OKT görüntüleri üzerinde yürütülmüş olmakla birlikte, hastalığın patolojik sürecini katman düzeyinde yansıtması nedeniyle OKT temelli yaklaşımlar literatürde belirgin biçimde ön plana çıkmaktadır. Kermany ve arkadaşlarının 2018 tarihli çalışmasında, 108.312 OKT görüntüsü üzerinde eğitilen Inception-v3 tabanlı model; yaş YBMD'ye özgü koroid neovaskülarizasyonunu ve kuru YBMD'de drusen birikimini normal görüntülerden ayırt etmede %96,6 doğruluk oranına ulaşmış, bu performans değeri uzman retina hekimlerinin ortalamasıyla örtüşmüştür.(Kermany ve diğerleri, 2018) Aynı çalışmada modelin karar sürecini görselleştiren ısı haritaları incelendiğinde, klinisyenin odaklandığı anatomik yapılarla büyük ölçüde örtüştüğü görülmüş; bu bulgu modelin klinik olarak anlamlı görüntü bölgelerini öğrendiğine işaret etmesi bakımından önemlidir.

DeepMind'ın daha önce DR bağlamında da değinilen iki aşamalı OKT analiz sistemi, YBMD evrelemesinde de dikkat çekici sonuçlar vermiştir. Retinal katmanları önce segmente eden, ardından bu yapısal haritadan sınıflandırma yapan bu mimari, yaş YBMD için oftalmolojiye sevk kararını %88,9 duyarlılık ve %92,3 özgüllük ile vermiş; özellikle subretinal sıvı ve pigment epitel dekolmanının tespitinde uzman performansına yaklaşmıştır.(De Fauw ve diğerleri, 2018) Modelin açıklanabilirlik katmanları, hangi retinal yapıya dayanarak karar verdiğini görselleştirebildiğinden klinisyen güveninin pekişmesi açısından da anlamlı bir katkı sunmuştur.

Progresyon tahmini bu alanda da gündemdeki yerini korumaktadır. Burlina ve arkadaşları, erken ve orta evre YBMD hastalarının fundus görüntülerinden yola çıkarak iki yıl içinde ileri evreye geçiş riskini tahmin eden CNN modelleri geliştirmiş; bu modellerin standart klinik risk skorlama sistemlerini istatistiksel olarak geçtiğini bildirmiştir.(Burlina ve diğerleri, 2017) Benzer biçimde OKTA üzerinde çalışan modeller, koriodal neovaskülarizasyonun aktivitesini ve tedaviye yanıtı nicel olarak değerlendirme kapasitesi göstermiş; anti-VEGF enjeksiyon sıklığının kişiselleştirilmesinde YZ destekli karar protokollerinin önünü açmıştır.(Bogunovic ve diğerleri, 2017; Pfau ve diğerleri, 2020)

Bununla birlikte YBMD'de YZ uygulamalarının birtakım sınırlılıkları mevcuttur. Mevcut modellerin büyük çoğunluğu, belirli OKT cihaz markalarına ve görüntüleme protokollerine özgü veri setleri üzerinde eğitilmiş olup farklı cihazlardan elde edilen görüntülere genellenebilirlikleri henüz yeterince sınanmamıştır. Öte yandan kuru YBMD'nin erken evresinde drusen yükünün ve coğrafi atrofinin nicel olarak değerlendirilmesi, model performansını doğrudan etkileyen görüntü kalitesi sorunlarına karşı hassasiyetini korumaktadır. Son olarak, mevcut çalışmaların büyük bölümünün retrospektif ve tek merkezli tasarımı, gerçek dünya uygulamalarında beklenen performansın prospektif çok merkezli çalışmalarla doğrulanması gerekliliğini ortaya koymaktadır.(Keane ve Topol, 2018)

Glokomda Yapay Zekanın Rolü

Glokom, primer olarak optik sinir hasarıyla seyreden ve irreversibl görme kaybına yol açan bir hastalık olmakla birlikte; retinal sinir lifi tabakasını (RSLT) doğrudan etkileyen seyri nedeniyle retinal görüntüleme ve YZ çalışmaları açısından bu başlık altında değerlendirilebilir. Hastalığın sinsi ilerleyişi ve erken evrede merkezi görmeyi koruması, tanının çoğunlukla ileri evrede konulmasına zemin hazırlamaktadır. Bu özelliği, glokomu erken YZ destekli taramanın en fazla fayda sağlayabileceği klinik tablolar arasına sokmaktadır.(Weinreb, Aung ve Medeiros, 2014)

YZ çalışmalarında glokom tespiti için iki temel görüntüleme modalitesi kullanılmaktadır: fundus fotoğrafı üzerinden optik disk ve cup disk oranının değerlendirilmesi ile OKT üzerinden RSLT kalınlık haritalarının analizi. Li ve arkadaşlarının fundus fotoğrafı üzerinde geliştirdiği CNN modeli, glokomlu optik sinir başını %95,6 duyarlılık ve %92,0 özgüllük ile tespit etmiş; performans açısından genel oftalmologları geride bırakırken retina uzmanlarıyla kıyaslanabilir düzeyde kalmıştır.(Li ve diğerleri, 2018) Benzer çalışmalarda ResNet ve DenseNet mimarileri de yüksek AUC değerleriyle öne çıkmıştır.

OKT tabanlı yaklaşımlarda ise RSLT kalınlık haritaları üzerinde çalışan modeller, yapısal hasarı daha erken ve daha nicel biçimde ortaya koyabilmektedir.(Medeiros ve diğerleri, 2012) Bu alanda geliştirilen modellerin bir kısmı, klinisyenin henüz patolojik saymadığı RSLT incelme örüntülerinden yola çıkarak glokom gelişim riskini öngörebilmiş; bu durum YZ'nin yapısal değişiklikleri insan gözünden önce fark edebileceğine dair önemli bir kanıt sunmuştur.(Shibata ve diğerleri, 2018)

Çok modlu yaklaşımlar da literatürde giderek daha fazla yer bulmaktadır. Fundus fotoğrafı, OKT ve görme alanı verilerini birlikte işleyen modeller, tek modaliteye dayanan sistemlere kıyasla daha yüksek tanısal doğruluk sergilemiş; özellikle erken evre glokomda yanlış negatif oranını anlamlı ölçüde düşürmüştür.(Asaoka, Murata, Iwase ve Araie, 2016)

Sınırlılıklar açısından glokom, DR ve YBMD'ye kıyasla daha heterojen bir klinik tablo sunmaktadır. Normotansif glokom, pigmenter glokom veya psödoeksfoliyasyon glokomu

gibi alt tiplerin eğitim veri setlerinde yeterince temsil edilmemesi, model performansını klinik pratikte kısıtlayabilmektedir. Ayrıca görme alanı kaybının yapısal hasarla her zaman paralel seyretmemesi, YZ modellerinin hangi parametreyi referans alarak eğitildiği sorusunu kritik hâle getirmektedir.(Boland ve Quigley, 2007)

3. Yapay Zeka Yöntemleri ve Mimariler

Retina hastalıklarının YZ destekli tanısında kullanılan yöntemler, temel olarak derin öğrenme tabanlı görüntü analizi üzerine kuruludur. Bu alanda en yaygın kullanılan mimari olan evrişimsel sinir ağları (CNN), görüntü üzerinde hiyerarşik özellik öğrenimi yaparak ham piksel verisinden klinik anlamlı örüntülere ulaşmaktadır. Kenar ve doku gibi düşük seviyeli özelliklerden başlayarak mikroanevrizma, subretinal sıvı veya RSLT incelenmesi gibi hastalığa özgü bulgulara kadar uzanan bu öğrenme süreci, CNN'i tıbbi görüntü analizinde güçlü bir araç hâline getirmektedir.(Litjens ve diğerleri, 2017)

Literatürdeki çalışmalarda Inception, ResNet, VGG ve EfficientNet gibi farklı CNN mimarileri kullanılmış olmakla birlikte, bu modeller çoğunlukla sıfırdan eğitilmemektedir. Milyonlarca genel görüntü üzerinde önceden eğitilmiş ağırlıkların tıbbi veri setiyle ince ayarlanması anlamına gelen transfer learning yaklaşımı, sınırlı etiketli veriyle yüksek performans elde etmeyi mümkün kılmakta ve retina çalışmalarının büyük çoğunluğunda tercih edilmektedir.(Tajbakhsh ve diğerleri, 2016)

Son yıllarda görüntü analizine uyarlanan Vision Transformer (ViT) mimarileri de retina çalışmalarında yer bulmaya başlamıştır. CNN'lerin yerel örüntülere odaklanmasının aksine ViT, görüntüyü yamalar hâlinde işleyerek uzak bölgeler arasındaki ilişkileri de modelleyebilmektedir; bu özellik özellikle geniş retinal alanı etkileyen patolojilerde avantaj sağlamaktadır. Öte yandan OKT görüntülerinde katman segmentasyonu için U-Net gibi encoder-decoder mimarileri yaygın biçimde kullanılmakta; bu modeller piksel düzeyinde sınıflandırma yaparak retinal katmanların sınırlarını ve patolojik sıvı birikimlerini hassas biçimde ortaya koymaktadır.(Roy ve diğerleri, 2017)

4. Klinik Doğrulama Çalışmaları ve Performans Metrikleri

YZ modellerinin klinik kullanıma alınabilmesi için teknik performansının standart metriklerle ölçülmesi ve gerçek dünya koşullarında doğrulanması gerekmektedir. Bu amaçla kullanılan temel ölçütler duyarlılık, özgüllük, ROC eğrisi altında kalan alan (AUC) ve Cohen kappa katsayısıdır. Duyarlılık, hastayı hasta olarak doğru tespit etme; özgüllük ise sağlıklıyı sağlıklı olarak doğru sınıflandırma kapasitesini yansıtmaktadır. Tarama bağlamında yanlış negatif; yani oftalmolojiye sevk gerektiren bir hastanın gözden kaçırılması; yanlış pozitife kıyasla daha ağır bir klinik sonuç doğurduğundan, tarama amaçlı modellerde yüksek duyarlılık öncelikli hedef olarak benimsenmektedir.(Collins, Reitsma, Altman ve Moons, 2015)

Doğrulama çalışmaları metodolojik açıdan iç ve dış doğrulama olarak ikiye ayrılmaktadır. İç doğrulamada model, eğitimde kullanılan veri setiyle aynı kaynaktan ayrılan bir test kümesiyle sınanmakta; dış doğrulamada ise farklı popülasyonlardan, farklı cihazlarla ve farklı klinik koşullarda elde edilmiş bağımsız veri setleri kullanılmaktadır. Literatürdeki pek çok çalışmanın yalnızca iç doğrulama ile sınırlı kalması, yayımlanan performans değerlerinin gerçek dünya uygulamalarında ne ölçüde korunacağı konusunda önemli bir soru işareti oluşturmaktadır.(Nagendran ve diğerleri, 2020; Varoquaux ve Cheplygina, 2022)

Doğrulama çalışmalarında YZ modellerinin performansı çoğunlukla uzman hekimlerle kıyaslanmaktadır. Bu karşılaştırmalarda modelin genel pratisyen ya da birinci basamak hekimiyle değil, retina uzmanıyla kıyaslandığında bile rekabetçi sonuçlar verdiği görülmektedir.(Ting ve diğerleri, 2019) Bununla birlikte uzman karşılaştırmasının kendi içinde metodolojik güçlükleri mevcuttur; uzmanlar arasındaki gözlemci uyumunun her zaman yüksek olmaması, referans standardının belirlenmesini zorlaştırmakta ve model değerlendirmelerini doğrudan etkilemektedir.(Wilkinson ve diğerleri, 2003)

Prospektif klinik çalışmalar ise bu alanda hâlâ sınırlı sayıdadır. Mevcut kanıtların büyük bölümü retrospektif veri analizi üzerine kuruludur; oysa bir modelin gerçek hasta akışına entegre edildiğinde klinik sonuçları nasıl etkilediği, ancak prospektif ve tercihen randomize kontrollü tasarımlarla ortaya konabilmektedir. Bu boşluk, YZ tabanlı tarama sistemlerinin rutin pratiğe alınması önündeki en önemli metodolojik engellerden biri olmaya devam etmektedir.(Liu ve diğerleri, 2019)

Tablo 1. Seçilmiş Yapay Zeka Modellerinin Retina Hastalıkları Tespitindeki Performansı

Çalışma	Hastalık	Duyarlılık	Özgüllük	AUC
Gulshan ve ark. (2016)(Gulshan ve diğerleri, 2019)	Diyabetik Retinopati	%97,5	%93,4	0,99
Ting ve ark. (2017)(Ting ve diğerleri, 2017)	DR / Glokom / YBMD	%90,5	%91,6	0,94
De Fauw ve ark. (2018)(De Fauw ve diğerleri, 2018)	OCT Patolojileri	%86,4	%99,8	0,98
Li ve ark. (2018)(Li ve diğerleri, 2018)	Glokom	%95,6	%92,0	0,97
Burlina ve ark. (2017)(Burlina ve diğerleri, 2017)	YBMD Evresi	%88,4	%84,0	0,94

5. Gelecek Projeksiyonu

Retina hastalıklarında YZ'nin kısa vadeli geleceği, mevcut modellerin klinik iş akışına daha derin biçimde entegre edilmesi üzerine şekillenmektedir. Tek bir patolojiyi tespit etmek üzere tasarlanmış sistemlerin yerini, aynı görüntüden eş zamanlı olarak birden fazla hastalığı değerlendiren, evreleyebilen ve sevk kararı üretebilen çok görevli modeller almaya başlamıştır. Bu yaklaşım, özellikle birinci basamak tarama programlarında tek seferde kapsamlı bir değerlendirme sunması bakımından klinik açıdan son derece verimlidir.(Ting ve diğerleri, 2017)

Orta vadede en dikkat çekici gelişme alanlarından biri, tedavi yanıtının ve hastalık progresyonunun YZ ile öngörülmesidir. Anti-VEGF tedavisine yanıtın ilk enjeksiyon

öncesinde tahmin edilmesi, enjeksiyon sıklığının kişiselleştirilmesi ve erken progresyon riskine göre takip sıklığının ayarlanması; YZ'yi tanısal bir araçtan klinik karar ortağına dönüştürme potansiyeli taşımaktadır.(Bogunovic ve diğerleri, 2017) Bu yaklaşım hem hasta sonuçlarını iyileştirme hem de sağlık sistemi üzerindeki yükü azaltma açısından anlamlı bir fırsat sunmaktadır.

Büyük dil modelleri ve çok modlu YZ sistemlerinin gelişimiyle birlikte, görüntü verisinin hasta öyküsü, laboratuvar bulguları ve sistemik hastalık bilgisiyle bütünleştirildiği hibrit modeller de gündeme girmektedir. Diyabetik bir hastada HbA1c düzeyi, diyabet süresi ve böbrek fonksiyon testleriyle retinal görüntünün birlikte işlenmesi; salt görüntü tabanlı modellerin ötesinde daha bütüncül bir risk değerlendirmesi yapılmasını mümkün kılabilir.

Federe öğrenme, bu alandaki bir diğer önemli gelişme yönünü oluşturmaktadır. Hasta verilerinin kurumlar arasında paylaşılması yerine modelin farklı merkezlerde yerel olarak eğitilip yalnızca ağırlıkların birleştirilmesi esasına dayanan bu yaklaşım, gizlilik mevzuatıyla uyumu korurken geniş ve çeşitli veri setlerinin sağlayacağı performans kazanımına ulaşmayı mümkün kılmaktadır.(Rieke ve diğerleri, 2020) Türkiye gibi merkezi sağlık veri altyapısına sahip ülkelerde bu yaklaşımın ulusal ölçekli tarama programlarıyla entegrasyonu, gerçekçi bir orta vadeli hedef olarak değerlendirilebilir.

6. Zorluklar ve Etik Boyutlar

YZ tabanlı retina tarama sistemlerinin klinik pratiğe entegrasyonu, teknik performansın ötesinde bir dizi yapısal ve etik sorunu da beraberinde getirmektedir. Bu sorunların yeterince ele alınmadan yalnızca model doğruluk değerleri üzerinden ilerlenmesi, gerçek dünya uygulamalarında ciddi aksaklıklara zemin hazırlayabilir.

Veri kalitesi ve temsil edilebilirlik bu alandaki temel güçlüklerden birini oluşturmaktadır. Mevcut modellerin büyük çoğunluğu belirli etnik grupları, cihaz markalarını ya da hastalık evrelerini orantısız biçimde temsil eden veri setleri üzerinde eğitilmiştir.(Oloruntoba ve diğerleri, 2022) Farklı göz renklerine ve retinal pigmentasyon düzeylerine sahip popülasyonlarda model performansının düşebildiği bildirilmekte; bu durum YZ sistemlerinin evrensel kullanıma alınmadan önce hedef popülasyona özgü doğrulama çalışmalarından geçirilmesi gerektiğini ortaya koymaktadır. Türkiye gibi mevcut büyük çalışmaların ağırlıklı olarak Batı veya Doğu Asya kohortlarına dayandığı ülkelerde bu mesele özellikle kritik bir önem taşımaktadır.

Açıklanabilirlik sorunu da klinik benimseme önündeki önemli engellerden biri olmaya devam etmektedir. Derin öğrenme modellerinin büyük bölümü kara kutu niteliği taşımakta; yani hangi görüntü özelliğine dayanarak karar verdiğini klinisyene açık biçimde sunamamaktadır. Grad-CAM gibi ısı haritası yöntemleri bu şeffaflık açığını kısmen kapatmakla birlikte, üretilen görselleştirmelerin klinik olarak her zaman anlamlı yapılara karşılık gelmediği de gösterilmiştir.(Amann ve diğerleri, 2020) Bir klinisyenin YZ çıktısına güvenebilmesi için modelin ne gördüğünü anlaması, yalnızca ne söylediğini bilmesi yeterli değildir.

Hukuki sorumluluk meselesi ise henüz netlik kazanmamış bir alan olmayı sürdürmektedir. YZ'nin önerdiği sevk kararına göre hareket eden bir hekimin hastasında olumsuz bir sonuç geliştiğinde sorumluluk kime aittir; hekime mi, yazılımı geliştiren firmaya mı, yoksa sistemi satın alıp kullanan kuruma mı? Türkiye'de ve pek çok ülkede bu soruya yanıt verecek yasal düzenlemeler henüz oluşturulmamıştır. Bu belirsizlik,

kurumların sistemi benimsemesini geciktiren pratik bir engel oluşturmaktadır.(Gerke, Minssen ve Cohen, 2020)

Son olarak, YZ sistemlerinin zamanla performans kaymasına uğrayabileceği göz ardı edilmemelidir. Hasta popülasyonunun değişmesi, cihaz yazılımlarının güncellenmesi ya da görüntüleme protokollerinin farklılaşması, eğitim sırasında yüksek performans sergileyen bir modelin zaman içinde klinik açıdan yetersiz kalmaya başlamasına neden olabilmektedir. Bu durum, YZ sistemlerinin tek seferlik bir doğrulamayla değil; sürekli izleme ve periyodik yeniden eğitim protokolleriyle yönetilmesi gerektiğini ortaya koymaktadır.

7. Sonuç

Retina hastalıklarının erken tanısında YZ, klinik pratiği dönüştürme potansiyeli taşıyan bir teknoloji olarak literatürdeki yerini giderek güçlendirmektedir. DR, YBMD ve glokom gibi farklı patolojilerde yürütülen geniş ölçekli çalışmalar, derin öğrenme tabanlı modellerin oftalmolojiye sevk kararı verme, hastalığı evreleme ve progresyonu öngörme gibi görevlerde uzman hekimlerle kıyaslanabilir performansa ulaşabildiğini ortaya koymaktadır. Bu durum YZ'yi, özellikle uzman erişiminin kısıtlı olduğu birinci basamak ortamlarında ve yüksek hasta hacmiyle çalışan tarama programlarında değerli bir karar destek aracı konumuna taşımaktadır.

Bununla birlikte mevcut kanıt tabanının sınırlılıkları da göz ardı edilmemelidir. Retrospektif tasarımın baskınlığı, dış doğrulama çalışmalarının yetersizliği, temsil edilebilirlik sorunları ve açıklanabilirlik güçlükleri; YZ sistemlerinin rutin klinik kullanıma alınması için aşılması gereken öncelikli engeller arasında yer almaktadır. Teknik performansın yanı sıra hukuki sorumluluk, veri güvenliği ve sürekli izleme gereklilikleri de bu sistemlerin sağlık politikası düzeyinde ele alınmasını zorunlu kılmaktadır.

Sonuç olarak YZ, retina hastalıklarında erken tanının önündeki insan kaynağı ve erişim engellerini aşma kapasitesiyle körlüğü önlemeye yönelik küresel çabaların ayrılmaz bir parçası hâline gelmektedir. Ancak bu potansiyelin gerçek dünya pratiğine yansıyabilmesi; prospektif klinik doğrulama çalışmalarına, çeşitli popülasyonları kapsayan veri altyapısına ve klinisyen-mühendis-politika yapıcı iş birliğine olan ihtiyacı ortadan kaldırmamaktadır.

Kaynakça

Abràmoff, M. D., Garvin, M. K. ve Sonka, M. (2010). Retinal imaging and image analysis. *IEEE reviews in biomedical engineering*, *3*, 169-208. doi:10.1109/RBME.2010.2084567

Abràmoff, M. D., Lavin, P. T., Birch, M., Shah, N. ve Folk, J. C. (2018). Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *NPJ digital medicine*, *1*, 39. doi:10.1038/s41746-018-0040-6

Aghabeigi Alooghareh, M. M., Sheikhey, M. M., Sahafi, A., Pirnejad, H. ve Naemi, A. (2025). Deep Learning for Comprehensive Analysis of Retinal Fundus Images: Detection of Systemic and Ocular Conditions. *Bioengineering*, *12*(8), 840. doi:10.3390/bioengineering12080840

Amann, J., Blasimme, A., Vayena, E., Frey, D., Madai, V. I., ve Precise4Q consortium. (2020). Explainability for artificial intelligence in healthcare: A multidisciplinary perspective. *BMC medical informatics and decision making*, *20*(1), 310. doi:10.1186/s12911-020-01332-6

Arcadu, F., Benmansour, F., Maunz, A., Willis, J., Haskova, Z. ve Prunotto, M. (2019). Deep learning algorithm predicts diabetic retinopathy progression in individual patients. *NPJ digital medicine*, *2*, 92. doi:10.1038/s41746-019-0172-3

Asaoka, R., Murata, H., Iwase, A. ve Araie, M. (2016). Detecting Preperimetric Glaucoma with Standard Automated Perimetry Using a Deep Learning Classifier. *Ophthalmology*, *123*(9), 1974-1980. doi:10.1016/j.ophtha.2016.05.029

Bogunovic, H., Waldstein, S. M., Schlegl, T., Langs, G., Sadeghipour, A., Liu, X., … Schmidt-Erfurth, U. (2017). Prediction of Anti-VEGF Treatment Requirements in Neovascular AMD Using a Machine Learning Approach. *Investigative Ophthalmology & Visual Science*, *58*(7), 3240-3248. doi:10.1167/iovs.16-21053

Boland, M. V. ve Quigley, H. A. (2007). Risk factors and open-angle glaucoma: Classification and application. *Journal of Glaucoma*, *16*(4), 406-418. doi:10.1097/IJG.0b013e31806540a1

Burlina, P. M., Joshi, N., Pekala, M., Pacheco, K. D., Freund, D. E. ve Bressler, N. M. (2017). Automated Grading of Age-Related Macular Degeneration From Color Fundus Images Using Deep Convolutional Neural Networks. *JAMA ophthalmology*, *135*(11), 1170-1176. doi:10.1001/jamaophthalmol.2017.3782

Collins, G. S., Reitsma, J. B., Altman, D. G. ve Moons, K. G. M. (2015). Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): The TRIPOD statement. *BMJ*, *350*, g7594. doi:10.1136/bmj.g7594

De Fauw, J., Ledsam, J. R., Romera-Paredes, B., Nikolov, S., Tomasev, N., Blackwell, S., … Ronneberger, O. (2018). Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nature Medicine*, *24*(9), 1342-1350. doi:10.1038/s41591-018-0107-6

Ferris, F. L., Davis, M. D. ve Aiello, L. M. (1999). Treatment of diabetic retinopathy. *The New England Journal of Medicine*, *341*(9), 667-678. doi:10.1056/NEJM199908263410907

GBD 2019 Blindness and Vision Impairment Collaborators ve Vision Loss Expert Group of the Global Burden of Disease Study. (2021). Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: The Right to Sight: an analysis for the Global Burden of Disease Study. *The Lancet. Global Health*, *9*(2), e144-e160. doi:10.1016/S2214-109X(20)30489-7

Gerke, S., Minssen, T. ve Cohen, G. (2020). Ethical and legal challenges of artificial intelligence-driven healthcare. *Artificial Intelligence in Healthcare*, 295-336. doi:10.1016/B978-0-12-818438-7.00012-5

Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., … Webster, D. R. (2016). Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, *316*(22), 2402-2410. doi:10.1001/jama.2016.17216

Gulshan, V., Rajan, R. P., Widner, K., Wu, D., Wubbels, P., Rhodes, T., … Webster, D. R. (2019). Performance of a Deep-Learning Algorithm vs Manual Grading for Detecting Diabetic Retinopathy in India. *JAMA ophthalmology*, *137*(9), 987-993. doi:10.1001/jamaophthalmol.2019.2004

Huang, D., Swanson, E. A., Lin, C. P., Schuman, J. S., Stinson, W. G., Chang, W., … Puliafito, C. A. (1991). Optical coherence tomography. *Science*, *254*(5035), 1178-1181. doi:10.1126/science.1957169

Keane, P. A. ve Topol, E. J. (2018). With an eye to AI and autonomous diagnosis. *NPJ digital medicine*, *1*, 40. doi:10.1038/s41746-018-0048-y

Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., … Zhang, K. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, *172*(5), 1122-1131.e9. doi:10.1016/j.cell.2018.02.010

Li, Z., He, Y., Keel, S., Meng, W., Chang, R. T. ve He, M. (2018). Efficacy of a Deep Learning System for Detecting Glaucomatous Optic Neuropathy Based on Color Fundus Photographs. *Ophthalmology*, *125*(8), 1199-1206. doi:10.1016/j.ophtha.2018.01.023

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., … Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, *42*, 60-88. doi:10.1016/j.media.2017.07.005

Liu, X., Faes, L., Kale, A. U., Wagner, S. K., Fu, D. J., Bruynseels, A., … Denniston, A. K. (2019). A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: A systematic review and meta-analysis. *The Lancet. Digital Health*, *1*(6), e271-e297. doi:10.1016/S2589-7500(19)30123-2

Masland, R. H. (2012). The neuronal organization of the retina. *Neuron*, *76*(2), 266-280. doi:10.1016/j.neuron.2012.10.002

Medeiros, F. A., Zangwill, L. M., Anderson, D. R., Liebmann, J. M., Girkin, C. A., Harwerth, R. S., … Weinreb, R. N. (2012). Estimating the rate of retinal ganglion cell loss in glaucoma. *American Journal of Ophthalmology*, *154*(5), 814-824.e1. doi:10.1016/j.ajo.2012.04.022

Nagendran, M., Chen, Y., Lovejoy, C. A., Gordon, A. C., Komorowski, M., Harvey, H., … Maruthappu, M. (2020). Artificial intelligence versus clinicians: Systematic review of design, reporting standards, and claims of deep learning studies. *BMJ*, *368*, m689. doi:10.1136/bmj.m689

Oloruntoba, A. I., Vestergaard, T., Nguyen, T. D., Yu, Z., Sashindranath, M., Betz-Stablein, B., … Mar, V. (2022). Assessing the Generalizability of Deep Learning Models Trained on Standardized and Nonstandardized Images and Their Performance Against Teledermatologists: Retrospective Comparative Study. *JMIR dermatology*, *5*(3), e35150. doi:10.2196/35150

Pfau, M., Möller, P. T., Künzel, S. H., von der Emde, L., Lindner, M., Thiele, S., … Fleckenstein, M. (2020). Type 1 Choroidal Neovascularization Is Associated with Reduced Localized Progression of Atrophy in Age-Related Macular Degeneration. *Ophthalmology. Retina*, *4*(3), 238-248. doi:10.1016/j.oret.2019.09.016

Rajalakshmi, R., Subashini, R., Anjana, R. M. ve Mohan, V. (2018). Automated diabetic retinopathy detection in smartphone-based fundus photography using artificial intelligence. *Eye*, *32*(6), 1138-1144. doi:10.1038/s41433-018-0064-9

Rieke, N., Hancox, J., Li, W., Milletarì, F., Roth, H. R., Albarqouni, S., … Cardoso, M. J. (2020). The future of digital health with federated learning. *NPJ digital medicine*, *3*, 119. doi:10.1038/s41746-020-00323-1

Rosenfeld, P. J., Brown, D. M., Heier, J. S., Boyer, D. S., Kaiser, P. K., Chung, C. Y., … MARINA Study Group. (2006). Ranibizumab for neovascular age-related macular degeneration. *The New England Journal of Medicine*, *355*(14), 1419-1431. doi:10.1056/NEJMoa054481

Roy, A. G., Conjeti, S., Karri, S. P. K., Sheet, D., Katouzian, A., Wachinger, C. ve Navab, N. (2017). ReLayNet: Retinal layer and fluid segmentation of macular optical coherence tomography using fully convolutional networks. *Biomedical Optics Express*, *8*(8), 3627-3642. doi:10.1364/BOE.8.003627

Scanlon, P. H. (2017). The English National Screening Programme for diabetic retinopathy 2003-2016. *Acta Diabetologica*, *54*(6), 515-525. doi:10.1007/s00592-017-0974-1

Shibata, N., Tanito, M., Mitsuhashi, K., Fujino, Y., Matsuura, M., Murata, H. ve Asaoka, R. (2018). Development of a deep residual learning algorithm to screen for glaucoma from fundus photography. *Scientific Reports*, *8*(1), 14665. doi:10.1038/s41598-018-33013-w

Spaide, R. F., Klancnik, J. M. ve Cooney, M. J. (2015). Retinal vascular layers imaged by fluorescein angiography and optical coherence tomography angiography. *JAMA ophthalmology*, *133*(1), 45-50. doi:10.1001/jamaophthalmol.2014.3616

Sun, H., Saeedi, P., Karuranga, S., Pinkepank, M., Ogurtsova, K., Duncan, B. B., … Magliano, D. J. (2022). IDF Diabetes Atlas: Global, regional and country-level diabetes prevalence estimates for 2021 and projections for 2045. *Diabetes Research and Clinical Practice*, *183*, 109119. doi:10.1016/j.diabres.2021.109119

Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B. ve Jianming Liang, null. (2016). Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? *IEEE transactions on medical imaging*, *35*(5), 1299-1312. doi:10.1109/TMI.2016.2535302

Ting, D. S. W., Cheung, C. Y.-L., Lim, G., Tan, G. S. W., Quang, N. D., Gan, A., … Wong, T. Y. (2017). Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations With Diabetes. *JAMA*, *318*(22), 2211-2223. doi:10.1001/jama.2017.18152

Ting, D. S. W., Pasquale, L. R., Peng, L., Campbell, J. P., Lee, A. Y., Raman, R., … Wong, T. Y. (2019). Artificial intelligence and deep learning in ophthalmology. *The British Journal of Ophthalmology*, *103*(2), 167-175. doi:10.1136/bjophthalmol-2018-313173

Varoquaux, G. ve Cheplygina, V. (2022). Machine learning for medical imaging: Methodological failures and recommendations for the future. *NPJ digital medicine*, *5*(1), 48. doi:10.1038/s41746-022-00592-y

Weinreb, R. N., Aung, T. ve Medeiros, F. A. (2014). The Pathophysiology and Treatment of Glaucoma. *JAMA*, *311*(18), 1901-1911. doi:10.1001/jama.2014.3192

Wilkinson, C. P., Ferris, F. L., Klein, R. E., Lee, P. P., Agardh, C. D., Davis, M., … Global Diabetic Retinopathy Project Group. (2003). Proposed international clinical diabetic retinopathy and diabetic macular edema disease severity scales. *Ophthalmology*, *110*(9), 1677-1682. doi:10.1016/S0161-6420(03)00475-5

Wong, W. L., Su, X., Li, X., Cheung, C. M. G., Klein, R., Cheng, C.-Y. ve Wong, T. Y. (2014). Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: A systematic review and meta-analysis. *The Lancet. Global Health*, *2*(2), e106-116. doi:10.1016/S2214-109X(13)70145-1

Çocuk Ruh Sağlığında Yapay Zekâ: Davranış Analizi ve Erken Müdahale

Merve Dilli Gürkan, Ceylin Olkuner

1. Giriş

Çocuk ruh sağlığı alanında yapay zekâ (YZ) uygulamaları, son yıllarda özellikle davranış analizi ve erken müdahale süreçlerinde önemli hâle gelmiştir. Gelişen teknoloji ile birlikte, çocukların bilişsel, duygusal ve davranışsal gelişimlerine ilişkin büyük veri setlerinin analiz edilmesi mümkün hâle gelmiş ve bu durum erken tanı süreçlerine önemli katkılar sağlamıştır.[1] Özellikle makine öğrenmesi ve derin öğrenme algoritmaları aracılığıyla çocuklarda görülen nörogelişimsel bozuklukların erken tespiti mümkün hale gelmektedir.[2,3] Erken çocukluk döneminde davranışsal örüntülerin sistematik biçimde analiz edilmesi, çocukların gelişimsel risklerinin belirlenmesinde de önemli bir rol oynamaktadır. Yapay zekâ sistemleri, geleneksel değerlendirme yöntemlerine kıyasla daha hızlı ve kapsamlı analizler yapabilmekte ve böylece klinik karar süreçlerine önemli bir destek sağlamaktadır.[4]

Bunun yanı sıra, yapay zekâ destekli müdahale yaklaşımları, çocuk ruh sağlığı alanında bireyselleştirilmiş tedavi planlarının oluşturulmasına önemli katkılar sağlamaktadır. Bu sistemler, çocukların duygu durumları, davranış örüntüleri ve sosyal etkileşimleri üzerinden elde edilen verileri analiz ederek her bireye özgü müdahale stratejileri geliştirilmesine olanak tanımaktadır.[5] Özellikle dijital terapötik uygulamalar ve yapay zekâ destekli psikolojik müdahale araçları, çocukların duygu düzenleme becerilerini geliştirmeye yönelik yapılandırılmış programlar sunmaktadır.[6,7]

Bununla birlikte, yapay zekâ uygulamalarının çocuk ruh sağlığı alanında kullanımı bazı etik ve uygulamaya yönelik sorunları da beraberinde getirmektedir. Özellikle veri gizliliği, çocuklara ait hassas bilgilerin korunması ve algoritmik önyargı gibi konular literatürde önemli tartışma alanları arasında yer almaktadır.[8] Ayrıca, yapay zekâ sistemlerinin klinik karar süreçlerinde tamamen bağımsız bir araç olarak değil, uzman destekli bir sistem olarak kullanılması gerektiği vurgulanmaktadır.[5]

Sonuç olarak, çocuk ruh sağlığı alanında yapay zekâ uygulamaları erken tanı ve müdahale süreçlerinde önemli fırsatlar sunmakta; ancak bu teknolojilerin etkili ve güvenli biçimde kullanılabilmesi için etik, bilimsel ve uygulamaya yönelik boyutların birlikte ele alınması gerekmektedir.

2. Davranış Analizi ile Erken Risk Tahmini

Yapay zekâ temelli davranış analizi, günlük yaşamdan elde edilen dijital veriler yoluyla henüz klinik olarak belirgin hale gelmemiş psikiyatrik belirtileri saptamaya olanak tanıyarak, çocuk ve ergen ruh sağlığında erken risk tahmini açısından yeni bir paradigma sunmaktadır. Bu yaklaşım, özellikle erken gelişim döneminde ortaya çıkan ince davranışsal sinyallerin nesnel olarak değerlendirilmesini mümkün kılarak, geleneksel klinik gözleme dayalı yöntemleri tamamlayıcı bir rol üstlenmektedir.

Erken çocukluk döneminde, özellikle bebeklikte ortaya çıkan davranışsal ve fizyolojik sinyaller, nörogelişimsel risklerin erken göstergeleri olarak değerlendirilmektedir. Bu bağlamda, bebek ağlamalarının derin öğrenme temelli modeller aracılığıyla analiz edilmesi, ağlamaların açlık, ağrı veya rahatsızlık gibi durumlara göre yüksek doğruluk oranlarıyla sınıflandırılabildiğini göstermiştir . Bu tür yaklaşımlar, hem yoğun bakım hem de ev ortamında ebeveynlere rehberlik sağlama ve erken risk taraması yapabilme potansiyeli taşımaktadır.[9] Benzer şekilde, yapay zekâ destekli yüz analiz sistemleri,

yenidoğanlarda ağrı ve distres gibi sözel olarak ifade edilemeyen durumların nesnel biçimde değerlendirilmesine katkı sunmaktadır. Bununla birlikte, bu tür verilerin klinik karar süreçlerinde kullanılabilmesi için fizyolojik ve davranışsal göstergelerle birlikte bütüncül olarak ele alınması gerektiği vurgulanmaktadır.[10,11]

Otizm spektrum bozukluğu (OSB) alanında yapılan çalışmalar, erken dönemde ortaya çıkan atipik davranış örüntülerinin yapay zekâ yöntemleriyle saptanabileceğini göstermektedir. Göz izleme verileri kullanılarak geliştirilen makine öğrenmesi modelleri, OSB'li çocukları tipik gelişim gösteren çocuklardan anlamlı doğrulukla ayırt edebilmiştir.[12] Ayrıca sensör tabanlı teknolojiler aracılığıyla motor hareket örüntülerinin analizi, risk altındaki bebeklerde nörogelişimsel farklılıkların erken dönemde belirlenmesine olanak tanımaktadır.[13] Otizm spektrum bozukluğu (OSB) açısından yüksek riskli (OSB'li kardeşi olan) 6 aylık bebeklerin ağlama seslerinin akustik özelliklerini inceleyen bir çalışmada, bu bebeklerin ağlama seslerinde daha yüksek temel frekans ve artmış akustik düzensizlik gibi atipik özellikler saptanmıştır. Bu bulgular, nörogelişimsel farklılıkların sosyal belirtiler belirginleşmeden önce ses üretim sisteminde ortaya çıkabileceğini göstermektedir. [14] On sekiz ay altındaki bebeklerde ağlama akustiği ile nörolojik disfonksiyon arasındaki ilişkiyi inceleyen sistematik derleme ve meta-analiz bulguları, nörolojik risk altındaki bebeklerin daha yüksek ortalama ve minimum temel frekans (F0) ile hiperfonasyon ve biphonasyon gibi atipik melodik özellikler sergilediğini ortaya koymaktadır. [15] Erken doğan bebeklerle yapılan başka bir çalışmada, taburculuk öncesinde kaydedilen ağlama seslerinin akustik özelliklerinin iki yaşta değerlendirilen dil, bilişsel ve davranışsal sorunlarla anlamlı düzeyde ilişkili olduğu saptanmıştır.[16] Bu bulgular, akustik ağlama analizinin erken dönemde nörolojik açıdan yüksek riskli bebeklerin belirlenmesinde hızlı, non-invaziv ve potansiyel olarak ölçeklenebilir bir tarama aracı olabileceğine işaret etmektedir.

Dijital fenotipleme, bireylerin akıllı telefonlar, giyilebilir cihazlar ve diğer dijital platformlar aracılığıyla ürettikleri verilerin analiz edilmesi yoluyla davranışsal ve fizyolojik özelliklerin anlık ve doğal ortamda değerlendirilmesini amaçlayan yenilikçi bir yaklaşımdır. Bu yöntem, bireyin günlük yaşamındaki "dijital ayak izlerini" izleyerek ruh sağlığına ilişkin kapsamlı ve dinamik bir profil oluşturulmasına olanak tanır.[17] Erken çocukluk dönemine yönelik geliştirilen mobil uygulamalar, bu alandaki uygulamaların somut örneklerini sunmaktadır. Örneğin, ChAMP (Child Health and Mental Health App) adlı mobil uygulama aracılığıyla çocuklara kısa, oyun benzeri görevler verilmiş ve bu süreçte çok boyutlu veri toplanmıştır. Bunlar; konuşma, mimikler, ekrana dokunma paterni, hız, koordinasyon, tepki süreleri gibi verilerden oluşmaktadır. Uygulama üzerinden elde edilen dijital veriler, çocukların ruh sağlığıyla ilişkili anlamlı davranış örüntüleri ortaya koymuş olup özellikle duygusal tepki farklılıkları, motor davranış paternleri ve konuşma özellikleri psikopatoloji ile ilişkili bulunmuştur.[18] Benzer şekilde, erken çocukluk döneminde (3-7 yaş) çocuklarda stres oluşturabilecek bir hikâye okutularak akustik özelliklerin makine öğrenmesi algoritmalarıyla analizi yapılan bir çalışmada, anksiyete ve depresyon belirtilerinin objektif ve non-invaziv biçimde saptanabileceği gösterilmiş olup içe yönelim bozukluklarını erken tarama açısından umut verici bir yaklaşım sunmuştur.[19] Bu yaklaşımın en önemli avantajlarından biri, yalnızca mevcut psikopatolojilerin tespitiyle sınırlı kalmayıp, aynı zamanda henüz tanımlanmamış davranışsal alt tiplerin keşfedilmesine de olanak sağlamasıdır. Denetimli ve denetimsiz makine öğrenmesi yöntemlerinin birlikte kullanımı, çocuk ruh sağlığında daha hassas ve bireyselleştirilmiş değerlendirme modellerinin geliştirilmesine katkı sunmaktadır.[20]

Makine öğrenmesi temelli yaklaşımlar, çocuklarda ruh sağlığı sorunlarına ilişkin çok boyutlu verilerin (davranışsal veriler, okul/ebeveyn raporları, dijital izler) analiz edilmesi

yoluyla riskli bireylerin erken dönemde saptanmasına ve bu doğrultuda bireyselleştirilmiş müdahalelerin planlanmasına olanak sağlayarak erken tanı ve tedavi süreçlerine önemli katkı sunmaktadır.[21] Bu kapsamda yetişkin örnekleminde yapılan bir çalışmada akıllı telefonlardan elde edilen pasif dijital verilerin (telefon kullanım paternleri, konum verileri, iletişim davranışları ve günlük aktivite döngüleri) makine öğrenmesi ile analizi, bipolar bozuklukta sosyal ritimlerin objektif biçimde modellenmesine ve bu ritimlerdeki bozulmaların erken dönemde saptanarak olası duygu durum değişikliklerinin öngörülmesine olanak sağlamaktadır.[22] Bu tür yaklaşımlar, çocuk ve ergen örneklemlerine uyarlanabilir olması açısından önemli bir potansiyel taşımaktadır. Ayrıca, serbest konuşma örneklerinin bilgisayar destekli analizi yoluyla düşünce akışı ve anlamsal bütünlükteki bozulmaların saptanabilmesi, psikoz gelişimi açısından yüksek riskli bireylerin erken dönemde belirlenmesine katkı sunmaktadır. Bu yaklaşımın yalnızca psikozla sınırlı kalmayıp depresyon, anksiyete ve otizm gibi farklı psikopatoloji alanlarına da genişletilebilir olması, erken tanı ve müdahale süreçleri açısından dikkat çekicidir.[23]

3. Erken Tanı

Erken tanı bağlamında, yapay zekâ temelli video, ses ve dijital davranış analizleri, çocuk davranışındaki ince ve erken belirtileri objektif biçimde yakalayarak klinik gözlemi güçlendiren ve özellikle otizm spektrum bozukluğu (OSB) ile dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) gibi nörogelişimsel bozukluklarda erken saptamaya katkı sağlayabilecek tamamlayıcı araçlar sunmaktadır. Bu yaklaşımlar, klinik başvuru öncesi dönemde dahi riskli bireylerin belirlenmesine olanak tanıyarak erken müdahale açısından önemli bir potansiyel taşımaktadır.[24]

Giyilebilir cihazlardan pasif veri toplama yoluyla elde edilen uyku ve aktivite verilerinin makine öğrenmesi ile analizi, dikkat eksikliği ve hiperaktivite bozukluğu ile ilişkili davranışsal örüntülerin erken dönemde objektif biçimde saptanmasına olanak sağlayarak erken tanı süreçlerine önemli katkı sunmaktadır.[25] Benzer şekilde, klinik ölçekler, ebeveyn ve öğretmen raporları ile davranışsal verilerin birlikte değerlendirildiği makine öğrenmesi modelleri, obsesif-kompulsif bozukluk, ayrılık anksiyetesi bozukluğu ve DEHB gibi psikopatolojilere ilişkin riskin erken dönemde anlamlı doğrulukla öngörülebileceğini göstermektedir.[26]

Otizm spektrum bozukluğu özelinde, yapay zekâ destekli video, ses ve davranış analizine dayalı yaklaşımlar, sosyal dikkat, yüz yönelimi ve etkileşim örüntülerine ilişkin erken belirtilerin objektif ve duyarlı biçimde saptanmasına olanak sağlamaktadır.[27] Video tabanlı analizler ve makine öğrenmesi yöntemleri aracılığıyla çocukların sosyal davranışlarının doğal ortamda değerlendirilmesi, geleneksel klinik gözleme kıyasla daha erken ve erişilebilir tanı süreçleri için umut verici bulgular sunmaktadır.[28] Ebeveyn raporları ile çocukların doğal etkileşimlerini içeren video verilerinin birlikte analiz edildiği hibrit modeller, tek bir veri kaynağına dayanan yaklaşımlara kıyasla daha yüksek doğrulukla OSB ayrımı yapabilmekte ve çoklu veri entegrasyonunun erken tanı performansını artırabileceğini göstermektedir.[3] Ayrıca, makine öğrenmesi modelleri aracılığıyla OSB ve DEHB gibi klinik olarak sıklıkla karışabilen tanılar arasında ayırt edici olan temel belirtilerin belirlenebilmesi, daha az sayıda fakat daha özgül klinik göstergelerle doğru sınıflama yapılabileceğini ortaya koymaktadır.[2]

4. Müdahale Alanları

Çocuk ruh sağlığı alanında yapay zekâ (YZ) destekli müdahaleler, psikopatolojilerin değerlendirilmesi, izlenmesi ve tedavi süreçlerinin iyileştirilmesine yönelik olarak giderek artan bir kullanım alanı bulmaktadır. Bu yaklaşımlar, erken tanıdan tedavi sürecinin bireyselleştirilmesine kadar uzanan geniş bir yelpazeyi

kapsamakta; özellikle müdahalelerin erişilebilirliğini, sürekliliğini ve etkinliğini artırma potansiyeli taşımaktadır. Yapay zekâ temelli sistemler, çok boyutlu verileri analiz ederek bireyselleştirilmiş müdahale planlarının oluşturulmasına, tedavi sürecinin dinamik olarak izlenmesine ve müdahalelerin dijital platformlar aracılığıyla günlük yaşama entegre edilmesine olanak sağlamaktadır.[29]

Yapay zekâ, özellikle otizm spektrum bozukluğunda müdahale süreçlerini daha erken, bireyselleştirilmiş ve uyarlanabilir hale getirme potansiyeline sahiptir. YZ tabanlı sistemler, çocuğun davranışsal verilerini sürekli analiz ederek müdahale programlarını gerçek zamanlı olarak çocuğun ihtiyaçlarına göre uyarlayabilmektedir. Oyun temelli dijital uygulamalar ve etkileşimli platformlar aracılığıyla sosyal iletişim becerileri desteklenirken, ilerleme objektif verilerle izlenebilmektedir. Bu sayede müdahaleler yalnızca klinik ortamla sınırlı kalmayıp ev ve günlük yaşam içine entegre edilerek daha sürdürülebilir ve etkili hale gelmektedir.[27]

Yapay zekâ destekli dijital müdahaleler, özellikle ergenlerde ruh sağlığı hizmetlerine erişimi artırma açısından dikkat çekmektedir. Sohbet botları ve sanal terapistler, kaygı ve depresyon belirtileri olan gençlerde psiko-eğitim sağlama, beceri pratiği sunma ve profesyonel tedaviye yönlendirme açısından bir köprü işlevi görebilmektedir. Bu yaklaşımlar, damgalanmayı azaltma ve hizmete erişim engellerini aşma potansiyeli taşımaktadır.[7] Müzik temelli bir mobil uygulama ile yürütülen randomize kontrollü bir çalışmada, duygusal sıkıntı yaşayan gençlerde bu tür dijital müdahalelerin duygu düzenleme becerilerini artırdığı ve depresyon ile anksiyete belirtilerinde azalma sağladığı gösterilmiştir.[30] Bu bulgular, dijital terapötiklerin erişilebilir ve kullanıcı dostu müdahale seçenekleri sunabileceğini desteklemektedir.

Sosyal yardımcı robotik (socially assistive robotics – SAR), robotların yalnızca fiziksel yardım değil, sosyal etkileşim yoluyla destek sağladığı yeni bir robotik alanı tanımlamaktır. Bu robotlar; göz teması kurar, konuşur/geri bildirim verir, oyun, egzersiz, eğitim gibi görevler sunar. Bireylerin davranışlarını, motivasyonlarını ve öğrenme süreçlerini destekleyen, özellikle rehabilitasyon ve gelişimsel bozukluklarda (otizm spektrum bozukluğu gibi) müdahale potansiyeli sunan yenilikçi bir yaklaşım olarak tanımlanmaktadır.[31] İnsan-robot etkileşimi alanındaki gelişmeler, otizm spektrum bozukluğu olan bireylerde sosyal iletişim becerilerini destekleme potansiyeli taşımakla birlikte, bu teknolojilerin klinik uygulamalara etkin biçimde entegre edilebilmesi için araştırma bulgularının gerçek yaşam koşullarına uyarlanması ve genellenebilirliğinin artırılması gerekmektedir.[32]

Dijital terapötik oyunlar, çocuk ve ergenlerde bilişsel süreçleri hedef alan yenilikçi müdahale araçları arasında yer almaktadır. Bu alanda öne çıkan örneklerden biri olan EndeavorRx, dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) olan çocuklarda dikkat süreçlerini hedefleyen, performansa uyum sağlayan algoritmalarla kişiselleştirilmiş bilişsel eğitim sunan ve ev ortamında uygulanabilen bir dijital terapötiktir. Klinik etkinliği gösterilmiş ve FDA onayı almış olması, bu tür müdahalelerin gelecekteki klinik kullanım potansiyeline işaret etmektedir.[33]

5. Etik ve Sınırlılıklar

Çocuk ruh sağlığı alanında yapay zekâ (YZ) uygulamaları önemli fırsatlar sunmakla birlikte, bu teknolojilerin kullanımı çeşitli etik sorunları ve sınırlılıkları da beraberinde getirmektedir. Özellikle psikiyatri alanında YZ'nin kullanımı, veri temelli karar alma süreçlerinin doğası gereği etik açıdan dikkatli bir değerlendirme gerektirmektedir.[34]

En önemli etik sorunlardan biri veri gizliliği ve mahremiyet konusudur. Çocuklara ait ruh sağlığı verileri son derece hassas olup, bu verilerin toplanması, saklanması ve işlenmesi süreçlerinde yüksek düzeyde güvenlik önlemleri alınması gerekmektedir.[35,36] Bir diğer önemli konu algoritmik önyargıdır. YZ sistemleri, eğitildikleri veri setlerindeki mevcut önyargıları yansıtabilmekte ve bu durum yanlış ya da adaletsiz klinik sonuçlara yol açabilmektedir.[36] YZ uygulamalarının bir diğer sınırlılığı, klinik karar süreçlerinde aşırı güven (automation bias) riskidir. Klinik uzmanların YZ tarafından üretilen sonuçlara eleştirel yaklaşmadan güvenmesi, yanlış tanı ve müdahale riskini artırabilir. Bu nedenle, YZ sistemlerinin karar verici değil, karar destekleyici araçlar olarak konumlandırılması gerektiği ifade edilmektedir.[37] Ayrıca, açıklanabilirlik sorunu da önemli bir sınırlılık olarak öne çıkmaktadır. Birçok YZ modeli "kara kutu" (black box) olarak çalışmakta ve kararların nasıl alındığı tam olarak anlaşılamamaktadır. Bu durum, özellikle ruh sağlığı gibi hassas alanlarda klinisyenlerin ve ailelerin sisteme duyduğu güveni azaltabilmektedir. [38] Son olarak, YZ uygulamalarının klinik bağlamda genellenebilirliği ve güvenilirliği de tartışmalı bir konudur. Farklı popülasyonlarda elde edilen verilerle geliştirilen modeller, her çocuk için aynı doğrulukta sonuç vermeyebilir. Bu nedenle, YZ sistemlerinin klinik kullanıma sunulmadan önce kapsamlı biçimde test edilmesi ve sürekli olarak izlenmesi gerekmektedir.[34]

6. Sonuç

Yapay zekâ temelli davranış analizi, çocuk ve ergen ruh sağlığında yalnızca mevcut semptomların değerlendirilmesini değil, henüz klinik düzeye ulaşmamış risklerin erken dönemde saptanmasını mümkün kılmaktadır. Bu yaklaşım, geleneksel değerlendirme yöntemlerinin sınırlı kaldığı sürekli izlem ve erken müdahale alanlarında önemli bir potansiyel sunmaktadır. Bununla birlikte, etik sorunlar, veri güvenliği ve klinik geçerlilik gibi temel sınırlılıkların göz önünde bulundurulması gerekmektedir. Gelecekte, yapay zekanın klinik pratiğe entegre edilmesiyle birlikte, daha erken, daha bireyselleştirilmiş ve daha etkili ruh sağlığı hizmetleri sunulması mümkün olabilir.

Kaynakça

1. Topol, E.J. (2019) Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again. Basic Books.
2. Duda M, Ma R, Haber N, Wall DP. Use of machine learning for behavioral distinction of autism and ADHD. *Transl Psychiatry*. 2016;6(2):e732-e732. doi:10.1038/tp.2015.221
3. Abbas H, Garberson F, Glover E, Wall DP. Machine learning approach for early detection of autism by combining questionnaire and home video screening. *Journal of the American Medical Informatics Association*. 2018;25(8):1000-1007. doi:10.1093/jamia/ocy039
4. Obermeyer Z, Emanuel EJ. Predicting the Future - Big Data, Machine Learning, and Clinical Medicine. *N Engl J Med*. 2016;375(13):1216-1219. doi:10.1056/NEJMp1606181
5. Shatte ABR, Hutchinson DM, Teague SJ. Machine learning in mental health: a scoping review of methods and applications. *Psychol Med*. 2019;49(09):1426-1448. doi:10.1017/S0033291719000151

6. Dritsona A, Koutroumpa ME, Sergentanis TN, Tsitsika AK. Artificial Intelligence and Mental Health of Children and Adolescents: Current Status and Perspectives. In: 2026:477-484. doi:10.1007/978-3-032-03394-9_45

7. Mansoor M, Hamide A, Tran T. Conversational AI in Pediatric Mental Health: A Narrative Review. *Children*. 2025;12(3):359. doi:10.3390/children12030359

8. Floridi L, Cowls J, Beltrametti M, et al. AI4People—An Ethical Framework for a Good AI Society: Opportunities, Risks, Principles, and Recommendations. *Minds Mach (Dordr)*. 2018;28(4):689-707. doi:10.1007/s11023-018-9482-5

9. G. A S, S G, Tharagarani G, P S, B S. An Automated Mood Analysis of Crying Infants Through Sound Recognition Using Hybrid Deep Learning. In: *2024 Third International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)*. IEEE; 2024:1-6. doi:10.1109/ICSTSN61422.2024.10671224

10. Das C, Nanda D, Chatterjee S, Dutta D. Comparative Analysis of Neonatal Facial Expression from Images using Deep Learning. In: *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*. IEEE; 2024:1-7. doi:10.1109/ICCCNT61001.2024.10725190

11. Gau ML, Ting HY, Toh TH, et al. Effectiveness of Using Artificial Intelligence for Early Child Development Screening. *Green Intelligent Systems and Applications*. 2023;3(1):1-13. doi:10.53623/gisa.v3i1.229

12. Liu W, Li M, Yi L. Identifying children with autism spectrum disorder based on their face processing abnormality: A machine learning framework. *Autism Research*. 2016;9(8):888-898. doi:10.1002/aur.1615

13. Taffoni F, Focaroli V, Formica D, Gugliemelli E, Keller F, Iverson JM. Sensor-based technology in the study of motor skills in infants at risk for ASD. In: *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*. IEEE; 2012:1879-1883. doi:10.1109/BioRob.2012.6290922

14. Sheinkopf SJ, Iverson JM, Rinaldi ML, Lester BM. Atypical Cry Acoustics in 6-Month-Old Infants at Risk for Autism Spectrum Disorder. *Autism Research*. 2012;5(5):331-339. doi:10.1002/aur.1244

15. Lawford HLS, Sazon H, Richard C, Robb MP, Bora S. Acoustic Cry Characteristics of Infants as a Marker of Neurological Dysfunction: A Systematic Review and Meta-Analysis. *Pediatr Neurol*. 2022;129:72-79. doi:10.1016/j.pediatrneurol.2021.10.017

16. Manigault AW, Sheinkopf SJ, Carter BS, et al. Acoustic Cry Characteristics in Preterm Infants and Developmental and Behavioral Outcomes at 2 Years of Age. *JAMA Netw Open*. 2023;6(2):e2254151. doi:10.1001/jamanetworkopen.2022.54151

17. Zhang Y, Wang J, Zong H, et al. The comprehensive clinical benefits of digital phenotyping: from broad adoption to full impact. *NPJ Digit Med*. 2025;8(1):196. doi:10.1038/s41746-025-01602-5

18. Loftness BC, Halvorson-Phelan J, O'Leary A, et al. The ChAMP App: A Scalable mHealth Technology for Detecting Digital Phenotypes of Early Childhood Mental Health. *IEEE J Biomed Health Inform*. 2024;28(4):2304-2313. doi:10.1109/JBHI.2023.3337649

19. McGinnis EW, Anderau SP, Hruschak J, et al. Giving Voice to Vulnerable Children: Machine Learning Analysis of Speech Detects Anxiety and Depression in Early Childhood. *IEEE J Biomed Health Inform*. 2019;23(6):2294-2301. doi:10.1109/JBHI.2019.2913590

20. Loftness BC, Rizzo DM, Halvorson-Phelan J, et al. Toward Digital Phenotypes of Early Childhood Mental Health via Unsupervised and Supervised Machine Learning. In: *2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. IEEE; 2023:1-4. doi:10.1109/EMBC40787.2023.10340806

21. Kataru S, King K, Fernando L. Machine Learning-Based Early Detection and Intervention for Mental Health Issues in Children. In: *2024 IEEE 48th Annual Computers, Software, and Applications Conference (COMPSAC)*. IEEE; 2024:2001-2007. doi:10.1109/COMPSAC61105.2024.00320

22. Abdullah S, Matthews M, Frank E, Doherty G, Gay G, Choudhury T. Automatic detection of social rhythms in bipolar disorder. *Journal of the American Medical Informatics Association*. 2016;23(3):538-543. doi:10.1093/jamia/ocv200

23. Bedi G, Carrillo F, Cecchi GA, et al. Automated analysis of free speech predicts psychosis onset in high-risk youths. *NPJ Schizophr*. 2015;1(1):15030. doi:10.1038/npjschz.2015.30

24. Minnis H, Vinciarelli A, Alsofyani H. The use and potential of artificial intelligence for supporting clinical observation of child behaviour. *Child Adolesc Ment Health*. 2024;29(4):340-344. doi:10.1111/camh.12714

25. Kim WP, Kim HJ, Pack SP, Lim JH, Cho CH, Lee HJ. Machine Learning–Based Prediction of Attention-Deficit/Hyperactivity Disorder and Sleep Problems With Wearable Data in Children. *JAMA Netw Open*. 2023;6(3):e233502. doi:10.1001/jamanetworkopen.2023.3502

26. Haque UM, Kabir E, Khanam R. Early detection of paediatric and adolescent obsessive–compulsive, separation anxiety and attention deficit hyperactivity disorder using machine learning algorithms. *Health Inf Sci Syst*. 2023;11(1):31. doi:10.1007/s13755-023-00232-z

27. Zhang S. AI-assisted early screening, diagnosis, and intervention for autism in young children. *Front Psychiatry*. 2025;16. doi:10.3389/fpsyt.2025.1513809

28. Perochon S, Di Martino JM, Carpenter KLH, et al. Early detection of autism using digital behavioral phenotyping. *Nat Med*. 2023;29(10):2489-2497. doi:10.1038/s41591-023-02574-3

29. Dritsona A, Koutroumpa ME, Sergentanis TN, Tsitsika AK. Artificial Intelligence and Mental Health of Children and Adolescents: Current Status and Perspectives. In: 2026:477-484. doi:10.1007/978-3-032-03394-9_45

30. Hides L, Dingle G, Quinn C, et al. Efficacy and Outcomes of a Music-Based Emotion Regulation Mobile App in Distressed Young People: Randomized Controlled Trial. *JMIR Mhealth Uhealth*. 2019;7(1):e11482. doi:10.2196/11482

31. Eriksson J, Mataric MJ, Winstein CJ. Hands-Off Assistive Robotics for Post-Stroke Arm Rehabilitation. In: *9th International Conference on Rehabilitation Robotics, 2005. ICORR 2005.* IEEE:21-24. doi:10.1109/ICORR.2005.1501042

32. Kim E, Paul R, Shic F, Scassellati B. Bridging the Research Gap: Making HRI Useful to Individuals with Autism. *J Hum Robot Interact*. Published online August 1, 2012:26-54. doi:10.5898/JHRI.1.1.Kim

33. Kollins SH, DeLoss DJ, Cañadas E, et al. A novel digital intervention for actively reducing severity of paediatric ADHD (STARS-ADHD): a randomised controlled trial. *Lancet Digit Health*. 2020;2(4):e168-e178. doi:10.1016/S2589-7500(20)30017-0

34. McCradden M, Hui K, Buchman DZ. Evidence, ethics and the promise of artificial intelligence in psychiatry. *J Med Ethics*. 2023;49(8):573-579. doi:10.1136/jme-2022-108447

35. Mansoor M, Hamide A, Tran T. Conversational AI in Pediatric Mental Health: A Narrative Review. *Children*. 2025;12(3):359. doi:10.3390/children12030359

36. Saeidnia HR, Hashemi Fotami SG, Lund B, Ghiasi N. Ethical Considerations in Artificial Intelligence Interventions for Mental Health and Well-Being: Ensuring Responsible Implementation and Impact. *Soc Sci*. 2024;13(7):381. doi:10.3390/socsci13070381

37. Tavory T. Regulating AI in Mental Health: Ethics of Care Perspective. *JMIR Ment Health*. 2024;11:e58493. doi:10.2196/58493

38. Rogan J, Bucci S, Firth J. Health Care Professionals' Views on the Use of Passive Sensing, AI, and Machine Learning in Mental Health Care: Systematic Review With Meta-Synthesis. *JMIR Ment Health*. 2024;11:e49577. doi:10.2196/49577

Beslenme Uygulamalarında Yapay Zeka: Kişiselleştirilmiş Beslenme Planlaması ve Hasta Takibi

Ümmügülsün ÇAKIR* Zeren Uylaş* Hüseyin ESECELİ**

ummugulsuncakir@ogr.bandirma.edu.tr, zerenuylas@ogr.bandirma.edu.tr, heseceli@bandirma.edu.tr

*Bandırma Onyedi Eylül Üniversitesi Beslenme ve Diyetetik Bölümü 4. Sınıf Öğrencisi

** Bandırma Onyedi Eylül Üniversitesi Beslenme ve Diyetetik Bölümü

Özet:

Son yıllarda yapay zeka (YZ) teknolojilerinin sağlık bilimleri alanında kullanımı önemli ölçüde artmış ve özellikle beslenme ve diyetetik uygulamalarında dönüşümsel etkiler yaratmıştır. Kişiselleştirilmiş beslenme yaklaşımı, bireylerin genetik özellikleri, metabolik yanıtları, yaşam tarzı, bağırsak mikrobiyatası ve çevresel faktörlerini dikkate alarak optimal beslenme planlarının oluşturulmasını hedeflemektedir. Bu süreçte yapay zeka; büyük veri analitiği, makine öğrenmesi ve derin öğrenme yöntemleri aracılığıyla bireysel besin yanıtlarının öngörülmesine ve etkili diyet planlarının geliştirilmesine katkı sağlamaktadır. Ayrıca, mobil sağlık (mHealth) uygulamaları ve giyilebilir teknolojilerle entegre edilen YZ sistemleri; fiziksel aktivite, enerji harcaması, uyku düzeni ve besin tüketimi gibi parametreleri gerçek zamanlı olarak izleyerek hasta takibini kolaylaştırmakta ve tedaviye uyumu artırmaktadır. Bu sistemler, sağlık profesyonellerine sürekli veri akışı sunarak daha hızlı ve doğru klinik kararlar alınmasına olanak tanımakta, aynı zamanda bireylerin kendi sağlık yönetimlerine aktif katılımını teşvik etmektedir. Yapay zekanın beslenme alanındaki kullanımı bazı sınırlılıkları da beraberinde getirmektedir. Veri gizliliği ve güvenliği, algoritmik yanlılık, etik sorunlar ve bireyler arası biyolojik farklılıkların tam olarak modellenememesi bu teknolojilerin en önemli kısıtları arasında yer almaktadır. Ayrıca, YZ tabanlı sistemlerin klinik uygulamalarda etkinliğinin artırılması için yüksek kaliteli, standartlaştırılmış ve geniş ölçekli veri setlerine ihtiyaç duyulmaktadır. Bu çalışmada, yapay zekanın beslenme planlaması ve hasta takibindeki rolü kapsamlı bir şekilde incelenmiş, avantajları ve sınırlılıkları güncel literatür doğrultusunda değerlendirilmiştir.

Anahtar Kelimeler: Yapay zeka, kişiselleştirilmiş beslenme, veri güvenliği, hasta takibi, giyilebilir teknoloji

Artificial Intelligence in Nutrition Practices: Personalized Nutrition Planning and Patient Monitoring

Abstract:

In recent years, the application of artificial intelligence (AI) technologies in the field of health sciences has markedly increased, exerting transformative impacts particularly within nutrition and dietetics practices. Personalized nutrition aims to generate optimal dietary interventions by integrating individuals' genetic profiles, metabolic responses, lifestyle factors, gut microbiota, and environmental influences. In this context, AI facilitates the prediction of individual dietary responses and the development of effective, tailored nutritional strategies through the utilization of big data analytics, machine learning, and deep learning methodologies. Moreover, AI-driven systems integrated with mobile health (mHealth) applications and wearable technologies enable continuous patient monitoring by capturing real-time data on physical activity, energy expenditure, sleep patterns, and dietary intake. Such systems enhance treatment adherence and support more precise and timely clinical decision-making by providing healthcare professionals with continuous and comprehensive data streams. Additionally, these technologies promote patient engagement

by encouraging active participation in personal health management. Nevertheless, the implementation of AI in nutrition is accompanied by several limitations. Key challenges include concerns regarding data privacy and security, algorithmic bias, ethical considerations, and the limited capacity to fully account for inter-individual biological variability. Furthermore, improving the clinical applicability and reliability of AI-based systems necessitates the availability of high-quality, standardized, and large-scale datasets. This study comprehensively examines the role of artificial intelligence in nutrition planning and patient monitoring, and critically evaluates its advantages and limitations in light of current literature.

Keywords: Artificial intelligence, personalized nutrition, Data Security, patient monitoring, Wearable Technology

1. Giriş

Beslenme, sağlığın korunması, geliştirilmesi, hastalıkların önlenmesi ve tedavi süreçlerinin desteklenmesi açısından temel belirleyicilerden biridir. Bununla birlikte bireyler; genetik yapı, metabolik özellikler, yaşam tarzı, çevresel etmenler ve besin ögelerine verdikleri fizyolojik yanıtlar bakımından önemli farklılıklar göstermektedir. Bu nedenle, topluma yönelik standart beslenme önerilerinin her birey için aynı düzeyde etkili olması her zaman mümkün olmamaktadır. Bireyler arası bu farklılıkların daha belirgin biçimde ortaya konulmasıyla birlikte kişiselleştirilmiş beslenme yaklaşımı ön plana çıkmıştır (Ordovas et al., 2018).

Son yıllarda yapılan çalışmalar, yapay zekânın beslenme ve diyetetik alanında giderek daha geniş bir kullanım alanı bulduğunu göstermektedir. Özellikle diyet değerlendirme, besin tanıma, bireye özgü beslenme öneri sistemlerinin geliştirilmesi ve hasta takibi gibi alanlarda yapay zekâ temelli uygulamaların yaygınlaştığı bildirilmektedir (Sosa-Holwerda et al., 2024; Zheng et al., 2024; Ngo et al., 2025). Bu gelişmeler, yapay zekânın yalnızca teknolojik bir yenilik olarak değil, aynı zamanda beslenme uygulamalarının etkinliğini artıran destekleyici bir karar mekanizması olarak değerlendirilmesine olanak sağlamaktadır.

Bu bağlamda yapay zekâ, büyük ve çok boyutlu verileri hızlı, sistematik ve bütüncül biçimde analiz edebilme kapasitesi sayesinde beslenme alanında önemli bir rol üstlenmektedir. Makine öğrenmesi ve derin öğrenme temelli yaklaşımlar aracılığıyla örüntü tanıma, tahmine dayalı modelleme ve karar destek sistemlerinin geliştirilmesine katkı sağlayarak daha doğru, hızlı ve bireyselleştirilmiş beslenme uygulamalarının oluşturulmasını mümkün kılmaktadır (Sosa-Holwerda et al., 2024; Panayotova, 2025).

2. Yapay Zeka ve Beslenme Bilimi

Yapay zekâ, bilgisayar sistemlerinin insan benzeri bazı bilişsel işlemleri algoritmalar aracılığıyla gerçekleştirebilmesini sağlayan teknolojiler bütünü olarak tanımlanmaktadır (Panayotova, 2025). Sağlık alanında yapay zekâ; veri kümelerinin analiz edilmesi, tahmine dayalı modellerin oluşturulması, klinik karar destek sistemlerinin geliştirilmesi ve izlem süreçlerinin kolaylaştırılması gibi amaçlarla kullanılmaktadır (Jiang et al., 2017; Park et al., 2020). Beslenme ve diyetetik alanında ise bireyin besin tüketiminin değerlendirilmesi, enerji ve besin ögesi gereksinimlerinin belirlenmesi, diyet planlarının oluşturulması ve sürecin izlenmesi gibi alanlarda kullanılmaktadır (Panayotova, 2025; Sosa-Holwerda et al., 2024).

Beslenme bilimi, çok fazla veri içermesi nedeniyle yapay zekâ uygulamalarına uygun bir alandır (Bailey et al., 2024). Besin tüketim kayıtları, fiziksel aktivite düzeyi, biyokimyasal göstergeler, yaşam tarzı özellikleri ve sağlık verileri birlikte değerlendirildiğinde karmaşık bir yapı ortaya çıkmaktadır (Ordovas et al., 2018; Zeevi et al., 2015). Yapay zekâ ise bu verileri daha hızlı ve bütüncül biçimde analiz ederek anlamlı sonuçlar ortaya

koyabilmektedir (Topol, 2019; Panayotova, 2025). Bu yönüyle yapay zekâ, beslenme uygulamalarında karar verme sürecini destekleyen önemli bir araç haline gelmiştir (Park et al., 2020).

Beslenme alanında en sık kullanılan yapay zekâ yöntemleri arasında makine öğrenmesi, derin öğrenme, görüntü işleme ve doğal dil işleme yer almaktadır (Jiang et al., 2017; Panayotova, 2025). Özellikle görüntü işleme temelli sistemler sayesinde yemek fotoğraflarından besinlerin tanınması, porsiyon miktarlarının tahmin edilmesi ve enerji ile besin ögesi alımının hesaplanması mümkün hale gelmiştir (Zheng et al., 2024). Bu durum, bireylerin besin tüketim kayıtlarını daha pratik biçimde tutmasına yardımcı olmakta ve bazı hataları azaltabilmektedir (Sosa-Holwerda et al., 2024; Zheng et al., 2024).

Bunun yanında yapay zekâ sistemleri, bireylerin beslenme alışkanlıklarını sağlık verileriyle birlikte değerlendirerek daha hızlı ve daha hedefe yönelik öneriler sunabilmektedir (Ngo et al., 2025; Panayotova, 2025). Böylece hem araştırmalarda büyük veri setlerinin analizine katkı sağlanmakta hem de uygulama alanında beslenme uzmanlarının karar alma süreçleri desteklenmektedir (Bailey et al., 2024; Sosa-Holwerda et al., 2024).

3. Kişiselleştirilmiş Beslenme Planlamasında Yapay Zeka

Kiselleştirilmiş beslenme, bireyin genetik özellikleri, biyokimyasal göstergeleri, bağırsak mikrobiyotası, fiziksel aktivite düzeyi, sağlık durumu ve beslenme alışkanlıklarının birlikte değerlendirilmesiyle bireye özgü beslenme önerilerinin geliştirilmesini amaçlayan bir yaklaşımdır (Ordovas et al., 2018). Bu yaklaşım, geleneksel beslenme modellerine kıyasla bireysel farklılıklara dikkat çekerek; özellikle obezite, diyabet, kardiyovasküler hastalıklar ve diğer kronik hastalıkların önlenmesi ve yönetiminde önemli bir etken sunmaktadır. Ancak kişiselleştirilmiş beslenme kapsamında dikkate alınması gereken verilerin çok boyutlu yapıda olması, bu sürecin değerlendirilmesini zorlaştırmaktadır. Genetik veriler, metabolik belirteçler, yaşam tarzı özellikleri, besin tüketim kayıtları ve dijital sağlık verilerinin birlikte analiz edilmesi, klasik yöntemlerle zaman alıcı ve karmaşık bir süreç haline gelebilmektedir.

Kişiselleştirilmiş beslenme planları oluşturulurken aşağıdaki veri kaynakları kullanılmaktadır:

- Genetik veriler (nutrigenomik)
- Mikrobiyota profili
- Biyokimyasal parametreler
- Fiziksel aktivite düzeyi
- Besin tüketim kayıtları

Bu veri kaynakları, yapay zeka tabanlı sistemler aracılığıyla uyum sağlayarak bireye özgü beslenme düzenlerinin tanımlanmasına olanak sağlamaktadır. Yapay zeka, özellikle makine öğrenmesi (ML) tekniklerinden yararlanarak, bireylerin çeşitli besin ögelerine verdikleri metabolik yanıtlarını tahmin edebilmektedir.

Literatürdeki öncü çalışmalar, aynı miktarda karbonhidrat içeren besinlerin farklı bireylerde tamamen farklı glisemik yanıtlar oluşturabildiğini; bu bireyler arası çeşitliliğin ise makine öğrenmesi algoritmaları kullanılarak önceden öngörülebileceğini ortaya koymuştur (Zeevi vd., 2015; Kirk vd., 2021). Bu analitik modeller, yalnızca mevcut biyokimyasal durumu değerlendirmekle kalmayıp, elde edilen verilerle bireyin gelecekte karşılaşabileceği metabolik riskleri ve kronik hastalık eğilimlerini de sunabilmektedir.

Obezite Tedavisi: Yapay zeka, bireyin yeme davranışlarını (hızlı yeme, duygusal yeme) ve metabolik hızını analiz ederek, kişiye en uygun kalori kısıtlama yöntemini (aralıklı oruç, ketojenik veya Akdeniz diyeti vb.) belirler (Topol, 2019).

Kardiyovasküler Sağlık: Lipidomik verilerin analizi ile yapay zeka, hangi bireyin doymuş yağ kısıtlamasından, hangisinin ise omega-3 takviyesinden daha fazla fayda göreceğini belirleyerek "precision kardiyoloji" desteği sunar (Kirk vd., 2021).

Sporcu Performansı: Sporcularda ter analizi, genetik yatkınlık ve antrenman yükü verileri işlenerek antrenman sonrası toparlanma sürecini hızlandıracak spesifik amino asit ve elektrolit planlamaları yapılmaktadır. (Baker vd., 2024).

4. Hasta Takibinde Yapay Zeka Kullanımı

Yapay zekâ, yalnızca beslenme planlamasında değil, aynı zamanda hasta takibi süreçlerinde de önemli katkılar sağlamaktadır. Beslenme tedavisinin başarısı, yalnızca uygun bir planın hazırlanmasına değil; bireyin bu plana uyumunun izlenmesine, klinik değişimlerin takip edilmesine ve gerektiğinde müdahalenin güncellenmesine de bağlıdır. Bu nedenle yapay zekâ destekli sistemler, hasta takibinde veri toplama, veri analizi ve geri bildirim sağlama açısından giderek daha fazla önem kazanmaktadır (Panayotova, 2025; Ngo et al., 2025).

Mobil sağlık uygulamaları, giyilebilir teknolojiler ve dijital kayıt sistemleri sayesinde bireyin günlük yaşamına ait çok sayıda veri düzenli olarak toplanabilmektedir. Fiziksel aktivite düzeyi, öğün düzeni, enerji alımı, uyku süresi, vücut ağırlığındaki değişimler ve bazı durumlarda glukoz düzeyleri gibi veriler yapay zekâ tarafından birlikte değerlendirilebilmektedir. Böylece beslenme tedavisine uyum, yaşam tarzındaki değişiklikler ve olası riskler daha erken fark edilebilmektedir (Jiang et al., 2017; Sosa-Holwerda et al., 2024).

Yapay zekâ destekli sistemlerin önemli avantajlarından biri, yalnızca veri toplamakla kalmayıp bu verileri analiz ederek anlamlı geri bildirimler sunabilmesidir. Özellikle obezite, diyabet ve kardiyovasküler hastalıklar gibi uzun süreli izlem gerektiren durumlarda bu sistemler, diyetisyene daha düzenli ve hızlı bir takip imkânı sağlamaktadır. Örneğin diyabetli bir bireyde öğün içeriği ile glukoz değişimleri birlikte değerlendirilerek daha uygun beslenme önerileri geliştirilebilir. Benzer şekilde kilo yönetiminde, besin tüketim kayıtları ve fiziksel aktivite verileri analiz edilerek bireyin plana uyum düzeyi izlenebilir ve gerektiğinde güncellenebilir (Park et al., 2020; Wu et al., 2025).

Sonuç olarak yapay zekâ, hasta takibinde diyetisyenin yerini alan bir sistem değil, izlem, değerlendirme ve karar verme süreçlerini destekleyen bir araç olarak görülmelidir. Bu yönüyle hem takip sürecinin bireyselleştirilmesine katkı sağlamakta hem de beslenme tedavisinin sürdürülebilirliğini artırmaktadır (Ngo et al., 2025; Panayotova, 2025).

5. Tartışma

Yapay zekânın beslenme ve diyetetik alanındaki kullanımı, kişiselleştirilmiş sağlık hizmetlerinin geliştirilmesi açısından önemli fırsatlar sunmaktadır (Sosa-Holwerda et al., 2024; Panayotova, 2025). Özellikle büyük verilerin kısa sürede analiz edilebilmesi, bireysel farklılıkların daha iyi anlaşılmasına ve beslenme planlarının hedefe yönelik hazırlanmasına olanak sağlamaktadır (Bailey et al., 2024; Topol, 2019). Bu durum; diyet değerlendirme, besin tanıma, kişiselleştirilmiş öneri geliştirme ve hasta takibi gibi alanlarda yapay zekâyı ön plana çıkarmıştır (Sosa-Holwerda et al., 2024; Wu et al., 2025). Bununla birlikte, mevcut literatür yapay zekânın beslenme alanındaki yeteneğini ortaya koymakla birlikte, bu sistemlerin klinik uygulamaya doğrudan ve sorunsuz biçimde aktarılabildiğini tam olarak göstermemektedir (Bailey et al., 2024; Panayotova, 2025).

Yapay zekâ sistemlerinin başarısı, büyük ölçüde kullanılan verilerin niteliğine bağlıdır (Topol, 2019; Bailey et al., 2024). Beslenme alanında kullanılan veriler çoğu zaman bireyin kendi bildirimine dayalı olduğundan, eksik kayıt, hatırlama yanlılığı ve porsiyon tahmin hataları gibi sorunlar ortaya çıkabilmektedir (Sosa-Holwerda et al., 2024). Görüntü işleme ve otomatik kayıt sistemleri bu sınırlılıkları azaltma potansiyeli taşısa da, özellikle gerçek yaşam koşullarında besin çeşitliliği, karışık öğünler ve farklı sunum biçimleri sistemlerin doğruluğunu etkileyebilmektedir (Zheng et al., 2024; Sosa-Holwerda et al., 2024). Bu nedenle yapay zekâ destekli sistemlerin performansı değerlendirilirken yalnızca doğruluk değil, kullanılan verinin güvenilirliği de dikkate alınmalıdır (Bailey et al., 2024).

Yapay zekâ modelleri çoğu zaman belirli popülasyonlardan elde edilen verileri kullanabilmektedir (Khan et al., 2024; Wu et al., 2025). Bu durum, farklı yaş gruplarında, kültürel beslenme örüntülerinde veya sosyoekonomik koşullarda aynı performansın elde edilememesine neden olabilir (Ordovas et al., 2018; Wu et al., 2025). Özellikle beslenme alışkanlıklarının toplumdan topluma değişmesi, yapay zekâ tabanlı öneri sistemlerinin evrensel biçimde uygulanmasını zorlaştırır (Ordovas et al., 2018). Bir modelin başarılı olması, her birey ve her toplum için aynı düzeyde uygun olduğu anlamına gelmemektedir (Panayotova, 2025; Wu et al., 2025).

Yapay zekânın beslenme alanındaki bir başka tartışmalı yönü, etik ve veri güvenliği ile ilişkilidir (Park et al., 2020; Khan et al., 2024). Kişiselleştirilmiş beslenme yaklaşımlarında genetik veriler, biyokimyasal bulgular, yaşam tarzı bilgileri ve bazı durumlarda mikrobiyota verileri kullanılabilmektedir (Ordovas et al., 2018; Zeevi et al., 2015). Bu kapsamlı verilerin toplanması, saklanması ve işlenmesi sürecinde veri mahremiyeti önemli bir konu haline gelmektedir (Park et al., 2020). Ayrıca algoritmaların nasıl çalıştığının her zaman açık olmaması, önerilerin klinik olarak yorumlanmasını zorlaştırabilmektedir (Topol, 2019; Park et al., 2020). Bu nedenle sağlık alanında kullanılan yapay zekâ sistemlerinin şeffaf, güvenilir ve etik ilkelere uygun biçimde geliştirilmesi gerekmektedir (Khan et al., 2024; Panayotova, 2025).

Beslenme tedavisi yalnızca sayısal verilerin analizine dayanmaz; bireyin sosyal çevresi, ekonomik durumu, kültürel alışkanlıkları, besin tercihleri, motivasyonu ve davranış değişikliğine açıklığı gibi çok sayıda unsur da dikkate alınmalıdır (Ordovas et al., 2018; Ngo et al., 2025). Yapay zekâ bu verilerin bir kısmını analiz edebilse de, bireyin yaşam koşullarını bütün olarak değerlendirme ve uygun iletişim kurma konusunda insan uzmanlığının önemi devam etmektedir (Hazarika, 2020; Ngo et al., 2025). Bu nedenle yapay zekânın, diyetisyenin yerine geçen bir sistemden çok, onun karar verme sürecini destekleyen yardımcı bir araç olarak değerlendirilmesi daha uygun görünmektedir (Panayotova, 2025; Sosa-Holwerda et al., 2024).

6. Sonuç ve Öneriler

Yapay zekâ, beslenme ve diyetetik alanında giderek artan önemi ile diyet değerlendirme, besin tanıma, kişiselleştirilmiş beslenme planlaması ve hasta takibi gibi uygulamalarda öne çıkmaktadır (Sosa-Holwerda et al., 2024; Panayotova, 2025; Zheng et al., 2024; Ngo et al., 2025). Çok boyutlu verilerin hızlı bir şekilde analiz edilebilmesi, bireysel farklılıkların daha doğru değerlendirilmesine ve hedefe yönelik beslenme önerilerinin geliştirilmesine olanak sağlamaktadır (Bailey et al., 2024; Wu et al., 2025). Bu yönüyle yapay zekâ, hem klinik uygulamalarda hem de araştırma süreçlerinde önemli fırsatlar sunmaktadır (Topol, 2019).

Bununla birlikte, yapay zekâ uygulamalarının etkinliği; veri doğruluğu, etik ilkeler, veri güvenliği gibi faktörlere bağlıdır (Park et al., 2020; Khan et al., 2024). Ayrıca elde edilen sonuçların bireyin klinik durumu ve yaşam koşulları ile birlikte değerlendirilmesi gerekmektedir (Ordovas et al., 2018). Bu nedenle yapay zekâ, bağımsız bir karar verici

olarak değil, beslenme uzmanlarının karar süreçlerini destekleyen bir araç olarak ele alınmalıdır.

Sonuç olarak, yapay zekâ destekli sistemlerin beslenme alanında daha yaygın kullanımı beklenmekte olup, bu sistemlerin klinik geçerlilik, güvenilirlik ve uygulanabilirlik açısından geliştirilmesi önem taşımaktadır (Wu et al., 2025; Panayotova, 2025). Gelecekte yapılacak çalışmaların, teknolojik gelişmeler ile etik ve klinik boyutları bütüncül bir yaklaşımla ele alması gerekmektedir.

7. Kaynaklar

Armand, T. P. T., Nfor, K. A., Kim, J.-I., & Kim, H.-C. (2024). Applications of artificial intelligence, machine learning, and deep learning in nutrition: A systematic review. Nutrients, 16(7), 1073. doi:10.3390/nu16071073

Atwal, K. (2024). Artificial intelligence in clinical nutrition and dietetics: A brief overview of current evidence. Nutrition in Clinical Practice, 39(4), 736–742. doi:10.1002/ncp.11150

Bailey, R. L., MacFarlane, A. J., Field, M. S., Tagkopoulos, I., Baranzini, S. E., Edwards, K. M., … Stover, P. J. (2024). Artificial intelligence in food and nutrition evidence: The challenges and opportunities. PNAS Nexus, 3(12), pgae461. doi:10.1093/pnasnexus/pgae461

Braakhuis, A., Monnard, C. R., Ellis, A., & Rozga, M. (2021). Consensus report of the Academy of Nutrition and Dietetics: Incorporating genetic testing into nutrition care. Journal of the Academy of Nutrition and Dietetics, 121(3), 545–552. doi:10.1016/j.jand.2020.04.002

Camp, K. M., & Trujillo, E. (2014). Position of the Academy of Nutrition and Dietetics: Nutritional genomics. Journal of the Academy of Nutrition and Dietetics, 114(2), 299–312. doi:10.1016/j.jand.2013.12.001

Cofre, S., Sanchez, C., Quezada-Figueroa, G., & López-Cortés, X. A. (2025). Validity and accuracy of artificial intelligence-based dietary intake assessment methods: A systematic review. British Journal of Nutrition, 133(9). doi:10.1017/S0007114525000522

Côté, M., & Lamarche, B. (2022). Artificial intelligence in nutrition research: Perspectives on current and future applications. Applied Physiology, Nutrition, and Metabolism, 47(1), 1–8. doi:10.1139/apnm-2021-0448

Deniz-Garcia, A., Fabelo, H., Rodriguez-Almeida, A. J., Zamora-Zamorano, G., Castro-Fernandez, M., del Pino Alberiche Ruano, M., … Wägner, A. M. (2023). Quality, usability, and effectiveness of mHealth apps and the role of artificial intelligence in patient-centered care for chronic disease management. Journal of Medical Internet Research, 25, e44030. doi:10.2196/44030

El Sherbini, A., Abbenhardt, C., Cicoira, M., D'Agostino, E. M., D'Onofrio, G., Fuster, V., … Sattar, N. (2024). Artificial intelligence in preventive cardiology. Progress in Cardiovascular Diseases, 84, 34–43. doi:10.1016/j.pcad.2024.03.002

Hazarika, I. (2020). Artificial intelligence: Opportunities and implications for the health workforce. International Health, 12(4), 241–245. doi:10.1093/inthealth/ihaa007

Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., … Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. Stroke and Vascular Neurology, 2(4), 230–243. doi:10.1136/svn-2017-000101

Khan, A. M., Faheem, S., Khan, A. Y., & Taj, R. (2024). A systematic review of artificial intelligence in healthcare: Opportunities, advancements, and challenges. Journal of

University College of Medicine and Dentistry, 3(2), 116–120. doi:10.51846/jucmd.v3i2.3156

Kirk, D., Catal, C., & Tekinerdogan, B. (2021). Precision nutrition: A systematic literature review. Computers in Biology and Medicine, 133, 104365. doi:10.1016/j.compbiomed.2021.104365

Kittrell, H. D., Shaikh, A., Adintori, P. A., Nadkarni, G. N., Singer, P., & Sakhuja, A. (2024). Role of artificial intelligence in critical care nutrition support and research. Nutrition in Clinical Practice, 39(5), 1069–1080. doi:10.1002/ncp.11194

Lo, F. P.-W., Qiu, J., Wang, Z., Chen, J., Xiao, B., Yuan, W., … Lo, B. (2024). Dietary assessment with multimodal ChatGPT: A systematic analysis. IEEE Journal of Biomedical and Health Informatics, 28(12), 7577–7587. doi:10.1109/JBHI.2024.341728

Miyazawa, T., Hiratsuka, Y., Toda, M., Hatakeyama, N., Ozawa, H., Abe, C., … Tsubota, K. (2022). Artificial intelligence in food science and nutrition: A narrative review. Nutrition Reviews, 80(12), 2288–2300. doi:10.1093/nutrit/nuac033

Ngo, K., Mekhail, S., Chan, V., Li, X., Yin, A., Choi, H. Y., … Chen, J. (2025). The use of artificial intelligence (AI) to support dietetic practice across primary care: A scoping review of the literature. Nutrients, 17(22), 3515. doi:10.3390/nu17223515

Ordovas, J. M., Ferguson, L. R., Tai, E. S., & Mathers, J. C. (2018). Personalised nutrition and health. BMJ, 361, k2173. doi:10.1136/bmj.k2173

Panayotova, G. G. (2025). Artificial intelligence in nutrition and dietetics: A comprehensive review of current research. Healthcare, 13(20), 2579. doi:10.3390/healthcare13202579

Park, C. W., Seo, S. W., Kang, N., Ko, B., Choi, B. W., Park, C. M., … Yoon, H. J. (2020). Artificial intelligence in health care: Current applications and issues. Journal of Korean Medical Science, 35(42), e379. doi:10.3346/jkms.2020.35.e379

Phalle, A., & Gokhale, D. (2025). Navigating next-gen nutrition care using artificial intelligence-assisted dietary assessment tools: A scoping review of potential applications. Frontiers in Nutrition, 12, 1518466. doi:10.3389/fnut.2025.1518466

Rozga, M., & Handu, D. (2019). Nutritional genomics in precision nutrition: An Evidence Analysis Center scoping review. Journal of the Academy of Nutrition and Dietetics, 119(3), 507–515.e7. doi:10.1016/j.jand.2018.05.022

Singer, P., Robinson, E., & Raphaeli, O. (2024). The future of artificial intelligence in clinical nutrition. Current Opinion in Clinical Nutrition and Metabolic Care, 27(2), 200–206. doi:10.1097/MCO.0000000000000977

Sosa-Holwerda, A., Park, O. H., Albracht-Schulte, K., Niraula, S., Thompson, L., & Oldewage-Theron, W. (2024). The role of artificial intelligence in nutrition research: A scoping review. Nutrients, 16(13), 2066. doi:10.3390/nu16132066

Tahir, G. A., & Loo, C. K. (2021). A comprehensive survey of image-based food recognition and volume estimation methods for dietary assessment. Healthcare, 9(12), 1676. doi:10.3390/healthcare9121676

Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. Nature Medicine, 25(1), 44–56. doi:10.1038/s41591-018-0300-7

Vasiloglou, M. F., Marcano, I., Lizama, S., Papathanail, I., Spanakis, E. K., & Mougiakakou, S. (2023). Multimedia data-based mobile applications for dietary assessment. Journal of Diabetes Science and Technology, 17(4), 1056–1065. doi:10.1177/19322968221085026

Wu, X., Oniani, D., Shao, Z., Arciero, P., Sivarajkumar, S., Hilsman, J., … Wang, Y. (2025). A scoping review of artificial intelligence for precision nutrition. Advances in Nutrition, 16(4), 100398. doi:10.1016/j.advnut.2025.100398

Zeevi, D., Korem, T., Zmora, N., Israeli, D., Rothschild, D., Weinberger, A., … Segal, E. (2015). Personalized nutrition by prediction of glycemic responses. Cell, 163(5), 1079–1094. doi:10.1016/j.cell.2015.11.001

Zheng, J., Wang, J., Shen, J., & An, R. (2024). Artificial intelligence applications to measure food and nutrient intakes: Scoping review. Journal of Medical Internet Research, 26, e54557. doi:10.2196/54557

Tıpta Yapay Zekâ: Veri Güvenliği, Etik ve Hukuki Sorumluluklar

Zelal YILDIZ[1], Özgür KUŞ[2]

[1]Tıp Fakültesi Dönem 2 Öğrencisi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, zelalyildiz@ogr.bandirma.edu.tr

[2]Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Tıp Tarihi ve Etik Anabilim Dalı, ozgurkus@bandirma.edu.tr

Özet

Tıp alanında kullanılan yapay zekâ uygulamalarının, tanı, tedavi ve bakım süreçlerinde doğruluk, hız ve maliyet avantajı sağladığı bununla birlikte önemli etik ve hukuki sorunları da beraberinde getirdiği görülmektedir. Bu çalışmada tıpta yapay zekâ teknolojilerinin kullanım alanlarını değerlendirmek, ortaya çıkan etik ve hukuki sorunları analiz etmek ve bu sorunlara yönelik çözüm önerileri geliştirmek amaçlanmıştır. Bu kapsamda, tıp alanında yapay zekâ uygulamalarına ilişkin güncel literatür taranmış ve elde edilen veriler içerik analizi yöntemiyle incelenmiştir. Yapay zekâ uygulamalarının özellikle veri güvenliği, hasta mahremiyeti, algoritmik şeffaflık ve karar verme süreçlerinde sorumluluğun belirsizliği gibi alanlarda ciddi etik ve hukuki sorunları barındırdığı görülmüştür. Bu sorunların giderilmesine yönelik olarak güçlü veri koruma mekanizmalarının oluşturulması, açıklanabilir yapay zekâ sistemlerinin geliştirilmesi, etkin etik denetim süreçlerinin işletilmesi ve kapsamlı yasal düzenlemelerin hayata geçirilmesi önerilmiştir. Ayrıca, etik farkındalık eğitimlerinin yaygınlaştırılması ve insan denetiminin sürdürülmesi gerektiği vurgulanmıştır. Sonuç olarak yapay zekânın bağımsız bir karar verici olmaktan ziyade, klinik karar süreçlerinde hekimleri destekleyen bir araç olarak konumlandırılması gerektiği değerlendirilmektedir.

Anahtar kelimeler: Yapay zekâ (artificial intelligence), tıp ve sağlık hizmetleri, etik sorunlar, veri güvenliği, hukuki sorumluluk

Giriş

Yapay zekâ (YZ), öğrenme, problem çözme, hatırlama, değerlendirme ve karar verme gibi insan zekâsına özgü bilişsel işlevleri taklit edebilen teknolojik sistemler olarak tanımlanmaktadır (Keleş, 2022; Güvercin, 2020; Alpaydın, 2020). Günümüzde yapay zekâ, pek çok alanda olduğu gibi tıp alanında da yaygın biçimde kullanılmakta; tanı, tedavi ve hasta bakım süreçlerinde doğruluk, hız ve maliyet etkinliği açısından önemli katkılar sunmaktadır (Keleş, 2022). Büyük veri setlerinin algoritmalar aracılığıyla işlenmesi sayesinde tanı ve tedavi süreçlerinin optimize edilmesi, ilaç geliştirme faaliyetlerinin hızlandırılması ve kişiselleştirilmiş tedavi yaklaşımlarının geliştirilmesi mümkün hâle gelmektedir (Sağıroğlu & Tosun, 2023). Bunun yanı sıra, klinik uygulamaların ötesinde tıp eğitimi, medikal araştırmalar ve hastalık olasılıklarının öngörülmesi gibi alanlarda da etkin bir şekilde kullanılmaktadır (Güvercin, 2020; Keleş, 2022).

Yapay Zekânın tıp alanındaki kullanımı önemli avantajlar sağlamakla birlikte çeşitli etik sorunları da beraberinde getirmektedir. Özellikle hasta mahremiyeti, veri güvenliği, algoritmik önyargı ve karar verme süreçlerinde sorumluluğun belirlenmesine ilişkin sorunlar, bu teknolojilerin güvenilir ve etik biçimde uygulanabilmesi açısından kritik öneme sahiptir (Keskinbora, 2019).

Bu çalışmanın amacı, yapay zekânın tarihsel gelişimini ve tıp alanındaki kullanımını incelemek, ortaya çıkan etik sorunları başta veri güvenliği olmak üzere hukuki boyutlar çerçevesinde değerlendirmektir. Bu bağlamda yapay zekânın tıpta kullanımına ilişkin etik

tartışmaları analiz ederek potansiyel riskleri ortaya koymak ve çözüm önerileri geliştirmektir.

Yapay zekâ ve tarihsel gelişimi

Yapay zekâ (YZ), insan zekâsına özgü bilişsel süreçleri (öğrenme, akıl yürütme, problem çözme ve karar verme gibi) taklit etmeyi amaçlayan disiplinler arası bir araştırma alanıdır. Bilgisayar bilimleri başta olmak üzere matematik, istatistik, nörobilim ve mühendislik gibi farklı alanların kesişiminde yer alan YZ, son yıllarda tıp dâhil birçok sektörde artan bir ilgi odağı hâline gelmiştir (Gündüz & Eren, 2024; Güvercin, 2020; Keleş, 2022).

Yapay zekâ kavramının temelleri, Alan Turing'in 1950 yılında yayımladığı çalışmalara dayanmaktadır. Turing, makinelerin insan benzeri düşünme yetisine sahip olup olamayacağını sorgulamış ve bu bağlamda YZ'nin teorik çerçevesini ortaya koymuştur (Keleş, 2022). 1956 yılında ise John McCarthy tarafından düzenlenen Dartmouth Konferansı ile "yapay zekâ" terimi literatüre kazandırılmış ve YZ "zekâ gerektiren görevleri yerine getirebilen makineler" olarak tanımlanmıştır (Alpkoçak, 2024; Keleş, 2022; Uzun, 2020).

Yapay zekânın tıp alanında uygulanması ise 1970'li yıllarda başlamıştır. Bu dönemde geliştirilen INTERNIST-1, MYCIN ve CASNET gibi erken dönem uzman sistemler, klinik karar destek mekanizmalarının ilk örneklerini oluşturmuş ve özellikle tanı süreçlerinde hekimlere yardımcı olmuştur (Uzun, 2020). Bu sistemler, sınırlı veri ve kural tabanlı yapılarıyla çalışmakla birlikte, modern tıbbi yapay zekâ uygulamalarının öncüsü olarak kabul edilmektedir.

2000'li yıllardan itibaren bilişim teknolojilerindeki gelişmeler, büyük veri (big data) altyapılarının oluşumu ve işlem gücündeki artış, makine öğrenmesi algoritmalarının hızla gelişmesine zemin hazırlamıştır. Özellikle 2010'lu yıllarda derin öğrenme (deep learning) yöntemlerinin yaygınlaşmasıyla birlikte görüntü işleme ve doğal dil işleme gibi alanlarda önemli ilerlemeler kaydedilmiştir (LeCun et al., 2015). Bu gelişmeler, yapay zekânın daha karmaşık ve çok boyutlu tıbbi problemlerin çözümünde etkin biçimde kullanılmasını mümkün kılmıştır (Akalın & Veranyurt, 2022).

Sağlık ve tıp alanında yapay zekânın kullanım alanları

Günümüzde yapay zekâ, sağlık ve tıp alanında farklı disiplinlerle entegre bir biçimde geniş bir uygulama yelpazesinde kullanılmaktadır. Bu kapsamda öne çıkan başlıca kullanım alanları şunlardır:

- Tıbbi tanı: Yapay zekâ uygulamaları klinik muayene bulguları, klinik test verileri, patolojik bulgular, radyolojik görüntüler gibi tanı araçlarını hızla analiz edebilir ve algoritmada bulunan çok sayıdaki veriyle kıyaslayıp karmaşık vakalarda bile tanı için gereken süreyi büyük ölçüde kısaltabilmektedir (Keleş, 2022). Tanı sürecinde yüksek doğruluk oranına sahip sonuçlarla hekimin işini kolaylaştırabilmekte ve tedavi sürecinin daha etkin bir şekilde şekillenmesine katkıda bulunabilmektedir (Keleş, 2022; Sağıroğlu & Tosun, 2023).

- Tıbbi görüntüleme: Yapay zekâ algoritmalarındaki derin öğrenme teknikleri sayesinde BT, MR, PET gibi görüntüleme yöntemlerinde anormallikleri tespit edebilir ve yüksek doğruluk oranıyla doktorlara zaman kazandırabilmektedir (Kaplan & Bingöl, 2024; Sayar, 2023).

- Kişiselleştirilmiş tedavi: Yapay zekâ hasta verilerini analiz ederek, bireylerin genetik yapısı, çevresel faktörleri ve tıbbi geçmişi doğrultusunda kişiye özel tedavi seçenekleri sunmaktadır (Kaplan & Bingöl, 2024). Bu sistemler hasta ile ilgili birçok veriyi analiz ederek hekimin hata riskini ve olası yan etkileri azaltmaktadır (Kaplan & Bingöl, 2024;

Sayar, 2023). Hekime birçok tedavi seçeneği sunarak tedavi sürecinde başarı oranını ve güvenirliğini artırmaktadır (Güvercin, 2020; Sayar, 2023). Örneğin kanser hastaları gibi ilaç yükünün yüksek olduğu hasta gruplarında, hastanın tedaviye vereceği yanıt öngörülmekte ve gereksiz ilaç kullanımının önüne geçilmiş olunmaktadır (Keleş, 2022).

- Klinik karar destek sistemleri: Bu sistemler hekime tanı, tedavi ve hasta yönetimi süreçlerinde yardımcı olmaktadır. Örneğin laboratuvar sonuçlarını ve hasta verilerini analiz ederek hekime öneriler sunmaktadır. Böylece tedavinin etkinliğini de artırmış olmaktadır (Kaplan & Bingöl, 2024).

- İlaç ve aşı geliştirme: İlaç üretimi içerik tasarımı, klinik deneyler, performans testleri gibi birçok basamakları olan uzun bir süreçtir (Keleş, 2022). Yapay zekâ ilaç ve aşı geliştirme süreçlerinde araştırma süresini kısaltan ve maliyeti düşüren bir yardımcıdır (Kaplan & Bingöl, 2024; Güvercin, 2020). Derin öğrenme yapay zekâ teknolojileri ile desteklenerek üretilen ilaçların kalitesi artırılmakta ve tedavi sürecinde önemli aşamalar kat edilmektedir (Keleş, 2022; Sağıroğlu & Tosun, 2023). Nitekim yakın dönemde tüm dünyayı etkisi altına alan COVID-19 pandemisi sırasında yapay zekâ destekli çalışmalar, aşı geliştirme sürecinin önemli ölçüde hızlanmasına katkı sağlamıştır (Sağıroğlu & Tosun, 2023; Şener & Kıtır, 2022).

- Robotik cerrahi: Yapay zekâ destekli cerrahi sistemler zorlu ve hassasiyet isteyen ameliyatlarda cerraha yardımcı olmakta, hata oranını azaltmakta ve iyileşme süresini kısaltmaktadır (Akalın & Veranyurt, 2022; Kaplan & Bingöl, 2024; Sayar, 2023; Uzun, 2020).

- Hasta izleme ve mobil sağlık: Yapay zekâ hasta izleme ve mobil sağlık uygulamalarında bireylerin sağlık durumunun sürekli olarak takip edilmesini mümkün kılmaktadır (Doğan Merih & Akdoğan, 2021; Akgerman et al., 2022). Özellikle kardiyak hastalıklar, diyabet, hipertansiyon gibi sürekli takip edilmesi gereken hastalıklarda yapay zekâ iş yükünü oldukça azaltmakta ve olası riskleri hesaplayarak hekimlere gerçek zamanlı geri bildirim sunmaktadır (Özdemir & Bilgin, 2021).

- Sağlık yönetimi ve idari süreçler: Yapay zekâ sağlık yönetimi ve idari süreçlerde kaynakların daha verimli kullanılmasını sağlamaktadır (Davenport & Kalakota, 2019). Hastane yönetiminde hastane kapasitesi planlanması, ilaç stoku yönetimi, randevu sistemlerinin düzenlenmesi, insan kaynakları planlanması gibi birçok konuda kullanılmaktadır (Gündüz & Eren, 2024). Ayrıca elektronik sağlık kayıtlarının analiz edilmesi sayesinde idari süreçler hızlanmakta ve hata oranını düşürerek maliyeti azaltmaktadır (Çilhoroz & Işık, 2021; Davenport & Kalakota, 2019; Jiang et al., 2017).

- Tıp eğitimi: Yapay zekâ, yoğun mesleki bilgi gereksinimi olan tıp eğitiminde öğrencilerin öğrenme süreçlerini desteklemekte ve büyük katkı sunmaktadır (Keleş, 2022). Simülasyon temelli hasta uygulamaları sayesinde öğrenciler hata yapmadan deneyim kazanmakta, hasta güvenliğini tehlikeye atmadan klinik karar verme becerilerini geliştirmektedir (Uzun, 2020). Cerrahi eğitimde yapay zekâ destekli sistemler, öğrencilerin anatomik yapıları üç boyutlu olarak öğrenmelerine imkân sağlayarak, geleneksel iki boyutlu yöntemlere kıyasla daha iyi performans ve daha yüksek öz güven geliştirmelerine katkıda bulunmaktadır (Keleş, 2022).

Tıpta yapay zekâ kullanımında etik ve yasal sorunlar

Yapay zekâ teknolojileri tıp alanına tanı, tedavi, eğitim gibi birçok konuda yenilikler sunmaktadır. Ancak bu yeniliklerin yanında ciddi etik tartışmaları ve yasal sorunları da beraberinde getirmektedir. Yaşanan etik ve yasal sorunlar şu başlıklar altında ele alınmaktadır:

- Yanlılık ve önyargı: Yapay zekâ sistemleri kullanılan veri setlerinde ve algoritma tasarımlarında bulunan önyargıları taklit edebilmekte ve var olan önyargıları öğrenerek karar süreçlerine yansıtabilmektedir (Güvercin, 2020; Sağıroğlu & Tosun, 2023). Bu önyargı, farklı aşamalarda ve çeşitli biçimlerde ortaya çıkabilmektedir: veri üretim sürecinde insan kaynaklı yanlılık, sistem tasarımına ilişkin yapısal yanlılık ve sağlık sistemlerinde kullanılan veri setlerinden kaynaklanan yanlılık (Güvercin, 2020). Özellikle veri setlerinin belirli grupları yeterince temsil etmemesi, bazı hasta gruplarında hatalı veya eksik sonuçlara yol açabilmektedir (Güvercin, 2020). Veri setlerinde var olan dengesizlikler veya belirli grupların yeterince temsil edilememesi, algoritmaların belirli gruplar lehine veya aleyhine hatalar üretmesine neden olabilmektedir (Güvercin, 2020; Sağıroğlu & Tosun, 2023). Özellikle cinsiyet, yaş, etnik köken veya sosyoekonomik durum açısından yeterince çeşitlilik içermeyen verilerle eğitilen modeller, bazı hasta gruplarında daha düşük doğruluk oranlarıyla çalışarak yanlış ya da eksik değerlendirmelere yol açabilmektedir (Sağıroğlu & Tosun, 2023). Bu durum zaten dezavantajlı konumda bulunan bireylerin sağlık hizmetlerine erişimine de engel oluşturmaktadır (Kaplan & Bingöl, 2024; Uzun, 2020). Dolayısıyla yapay zekâ uygulamalarında adalet ve hakkaniyetin sağlanabilmesi için eğitim verilerinin azınlık grupların verilerini de kapsayacak şekilde oluşturulması ve elde edilen verilerin eleştirel bir bakış açısıyla değerlendirilmesi büyük önem taşımaktadır (İlkılıç, 2021; Keleş,2022; Sağıroğlu & Tosun, 2023).

- Mahremiyet ve veri güvenliği: Tıp alanında yapay zekâ uygulamalarının etkin şekilde çalışabilmesi için büyük hacimli sağlık verilerine ihtiyaç duyulmaktadır. Bu ihtiyaç, bireylerin mahremiyetinin korunmasını ve verilerin güvenliğinin sağlanmasını güç hale getirmektedir (Özdemir & Bilgin, 2021). Veri sızıntıları, siber saldırılar veya hasta verilerinin kötüye kullanımı hastaların mahremiyetini tehlikeye atabilmektedir (Kaplan & Bingöl, 2024; Uzun, 2020). Veri güvenliği açıkları yalnızca bireylerin hak ihlallerine değil, aynı zamanda sağlık sistemine duyulan güveni de zedelemektedir (Kaplan & Bingöl, 2024; Sağıroğlu& Tosun, 2023). Bu nedenle veriler anonimleştirilmeli, güçlü şifre yöntemleri ve erişim kontrolü ile hasta verilerinin korunması sağlanmalıdır (Alpkoçak, 2024; Koç et al., 2023).

- Açıklanabilirlik eksikliği: Yapay zekâ sistemleri derin öğrenme algoritmalarına dayanmaktadır (Keleş, 2022). Yapay zekâ sistemleri karar alma süreçlerini çoğu zaman açık ve anlaşılır şekilde ortaya koyamaz. Bu durum "kara kutu (black box)" problemi olarak karşımıza çıkmaktadır (Alpkoçak, 2024). Bir yapay zekâ sisteminin neden belirli tanı veya tedavi önerisinde bulunduğunun açıklanamaması, hekimlerin yapay zekâ sistemlerine olan güvenini azaltabilir (Keskinbora, 2019). Ayrıca hatalı bir karar verildiğinde sorumluluğun kime ait olduğunun belirlenmesini de zorlaştırmaktadır (Güvercin, 2020).

- Sorumluluk ve hesap verilebilirlik eksikliği: Yapay zekâ sistemlerinin sağlık alanında kullanımı, olası bir hata durumunda sorumluluğun kime ait olacağı konusunda belirsizlikler taşımaktadır (Keskinbora, 2019). Bir yapay zekâ sisteminin yanlış tanı koyması ya da hatalı tedavi önerisinde bulunması durumunda; bu hatadan hekim mi, yapay zekâyı geliştiren yazılımcı mı yoksa bu yapay zekâ sistemini kullanan hastane mi sorumludur sorusu net ve adil bir şekilde cevaplanamamaktadır (Güvercin, 2020). Bu durum hem etik hem de hukuki açıdan ciddi belirsizliklere yol açmaktadır (Kaplan & Bingöl, 2024; Sağıroğlu & Tosun, 2023). Hesap verilebilirliğin sağlanamaması, hasta güvenliğini riske atabilir ve sağlık hizmetlerine duyulan güveni azaltabilir (İlkılıç, 2021).

- Hasta özerkliğinin zedelenmesi: Yapay zekâ sistemleri, hastaların sağlık kararlarına aktif katılımını azaltabilmektedir. Bunun temel nedenlerinden biri, bu sistemlerin nasıl çalıştığının ve hangi verilerle hangi sonuçlara ulaştığının hastalar tarafından çoğu zaman anlaşılamamasıdır (Uzun, 2020). Hastaların, kendilerine uygulanan tanı ve tedavi

süreçlerinde kararın yapay zekâ tarafından mı yoksa hekim tarafından mı verildiğini bilmeden sürece dahil olması, hasta özerkliği ilkesine aykırılık teşkil etmektedir (Keleş, 2022). Bu durum bilgilendirilmiş onam sürecini zayıflatmaktadır. Bu bağlamda yapay zekâ sistemlerinin şeffaf olması ve hastaların bu sistemlerin işleyişi hakkında yeterli düzeyde bilgilendirilmesi büyük önem taşımaktadır (İlkılıç, 2021; Koç et al., 2023).

- Yasal düzenleme eksikliği: Yapay zekâ teknolojilerinin sağlık ve tıp alanındaki kullanımı hızla artmakla birlikte, bu sistemlerin kullanımını düzenleyen yasal çerçeveler birçok ülkede henüz yeterli düzeyde gelişmemiştir (Güvercin, 2020; İlkılıç, 2021; Koç et al., 2023). Hasta hakları, veri güvenliği, yapay zekâ destekli tanı ve tedavi süreçlerinde ortaya çıkabilecek hatalarda hukuki sorumluluğun kimde olduğu konusunda ciddi boşluklar vardır (Sağıroğlu & Tosun, 2023; Özdemir & Bilgin, 2021). Bu durum belirsizlik yaratmakta ve olası hak ihlallerinin çözümünü zorlaştırmaktadır (Kaplan & Bingöl, 2024). Bu nedenle yapay zekâ uygulamalarının güvenli ve etik bir şekilde kullanılabilmesi için kapsamlı, güncel ve bağlayıcı yasal düzenlemelere ihtiyaç duyulmaktadır (Yorgancıoğlu et al., 2024).

Etik ve yasal sorunlara yönelik alınabilecek önlemler ve sorumluluklar

Yapay zekânın sağlık ve tıp alanında güvenli ve etik bir şekilde kullanılabilmesi için çeşitli önlemlerin alınması gerekmektedir. Alınabilecek önlemler sırasıyla şu şekilde sıralanabilir:

- Açıklanabilir yapay zekâ: "Kara kutu" problemi olarak adlandırdığımız yapay zekâ sistemlerinin karar alma süreçlerini anlaşılır hale getirmek şeffaflık ve hesap verebilirlik ilkeleri açısından kritik öneme sahiptir (Alpkoçak, 2024; Güvercin, 2020). Açıklanabilirliğin sağlanması, hekimlerin yapay zekâ sistemlerine olan güvenini artırırken hastaların da bilgilendirilmiş onam sürecine daha etkin katılımını mümkün kılar (Güvercin, 2020). Açıklanabilirlik, olası hataların tespit edilmesini kolaylaştırır ve sorumluluğun daha net belirlenmesine katkı sağlayarak hesap verilebilirlik ilkesine doğrudan katkı sağlar (Alpkoçak, 2024; Güvercin, 2020). Bu nedenle yapay zekâ sistemlerinin geliştirilmesinde şeffaflık ön plana alınmalı ve kara kutu algoritmalar yerine açıklanabilirliği yüksek sistemler tercih edilmelidir (İlkılıç, 2021).

- Veri güvenliği ve mahremiyetin korunması: Sağlık ve tıp alanında kullanılan yapay zekâ sistemleri çok sayıda kişisel bilgiye gereksinim duymaktadır. Bu durum kişisel verilerin kötü niyetli kullanılması açısından hassasiyet yaratmaktadır (Özdemir & Bilgin, 2021). Veri mahremiyeti ihlallerine karşı önlem olarak, verilerin anonimleştirilmesi, güçlü şifreleme yöntemlerinin kullanılması ve erişim kontrollerinin uygulanması gerekmektedir (Gündüz & Eren, 2024; Özdemir & Bilgin, 2021). Veri ihlallerinin önlenmesi için teknik önlemlerin yanı sıra yasal düzenlemeler ve etik standartlar da etkin bir şekilde uygulanmalıdır. Örneğin veri işleme süreçlerinde ulusal mevzuatlar (KVKK) ve uluslararası düzenlemelere uyum sağlanmalıdır (Alpkoçak, 2024). Hasta verileri sadece belirli amaçlar doğrultusunda ve hastanın onayıyla kullanılmalıdır. Veri güvenliği hem bireyin mahremiyetine saygının hem de sağlık sistemine güvenin temelini oluşturur (Güvercin, 2020).

- Hukuki ve etik yönetim: Hukuki yönetim, sorumlulukların net bir şekilde tanımlanmasını, veri kullanımının düzenlenmesini ve olası ihlallerde uygulanacak yaptırımların belirlenmesini sağlar. Etik yönetim ise adalet, hasta hakları, zarar vermeme ilkeleri gibi etik ilkelerin korunmasına odaklanır (WHO, 2021). Bu iki yönetimin birlikte ele alınması, yapay zekâ uygulamalarının güvenirliğinin arttırılmasına katkıda bulunur.

- Algoritmik adalet ve önyargının azaltması: Yapay zekâ eğitildikleri veri setlerindeki önyargıları öğrenebilir ve tekrarlayabilir (Güvercin, 2020; Sağıroğlu & Tosun, 2023). Yapay zekâ modelleri belirli yaş grupları, cinsiyet ve etnik grup açısından hatalı ve adaletsiz sonuçlar üretebilmektedir. Bu nedenle veri setleri azınlık grupların verilerini de kapsayacak

şekilde çeşitlendirilmelidir (İlkılıç, 2021; Keleş, 2022; Sağıroğlu & Tosun, 2023). Algoritma çıktıları düzenli olarak denetlenmeli ve ayrımcılık içeren eğilimlere müdahale edilmelidir (Kaplan & Bingöl, 2024).

- Hasta katılımı ve bilgilendirilmiş onamın güçlendirilmesi: Hastaların kendilerine uygulanacak tanı ve tedavi süreçlerinde kullanılan yapay zekâ sistemleri hakkında açık ve anlaşılır şekilde bilgilendirilmesi gerekmektedir. Hastaya sistemin nasıl çalıştığı, hangi verileri kullandığı ve olası riskler detaylı şekilde ve hastanın anlayacağı sade bir dille anlatılmalıdır (Keskinbora, 2019). Hasta katılımının güçlendirilmesi, hasta özerkliğini korur ve sağlık hizmetlerine duyulan güveni artırır (Güvercin, 2020).

- İnsan denetiminin korunması (Human-in-the-loop): Yapay zekâ sistemleri sağlık alanında tamamen bağımsız karar verici olarak değil verdiği kararların insan denetiminden geçmesi gerekmektedir (Alpkoçak, 2024). "Human-in-the-loop" terimi, yapay zekânın önerilerinin uzman kişilerce incelenip onaylanmasını ifade etmektedir (Keskinbora, 2019). Bu yöntem sayesinde olası hatalar fark edilmekte ve hasta güvenliğini artırmaktadır (Koç et al., 2023). Bu nedenle "Human-in-the-loop" yaklaşımı hem güvenli sağlık hizmeti hem hasta özerkliğinin korunması yönünde temel bir ilke olarak kabul edilmelidir (Keleş, 2022; Koç et al., 2023).

- Ulusal ve uluslararası yasal düzenlemelerin oluşturulması: Yapay zekânın güvenli ve etik bir şekilde kullanılabilmesi için hem ulusal hem de uluslararası düzenlemelere ihtiyaç duyulmaktadır. Bu düzenlemeler hasta mahremiyeti, insan hakları, veri güvenliği ve etik ilkelere uygun bir şekilde hazırlanmalıdır (Özdemir & Bilgin, 2021). Ulusal ve uluslararası standartlar paralel olmalı ve iki kurum arası denetimler yapılmalıdır (İlkılıç, 2021). Bu tür düzenlemeler sağlık alanında yapay zekânın daha şeffaf ve etik ilkelere uygun bir şekilde kullanılmasına katkı sağlar (Güvercin, 2020; Sağıroğlu & Tosun, 2023).

Sonuç

Yapay zekâ teknolojileri, sağlık ve tıp alanında tanı, tedavi, görüntüleme, ilaç ve aşı geliştirme, sağlık yönetimi, tıp eğitimi gibi birçok konuda yardımcı olmakta, insan zekasının tek başına yapamayacak kadar karmaşık ve zor işlemleri saniyeler içerisinde yaparak zaman ve para tasarrufu sağlamaktadır. Bununla birlikte yapay zekâ ne kadar mükemmel bir yardımcı olarak görülse de birçok etik ve hukuki sorunu da beraberinde getirmektedir. Örneğin hasta özerkliğinin zedelenmesi, veri güvenliği ihlalleri, açıklanabilirlik eksikliği, sorumluluk ve hesap verilebilirlik eksikliği, önyargı ve yanlılık gibi birçok problem karşımıza çıkmaktadır. Bu problemlere çözüm olarak ulusal ve uluslararası düzenlemelerin oluşturulması, açıklanabilir yapay zekâ modellerinin tasarlanması, veri güvenliğinin sağlanması, etik denetim mekanizmalarının kurulması gibi önlemler alınabilir. Bu önlemler sayesinde yapay zekânın sağlık sisteminde kullanımı etik ilkelere uygun ve insan merkezli olacaktır. Bu sayede sağlık ve tıp alanındaki uygulamaların kalitesi artacak hem sağlık çalışanlarının hem de hastaların memnuniyeti yükselecektir. Ayrıca, yapay zekâ uygulamalarının insan odaklı bir anlayışla geliştirilmesi ve disiplinler arası bir perspektifle ele alınması büyük önem taşımaktadır.

Kaynakça

1. Akalın, B., & Veranyurt, Ü. (2022). Sağlık 4.O ve sağlıkta yapay zekâ. *Sağlık Profesyonelleri Araştırma Dergisi, 4*(1), 57-64. https://dergipark.org.tr/tr/pub/jhpr/article/1060839

2. Akgerman, B., Özdemir Yavuz, E. D., Kavaslar, İ., Güngör, S. (2022). Yapay zekâ ve hemşirelik. *Sağlık Bilimlerinde Yapay Zekâ Dergisi, 2*(1), 21–27. https://dergipark.org.tr/tr/pub/jaihs/issue/84896/1493549
3. Alpaydın, E. (2020). Machine Learning. Cambridge, MA: MIT Press.
4. Alpkoçak, A. (2024). Sağlıkta açıklanabilir yapay zekâ. *TOTBİD Dergisi*, 23, 18-19. https://doi.org/10.5578/totbid.dergisi.2024.04
5. Çilhoroz, Y., & Işık, O. (2021). Yapay zekâ: Sağlık hizmetlerinden uygulamalar. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 23*(2), 573–588. https://dergipark.org.tr/tr/pub/ahbvuibfd/issue/64683/905614
6. Davenport, T. H., & Kalakota, R. (2019). The potential for artificial intelligence in healthcare. *Future Healthcare Journal, 6*(2), 94-98. DOI:10.7861/futurehosp.6-2-94
7. Doğan Merih, Y., & Akdoğan, E. (2021). Hemşirelikte yapay zekâ. *4th International Eurasian Conference on Biological and Chemical Sciences (EurasianBioChem 2021)*, Ankara, Türkiye, 945-955. https://avesis.yildiz.edu.tr/yayin/231b6227-71aa-4698-96ef-d61d274cbd8a/artificial-intelligence-in-nursing
8. Gündüz, T., & Eren, F. (2024). Sağlıkta yapay zekâ: Bibliyometrik bir analiz. *Sağlık Akademisyenleri Dergisi, 11*(2), 277-285. https://doi.org/10.52880/sagakaderg.1420580
9. Güvercin, CH. (2020). Tıpta yapay zekâ ve etik. Ekmekçi PE, editör. Yapay Zekâ ve Tıp Etiği. 1. Baskı. Ankara: Türkiye Klinikleri, 1,7-13. https://www.turkiyeklinikleri.com/article/tr-tipta-yapay-zeka-ve-etik-88981.html
10. İlkılıç, İ. (2021). Tıpta yapay zekâ kullanımının etik açıdan değerlendirilmesi. *SD (Sağlık Düşüncesi ve Tıp Kültürü) Dergisi, 58*, 18-21. https://sdplatform.com/tipta-yapay-zeka-kullaniminin-etik-acidan-degerlendirilmesi
11. Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., Wang, Y., Dong, Q., Shen, H., Wang, Y. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2(4), 230-243. https://doi.org/10.1136/svn-2017-000101
12. Kaplan, M., Çakar, F., Bingöl, H. (2024). Sağlık alanında yapay zekânın kullanımı: Derleme. *Muş Alparslan Üniversitesi Sağlık Bilimleri Dergisi*, 4(3), 75-85. https://dergipark.org.tr/tr/pub/maunsbd/article/1576690
13. Keleş, H. (2022). Tıpta yapay zekâ uygulamaları. *Kırıkkale Üniversitesi Tıp Fakültesi Dergisi*, 24(3), 604-613. https://doi.org/10.24938/kutfd.1214512
14. Keskinbora, K. H. (2019). Medical ethics considerations on artificial intelligence. *Journal of Clinical Neuroscience, 64*, 277-282. https://doi.org/10.1016/j.jocn.2019.03.001
15. Koç, A. M., Bakiu, E., Gülas, G. E., & Koç, E. M. (2023). Sağlık için yapay zekâ teknolojilerinin etik tasarımı, uygulanması ve kullanımı için dikkat edilecek hususlar. *Sağlık Bilimlerinde Yapay Zekâ Dergisi, 3*(2), 14-21. https://dergipark.org.tr/tr/pub/jaihs/article/1497465
16. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*(7553), 436-444. https://doi.org/10.1038/nature14539
17. Özdemir, L., & Bilgin, A. (2021). Sağlıkta yapay zekânın kullanımı ve etik sorunlar. *Sağlık ve Hemşirelik Yönetimi Dergisi, 8*(3), 439–445. https://doi.org/10.54304/SHYD.2021.63325
18. Sağıroğlu, E., & Tosun, H. (2023). Yapay zekânın sağlık uygulamalarındaki kullanımı ve etik açıdan tartışılması: Geleneksel derleme. *Türkiye klinikleri Tıp Etiği, Hukuku ve Tarihi Dergisi*, 31(2), 140-8. DOI: 10.5336/mdethic.2022-92760
19. Sayar, B. (2023). Tıp alanında yapay zekânın kullanımı. *Acta Medica Ruha, 1*(1), 27-33. https://doi.org/10.5281/zenodo.7749209

20. Şener, L. T., Bozkaya, D. N., & Kıtır, T. (2022). COVID-19 sürecindeki yapay zeka, dijital sağlık tanı ve tedavisindeki gelişmeler. *Sağlık Bilimlerinde Yapay Zekâ Dergisi, 2*(1), 13-20. https://dergipark.org.tr/tr/pub/jaihs/issue/84896/1493528
21. Uzun, T. (2020). Yapay zeka ve sağlık uygulamaları. *İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3(1), 80-92. https://izlik.org/JA68LR92EJ
22. World Health Organization (WHO). (2021). *Ethics and governance of artificial intelligence for health*. https://www.who.int/publications/i/item/9789240029200
23. Yorgancıoğlu, G.T., Balçık, Y.P., Sebik, N.B. (2024). Türkiye ve dünyada sağlık hizmetlerinde yapay zekâ. *Mersin Üniversitesi Tıp Fakültesi Lokman Hekim Tıp Tarihi ve Folklorik Tıp Dergisi*, 14(1), 50-60. https://doi.org/10.31020/mutftd.1278529

Postmenopozal Osteoporozda Gastrointestinal Mikrobiyota: Patofizyoloji, Kanıtlar ve Tedaviye Yansımalar

Alihan Tığlı[1]

[1] Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi Kadın Hastalıkları ve Doğum AD Bandırma Türkiye

Özet

Postmenopozal osteoporoz (PMO), kemik mineral yoğunluğunda azalma, kemik mikro-mimarisinde bozulma ve kırık riskinde artış ile karakterize, menopoz sonrası kadınlarda sık görülen önemli bir metabolik kemik hastalığıdır. Hastalığın klasik patofizyolojisi büyük ölçüde östrojen eksikliğine dayandırılmakla birlikte, son yıllarda bağırsak mikrobiyotasının kemik homeostazı üzerindeki belirleyici rolü giderek daha fazla ilgi çekmektedir. Bağırsak mikrobiyotası; kısa zincirli yağ asitleri üretimi, bağırsak bariyer bütünlüğünün korunması, immün yanıtın düzenlenmesi, mineral emiliminin desteklenmesi, safra asidi metabolizmasının modülasyonu ve östrojenlerin enterohepatik dolaşımının etkilenmesi gibi çok yönlü mekanizmalar aracılığıyla kemik metabolizmasını etkileyebilmektedir. Menopoz sonrası dönemde gelişen hormonal değişikliklerin mikrobiyota kompozisyonunda bozulmaya yol açabildiği; bunun da bağırsak geçirgenliğinde artış, düşük dereceli sistemik inflamasyon, endotoksemi ve osteoklast aktivasyonunda artış ile ilişkili olduğu düşünülmektedir. Özellikle bütirat üreten bakterilerde azalma, proinflamatuvar sitokinlerde yükselme ve estrobolom aktivitesindeki değişiklikler, PMO patogenezinde öne çıkan mekanizmalar arasında yer almaktadır.

Deneysel hayvan modelleri ve insan çalışmaları, mikrobiyota bileşimi ile kemik mineral yoğunluğu, kemik döngü belirteçleri ve osteoporoz riski arasında anlamlı ilişkiler bulunduğunu göstermektedir. Ayrıca probiyotik, prebiyotik, postbiyotik ve diyet temelli müdahalelerin bağırsak mikrobiyotasını düzenleyerek kemik kaybını azaltabileceğine dair umut verici bulgular elde edilmiştir. Bununla birlikte mevcut klinik veriler; çalışma tasarımlarındaki farklılıklar, örneklem büyüklüklerinin sınırlılığı, kullanılan suş ve müdahalelerin heterojenliği nedeniyle henüz kesin sonuçlar ortaya koymaktan uzaktır.

Bu derlemede, postmenopozal osteoporozda mikrobiyota-kemik ekseninin temel patofizyolojik mekanizmaları, güncel klinik ve deneysel kanıtlar ile mikrobiyota hedefli tedavi yaklaşımlarının potansiyeli kapsamlı biçimde ele alınmıştır. Mevcut bulgular, bağırsak mikrobiyotasının PMO'da yalnızca eşlik eden bir unsur değil, aynı zamanda önleme ve tedavi stratejileri açısından umut vadeden bir hedef olabileceğini düşündürmektedir.

Anahtar kelimeler: postmenopozal osteoporoz, bağırsak mikrobiyotası, mikrobiyota-kemik ekseni, probiyotik, prebiyotik

1. GİRİŞ

Postmenopozal osteoporoz (PMO), kemik mineral yoğunluğunda azalma, kemik mikro-mimarisinde bozulma ve buna bağlı kırık riskinde artış ile karakterize, ileri yaş kadınlarda sık görülen önemli bir metabolik kemik hastalığıdır[1,2]. Özellikle vertebra, kalça ve distal radius kırıkları; ağrı, hareket kısıtlılığı, yaşam kalitesinde düşüş, bağımlılık artışı ve mortalite gibi ciddi sonuçlara yol açabilmektedir. Yaşlanan nüfus ve menopoz sonrası

yaşam süresinin uzaması nedeniyle PMO, yalnızca bireysel değil aynı zamanda toplumsal ve ekonomik yükü yüksek bir halk sağlığı problemi olarak değerlendirilmektedir[1,3].

PMO'nun klasik patofizyolojik temeli östrojen eksikliğine dayanmaktadır. Menopozla birlikte azalan östrojen düzeyleri, osteoklast aktivitesini artırırken osteoblastik kemik yapımını göreceli olarak yetersiz bırakmakta; böylece kemik döngüsü rezorpsiyon lehine kaymaktadır[3,4]. Bunun yanında östrojen eksikliğinin yalnızca kemik hücreleri üzerinde değil, immün sistem ve sitokin ağı üzerinde de belirgin etkileri bulunmaktadır. TNF-α, IL-6 ve diğer proinflamatuvar mediyatörlerdeki artış, osteoklastogenezi destekleyerek menopoz sonrası kemik kaybını hızlandırmaktadır[4,5]. Ancak son yıllarda elde edilen veriler, PMO'nun sadece hormonal eksiklik üzerinden açıklanamayacağını; immünolojik, metabolik ve çevresel etmenlerin de bu sürece önemli katkılar sunduğunu göstermektedir.

Bu bağlamda bağırsak mikrobiyotası, kemik sağlığının düzenlenmesinde giderek daha fazla dikkat çeken bir alan haline gelmiştir. İnsan gastrointestinal sisteminde yaşayan trilyonlarca mikroorganizma; besin öğelerinin işlenmesi, vitamin sentezi, kısa zincirli yağ asitlerinin üretimi, bağırsak bariyer bütünlüğünün korunması ve immün sistemin düzenlenmesi gibi çok sayıda fizyolojik süreçte rol almaktadır[6,7]. Sağlıklı bir mikrobiyota kompozisyonundaki bozulma, yani disbiyoz, sistemik inflamasyonun artmasına, bağırsak geçirgenliğinin bozulmasına ve çeşitli metabolik yolakların etkilenmesine neden olabilmektedir. Bu değişimlerin kemik homeostazını da etkileyebileceği düşüncesi, "mikrobiyota-kemik ekseni" kavramını ortaya çıkarmıştır[5,8].

Menopoz sonrası dönemde hormonal değişikliklerin bağırsak mikrobiyotası kompozisyonunu ve fonksiyonunu etkileyebildiği; buna karşılık mikrobiyotanın da östrojen metabolizması, inflamasyon düzeyi ve mineral emilimi üzerinden kemik metabolizmasını şekillendirebildiği bildirilmektedir[9,10]. Özellikle kısa zincirli yağ asitleri (KZYA) üretimindeki azalma, bağırsak bariyerinde bozulma, endotoksemi ve osteoklast aktivasyonunda artış gibi mekanizmalar, PMO patogenezine katkıda bulunabilecek başlıca yollar arasında değerlendirilmektedir[5,7,8]. Ayrıca bağırsak mikrobiyotasının östrojenlerin enterohepatik dolaşımını etkileyen estrobolom bileşeni üzerinden hormonal çevreyi de modüle edebilmesi, bu ilişkinin daha da önemli hale gelmesine neden olmuştur[11,12]

Son yıllarda hem deneysel hayvan modellerinden hem de insan çalışmalarından elde edilen bulgular, bağırsak mikrobiyotası ile kemik mineral yoğunluğu, kemik döngü belirteçleri ve osteoporoz riski arasında anlamlı ilişkiler olabileceğini göstermektedir[13–16]. Buna ek olarak probiyotik, prebiyotik ve diyet temelli müdahalelerin kemik kaybını azaltma potansiyeli, mikrobiyotayı yalnızca patogenez açısından değil, aynı zamanda olası tedavi hedefi olarak da gündeme getirmiştir[17–19].

Bu derlemenin amacı, postmenopozal osteoporozda bağırsak mikrobiyotasının olası rolünü güncel literatür ışığında değerlendirmek; mikrobiyota-kemik ekseninin temel patofizyolojik mekanizmalarını, klinik ve deneysel kanıtlarını ve mikrobiyota hedefli tedavi yaklaşımlarının potansiyelini özetlemektir.

2. MİKROBİYOTA-KEMİK EKSENİ VE PMO PATOGENEZİ

2.1. Östrojen eksikliği, inflamasyon ve kemik kaybı

Östrojen, osteoblast ve osteoklast aktivitesinin dengelenmesinde temel rol oynar. Menopoz sonrası östrojen eksikliği, Receptor Activator of Nuclear Factor kappa-B Ligand (RANKL)/ Osteoprotegerin(OPG) dengesini osteoklastogenezi destekleyecek şekilde değiştirir ve kemik rezorpsiyonunu artırır[3,4]. Buna ek olarak menopoz sonrası dönemde

TNF-α, IL-6 ve IL-17 gibi proinflamatuvar sitokinlerde artış görülür; bu durum osteoimmünolojik mekanizmalar üzerinden kemik kaybını hızlandırır[5].

2.2. Bağırsak bariyeri ve endotoksemi

Bağırsak bariyer bütünlüğünün bozulması, lipopolisakkarit gibi mikrobiyal ürünlerin dolaşıma geçişini kolaylaştırır. Düşük dereceli endotoksemi; Toll-like receptor (TLR) aracılı inflamatuvar sinyalizasyonu, osteoklast aktivasyonunu ve kemik yıkımını artırabilir[5,8]. Menopozla ilişkili disbiyozun, bariyer fonksiyonunda bozulma ve kronik inflamasyonla birlikte ilerlemesi, PMO patogenezinin önemli bileşenlerinden biridir.

2.3. Kısa zincirli yağ asitleri ve immünomodülasyon

Mikrobiyota tarafından üretilen asetat, propiyonat ve özellikle bütirat; bağırsak epitel bütünlüğünü destekler, T-regülatör hücre yanıtını güçlendirir ve inflamasyonu baskılar[7,8]. Deneysel çalışmalarda KZYA'ların osteoklast farklılaşmasını baskıladığı ve kemik kütlesini koruyabildiği gösterilmiştir[20]. Bu nedenle bütirat üreten bakterilerin azalması, menopoz sonrası kemik kaybı açısından olumsuz bir biyolojik zemin oluşturabilir.

2.4. Estrobolom ve östrojen metabolizması

Bağırsak mikrobiyotasının östrojenlerin enterohepatik dolaşımına katılan kısmı "estrobolom" olarak tanımlanmaktadır. Mikrobiyal beta-glukuronidaz aktivitesi, konjuge östrojenlerin yeniden aktif hale gelmesini etkileyerek dolaşımdaki östrojen profilini modüle edebilir[11]. Postmenopozal kadınlarda mikrobiyota bileşimi ile endojen östrojen düzeyleri arasında ilişki bildiren çalışmalar, bu eksenin kemik metabolizması açısından da önemli olabileceğini düşündürmektedir[12].

2.5. Safra asitleri ve mineral emilimi

Bağırsak mikrobiyotası, safra asidi dönüşümü ve lüminal pH değişiklikleri yoluyla kalsiyum emilimi ve metabolik sinyal ağlarını etkileyebilir. Özellikle Farnesoid X Receptor (FXR) ve Takeda G protein-coupled receptor 5 (TGR5) gibi safra asidi reseptörleri üzerinden kemik homeostazına dolaylı katkı söz konusudur[21]. Bu nedenle mikrobiyota kaynaklı metabolik sinyaller, yalnızca inflamasyonu değil aynı zamanda mineral kullanımını da etkileyen çok katmanlı bir ağ oluşturmaktadır.

3. KLİNİK VE DENEYSEL KANITLAR

3.1. Klinik Kanıtlar

İnsan çalışmalarında, postmenopozal kadınlarda bütirat üreten bakterilerin daha yüksek kemik mineral yoğunluğu (KMY) ile, Proteobacteria artışının ise düşük KMY ve inflamasyonla ilişkili olduğu gösterilmiştir; ayrıca fekal beta-glukuronidaz aktivitesi, östrojen metabolit profilleri, kısa zincirli yağ asitleri ve endotoksemi belirteçleri ile kemik dönüşüm parametreleri arasındaki ilişkiler, mikrobiyota-kemik ekseninin klinik önemini desteklemektedir[7,12,15,16,22–26]. Müdahale çalışmalarında özellikle Lactobacillus reuteri ve L. rhamnosus gibi probiyotiklerin kemik dönüşüm belirteçleri üzerinde olumlu etkiler gösterebildiği, prebiyotik liflerin kalsiyum emilimini destekleyebildiği, ancak kemik mineral yoğunluğu üzerindeki klinik etkilerin genellikle sınırlı ve değişken olduğu bildirilmektedir[17,27–30]. Bu nedenle düşük bütirat üretimi, artmış beta-glukuronidaz aktivitesi, endotoksemi ve düşük mikrobiyotal çeşitlilik gibi özelliklerin gelecekte risk belirteci olarak kullanılabileceği düşünülse de, kırık ve KMY gibi sert sonlanımları değerlendiren büyük ölçekli çalışmalara hâlâ ihtiyaç vardır[26,31,32].

3.2. Deneysel Kanıtlar

Deneysel çalışmalar, mikrobiyota-kemik ekseninin nedensel ve mekanistik yönünü desteklemektedir: germ-free farelerde mikrobiyota kolonizasyonu sonrası kemik parametrelerinin normale yaklaşması, antibiyotik müdahalelerinin kısa süreli koruyucu ancak uzun dönemde sınırlı etkileri ve ovarektomi modellerinde disbiyoz, bariyer bozulması, endotoksemi ile TNF-α/IL-17 artışına eşlik eden kemik kaybı bu ilişkiyi göstermektedir[14,33–38]. Ayrıca Lactobacillus reuteri, L. rhamnosus ve Bifidobacterium suşları ile kısa zincirli yağ asitleri gibi metabolitlerin osteoklast aktivitesini baskılayabildiği, bağırsak bariyerini güçlendirebildiği ve kemik kaybını azaltabildiği; buna ek olarak FXR/TGR5 sinyali, estrobolom hedeflemesi, bakteriyofajlar, dirençli nişasta ve polifenoller gibi yaklaşımların da umut verici olduğu bildirilmiştir[7,13,21,39–45]. Bununla birlikte, probiyotikler, postbiyotikler ve safra asidi agonistleri için güvenlik, doz optimizasyonu ve klinik çeviri sorunları devam etmektedir[46–48]

4. MİKROBİYOTA HEDEFLİ TEDAVİ YAKLAŞIMLARI

4.1. Probiyotikler

Probiyotikler, PMO'da en çok çalışılan mikrobiyota temelli müdahalelerdendir. Özellikle Limosilactobacillus reuteri 6475 ile yürütülen klinik çalışmalarda, erken postmenopozal dönemde kemik kaybı hızının azalabileceğine dair bulgular elde edilmiştir[17,18]. Ayrıca izoflavon ve probiyotik kombinasyonlarının kemik ve östrojen metabolizması üzerinde olumlu etkiler gösterebileceği bildirilmiştir[28].

Bununla birlikte probiyotik etkinlik suş-özel görünmektedir. Tüm probiyotiklerin aynı biyolojik etkiyi göstermediği, doz, süre ve taşıyıcı matriksin sonuçları belirgin biçimde etkilediği unutulmamalıdır[19].

4.2. Prebiyotikler ve diyet lifi

Prebiyotik lifler, özellikle KZYA üretimini artırmaları ve kalsiyum emilimini desteklemeleri nedeniyle önem taşır. İnülin, fruktooligosakkaritler ve benzeri fermente olabilir liflerin kemik sağlığı üzerinde olumlu etkileri olduğu; ancak bu etkinin popülasyona ve müdahale süresine göre değişebildiği bildirilmektedir[30]. Bu nedenle liften zengin diyet yaklaşımı, PMO'da düşük riskli destekleyici stratejiler arasında değerlendirilebilir.

4.3. Postbiyotik ve Metabolit Takviyeleri: Bütirat tuzları ile yapılan insan çalışmaları sınırlı olup, tolere edilebilirlik ve gastrointestinal yan etkiler bu yaklaşımın klinik uygulanabilirliğini kısıtlayabilmektedir. Polifenol türevlerinin (epikateşin gibi) mikrobiyota aracılı mekanizmalarla kemik belirteçlerinde iyileşme sağlayabileceğine dair çalışmalar mevcuttur[49].

4.4. Hormon Replasman Tedavisi ve Mikrobiyota Etkileşimi: Hormon replasman tedavisi alan postmenopozal kadınlarda estrobolom aktivitesinde ve bazı bakteriyel taksonların dağılımında farklılıklar olduğu, inflamasyon belirteçlerinin azaldığı gözlemlenmiştir. Ancak nedensellik ilişkisinin ve klinik anlamının netleştirilmesi için daha fazla çalışmaya ihtiyaç vardır[24,50].

4.5. Gelecek vaat eden alanlar

Safra asidi reseptörleri, estrobolom hedeflemesi ve postbiyotikler gelecek açısından umut verici başlıklardır. Özellikle safra asidi sinyalinin kemik homeostazını etkileyebildiğini gösteren deneysel veriler, bu alanın farmakolojik olarak da hedeflenebileceğini düşündürmektedir[21,51]. Ancak bu yaklaşımların çoğu henüz erken aşamadadır ve klinik pratiğe girebilmesi için daha güçlü insan verilerine ihtiyaç vardır.

5. TARTIŞMA

Güncel bulgular, postmenopozal osteoporozun yalnızca östrojen eksikliğine bağlı klasik bir kemik hastalığı olarak değerlendirilmesinin yetersiz kaldığını göstermektedir. Menopoz sonrası dönemde azalan östrojen düzeyleri, kemik rezorpsiyonunu artıran temel faktör olmaya devam etmekle birlikte, bu hormonal değişikliğin bağırsak mikrobiyotası, bağışıklık sistemi ve bağırsak bariyer fonksiyonları üzerindeki etkileri de kemik kaybının şiddetini belirleyebilmektedir[3–5] . Bu nedenle PMO, hormonal, immünolojik ve mikrobiyal mekanizmaların kesişiminde yer alan çok boyutlu bir süreç olarak ele alınmalıdır[6,10].

Mikrobiyota-kemik ekseninin en dikkat çekici yönlerinden biri, inflamasyonun düzenlenmesindeki rolüdür. Menopoz sonrası dönemde görülen disbiyozun, bağırsak geçirgenliğini artırarak mikrobiyal ürünlerin dolaşıma geçişini kolaylaştırdığı; bunun da düşük dereceli sistemik inflamasyonu tetikleyebildiği düşünülmektedir[5,8]. TNF-α, IL-6 ve IL-17 gibi sitokinlerdeki artışın osteoklast aktivitesini desteklemesi, bağırsak kaynaklı inflamatuvar yanıtın kemik kaybına biyolojik bir zemin hazırladığını düşündürmektedir[4,5]. Bu bakımdan bağırsak bariyer bütünlüğünün korunması, yalnızca gastrointestinal sağlık açısından değil, kemik bütünlüğünün sürdürülmesi açısından da önemli görünmektedir[8].

Öte yandan mikrobiyota yalnızca inflamasyon üzerinden değil, metabolit üretimi yoluyla da kemik sağlığını etkileyebilmektedir. Özellikle kısa zincirli yağ asitleri, immün toleransın desteklenmesi, bağırsak epitel bütünlüğünün korunması ve osteoklastogenezin baskılanması gibi mekanizmalarla öne çıkmaktadır. Bu nedenle bütirat üreten bakterilerin azalması, postmenopozal dönemde kemik kaybını hızlandırabilecek önemli bir değişiklik olarak değerlendirilebilir[7,10,20]. Ayrıca estrobolom aracılığıyla östrojen metabolizmasının etkilenmesi, mikrobiyotanın menopoz sonrası hormonal çevre üzerinde dolaylı ama anlamlı etkiler oluşturabileceğini göstermektedir[11,12]. Bu durum, bağırsak mikrobiyotasının yalnızca eşlik eden bir değişken değil, hastalık sürecine aktif katkıda bulunan bir düzenleyici olabileceğini düşündürmektedir.

Klinik çalışmalar genel olarak mikrobiyota bileşimi ile kemik mineral yoğunluğu arasında ilişki olduğunu desteklese de, bu ilişkinin yönü ve gücü konusunda henüz tam bir fikir birliği yoktur. Düşük kemik mineral yoğunluğu olan bireylerde mikrobiyota çeşitliliğinde azalma, bazı faydalı taksonlarda düşüş ve olası disbiyotik örüntüler bildirilmiştir. Ayrıca metabolomik veriler, postmenopozal kadınlarda mikrobiyota ve serum metabolit paternlerinin kemik sağlığı ile ilişkili olabileceğini göstermektedir[15,16,22,52]. Bununla birlikte, insan çalışmalarındaki belirgin heterojenlik önemli bir sınırlılıktır. Katılımcıların yaş dağılımı, menopoz süresi, beslenme alışkanlıkları, fiziksel aktivite düzeyi, ilaç kullanımı, eşlik eden hastalıklar ve coğrafi farklılıklar mikrobiyota kompozisyonunu etkileyebilmektedir; bu nedenle nedensellik yorumları dikkatle yapılmalıdır[26].

Deneysel çalışmalar ise daha tutarlı biçimde mikrobiyota-kemik eksenini desteklemektedir. Özellikle ovariektomi modellerinde probiyotik uygulamaların kemik kaybını azalttığı, bağırsak geçirgenliğini iyileştirdiği ve inflamatuvar yanıtı baskılayabildiği gösterilmiştir. Bu bulgular, mikrobiyotanın östrojen eksikliğine bağlı kemik kaybında yalnızca eşlik eden bir değişken değil, aynı zamanda nedensel bir bileşen olabileceğini düşündürmektedir[5,13,14]. Ancak hayvan modellerinden elde edilen bu olumlu sonuçların insanlara birebir aktarılması her zaman mümkün değildir.

Mikrobiyota hedefli tedaviler içinde en çok dikkat çeken yaklaşım probiyotik ve prebiyotik uygulamalardır. Bazı klinik çalışmalar seçilmiş probiyotik suşların erken postmenopozal dönemde kemik kaybını yavaşlatabileceğini düşündürmektedir[17,18]. Benzer şekilde,

izoflavon ve probiyotik kombinasyonlarının kemik sağlığı ve östrojen metabolizması üzerine olumlu etkileri bildirilmiştir[28]. Prebiyotikler ve fermente olabilir lifler de kısa zincirli yağ asidi üretimini ve kalsiyum emilimini destekleyerek potansiyel yarar sağlayabilir[7,30]. Bununla birlikte bu etkinin tüm probiyotikler için genellenemeyeceği, sonucun suşa, doza, süreye ve hasta özelliklerine göre değiştiği açıktır[19,37]. Bu nedenle mikrobiyota temelli müdahaleler, mevcut aşamada standart osteoporoz tedavisinin yerine geçen uygulamalar olarak değil, destekleyici ve tamamlayıcı stratejiler olarak değerlendirilmelidir.

6. Sonuç

Postmenopozal osteoporozda bağırsak mikrobiyotası, kemik metabolizmasını inflamasyon, bağırsak bariyeri, metabolit üretimi ve hormon dönüşümü üzerinden etkileyen önemli bir düzenleyici olarak görünmektedir. Mevcut veriler; liften zengin beslenme, seçilmiş prebiyotik ve probiyotik uygulamalar ile mikrobiyota dostu yaşam tarzı düzenlemelerinin destekleyici yarar sağlayabileceğini düşündürmektedir. Gelecekte kırık riski, kemik mineral yoğunluğu, inflamasyon belirteçleri ve mikrobiyal metabolitlerin birlikte değerlendirildiği bütüncül çalışmalar, mikrobiyota-kemik ekseninin gerçek klinik değerini daha net ortaya koyacaktır. Mikrobiyota-kemik ekseninin daha iyi anlaşılması, gelecekte PMO'nun önlenmesi ve tedavisinde daha kişiselleştirilmiş yaklaşımların geliştirilmesine katkı sağlayabilir.

REFERANSLAR

1. Compston JE, McClung MR, Leslie WD. Osteoporosis. The Lancet. 2019;393:364–76. https://doi.org/10.1016/S0140-6736(18)32112-3

2. Eastell R, O'Neill TW, Hofbauer LC, Langdahl B, Reid IR, Gold DT, et al. Postmenopausal osteoporosis. Nat Rev Dis Primers. 2016;2:16069. https://doi.org/10.1038/nrdp.2016.69

3. Cauley JA. Estrogen and bone health in men and women. Steroids. 2015;99:11–5. https://doi.org/10.1016/j.steroids.2014.12.010

4. Weitzmann MN. Estrogen deficiency and bone loss: an inflammatory tale. Journal of Clinical Investigation. 2006;116:1186–94. https://doi.org/10.1172/JCI28550

5. Pacifici R. Bone Remodeling and the Microbiome. Cold Spring Harb Perspect Med. 2018;8:a031203. https://doi.org/10.1101/cshperspect.a031203

6. Ohlsson C, Sjögren K. Effects of the gut microbiota on bone mass. Trends in Endocrinology & Metabolism. 2015;26:69–74. https://doi.org/10.1016/j.tem.2014.11.004

7. Koh A, De Vadder F, Kovatcheva-Datchary P, Bäckhed F. From Dietary Fiber to Host Physiology: Short-Chain Fatty Acids as Key Bacterial Metabolites. Cell. 2016;165:1332–45. https://doi.org/10.1016/j.cell.2016.05.041

8. Zaiss MM, Jones RM, Schett G, Pacifici R. The gut-bone axis: how bacterial metabolites bridge the distance. Journal of Clinical Investigation. 2019;129:3018–28. https://doi.org/10.1172/JCI128521

9. Ticinesi A, Nouvenne A, Cerundolo N, Catania P, Prati B, Tana C, et al. Gut Microbiota, Muscle Mass and Function in Aging: A Focus on Physical Frailty and Sarcopenia. Nutrients. 2019;11:1633. https://doi.org/10.3390/nu11071633

10. Hao L, Yan Y, Huang G, Li H. From gut to bone: deciphering the impact of gut microbiota on osteoporosis pathogenesis and management. Front Cell Infect Microbiol. 2024;14:1416739. https://doi.org/10.3389/fcimb.2024.1416739

11. Flores R, Shi J, Fuhrman B, Xu X, Veenstra TD, Gail MH, et al. Fecal microbial determinants of fecal and systemic estrogens and estrogen metabolites: a cross-sectional study. J Transl Med. 2012;10:253. https://doi.org/10.1186/1479-5876-10-253

12. Yaghjyan L, Mai V, Darville LNF, Cline J, Wang X, Ukhanova M, et al. Associations of gut microbiome with endogenous estrogen levels in healthy postmenopausal women. Cancer Causes Control. 2023;34:873–81. https://doi.org/10.1007/s10552-023-01728-5

13. Ohlsson C, Engdahl C, Fåk F, Andersson A, Windahl SH, Farman HH, et al. Probiotics protect mice from ovariectomy-induced cortical bone loss. PLoS One. 2014;9:e92368. https://doi.org/10.1371/journal.pone.0092368

14. Li J-Y, Chassaing B, Tyagi AM, Vaccaro C, Luo T, Adams J, et al. Sex steroid deficiency–associated bone loss is microbiota dependent and prevented by probiotics. Journal of Clinical Investigation. 2016;126:2049–63. https://doi.org/10.1172/JCI86062

15. Das M, Cronin O, Keohane DM, Cormac EM, Nugent H, Nugent M, et al. Gut microbiota alterations associated with reduced bone mineral density in older adults. Rheumatology. 2019;58:2295–304. https://doi.org/10.1093/rheumatology/kez302

16. Wang J, Wang Y, Gao W, Wang B, Zhao H, Zeng Y, et al. Diversity analysis of gut microbiota in osteoporosis and osteopenia patients. PeerJ. 2017;5:e3450. https://doi.org/10.7717/peerj.3450

17. Nilsson AG, Sundh D, Bäckhed F, Lorentzon M. Lactobacillus reuteri reduces bone loss in older women with low bone mineral density: a randomized, placebo-controlled, double-blind, clinical trial. J Intern Med. 2018;284:307–17. https://doi.org/10.1111/joim.12805

18. Gregori G, Pivodic A, Magnusson P, Johansson L, Hjertonsson U, Brättemark E, et al. Limosilactobacillus reuteri 6475 and Prevention of Early Postmenopausal Bone Loss: A Randomized Clinical Trial. JAMA Netw Open. 2024;7:e2415455. https://doi.org/10.1001/jamanetworkopen.2024.15455

19. Wang F, Wei W, Liu PJ. Effects of probiotic supplementation on bone health in postmenopausal women: a systematic review and meta-analysis. Front Endocrinol (Lausanne). 2024;15. https://doi.org/10.3389/fendo.2024.1487998

20. Lucas S, Omata Y, Hofmann J, Böttcher M, Iljazovic A, Sarter K, et al. Short-chain fatty acids regulate systemic bone mass and protect from pathological bone loss. Nat Commun. 2018;9:55. https://doi.org/10.1038/s41467-017-02490-4

21. Wahlström A, Sayin SI, Marschall H-U, Bäckhed F. Intestinal Crosstalk between Bile Acids and Microbiota and Its Impact on Host Metabolism. Cell Metab. 2016;24:41–50. https://doi.org/10.1016/j.cmet.2016.05.005

22. Li S, Mao Y, Zhou F, Yang H, Shi Q, Meng B. Gut microbiome and osteoporosis. Bone Joint Res. 2020;9:524–30. https://doi.org/10.1302/2046-3758.98.BJR-2020-0089.R1

23. Sanidad KZ, Xiao H, Zhang G. Triclosan, a common antimicrobial ingredient, on gut microbiota and gut health. Gut Microbes. 2019;10:434–7. https://doi.org/10.1080/19490976.2018.1546521

24. Ta LDH, Chan JCY, Yap GC, Purbojati RW, Drautz-Moses DI, Koh YM, et al. A compromised developmental trajectory of the infant gut microbiome and metabolome in atopic eczema. Gut Microbes. 2020;12:1801964. https://doi.org/10.1080/19490976.2020.1801964

25. de Sire A, de Sire R, Curci C, Castiglione F, Wahli W. Role of Dietary Supplements and Probiotics in Modulating Microbiota and Bone Health: The Gut-Bone Axis. Cells. 2022;11:743. https://doi.org/10.3390/cells11040743

26. Vujkovic-Cvijin I, Sklar J, Jiang L, Natarajan L, Knight R, Belkaid Y. Host variables confound gut microbiota studies of human disease. Nature. 2020;587:448–54. https://doi.org/10.1038/s41586-020-2881-9

27. Britton RA, Irwin R, Quach D, Schaefer L, Zhang J, Lee T, et al. Probiotic L. reuteri Treatment Prevents Bone Loss in a Menopausal Ovariectomized Mouse Model. J Cell Physiol. 2014;229:1822–30. https://doi.org/10.1002/jcp.24636

28. Lambert MNT, Thybo CB, Lykkeboe S, Rasmussen LM, Frette X, Christensen LP, et al. Combined bioavailable isoflavones and probiotics improve bone status and estrogen metabolism in postmenopausal osteopenic women: a randomized controlled trial. Am J Clin Nutr. 2017;106:909–20. https://doi.org/10.3945/ajcn.117.153353

29. Weaver CM, Martin BR, Nakatsu CH, Armstrong AP, Clavijo A, McCabe LD, et al. Galactooligosaccharides Improve Mineral Absorption and Bone Properties in Growing Rats through Gut Fermentation. J Agric Food Chem. 2011;59:6501–10. https://doi.org/10.1021/jf2009777

30. Whisner CM, Castillo LF. Prebiotics, Bone and Mineral Metabolism. Calcif Tissue Int. 2018;102:443–79. https://doi.org/10.1007/s00223-017-0339-3

31. Afzaal M, Saeed F, Shah YA, Hussain M, Rabail R, Socol CT, et al. Human gut microbiota in health and disease: Unveiling the relationship. Front Microbiol. 2022;13. https://doi.org/10.3389/fmicb.2022.999001

32. Kennedy PJ, Cryan JF, Dinan TG, Clarke G. Kynurenine pathway metabolism and the microbiota-gut-brain axis. Neuropharmacology. 2017;112:399–412. https://doi.org/10.1016/j.neuropharm.2016.07.002

33. Mok S, Chen W, Lai W, Leung P, Wang X, Yao X, et al. Icariin protects against bone loss induced by oestrogen deficiency and activates oestrogen receptor-dependent osteoblastic functions in UMR 106 cells. Br J Pharmacol. 2010;159:939–49. https://doi.org/10.1111/j.1476-5381.2009.00593.x

34. Seely KD, Kotelko CA, Douglas H, Bealer B, Brooks AE. The Human Gut Microbiota: A Key Mediator of Osteoporosis and Osteogenesis. Int J Mol Sci. 2021;22. https://doi.org/10.3390/ijms22179452

35. Sjögren K, Engdahl C, Henning P, Lerner UH, Tremaroli V, Lagerquist MK, et al. The gut microbiota regulates bone mass in mice. Journal of Bone and Mineral Research. 2012;27:1357–67. https://doi.org/10.1002/jbmr.1588

36. Cenit MC, Sanz Y, Codoñer-Franch P. Influence of gut microbiota on neuropsychiatric disorders. World J Gastroenterol. 2017;23:5486–98. https://doi.org/10.3748/wjg.v23.i30.5486

37. Collins FL, Rios-Arce ND, Schepper JD, Parameswaran N, McCabe LR. The Potential of Probiotics as a Therapy for Osteoporosis. Microbiol Spectr. 2017;5. https://doi.org/10.1128/microbiolspec.BAD-0015-2016

38. Pacifici R. The Role of IL-17 and TH17 Cells in the Bone Catabolic Activity of PTH. Front Immunol. 2016;7. https://doi.org/10.3389/fimmu.2016.00057

39. Danhof HA, Lee J, Thapa A, Britton RA, Di Rienzi SC. Microbial stimulation of oxytocin release from the intestinal epithelium via secretin signaling. Gut Microbes. 2023;15:2256043. https://doi.org/10.1080/19490976.2023.2256043

40. Indrio F, Salatto A. Gut Microbiota-Bone Axis. Ann Nutr Metab. 2025;81:47–56. https://doi.org/10.1159/000541999

41. Montalvany-Antonucci CC, Duffles LF, de Arruda JAA, Zicker MC, de Oliveira S, Macari S, et al. Short-chain fatty acids and FFAR2 as suppressors of bone resorption. Bone. 2019;125:112–21. https://doi.org/10.1016/j.bone.2019.05.016

42. Deng X, Lin B, Xiao W, Wang F, Xu P, Wang N. Specnuezhenide Alleviates Senile Osteoporosis by Activating TGR5/FXR Signaling in Bone Marrow Mesenchymal Stem Cells and RANKL-Induced Osteoclasts. Drug Des Devel Ther. 2025;Volume 19:1595–608. https://doi.org/10.2147/DDDT.S493711

43. Gu C, Du H, Li N, Zhou Y, Li S, Sun Y, et al. The gut–bone axis in osteoporosis: a multifaceted interaction with implications for bone health. Front Endocrinol (Lausanne). 2025;16. https://doi.org/10.3389/fendo.2025.1569152

44. Novakovic M, Rout A, Kingsley T, Kirchoff R, Singh A, Verma V, et al. Role of gut microbiota in cardiovascular diseases. World J Cardiol. 2020;12:110–22. https://doi.org/10.4330/wjc.v12.i4.110

45. Lama Tamang R, Juritsch AF, Ahmad R, Salomon JD, Dhawan P, Ramer-Tait AE, et al. The diet-microbiota axis: a key regulator of intestinal permeability in human health and disease. Tissue Barriers. 2023;11. https://doi.org/10.1080/21688370.2022.2077069

46. Jafarnejad S, Djafarian K, Fazeli MR, Yekaninejad MS, Rostamian A, Keshavarz SA. Effects of a Multispecies Probiotic Supplement on Bone Health in Osteopenic Postmenopausal Women: A Randomized, Double-blind, Controlled Trial. J Am Coll Nutr. 2017;36:497–506. https://doi.org/10.1080/07315724.2017.1318724

47. Facchin S, Bertin L, Bonazzi E, Lorenzon G, De Barba C, Barberio B, et al. Short-Chain Fatty Acids and Human Health: From Metabolic Pathways to Current Therapeutic Implications. Life (Basel). 2024;14. https://doi.org/10.3390/life14050559

48. Zhao Y-X, Song Y-W, Zhang L, Zheng F-J, Wang X-M, Zhuang X-H, et al. Association between bile acid metabolism and bone mineral density in postmenopausal women. Clinics. 2020;75:e1486. https://doi.org/10.6061/clinics/2020/e1486

49. Clooney AG, Bernstein CN, Leslie WD, Vagianos K, Sargent M, Laserna-Mendieta EJ, et al. A comparison of the gut microbiome between long-term users and non-users of proton pump inhibitors. Aliment Pharmacol Ther. 2016;43:974–84. https://doi.org/10.1111/apt.13568

50. Chen KL, Madak-Erdogan Z. Estrogen and Microbiota Crosstalk: Should We Pay Attention? Trends Endocrinol Metab. 2016;27:752–5. https://doi.org/10.1016/j.tem.2016.08.001

51. Li Z, Huang J, Wang F, Li W, Wu X, Zhao C, et al. Dual Targeting of Bile Acid Receptor-1 (TGR5) and Farnesoid X Receptor (FXR) Prevents Estrogen-Dependent Bone Loss in Mice. Journal of Bone and Mineral Research. 2019;34:765–76. https://doi.org/10.1002/jbmr.3652

52. Xie X, Song J, Wu Y, Li M, Guo W, Li S, et al. Study on gut microbiota and metabolomics in postmenopausal women. BMC Womens Health. 2024;24:608. https://doi.org/10.1186/s12905-024-03448-7

Yoğun Bakım Ünitelerinde Karar Destek Sistemlerinde Yapay Zekânın Rolü: Anestezist Perspektifi

Muzaffer Şenveli, Dr. Öğr. Üyesi, Bandırma 17 Eylül Üniversitesi Tıp Fakültesi, Anestezi ve Reanimasyon ABD, msenveli@bandirma.edu.tr

Durdu Kahraman Yıldız, Karacabey Devlet Hastanesi, Anesteziyoloji ve Reanimasyon Kliniği,

durdukahraman@gmail.com

Özet

Yapay zekâ (YZ) tabanlı klinik karar destek sistemleri (Clinical Decision Support Systems – CDSS), yoğun bakım ünitelerinde (YBÜ) hasta yönetimini dönüştüren önemli araçlar haline gelmiştir. Bu sistemler; büyük veri analizi, gerçek zamanlı izlem ve öngörücü modelleme sayesinde sepsis, hemodinamik instabilite ve ventilatör yönetimi gibi kritik alanlarda erken uyarı ve karar desteği sağlar. Anestezistler açısından YZ-CDSS, özellikle perioperatif bakım sürekliliği, organ fonksiyonlarının yakın takibi ve hızlı klinik karar alma süreçlerinde önemli avantajlar sunmaktadır. Bununla birlikte veri kalitesi, algoritmik önyargı ve klinik entegrasyon zorlukları gibi sınırlılıklar devam etmektedir. Bu çalışmada YZ destekli CDSS sistemlerinin yoğun bakım uygulamalarındaki rolü ve özellikle anestezist bakış açısından klinik önemi detaylı şekilde ele alınmıştır.

Anahtar Kelimeler: yoğun bakım, karar destek sistemleri, yapay zeka (YZ)

1. Giriş

Yoğun bakım üniteleri (YBÜ), yüksek veri yoğunluğu, hızlı karar gereksinimi ve mortalite riski yüksek hasta grubu ile sağlık sisteminin en kompleks alanlarından biridir. Bu ortamda anestezistler; hemodinamik yönetim, ventilasyon, sedasyon ve organ destek tedavilerinde sürekli ve çok boyutlu kararlar almak zorundadır.

Bu bağlamda yapay zekâ destekli klinik karar destek sistemleri (YZ-CDSS), veri analizi kapasitesi sayesinde klinik karar süreçlerini destekleyen kritik araçlar olarak öne çıkmaktadır [1,2].

2. Yapay Zekâ Destekli Karar Destek Sistemlerinin Temel Fonksiyonları

2.1. Erken Uyarı ve Risk Tahmini

YZ sistemleri, elektronik sağlık kayıtları (EHR), vital bulgular ve laboratuvar verilerini analiz ederek sepsis, akut böbrek hasarı ve solunum yetmezliği gibi durumları klinik ortaya çıkmadan önce öngörebilir [4,5].

Anestezist açısından önemi :
Anestezistler yoğun bakımda çoğu zaman hemodinamik instabilitenin erken fazlarını klinik olarak fark etmekte zorlanılan bir dönemde müdahale etmek zorundadır. YZ tabanlı erken uyarı sistemleri klinik olarak henüz belirginleşmemiş mikro düzey değişimleri saptayarak gizli kötüleşme süreçlerini görünür hale getirir.

Bu durum, özellikle:

- Septik şokun erken evresinde sıvı ve vazopressör tedavisinin zamanında başlanmasını
- AKI gelişmeden önce renal perfüzyonun korunmasını
- Postoperatif hastalarda komplikasyonların preemptif yönetimini

mümkün kılar.

Dolayısıyla bu sistemler, klasik "bulguya dayalı müdahale" yaklaşımından "öngörüye dayalı müdahale" modeline geçişi temsil eder.

2.2. Kişiselleştirilmiş Tedavi ve Doz Optimizasyonu

YZ, hastaya özgü parametreleri analiz ederek sedasyon, analjezi ve hemodinamik tedavilerde bireyselleştirilmiş öneriler sunar [5].

Anestezist açısından önemi:

Yoğun bakım hastalarında farmakokinetik ve farmakodinamik parametreler ciddi değişkenlik gösterir. YZ sistemleri:

• Organ fonksiyonları
• Yaş ve komorbiditeler
• İlaç etkileşimleri
• Hemodinamik durum

gibi çok sayıda değişkeni eş zamanlı değerlendirerek hasta-spesifik doz önerileri oluşturur.

Bu yaklaşım:

• Aşırı sedasyon ve buna bağlı ventilasyon süresinin uzamasını
• Yetersiz analjeziye bağlı stres yanıtını
• Vazopressörlerin gereksiz yüksek doz kullanımını

azaltır.

2.3. Gerçek Zamanlı Klinik İzlem

YZ sistemleri sürekli veri akışını analiz ederek subklinik değişimleri yakalar ve klinik kötüleşmeyi erken tespit eder [6].

Anestezist açısından önemi:

Yoğun bakım pratiğinde anestezist, yüksek frekansta değişen parametreleri sürekli takip etmek zorundadır. Ancak insan bilişsel kapasitesi sınırlıdır. YZ sistemleri:

• Yüksek frekanslı monitörizasyon verilerini analiz ederek
• İnsan gözünün kaçırabileceği trendleri ortaya çıkarır

Bu durum:

• Hemodinamik dalgalanmaların daha erken fark edilmesini
• Alarm yorgunluğunun azalmasını
• Klinik kararların daha objektif verilmesini

sağlar.

2.4. Tanısal Destek

YZ, multimodal veri analizi ile tanı doğruluğunu artırabilir [3].

Anestezist açısından önemi :

Yoğun bakımda tanı çoğu zaman tek bir veriye değil, çoklu veri setlerinin birlikte yorumlanmasına dayanır. YZ sistemleri:

• Klinik veriler arasında ilişki kurarak
• Tanısal belirsizliği azaltır

Örneğin:

• ARDS ile kardiyojenik pulmoner ödem ayrımı
• Sepsis ile non-enfeksiyöz inflamasyon ayrımı
• Zor hava yolu öngörüsü

gibi durumlarda daha yüksek doğruluk sağlar.

2.5. Klinik İş Yükünü Azaltma

YZ sistemleri veri analizi ve dokümantasyonu kolaylaştırır [7].

Anestezist açısından önemi:

Anestezistler yoğun bakımda sadece klinik karar verici değil; aynı zamanda veri yorumlayıcı, süreç yöneticisi ve ekip koordinatörüdür. YZ sistemleri:

• Tekrarlayan görevleri otomatikleştirerek
• Klinik olarak anlamlı veriyi öne çıkararak

anestezistin yüksek değerli klinik kararlara odaklanmasını sağlar.

3. Anestezist Perspektifinden Klinik Katkılar

3.1. Hemodinamik Yönetim → YZ ile hipotansiyon öngörüsü ve sıvı yönetimi optimize edilir [6]
3.2. Ventilasyon → Kişiye özel ventilasyon stratejileri geliştirilir [8]
3.3. Sedasyon → Sedasyon ve analjezi daha hassas yönetilir [5]
3.4. Kritik Olay Yönetimi → Kardiyak arrest ve multiorgan yetmezlik erken öngörülür [4]

4. Sınırlılıklar ve Riskler

4.1. Klinik Validasyon Eksikliği

Yapay zekâ modellerinin büyük bölümü retrospektif veri setlerine dayanmaktadır ve prospektif validasyonları sınırlıdır [10].

4.2. Veri Kalitesi ve Bias Problemleri

Model genellenebilirliğini azaltır ve hatalı önerilere yol açabilir [3,9]

4.3. Açıklanabilirlik Sorunu

Black-box modeller klinik güveni azaltır.

4.4. Mediko-legal ve Etik Sorunlar

Henüz net bir çerçeve oluşmamıştır [9]

5. Sonuç

Yapay zekâ destekli karar destek sistemleri, yoğun bakım pratiğinde paradigma değişimi yaratma potansiyeline sahiptir.

Anestezist açısından:

• Klinik doğruluğu artırır
• Erken müdahaleyi sağlar
• Kişiselleştirilmiş tedavi sunar
• İş yükünü azaltır

Ancak:

• Klinik validasyon eksikliği
• Etik ve hukuki belirsizlikler
• Entegrasyon sorunları

halen önemli sınırlılıklardır [9,10].

Kaynaklar

1. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44–56.

2. Jiang F, Jiang Y, Zhi H, et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol*. 2017;2(4):230–243.

3. Esteva A, Robicquet A, Ramsundar B, et al. A guide to deep learning in healthcare. *Nat Med*. 2019;25(1):24–29.

4. Henry KE, Hager DN, Pronovost PJ, Saria S. A targeted real-time early warning score (TREWS) for septic shock. *Sci Transl Med*. 2015;7(299):299ra122.

5. Nemati S, Holder A, Razmi F, et al. An interpretable machine learning model for early detection of sepsis. *Crit Care Med*. 2018;46(4):547–553.

6. Hatib F, Jian Z, Buddi S, et al. Machine-learning algorithm to predict hypotension. *Anesthesiology*. 2018;129(4):663–674.

7. Shickel B, Tighe PJ, Bihorac A, et al. Deep EHR: a survey of recent advances. *J Biomed Inform*. 2017;76:76–87.

8. Prasad N, Cheng LF, Chivers C, et al. A reinforcement learning approach to ventilator management. *arXiv*. 2017.

9. Wiens J, Saria S, Sendak M, et al. Do no harm: a roadmap for responsible ML. *Nat Med*. 2019;25(9):1337–1340.

10. Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *N Engl J Med*. 2019;380:1347–1358.

Brakial arter kanülasyonunda kanül ucu kopması: Nadir bir komplikasyon

Durdu Kahraman Yıldız, Karacabey Devlet Hastanesi, Anesteziyoloji ve Reanimasyon Kliniği,

durdukahraman@gmail.com

Muzaffer Şenveli, Dr. Öğr. Üyesi, Bandırma 17 Eylül Üniversitesi Tıp Fakültesi, Anestezi ve Reanimasyon ABD, msenveli@bandirma.edu.tr

Özet:

Arteriyel kateterizasyon, yoğun bakım ve ameliyathane pratiğinde invaziv kan basıncı monitörizasyonu ve arteriyel kan gazı analizi için yaygın olarak kullanılan bir yöntemdir. Ancak bu girişim nadir de olsa ciddi komplikasyonlara yol açabilmektedir. Kateter ucunun koparak damar içerisinde kalması, tromboz, emboli ve iskemi gibi hayatı tehdit eden durumlara neden olabilir.

Bu olgu sunumunda, brakial arter kanülasyonu sonrası kateter ucunun koparak arter içerisinde kalması ile gelişen nadir bir komplikasyon sunulmaktadır. Yetmiş yaşında erkek hastada, kanül çekimi sırasında kateter ucunun eksik olduğu fark edilmiş; yapılan ultrasonografide brakial arter içerisinde 3,5 cm uzunluğunda yabancı cisim saptanmıştır. Cerrahi eksplorasyon ile kateter parçası başarıyla çıkarılmıştır.

Bu olgu, arteriyel kateterizasyon sırasında uygun ekipman seçimi ve dikkatli uygulamanın önemini vurgulamakta; kateter çıkarımı sonrası bütünlük kontrolünün hayati rolünü ortaya koymaktadır.

Anahtar Kelimeler:

Brakial arter, Arteriyel kateterizasyon, Yabancı cisim, Komplikasyon

Giriş:

Arteriyel kateterizasyon, kritik hastalarda hemodinamik parametrelerin invaziv izlenmesi ve arteriyel kan gazı analizlerinin tekrarlayan şekilde yapılabilmesi açısından önemli bir klinik uygulamadır (1). Özellikle yoğun bakım ünitelerinde sık kullanılan bu yöntem, hasta yönetiminde büyük kolaylık sağlamaktadır.

Bununla birlikte, bu girişimsel işlem tamamen risksiz değildir. En sık görülen komplikasyonlar arasında enfeksiyon, hematom, arter spazmı ve tromboz yer alırken; daha nadir olarak kateter kırılması ve intravasküler yabancı cisim kalması gibi ciddi komplikasyonlar da bildirilmektedir (2,3). Bu durum zamanında fark edilmezse distal embolizasyon, arteriyel oklüzyon ve iskemiye yol açabilir.

Bu çalışmada, brakial arter kanülasyonu sonrası kateter ucunun koparak damar içerisinde kalmasıyla gelişen nadir bir komplikasyon ve yönetimi sunulmuştur.

Olgu Sunumu:

Yetmiş yaşında erkek hasta, kronik obstrüktif akciğer hastalığı (KOAH) nedeniyle solunum sıkıntısı şikâyetiyle acil servise başvurdu. Venöz kan gazı analizinde pH: 7,19, pCO_2: 101 mmHg, pO_2: 39 mmHg ve satürasyon 65 olarak saptandı. Hasta ağır hiperkapnik solunum yetmezliği nedeniyle yoğun bakım ünitesine yatırıldı.

Sık arteriyel kan gazı takibi ihtiyacı nedeniyle sol brakial artere 18 gauge intraket ile arteriyel kanülasyon uygulandı. İşlem sırasında herhangi bir komplikasyon gelişmedi ve kateter uygun şekilde sabitlendi.İzlemin ikinci gününde kateterden kan geri dönüşü alınamaması üzerine kanül çekildi. Ancak kateter çıkarıldığında distal ucunun eksik olduğu

fark edildi. İntravasküler yabancı cisim şüphesi ile uzun kemik grafileri çekildi, ancak kateter görüntülenemedi.Kalp ve damar cerrahisi konsültasyonu sonrası yapılan ultrasonografide sol kübital bölgede brakial arter içerisinde yaklaşık 3,5 cm uzunluğunda yabancı cisim saptandı. Hasta ameliyathaneye alınarak brakial arter üzerine yaklaşık 5 cm'lik insizyon ile cerrahi eksplorasyon yapıldı. Kateter parçası başarıyla çıkarıldı ve dren yerleştirilerek operasyon sonlandırıldı. Postoperatif dönemde komplikasyon gelişmedi.

Tartışma:

Arteriyel kateterizasyon, klinik pratikte yaygın olarak kullanılan güvenilir bir yöntem olmakla birlikte nadir görülen komplikasyonlar ciddi sonuçlara yol açabilir. Kateter kırılması ve embolizasyonu bu komplikasyonlar arasında yer almakta olup genellikle teknik faktörler ve uygunsuz ekipman kullanımı ile ilişkilidir (1–3). Venöz girişimler için tasarlanmış kateterlerin arteriyel sistemde kullanılması, yüksek basınç nedeniyle kateter yapısında zayıflamaya ve kopmaya neden olabilir. Ayrıca uzun süreli kullanım, tekrarlayan manipülasyonlar ve yetersiz sabitleme de risk faktörleri arasındadır.

Tanı sürecinde kateterin çıkarılması sırasında bütünlüğünün kontrol edilmesi kritik öneme sahiptir. Radyopak olmayan materyallerde direkt grafiler yetersiz kalabileceğinden ultrasonografi gibi görüntüleme yöntemleri tercih edilmelidir. Tedavide yabancı cismin lokalizasyonuna bağlı olarak endovasküler veya cerrahi yöntemler uygulanabilir. Bu olguda cerrahi eksplorasyon ile başarılı sonuç elde edilmiştir.

Sonuç olarak, arteriyel kateterizasyon sırasında uygun kateter seçimi, dikkatli uygulama ve kateter çıkarımı sonrası bütünlük kontrolü, bu tür ciddi komplikasyonların önlenmesinde temel unsurlardır.

Sonuç:

Arteriyel kateterizasyon sırasında nadir de olsa kateter kırılması gibi ciddi komplikasyonlar gelişebilir. Bu nedenle işlem sırasında uygun ekipman seçimi, dikkatli uygulama ve kateter çıkarımı sonrası bütünlük kontrolü büyük önem taşımaktadır. Erken tanı ve hızlı müdahale, olası morbidite ve mortalitenin önlenmesinde kritik rol oynar.

KAYNAKLAR:

1. Byskosh A, Olsen K. Retained arterial catheter following patient self-discontinuation-a case report. J Surg Case Rep. 2024 Jan 16;2024(1):rjad727. doi: 10.1093/jscr/rjad727. PMID: 38239372; PMCID: PMC10795922.

2. Luo C-F, Mao CC, Su BC, Yu HP. An iatrogenic complication of radial artery cannulation. Acta Anaesthesiol Taiwan 2010;48:145–7.

3. Moody C, Bhimarasetty C, Deshmukh S. Ultrasound guided location and removal of retained arterial cannula fragment. Anaesthesia 2009;64:338–9.





RESİM 1: KATATER UCU AYRILMIŞ OLAN İNTRAKET

RESİM 2: OPERASYON BÖLGESİNİN GÖRÜNTÜSÜ

Eş zamanlı ön çapraz bağ rekonstrüksiyonu menisküs onarımının klinik sonuçlarını ve başarısızlık oranlarını etkiliyor mu?

Tunahan Aka

Bandırma Eğitim ve Araştırma Hastanesi Ortopedi ve Travmatoloji Kliniği, Balıkesir, Türkiye

Amaç:
Menisküs tamirinin izole olarak yapılması ile eş zamanlı ön çapraz bağ rekonstrüksiyonu (ÖÇB-R) ile birlikte yapılması arasındaki iyileşme oranları hâlen tartışma konusudur. Bu çalışmanın amacı, izole menisküs tamiri ile eş zamanlı ÖÇB rekonstrüksiyonu yapılan olgularda başarısızlık oranlarını karşılaştırmaktır.

Yöntemler:
Bu retrospektif analiz, artroskopik menisküs tamiri uygulanan 40 yaş altındaki 59 hastayı kapsamaktadır. Otuz hastada inside-out teknik, 29 hastada ise all-inside tamir tekniği kullanılmıştır. Otuz iki hastaya izole menisküs tamiri uygulanırken, 27 hastaya eş zamanlı ön çapraz bağ rekonstrüksiyonu yapılmıştır. Hastalar postoperatif 1., 3. ve 6. aylarda ve sonrasında en az 2 yıl süreyle 6 aylık aralıklarla takip edilmiştir.

Bulgular:
İzole ve eş zamanlı ÖÇB rekonstrüksiyonu uygulanan hastalar arasında yırtık tipi, yırtık uzunluğu ve etkilenen menisküs açısından istatistiksel olarak anlamlı fark saptanmamıştır. Yırtık zonu dağılımı izole grupta zon 2 lehine daha yüksek olmakla birlikte, bu fark istatistiksel anlamlılığa ulaşmamıştır ($p=0,095$). Preoperatif Lachman testi pozitifliği, eş zamanlı ÖÇB rekonstrüksiyonu uygulanan hastalarda anlamlı derecede daha yüksektir ($p<0,001$). Fonksiyonel skorlar değerlendirildiğinde, preoperatif ($p=0,006$) ve postoperatif ($p=0,032$) Tegner aktivite skorları eş zamanlı ÖÇB rekonstrüksiyonu grubunda anlamlı derecede daha yüksek bulunmuştur. Klinik başarısızlığın bir göstergesi olan revizyon cerrahisi oranı izole menisküs tamiri uygulanan hastalarda daha yüksek olmakla birlikte, bu fark istatistiksel anlamlılığa ulaşmamıştır ($p=0,060$).

Sonuç:
Bu çalışma, menisküs tamirinin ÖÇB rekonstrüksiyonundan bağımsız olarak yüksek klinik etkinliğe sahip olduğunu; ancak ÖÇB rekonstrüksiyonunun biyolojik ve mekanik avantajları nedeniyle bazı klinik parametrelerde daha olumlu eğilimler gösterebileceğini ortaya koymuştur.

Anahtar Kelimeler: *Ön Çapraz Bağ (ÖÇB), Menisküs Yaralanması, Onarım Tekniği*

Not: Yazarlar sunumun tam metinini göndermediği için özet metinleri basılmıştır.

OSTEOPOROTİK VERTEBRA KOMPRESYON KIRIKLARINDA VERTEBROPLASTİ VE KİFOPLASTİNİN KLİNİK VE RADYOLOJİK SONUÇLARININ KARŞILAŞTIRILMASI

Uğur Özdemir

Bandırma Onyedi Eylül Üniversitesi Ortopedi ve Travmatoloji AD, Balıkesir, Türkiye

Giriş

Osteoporotik vertebra kompresyon kırıkları (OVCF), özellikle ileri yaş popülasyonda ağrı, fonksiyon kaybı ve yaşam kalitesinde azalma ile seyreden önemli bir klinik sorundur. Bu çalışmada, osteoporotik vertebra kompresyon kırıklarının tedavisinde vertebroplasti ve kifoplastinin klinik ve radyolojik sonuçlarının karşılaştırılması amaçlandı.

Gereç ve Yöntem

Bu retrospektif çalışmaya Haziran 2023 – Ocak 2026 tarihleri arasında osteoporotik vertebra kompresyon kırığı nedeniyle vertebroplasti veya kifoplasti uygulanan 92 hasta dahil edildi. Tüm hastalar için yaş, cinsiyet, kullanılan teknik, takip süresi ve komplikasyon gibi veriler kaydedildi. Klinik değerlendirmede preoperatif ve postoperatif dönemde Visual Analog Scale (VAS), Oswestry Disability Index (ODI) ve EQ-5D skorları değerlendirildi. Radyolojik değerlendirmede lokal kifotik açı, anterior ve posterior vertebra korpus yüksekliği ile yükseklik restorasyon oranı ölçüldü. Radyolojik ölçümler preoperatif ve postoperatif dönemde çekilen Bilgisayarlı Tomografi (BT) üzerinden yapıldı. Hastalar uygulanan cerrahi yönteme göre iki gruba ayrıldı. Klinik ve radyolojik veriler iki grup arasında karşılaştırıldı.

Bulgular

Çalışmaya toplam 92 hasta dahil edildi ve hastalar vertebroplasti (n=46) ve kifoplasti (n=46) olmak üzere iki gruba ayrıldı. Gruplar arasında yaş (71.2 ± 7.8 vs. 72.5 ± 8.1 yıl; p=0.421) ve cinsiyet dağılımı açısından anlamlı fark saptanmadı (p=0.812). Takip süresi açısından gruplar arasında anlamlı fark bulunmadı (19.1 ± 5.9 ay vs. 18.2 ± 6.3 ay; p=0.487).

Her iki grupta da klinik skorlar açısından anlamlı iyileşme gözlendi. Vertebroplasti grubunda VAS skoru 6.3 ± 1.1'den 2.5 ± 0.9'a, kifoplasti grubunda ise 6.6 ± 1.0'dan 2.2 ± 0.8'e geriledi ve gruplar arasında postoperatif VAS skorları açısından anlamlı fark bulunmadı (p=0.118). Benzer şekilde ODI skorları vertebroplasti grubunda 68.4 ± 9.6'dan 32.1 ± 8.3'e, kifoplasti grubunda 69.7 ± 10.2'den 29.5 ± 7.9'a geriledi (p=0.094). EQ-5D skorları ise vertebroplasti grubunda 0.41 ± 0.09'dan 0.71 ± 0.08'e, kifoplasti grubunda 0.39 ± 0.08'den 0.74 ± 0.07'ye yükseldi ve gruplar arasında anlamlı fark saptanmadı (p=0.076).

Radyolojik değerlendirmede kifoplasti grubunda daha belirgin düzelme izlendi. Lokal kifotik açı vertebroplasti grubunda 14.2 ± 4.3°'den 11.8 ± 3.9°'ye, kifoplasti grubunda ise 15.1 ± 4.6°'den 9.2 ± 3.5°'ye geriledi ve postoperatif değerler kifoplasti lehine anlamlı bulundu (p=0.012). Anterior vertebra yüksekliği vertebroplasti grubunda 17.5 ± 3.2 mm'den 20.3 ± 3.1 mm'ye, kifoplasti grubunda 16.9 ± 3.4 mm'den 23.8 ± 3.6 mm'ye yükseldi ve kifoplasti grubunda anlamlı olarak daha yüksek bulundu (p=0.004). Posterior vertebra yüksekliği açısından gruplar arasında anlamlı fark saptanmadı (25.2 ± 2.7 mm vs. 26.1 ± 2.6 mm; p=0.067). Yükseklik restorasyon oranı kifoplasti grubunda (%29.4 ± 7.2) vertebroplasti grubuna (%18.7 ± 6.5) kıyasla anlamlı olarak daha yüksekti (p<0.001).

Komplikasyonlar değerlendirildiğinde çimento kaçağı vertebroplasti grubunda %17.4, kifoplasti grubunda %8.7 oranında izlenmiş olup fark istatistiksel olarak anlamlı bulundu

(p=0.041). Yeni vertebra kırığı gelişimi açısından ise gruplar arasında anlamlı fark saptanmadı (%13.0 vs. %10.9; p=0.754).

Sonuç

Vertebroplasti ve kifoplasti, osteoporotik vertebra kompresyon kırıklarının tedavisinde her ikisi de etkili yöntemler olup benzer düzeyde klinik iyileşme sağlamaktadır. Bununla birlikte kifoplasti, vertebra yüksekliği restorasyonu ve kifotik deformitenin düzeltilmesi açısından vertebroplastiye kıyasla anlamlı üstünlük göstermektedir. Ayrıca çimento kaçağı oranının kifoplasti grubunda daha düşük olması, bu yöntemin güvenlik profili açısından avantajlı olabileceğini düşündürmektedir. Ancak her iki yöntem arasında yeni vertebra kırığı gelişimi açısından anlamlı fark bulunmamıştır. Bu bulgular doğrultusunda, kifoplasti özellikle radyolojik düzelmenin ön planda olduğu olgularda tercih edilebilirken, her iki yöntemin de uygun hasta seçimi ile etkin ve güvenli bir şekilde uygulanabileceği düşünülmektedir.

Anahtar Kelimeler

Vertebroplasti, kifoplasti, osteoporotik vertebra kompresyon kırığı

Not: Yazarlar sunumun tam metinini göndermediği için özet metinleri basılmıştır.

Hidroklorotiyazid başlanmasını izleyen ağır semptomatik hipotonik hiponatremi: yoğun bakımda yönetilen yaşlı kadın olgu

Dr. Öğr. Üyesi Muammer Hayri BEKTAŞ

Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Anesteziyoloji ve Reanimasyon Anabilim Dalı, Balıkesir, Türkiye E-posta: mbektas@bandirma.edu.tr ORCID: 0009-0009-7577-9171

Özet

Tiyazid grubu diüretikler hipertansiyon tedavisinde yaygın kullanılmasına karşın, ileri yaşta yaşamı tehdit eden hipotonik hiponatremiye yol açabilir. Bu olgu sunumunda hidroklorotiyazid başlanmasını izleyen ikinci haftada halsizlik, sersemlik, yürümede dengesizlik ve konfüzyon ile acil servise başvuran 74 yaşındaki kadın hasta sunuldu. Başvuruda serum sodyumu 113 mmol/L, potasyumu 3.0 mmol/L idi; düşük serum ozmolalitesi ve uygunsuz natriürez hipotonik hiponatremiyi destekledi. Glukoz, böbrek fonksiyonları ve kraniyal görüntüleme alternatif akut nedenleri düşündürmedi. Hidroklorotiyazid kesildi; kontrollü hipertonik salin, potasyum replasmanı ve yakın yoğun bakım izlemi uygulandı. İlk 24 saatte bilinç bulanıklığı geriledi, ikinci günde yürüme ve oral alım düzeldi, dördüncü günde hasta taburcu edildi. Yaşlı hastada yeni başlayan konfüzyonda ilaç ilişkili elektrolit bozukluğu erken düşünülmelidir.

Anahtar kelimeler: tiyazid ilişkili hiponatremi; hidroklorotiyazid; semptomatik hiponatremi; yoğun bakım; yaşlı hasta

Giriş

Hiponatremi, serum sodyum düzeyinin 135 mmol/L altında olmasıyla tanımlanan ve klinik pratikte en sık karşılaşılan sıvı-elektrolit bozukluklarından biridir. Klinik tablo hafif halsizlik ve sersemlikten, bilinç değişikliği, nöbet, koma ve yaşamı tehdit eden beyin ödemine kadar değişebilir. Bu nedenle acil servis ve yoğun bakım pratiğinde hiponatreminin yalnızca laboratuvar anormalliği olarak değil, nörolojik kötüleşme ile sonuçlanabilecek dinamik bir klinik sendrom olarak değerlendirilmesi gerekir (Spasovski et al., 2014).

Tiyazid grubu diüretikler hipertansiyon tedavisinde uzun yıllardır kullanılan etkili ilaçlardır; ancak duyarlı hastalarda hipotonik hiponatremi gelişimine neden olabilir. İleri yaş, kadın cinsiyet, düşük vücut/solüt alımı, fazla serbest su tüketimi, eşlik eden hipokalemi ve tedavinin yeni başlanmış olması tiyazid ilişkili hiponatremi riskini artıran başlıca etkenlerdir (Filippone, Ruzieh, & Foy, 2020; Liamis, Filippatos, & Elisaf, 2016). Özellikle yaşlı hastalarda bulgular enfeksiyon, serebrovasküler olay, düşme riski veya genel durum bozukluğu gibi daha sık düşünülen tablolarla maskelenebilir.

Bu olgu sunumunun amacı, hidroklorotiyazid başlanmasından kısa süre sonra ağır semptomatik hipotonik hiponatremi gelişen yaşlı bir kadın hastada tanısal ipuçlarını, ayırıcı tanı sürecini ve yoğun bakımda güvenli düzeltme yaklaşımını klinik pratiğe uygulanabilir biçimde sunmaktır. Olgu, hasta kimliği gizlenerek ve olgu sunumlarının bütünlüğünü artıran CARE raporlama yaklaşımının temel ilkeleri gözetilerek hazırlanmıştır (Gagnier et al., 2014).

Olgu

Yetmiş dört yaşında kadın hasta, üç gündür giderek artan halsizlik, sersemlik hissi, yürümede dengesizlik ve başvuru günü belirginleşen dalgınlık nedeniyle acil servise getirildi. Özgeçmişinde hipertansiyon ve diz osteoartriti vardı. Aile öyküsünden, kan basıncı kontrolü amacıyla yaklaşık 14 gün önce hidroklorotiyazid başlandığı öğrenildi. Son günlerde

havaların sıcak olması nedeniyle su tüketiminin arttığı, buna karşın iştahının azaldığı ve solüt alımının düştüğü ifade edildi.

Başvuru değerlendirmesinde ateş yoktu. Kan basıncı 135/75 mmHg, nabız 82/dk idi. Belirgin periferik ödem, akciğer oskültasyonunda konjesyon veya ağır dehidratasyon bulgusu saptanmadı. Nörolojik muayenede yer ve zamanı karıştırdığı, basit komutlara yavaş yanıt verdiği ve dikkatini sürdürmekte zorlandığı gözlendi. Klinik görünüm ilk bakışta enfeksiyon, serebrovasküler olay veya yaşlı hastada genel durum bozukluğu ile uyumlu gibi görünse de yeni başlanan tiyazid öyküsü ayırıcı tanının yönünü değiştirdi.

Laboratuvar incelemesinde serum sodyumu 113 mmol/L ve potasyumu 3.0 mmol/L bulundu. Serum ozmolalitesinin düşük olması gerçek hipotonik hiponatremiyi destekledi. İdrar sodyumu ve idrar ozmolalitesinin beklenenden yüksek olması, serbest su atılımında bozulma ve uygunsuz natriürez ile uyumlu değerlendirildi. Kan glukozunun normal olması hiperglisemiye bağlı hipertonik hiponatremiyi düşündürmedi. Böbrek fonksiyonlarının korunmuş olması ve kraniyal bilgisayarlı tomografide akut patoloji izlenmemesi, klinik tabloyu açıklayabilecek ek akut nedenleri geri plana itti.

Tablo 1. Klinik zaman çizelgesi

Zaman	Klinik olay
Gün -14	Kan basıncı kontrolü amacıyla hidroklorotiyazid başlandı.
Gün -3	Halsizlik, sersemlik ve yürümede dengesizlik başladı.
Gün 0	Dalgınlık nedeniyle acil servise başvurdu; Na+ 113 mmol/L, K+ 3.0 mmol/L saptandı.
Gün 0	Hidroklorotiyazid kesildi; kontrollü hipertonik salin, potasyum replasmanı ve yoğun bakım izlemi başlandı.
İlk 24 saat	Serum sodyumu güvenli sınırlar içinde yükseldi; bilinç bulanıklığı belirgin geriledi.
2. gün	Yürüme ve oral alım düzeldi.
4. gün	Alternatif antihipertansif tedavi düzenlenerek taburcu edildi.

Not. Na+: sodyum; K+: potasyum.

Mevcut bulgular birlikte değerlendirildiğinde hidroklorotiyazid ilişkili semptomatik ağır hipotonik hiponatremi tanısı konuldu. Tedavide ilk adım olarak hidroklorotiyazid kesildi. Nörolojik semptomların varlığı nedeniyle kontrollü hipertonik salin uygulandı; eşlik eden hipokalemi için potasyum replasmanı yapıldı. Aşırı hızlı sodyum düzeltmesinden kaçınmak amacıyla hasta yoğun bakım ünitesinde yakın klinik izlem, seri elektrolit ölçümleri ve idrar çıkışı takibi ile yönetildi.

İlk 24 saat içinde bilinç bulanıklığı belirgin azaldı ve hasta komutlara daha uygun yanıt vermeye başladı. İkinci günde yürüme ve oral alım düzeldi. Klinik ve laboratuvar izlemi stabil seyreden hasta, dördüncü günde tiyazid yeniden başlanmaması konusunda hasta ve yakınları bilgilendirilerek, alternatif antihipertansif tedavi düzenlenmesi sonrası taburcu edildi.

Tablo 2. Tanısal değerlendirme ve klinik yorum

Bulgular	Klinik yorum
Serum Na+ 113 mmol/L	Nörolojik semptomlarla birlikte ağır semptomatik hiponatremi.
Serum K+ 3.0 mmol/L	Tiyazid kullanımıyla uyumlu hipokalemi; güvenli düzeltme açısından dikkat gerektirir.
Düşük serum ozmolalitesi	Gerçek hipotonik hiponatremi lehine.
Beklenenden yüksek idrar Na+ ve idrar ozmolalitesi	Uygunsuz natriürez ve serbest su atılımında bozulma ile uyumlu.
Normal glukoz	Hiperglisemiye bağlı hipertonik hiponatremi düşünülmedi.
Normal böbrek fonksiyonları ve akut patoloji göstermeyen kraniyal BT	Ek renal veya akut intrakraniyal nedenler geri planda.

Not. BT: bilgisayarlı tomografi; Na+: sodyum; K+: potasyum.

Tartışma

Bu olgunun temel öğretici yönü, ağır hiponatreminin yaşlı bir hastada nöbet veya koma olmadan, yalnızca halsizlik, sersemlik, dengesizlik ve konfüzyon gibi nonspesifik bulgularla ortaya çıkabilmesidir. Bu belirtiler acil serviste sık görülen enfeksiyon, inme veya genel durum bozukluğu başlıkları altında değerlendirildiğinde elektrolit bozukluğu tanısı gecikebilir. Bu nedenle yaşlı hastada akut bilişsel değişiklik, yürüme bozukluğu veya açıklanamayan halsizlik varlığında ilaç öyküsü ve elektrolit paneli erken aşamada birlikte değerlendirilmelidir.

Tiyazidler distal tübülde sodyum-klorür kotransportunu inhibe ederek natriürezi artırır. Duyarlı bireylerde distal seyreltme kapasitesinin azalması, potasyum kaybı, düşük solüt alımı ve fazla serbest su tüketimi ile birlikte hipotonik hiponatremi gelişebilir. Hidroklorotiyazid başlanmasını izleyen ilk haftalar yüksek riskli dönem olarak kabul edilir; ancak tiyazid ilişkili hiponatremi tedavinin daha geç dönemlerinde de ortaya çıkabilir (Hwang & Kim, 2010; Liamis et al., 2016). Olgumuzda ileri yaş, kadın cinsiyet, yeni başlanmış hidroklorotiyazid, sıcak havada artmış su alımı, iştah azalmasına bağlı düşük solüt alımı ve hipokalemi aynı anda bulunması, klinik tabloyu açıklayan güçlü bir nedensel zemin oluşturmuştur.

Tanısal yaklaşımda hiponatreminin tonisitesinin belirlenmesi kritik ilk basamaktır. Düşük serum ozmolalitesi olgunun gerçek hipotonik hiponatremi olduğunu göstermiştir. İdrar sodyumu ve idrar ozmolalitesinin beklenenden yüksek olması, tiyazid ilişkili olgularda görülebilen natriürez ve su atılım kusurunu desteklemiştir. Normal glukoz, korunmuş böbrek fonksiyonları ve akut patoloji göstermeyen kraniyal görüntüleme, alternatif akut nedenleri geri plana itmiştir. Bununla birlikte, benzer hastalarda klinik bağlama göre adrenal ve tiroid fonksiyonlarının da gözden geçirilmesi ayırıcı tanının tamamlanmasına katkı sağlar.

Tedavide ana hedef sodyum değerini hızla normale döndürmek değildir. Amaç, beyin ödemi ve nörolojik semptomları güvenli biçimde geriletirken ozmotik demiyelinizasyon sendromu riskini artırabilecek aşırı hızlı düzeltmeden kaçınmaktır. Avrupa kılavuzunda semptomatik hiponatremide 3% hipertonik salinin dikkatli kullanımı, serum sodyumunun ilk 24 saatte 10 mmol/L'den, sonraki her 24 saatte 8 mmol/L'den fazla artırılmaması ve erken dönemde seri sodyum kontrolleri önerilmektedir (Spasovski et al., 2014). Hipertonik salin uygulanan hastalarda hedef aşımı gerçek yaşam verilerinde önemli bir sorun olduğundan,

yoğun bakımda yakın izlem tedavinin güvenliği açısından belirleyicidir (Arshad et al., 2022; Rondon-Berrios & Sterns, 2022).

Hipokalemi varlığı yönetimi daha hassas hale getirir; çünkü potasyum replasmanı serum sodyum düzeltmesini dolaylı olarak etkileyebilir ve hipokalemi ozmotik demiyelinizasyon açısından ek risk oluşturabilir. Bu nedenle bu hastada potasyum replasmanı, hipertonik salin uygulaması, sık elektrolit kontrolü ve idrar çıkışı takibi birlikte yürütülmüştür. Sorumlu ilacın kesilmesi tedavinin zorunlu ilk adımıdır; iyileşme sonrasında aynı hastada tiyazid yeniden başlanmamalı, antihipertansif tedavi bireysel riskler gözetilerek yeniden düzenlenmelidir (Filippone et al., 2020).

Sonuç olarak, yaşlı hastada yeni başlayan konfüzyon ve dengesizlik her zaman enfeksiyon veya inme anlamına gelmez. Yeni başlanmış ya da dozu artırılmış bir tiyazid, ağır nörolojik acilin ardındaki basit fakat kritik ipucu olabilir. Bu olgu; ayrıntılı ilaç öyküsü, erken elektrolit değerlendirmesi, sorumlu ilacın kesilmesi, kontrollü hipertonik salin, potasyum replasmanı ve yakın yoğun bakım izleminin semptomatik ağır hipotonik hiponatremide güvenli klinik iyileşme sağlayabileceğini göstermektedir.

Kaynakça

Arshad, M. F., Iqbal, A., Weeks, J., Fonseca, I., Munir, A., & Bennet, W. (2022). Hypertonic saline for severe symptomatic hyponatraemia: Real-world findings from the UK. Endocrine Connections, 11(5), e220007. doi:10.1530/EC-22-0007

Filippone, E. J., Ruzieh, M., & Foy, A. (2020). Thiazide-associated hyponatremia: Clinical manifestations and pathophysiology. American Journal of Kidney Diseases, 75(2), 256-264. doi:10.1053/j.ajkd.2019.07.011

Gagnier, J. J., Kienle, G., Altman, D. G., Moher, D., Sox, H., Riley, D., & CARE Group. (2014). The CARE guidelines: Consensus-based clinical case reporting guideline development. Journal of Clinical Epidemiology, 67(1), 46-51. doi:10.1016/j.jclinepi.2013.08.003

Hwang, K. S., & Kim, G. H. (2010). Thiazide-induced hyponatremia. Electrolyte & Blood Pressure, 8(1), 51-57. doi:10.5049/EBP.2010.8.1.51

Liamis, G., Filippatos, T. D., & Elisaf, M. S. (2016). Thiazide-associated hyponatremia in the elderly: What the clinician needs to know. Journal of Geriatric Cardiology, 13(2), 175-182. doi:10.11909/j.issn.1671-5411.2016.02.001

Rondon-Berrios, H., & Sterns, R. H. (2022). Hypertonic saline for hyponatremia: Meeting goals and avoiding harm. American Journal of Kidney Diseases, 79(6), 890-896. doi:10.1053/j.ajkd.2021.07.020

Spasovski, G., Vanholder, R., Allolio, B., Annane, D., Ball, S., Bichet, D., ... Nagler, E. (2014). Clinical practice guideline on diagnosis and treatment of hyponatraemia. European Journal of Endocrinology, 170(3), G1-G47. doi:10.1530/EJE-13-1020

Empagliflozin kullanan tip 2 diyabetli hastada üriner sistem enfeksiyonu ve azalmış oral alım sonrası gelişen öglisemik diyabetik ketoasidoz: olgu sunumu

Vildan Çoban Kılınç[1], **Kadir Kabahasanoğlu**[2]

[1] Uzm. Dr., Bandırma Eğitim ve Araştırma Hastanesi, Yoğun Bakım, Balıkesir, Türkiye, wildone_bn@hotmail.com, ORCID: 0009-0005-5975-2965

[2] Dr. Öğr. Üyesi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi Anesteziyoloji ve Reanimasyon Anabilim Dalı, Balıkesir, Türkiye, k.kabahasanoglu@bandirma.edu.tr, ORCID: 0009-0002-9045-5123

Özet

Sodyum-glukoz kotransporter-2 (SGLT2) inhibitörleri tip 2 diyabet tedavisinde kardiyorenal yararlar sağlayan ajanlar olmakla birlikte, normoglisemiye yakın kan glukozu ile seyreden öglisemik diyabetik ketoasidoza (eDKA) neden olabilir. Bu olgu sunumunda, empagliflozin kullanan ve üriner sistem enfeksiyonu ile azalmış oral alım sonrası ağır anyon açıklıklı metabolik asidoz gelişen 64 yaşındaki kadın hasta sunulmaktadır. Başvuruda kan glukozu 178 mg/dL iken arteriyel kan gazında pH 7.12, HCO3- 8.5 mmol/L ve anyon açıklığı 28 mmol/L saptandı; idrarda 3+ keton pozitifliği mevcuttu. Serum beta-hidroksibütirat ölçümü yapılamadığından klinik bağlam, SGLT2 inhibitörü öyküsü, ketonüri ve asit-baz bulguları birlikte değerlendirilerek eDKA tanısı konuldu. Empagliflozin kesildi; sıvı, dekstroz eşliğinde intravenöz insülin ve antibiyotik tedavisiyle 48 saat içinde asidoz düzeldi.

Anahtar kelimeler: öglisemik diyabetik ketoasidoz, SGLT2 inhibitörleri, empagliflozin, üriner sistem enfeksiyonu, yoğun bakım

Giriş

Sodyum-glukoz kotransporter-2 (SGLT2) inhibitörleri, proksimal renal tübülde glukoz geri emilimini azaltarak glukozüri oluşturan ve tip 2 diyabet tedavisinde yaygın kullanılan ajanlardır. Kardiyovasküler ve renal yararları nedeniyle kullanım alanları genişlemiş olsa da, bu ilaç sınıfı nadir fakat yaşamı tehdit edebilen öglisemik diyabetik ketoasidoz (eDKA) ile ilişkilidir. Klasik diyabetik ketoasidozda belirgin hiperglisemi beklenirken, eDKA'da kan glukozu normal sınırlarda veya yalnızca hafif yüksek olabilir; bu nedenle tanı, yalnız glukoz değerine bakıldığında kolayca gecikebilir (Peters et al., 2015; Rosenstock & Ferrannini, 2015).

eDKA gelişiminde relatif insülin eksikliği, glukagon artışı, glukozürinin sürmesi, ketogenez ve volüm kaybı bir araya gelir. Enfeksiyon, açlık, kusma, dehidratasyon, cerrahi stres, alkol kullanımı ve düşük karbonhidrat alımı gibi durumlar tabloyu tetikleyebilir (Dhatariya et al., 2020; Taylor, Blau, & Rother, 2015). Bu nedenle acil servis ve yoğun bakım pratiğinde, SGLT2 inhibitörü kullanan hastada açıklanamayan takipne, bulantı-kusma, halsizlik veya yüksek anyon açıklıklı metabolik asidoz saptandığında, kan glukozu 250 mg/dL'nin altında olsa bile eDKA ayırıcı tanıda öncelikli olarak düşünülmelidir.

Olgu sunumları, nadir veya tanısal açıdan yanıltıcı klinik durumların erken tanınmasını destekleyen önemli eğitim araçlarıdır. Bu olgu, CARE olgu sunumu raporlama ilkelerinin şeffaf ve sistematik anlatım yaklaşımı dikkate alınarak hazırlanmıştır (Gagnier et al., 2014). Bu çalışmanın amacı, empagliflozin kullanan tip 2 diyabetli bir hastada üriner sistem enfeksiyonu ve azalmış oral alım sonrası gelişen eDKA tablosunu sunmak; kan beta-hidroksibütirat ölçümü yapılamayan koşullarda klinik öykü, asit-baz analizi, anyon açıklığı ve idrar ketonu birlikteliğinin tanısal değerini tartışmaktır.

Olgu

Altmış dört yaşında, bilinen tip 2 diyabet ve hipertansiyon tanıları bulunan kadın hasta, acil servise üç gündür devam eden halsizlik, bulantı, kusma, iştahsızlık, idrarda yanma, ateş ve artan nefes darlığı yakınmalarıyla başvurdu. İlaç öyküsünde empagliflozin, metformin ve amlodipin kullandığı öğrenildi. Hastanın son üç gündür oral gıda alımı belirgin azalmış olmasına rağmen oral antidiyabetik ilaçlarını almaya devam ettiği ifade edildi. Bu öykü, enfeksiyon ve karbonhidrat alımındaki azalma ile birlikte eDKA açısından kritik bir tetikleyici olarak değerlendirildi.

Başvuru muayenesinde bilinci açıktı ancak genel durumu orta-kötüydü ve letarjik görünümdeydi. Kan basıncı 95/60 mmHg, nabız 112/dk, vücut sıcaklığı 38.1°C ve oda havasında periferik oksijen satürasyonu %96 idi. Solunum sayısı 28/dk olarak ölçüldü ve derin, hızlı solunum paterni Kussmaul solunumunu düşündürdü. Batın muayenesinde suprapubik hassasiyet mevcuttu. Klinik tablo ilk bakışta üriner sistem enfeksiyonu ve sepsis ön tanılarını akla getirmekle birlikte, normoglisemiye yakın kan glukozuna eşlik eden belirgin takipne ve asidotik solunum metabolik acil yönünden uyarıcıydı.

Laboratuvar incelemelerinde kan glukozu 178 mg/dL olarak saptandı. Arteriyel kan gazında pH 7.12, pCO2 23 mmHg ve HCO3- 8.5 mmol/L ölçüldü. Serum sodyumu 134 mmol/L, potasyumu 4.8 mmol/L ve klorürü 97 mmol/L idi; hesaplanan serum anyon açıklığı 28 mmol/L ile belirgin yüksek bulundu. Laktat düzeyinin 1.7 mmol/L olması, asidozun temel nedeni olarak laktik asidozu desteklemiyordu. Tam idrar tetkikinde lökosit esteraz ve nitrit pozitifliği ile birlikte 3+ ketonüri saptandı. Kreatinin 1.4 mg/dL idi ve hafif prerenal akut böbrek hasarı düşünüldü. Lökosit sayısı 16.4 x 10^3/µL, C-reaktif protein 142 mg/L olarak ölçüldü; bu bulgular üriner sistem enfeksiyonunu destekledi.

Kurum laboratuvarında serum beta-hidroksibütirat ölçümü yapılamıyordu. Buna karşın SGLT2 inhibitörü kullanımı, azalmış oral alım, enfeksiyon varlığı, yüksek anyon açıklıklı ağır metabolik asidoz, normoglisemiye yakın glukoz değeri ve güçlü ketonüri birlikte değerlendirildiğinde SGLT2 inhibitörü ilişkili eDKA tanısı konuldu. Ayırıcı tanıda laktik asidoz düşük laktat nedeniyle, hiperglisemiye bağlı klasik DKA ise glukoz düzeyinin 178 mg/dL olması nedeniyle ön planda düşünülmedi. Belirgin üremik tablo olmaması ve öyküde toksik alımı destekleyen veri bulunmaması diğer yüksek anyon açıklıklı asidoz nedenlerini daha geri plana itti.

Tablo 1. *Klinik zaman çizelgesi*

Zaman	Klinik olay
Gün -3	Ateş, dizüri, bulantı-kusma ve oral alımda belirgin azalma başladı; hasta empagliflozin ve diğer oral antidiyabetiklerini almaya devam etti.
Gün 0	Acil servise başvuru; glukoz 178 mg/dL, pH 7.12, HCO3- 8.5 mmol/L, anyon açıklığı 28 mmol/L ve idrarda 3+ keton saptandı.
Gün 0	Yoğun bakım ünitesine kabul edildi; empagliflozin ve metformin kesildi, izotonik sıvı, dekstroz eşliğinde intravenöz insülin ve ampirik antibiyotik tedavisi başlandı.
İlk 24 saat	Solunum paterni düzeldi, bulantı azaldı; kan gazı, glukoz ve potasyum yakın aralıklarla izlendi.
48. saat	pH 7.36'ya yükseldi, HCO3- 19 mmol/L oldu, anyon açıklığı kapandı ve idrar ketonu negatifleşti.

Gün 3-5	Oral alım açıldı, subkutan insülin rejimine geçildi; idrar kültüründe Escherichia coli üremesi üzerine antibiyoterapi daraltıldı ve SGLT2 inhibitörü yeniden başlanmadan taburculuk planlandı.

Yoğun bakım ünitesinde empagliflozin ve metformin kesildi. İlk sıvı resüsitasyonu %0.9 sodyum klorür ile yapıldı. Üriner sistem enfeksiyonu düşünülerek kültür örnekleri alındıktan sonra ampirik intravenöz seftriakson başlandı. Ketogenezi baskılamak ve asidozu düzeltmek amacıyla intravenöz regüler insülin infüzyonu 0.1 Ü/kg/saat dozunda uygulandı. Hastanın kan glukozu normoglisemiye yakın olduğundan, hipoglisemiyi önlemek ve insülin tedavisinin kesintisiz sürdürülebilmesini sağlamak için tedaviye erken dönemde %5 dekstroz eklendi. Potasyum, kan gazı ve kapiller glukoz değerleri yakın aralıklarla izlendi.

Tedavinin ilk 24 saatinde hastanın solunum paterni normale döndü, bulantısı geriledi ve hemodinamisi stabil seyretti. İkinci gün kontrol kan gazında pH 7.36, HCO3- 19 mmol/L olarak ölçüldü ve anyon açıklığı kapandı. İdrar ketonu negatifleşti. Asidozu düzelen ve oral alımı başlayan hastada intravenöz insülin kademeli olarak azaltılarak subkutan insülin rejimine geçildi. İdrar kültüründe Escherichia coli üremesi üzerine antibiyoterapi duyarlılık sonucuna göre daraltıldı. Taburculuk planında SGLT2 inhibitörü yeniden başlanmadı; hastaya ve yakınlarına enfeksiyon, kusma, açlık veya belirgin oral alım azalması durumunda antidiyabetik ilaç kullanımı ve sağlık kuruluşuna erken başvuru konusunda hastalık günü eğitimi verildi. Olgu sunumunda hasta kimliğini açığa çıkarabilecek herhangi bir kişisel veri kullanılmadı.

Tartışma

Bu olgu, SGLT2 inhibitörü ilişkili eDKA'nın en önemli tanısal tuzağını göstermektedir: ağır metabolik asidoz bulunmasına rağmen kan glukozu belirgin yüksek olmayabilir. SGLT2 inhibitörleri glukozürinin sürmesine neden olarak plazma glukozunu düşürürken insülin-glukagon dengesini ketogenez lehine değiştirebilir. Buna enfeksiyon, kusma, dehidratasyon ve karbonhidrat alımının azalması eklendiğinde lipoliz ve hepatik keton üretimi artar (Taylor et al., 2015). Olgumuzda üriner sistem enfeksiyonu, üç günlük yetersiz oral alım ve empagliflozin kullanımının sürmesi bu mekanizmaları aynı anda tetiklemiştir.

Tanısal yaklaşımda yalnızca glukoz düzeyine odaklanmak gecikmeye yol açabilir. Güncel hiperglisemik kriz yaklaşımı, DKA tanı ve izleminde keton ölçümünün önemini vurgular; kan beta-hidroksibütirat ölçümü tercih edilen yöntemdir, ancak her merkezde acil koşullarda ulaşılabilir değildir (Umpierrez et al., 2024). İdrar keton testleri beta-hidroksibütiratı doğrudan ölçmediğinden tanısal sınırlılık taşır; yine de uygun klinik bağlamda, özellikle yüksek anyon açıklıklı asidoz ve SGLT2 inhibitörü öyküsü ile birlikte değerlendirildiğinde tanıyı destekleyen önemli bir bulgudur. Bu olguda 3+ ketonüri, pH 7.12, HCO3- 8.5 mmol/L ve anyon açıklığı 28 mmol/L birlikteliği tedavinin geciktirilmemesini gerektiren güçlü bir eDKA olasılığı oluşturmuştur.

Ayırıcı tanıda laktik asidoz, böbrek yetmezliği, toksik alkoller, salisilat intoksikasyonu, açlık ketoasidozu ve klasik DKA göz önünde bulundurulmalıdır. Olgumuzda laktatın normal olması, böbrek fonksiyon bozukluğunun asidozu açıklayacak düzeyde olmaması, kan glukozunun 178 mg/dL olması ve SGLT2 inhibitörü kullanım öyküsü eDKA tanısını öne çıkarmıştır. Azalmış oral alım tek başına açlık ketoasidozunu düşündürebilse de, diyabet öyküsü, empagliflozin kullanımı ve ağır anyon açıklıklı asidoz tablonun SGLT2 inhibitörü ilişkili eDKA olarak yönetilmesini klinik olarak daha uygun kılmıştır.

Tedavide temel amaç kan glukozunu düşürmek değil, ketogenezi durdurmak ve asidozu güvenli şekilde düzeltmektir. Bu nedenle sorumlu ilacın kesilmesi, intravasküler volümün düzeltilmesi, intravenöz insülin tedavisi, dekstroz desteği ve elektrolit izlemi birlikte yürütülmelidir (Dhatariya et al., 2020; Goldenberg et al., 2016). eDKA'da glukoz düzeyi normal veya düşük-normal olabileceğinden, insülin infüzyonunun hipoglisemi nedeniyle erken kesilmemesi için dekstroz eklenmesi kritik önemdedir. Olgumuzda insülin ve dekstrozun eş zamanlı kullanılmasıyla hipoglisemi gelişmeden 48 saat içinde anyon açıklığı kapanmış, ketonüri negatifleşmiş ve klinik iyileşme sağlanmıştır.

Önleme stratejisinin en önemli bileşeni hasta eğitimidir. SGLT2 inhibitörü kullanan hastalara akut enfeksiyon, tekrarlayan kusma, belirgin oral alım azalması, dehidratasyon veya cerrahi girişim öncesi ilaç kullanımına ara verme ve sağlık profesyoneli ile iletişime geçme konusunda net talimat verilmelidir. Amerikan Diyabet Derneği'nin güncel hastane bakımı standartlarında SGLT2 inhibitörlerinin elektif cerrahi öncesinde 3-4 gün süreyle kesilmesi önerilmekte ve akut hastalık durumlarında yakın izlem gerekliliği vurgulanmaktadır (American Diabetes Association Professional Practice Committee for Diabetes, 2026). Bu yaklaşım, yalnızca nüks riskini azaltmakla kalmaz; acil servis ve yoğun bakımda normoglisemik asidozla gelen hastada tanısal farkındalığı da artırır.

Bu olgunun sınırlılığı, serum beta-hidroksibütirat düzeyinin ölçülememiş olmasıdır. Bununla birlikte gerçek yaşam koşullarında birçok merkezde bu testin acil erişilebilir olmaması, olgunun eğitsel değerini artırmaktadır. Klinik karar; ilaç öyküsü, tetikleyici faktör, kan gazı, anyon açıklığı, idrar ketonu, laktat ve tedavi yanıtının birlikte değerlendirilmesine dayanmıştır. Sonuç olarak, SGLT2 inhibitörü kullanan diyabetli hastada bulantı-kusma, takipne veya açıklanamayan metabolik asidoz saptandığında kan glukozu 200 mg/dL'nin altında olsa bile eDKA dışlanmamalıdır. Keton, pH ve anyon açıklığı birlikte yorumlandığında erken tanı ve zamanında yoğun bakım tedavisi yaşam kurtarıcıdır.

Kaynakça

American Diabetes Association Professional Practice Committee for Diabetes. (2026). 16. Diabetes care in the hospital: Standards of Care in Diabetes-2026. Diabetes Care, 49(Suppl. 1), S339-S355. doi:10.2337/dc26-S016

Burke, K. R., Schumacher, C. A., & Harpe, S. E. (2017). SGLT2 inhibitors: A systematic review of diabetic ketoacidosis and related risk factors in the primary literature. Pharmacotherapy, 37(2), 187-194. doi:10.1002/phar.1881

Dhatariya, K. K., Glaser, N. S., Codner, E., & Umpierrez, G. E. (2020). Diabetic ketoacidosis. Nature Reviews Disease Primers, 6(1), 40. doi:10.1038/s41572-020-0165-1

Gagnier, J. J., Kienle, G., Altman, D. G., Moher, D., Sox, H., Riley, D., & CARE Group. (2014). The CARE guidelines: Consensus-based clinical case reporting guideline development. Journal of Clinical Epidemiology, 67(1), 46-51. doi:10.1016/j.jclinepi.2013.08.003

Goldenberg, R. M., Berard, L. D., Cheng, A. Y. Y., Gilbert, J. D., Verma, S., Woo, V. C., & Yale, J.-F. (2016). SGLT2 inhibitor-associated diabetic ketoacidosis: Clinical review and recommendations for prevention and diagnosis. Clinical Therapeutics, 38(12), 2654-2664.e1. doi:10.1016/j.clinthera.2016.11.002

Peters, A. L., Buschur, E. O., Buse, J. B., Cohan, P., Diner, J. C., & Hirsch, I. B. (2015). Euglycemic diabetic ketoacidosis: A potential complication of treatment with sodium-

glucose cotransporter 2 inhibition. Diabetes Care, 38(9), 1687-1693. doi:10.2337/dc15-0843

Rosenstock, J., & Ferrannini, E. (2015). Euglycemic diabetic ketoacidosis: A predictable, detectable, and preventable safety concern with SGLT2 inhibitors. Diabetes Care, 38(9), 1638-1642. doi:10.2337/dc15-1380

Taylor, S. I., Blau, J. E., & Rother, K. I. (2015). SGLT2 inhibitors may predispose to ketoacidosis. The Journal of Clinical Endocrinology & Metabolism, 100(8), 2849-2852. doi:10.1210/jc.2015-1884

Umpierrez, G. E., Davis, G. M., ElSayed, N. A., Fadini, G. P., Galindo, R. J., Hirsch, I. B., ... Dhatariya, K. K. (2024). Hyperglycemic crises in adults with diabetes: A consensus report. Diabetes Care, 47(8), 1257-1275. doi:10.2337/dci24-0032

Adölesan idiopatik skolyoz hastalarında anterior vertebral body tetherıng (avbt) ve posterior spinal füzyon (psf) cerahilerinin klinik ve fonksiyonel sonuçlarının karşılaştırılması

Abdülhalim Akar

Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Ortopedi ve Travmatoloji Anabilim Dalı, Balıkesir, Bandırma, Türkiye

Amaç:
Bu çalışmada, anterior vertebral body tethering (AVBT) ile posterior spinal füzyon (PSF) cerrahilerinin klinik ve fonksiyonel sonuçlarının karşılaştırılması hedeflenmiştir.

Gereç ve Yöntem:
Retrospektif ve karşılaştırmalı olarak tasarlanan bu çalışmaya, torakolomber eğriliği (T5–L3) bulunan ve AVBT uygulanan 25 hasta (VBT grubu) ile yaş, cinsiyet, füzyon seviyesi ve minimum takip süresi bakımından benzer özellikler gösteren, torakolomber eğriliği (T3–L3) olan ve PSF uygulanmış 28 hasta (PSF grubu) dahil edilmiştir. Ortalama takip süresi VBT grubunda 47.1 ay, PSF grubunda ise 47.8 ay olup gruplar arasında anlamlı fark saptanmamıştır ($p = 0.33$). Hastalara ait klinik veriler ile SRS-22 ve SF-36 yaşam kalitesi skorları geriye dönük olarak incelenmiş ve gruplar arasında karşılaştırılmıştır.

Bulgular:
AVBT grubunda lomber omurga hareket açıklığı, anterior ve lateral fleksibilite, gövde fleksör ve ekstansör kaslarının dayanıklılığı ile kas kuvveti değerlerinin PSF grubuna göre anlamlı düzeyde daha yüksek olduğu belirlenmiştir ($p < 0.05$). Bunun yanı sıra, yaşam kalitesi değerlendirmelerinde VBT grubunun daha avantajlı olduğu; toplam SRS-22 skorları ile SF-36'nın mental (MCS) ve fiziksel (PCS) alt bileşen skorlarının anlamlı şekilde daha yüksek olduğu görülmüştür.

Sonuç:
Elde edilen bulgular, iskelet gelişimi tamamlanmamış adolesan idiopatik skolyoz hastalarında AVBT yönteminin, büyüme modülasyonu etkisi sayesinde omurga hareketliliğinin korunmasına katkı sağladığını ve fonksiyonel sonuçlar ile yaşam kalitesini iyileştirdiğini göstermektedir. AVBT'nin, hareket koruyucu özelliği ile füzyon cerrahisine bağlı uzun dönem kısıtlılıkları azaltabilecek etkili bir alternatif olduğu düşünülmektedir.

Not: Yazarlar sunumun tam metinini göndermediği için özet metinleri basılmıştır.

Fiziksel tıp ve rehabilitasyonda yapay zekâ uygulamaları: son 10 yıldaki gelişmeler ve gelecek perspektifleri

Nurten NAS KIRDAR[1]

1 Dr.Öğr.Üyesi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Fiziksel Tıp ve Rehabilitasyon Anabilim Dalı, nkirdar@bandirma.edu.tr

ÖZET

Amaç: Bu derlemenin amacı, 2016–2026 yılları arasında fiziksel tıp ve rehabilitasyon alanında yapay zeka uygulamalarına ilişkin literatürü kapsamlı şekilde incelemek, kullanım alanlarını, yöntemsel eğilimleri ve klinik etkilerini değerlendirmektir.

Yöntem: Literatür taraması PubMed ve Scopus veritabanlarında gerçekleştirilmiş; "artificial intelligence", "machine learning", "deep learning", "rehabilitation" ve "physical therapy" anahtar kelimeleri Boolean operatörleri kullanılarak birleştirilmiştir. Çalışmalar önceden belirlenen dahil edilme ve dışlama kriterlerine göre seçilmiş ve süreç PRISMA 2020 rehberine uygun olarak yürütülmüştür.

Bulgular: Toplam 5.960 kayıttan 275 çalışma analize dahil edilmiştir. Yayın sayısında özellikle 2020 yılı sonrası belirgin bir artış saptanmıştır. Çalışmaların büyük kısmı nörolojik rehabilitasyon alanında yoğunlaşırken, ortopedik ve diğer rehabilitasyon alanlarında daha sınırlı sayıda çalışma olduğu görülmüştür. Yapay zekâ uygulamaları en sık hareket analizi, fonksiyonel değerlendirme, tedavi planlaması ve hasta takibinde kullanılmıştır. Makine öğrenmesi en yaygın yöntem olmakla birlikte, son yıllarda derin öğrenme ve görüntü işleme temelli yaklaşımlarda artış dikkat çekmektedir. Ayrıca telerehabilitasyon ve giyilebilir teknolojilerle entegrasyonun arttığı gözlenmiştir.

Sonuç: Yapay zekâ, fiziksel tıp ve rehabilitasyon alanında değerlendirme, tedavi ve izlem süreçlerini dönüştürme potansiyeline sahip güçlü bir araçtır. Ancak mevcut çalışmaların metodolojik heterojenitesi, sınırlı örneklem büyüklükleri ve dış doğrulama eksiklikleri göz önünde bulundurulduğunda, daha yüksek kaliteli, çok merkezli ve klinik uygulamaya entegre araştırmalara ihtiyaç bulunmaktadır.

Anahtar kelimeler: Derin Öğrenme, Fiziksel ve rehabilitasyon tıbbı, Makine öğrenmesi, Telerehabilitasyon, Yapay zeka

GİRİŞ

Fiziksel tıp ve rehabilitasyon (FTR), hastalık, yaralanma veya kronik durumlara bağlı gelişen fonksiyon kayıplarının azaltılması ve bireyin maksimum bağımsızlık düzeyine ulaştırılmasını amaçlayan multidisipliner bir tıp alanıdır. Geleneksel rehabilitasyon yaklaşımları büyük ölçüde klinisyen deneyimine ve standart protokollere dayanmakta olup, bireyler arası farklılıkların tedavi planlarına yansıtılmasının önemi bilinmektedir. Bu durum, son yıllarda daha objektif, veri temelli ve kişiselleştirilmiş yaklaşımlara olan ihtiyacı artırmıştır (Rajkomar, Dean, & Kohane, 2019; Topol, 2019). Bu bağlamda, yapay zeka teknolojilerindeki hızlı ilerlemeler, rehabilitasyon süreçlerinin yeniden şekillenmesinde önemli bir rol oynamaya başlamıştır.

Yapay zekâ; makine öğrenmesi, derin öğrenme ve bilgisayarla görme gibi alt alanları kapsayan geniş bir disiplin olup, büyük veri setlerinden anlamlı örüntüler çıkararak karar destek sistemleri oluşturabilmektedir. Rehabilitasyon alanında bu teknolojiler; klinik değerlendirme, tanı sınıflandırması, prognoz tahmini ve tedavi planlaması gibi birçok aşamada kullanılmaktadır(Esteva et al., 2019; Jiang et al., 2017). Özellikle hareket analizi, postür değerlendirmesi ve yürüyüş (gait) analizi gibi fonksiyonel ölçümlerde, yapay zekâ

tabanlı sistemlerin yüksek doğruluk oranlarına ulaştığı ve klinik gözlemlere kıyasla daha objektif sonuçlar sunduğu bildirilmektedir (Kanko, Laende, Strutzenberger, et al., 2021). Bunun yanı sıra, giyilebilir sensörler ve kamera tabanlı sistemlerle entegre edilen yapay zekâ algoritmaları sayesinde hastaların ev ortamında izlenmesi mümkün hale gelmiş, böylece telerehabilitasyon uygulamalarında önemli ilerlemeler kaydedilmiştir (Y.-P. Chen, Lin, Tsai, Chuang, & Lee, 2020).

Literatürde yapay zekâ uygulamalarının nörolojik ve ortopedik rehabilitasyon alanlarında da yaygın kullanıldığı görülmektedir. Özellikle inme, Parkinson hastalığı ve kas-iskelet sistemi bozukluklarında, fonksiyonel iyileşmenin değerlendirilmesi ve tedaviye yanıtın öngörülmesi amacıyla çeşitli makine öğrenmesi modelleri geliştirilmiştir (Choo & Chang, 2022; Dubey et al., 2025). Son yıllarda derin öğrenme yöntemlerinin kullanımının artmasıyla birlikte, insan hareketinin otomatik tanınması, egzersizlerin doğruluğunun değerlendirilmesi ve kişiselleştirilmiş rehabilitasyon programlarının oluşturulması gibi daha kompleks uygulamalar mümkün hale gelmiştir (Ravi, Wong, Lo, & Yang, 2016). Ayrıca, robotik rehabilitasyon sistemleri ile yapay zekânın entegrasyonu, özellikle inme sonrası rehabilitasyonda adaptif ve hasta odaklı tedavi yaklaşımlarının geliştirilmesine katkı sağlamaktadır (Louie & Eng, 2016).

Bununla birlikte, mevcut literatür incelendiğinde önemli sınırlılıklar dikkat çekmektedir. Çalışmaların büyük bir kısmının küçük örneklem büyüklüklerine sahip olduğu, dış doğrulama süreçlerinin yetersiz olduğu ve randomize kontrollü çalışma sayısının sınırlı kaldığı bildirilmektedir. Klinik uygulamaya entegrasyonun önündeki bir diğer engel ise veri standardizasyonunun eksikliği ve farklı merkezler arasında uyumsuz veri yapılarının bulunmasıdır.

Tüm bu gelişmeler göz önünde bulundurulduğunda, yapay zekâ uygulamalarının fiziksel tıp ve rehabilitasyon alanında önemli bir potansiyele sahip olduğu açıktır. Ancak, bu teknolojilerin rutin klinik uygulamalara etkin ve güvenilir bir şekilde entegre edilebilmesi için mevcut literatürün kapsamlı bir şekilde değerlendirilmesi, güncel eğilimlerin ortaya konulması ve gelecekteki araştırma alanlarının belirlenmesi gerekmektedir. Bu çalışmada, fiziksel tıp ve rehabilitasyon alanında yapay zekâ uygulamalarına ilişkin son yıllardaki gelişmeler incelenerek, mevcut durumun değerlendirilmesi ve geleceğe yönelik perspektiflerin ortaya konulması amaçlanmıştır.

MATERYAL METOD

Bu derleme çalışmasında, PubMed ve Scopus veritabanları kullanılarak 2016–2026 yılları arasında yayımlanan literatür taranmıştır. Literatür taraması “artificial intelligence”, “machine learning”, “deep learning”, “rehabilitation”, “physical medicine and rehabilitation” ve “physical therapy” anahtar kelimeleri kullanılarak gerçekleştirilmiş; bu terimler Boolean operatörleri (AND, OR) ile kombine edilmiştir. Kullanılan temel arama stratejisi (“artificial intelligence” OR “machine learning” OR “deep learning”) AND (“rehabilitation” OR “physical medicine and rehabilitation”) AND (“physical therapy” OR “physiotherapy”) şeklinde yapılandırılmıştır.

Elde edilen çalışmalar başlık ve özet düzeyinde incelenmiş, fiziksel tıp ve rehabilitasyon ile doğrudan ilişkili olmayan yayınlar çalışma dışı bırakılmıştır. Dahil edilme kriterleri; (i) insan üzerinde yapılmış çalışmalar, (ii) fiziksel tıp ve rehabilitasyon alanında yapay zekâ uygulamalarını içermesi ve (iii) İngilizce dilinde yayımlanmış özgün araştırma veya derleme makaleleri olarak belirlenmiştir. Olgu sunumları, editöre mektuplar, konferans özetleri ve tam metnine ulaşılamayan çalışmalar dışlanmıştır.

Çalışma seçimi süreci PRISMA akışına uygun olarak yürütülmüştür. İlk aşamada toplam 5.960 kayıt elde edilmiş, tekrar eden çalışmaların çıkarılmasının ardından 4.540 kayıt başlık ve özet düzeyinde değerlendirilmiştir. Uygun olmayan çalışmalar elendikten sonra 760 makale tam metin incelemeye alınmış ve dahil edilme kriterlerini karşılayan 275 çalışma nihai analizde yer almıştır (Şekil 1).

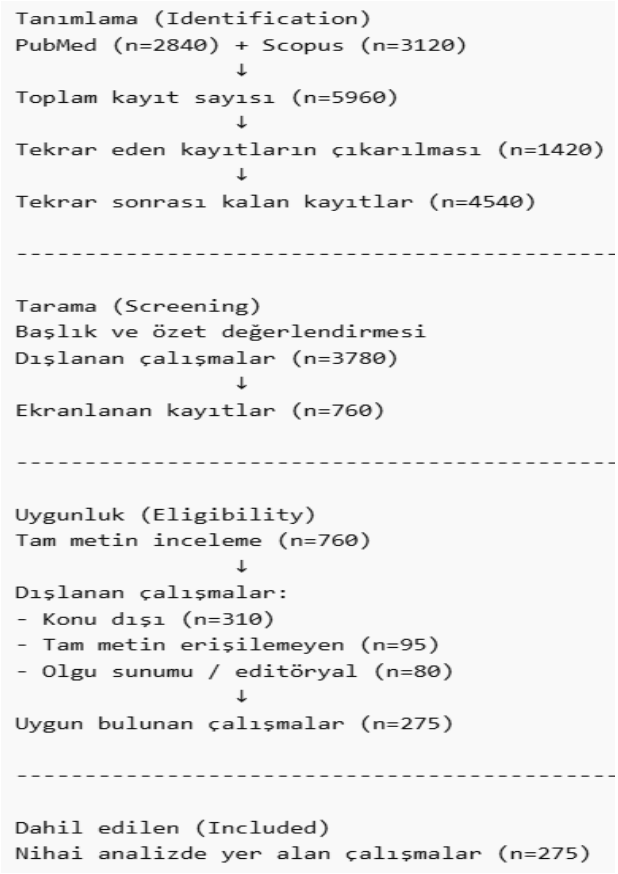

Şekil 1. Akış diagramı

BULGULAR

Literatür taraması sonucunda 2016–2026 yılları arasında PubMed ve Scopus üzerinden toplam 5.960 kayıt elde edilmiştir. Tekrar eden çalışmaların çıkarılması ve dahil edilme kriterlerine göre yapılan seçim süreci sonucunda 275 çalışma nihai analize dahil edilmiştir. Dahil edilen çalışmaların büyük çoğunluğu son beş yılda yayımlanmış olup, yapay zekâ uygulamalarında belirgin bir artış eğilimi gözlenmiştir.

Çalışmaların yıllara göre dağılımı incelendiğinde, 2016–2019 döneminde düşük düzeyde bir artış görülürken, 2020 sonrası dönemde belirgin bir yükseliş olduğu saptanmıştır. Özellikle 2021–2024 yılları arasında yayın sayısında hızlı bir artış gözlenmiştir (Tablo 1).

Tablo 1. Yıllara Göre Yayın Dağılımı

Yıl aralığı	Yayın sayısı (n)	Yüzde (%)
2016–2018	38	13.8
2019–2020	52	18.9
2021–2022	86	31.3
2023–2026	99	36.0

Toplam	275	100

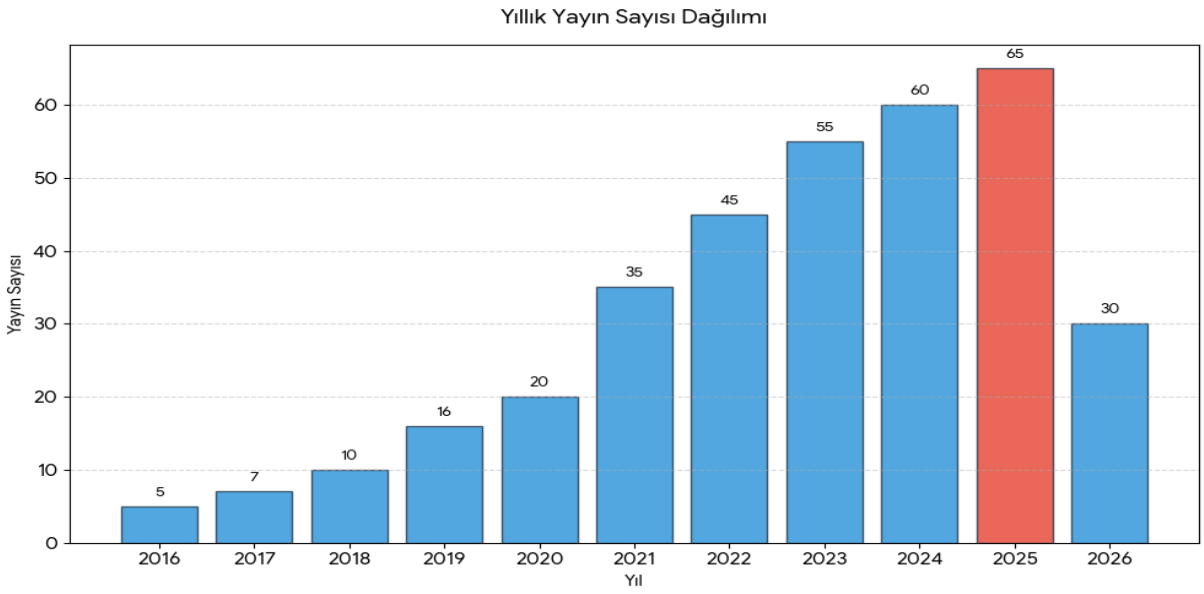

Grafik 1. Yıllık yayın sayısı dağılımı

2016'dan 2025 yılına kadar yayın sayısında sürekli ve ivmelenen bir artış görülmektedir. Yayın sayısı 2025 yılında 65 ile en yüksek seviyesine ulaşmıştır. 2026 yılı verilerinde (muhtemelen yılın tamamlanmamış olması nedeniyle) yayın sayısında 30'a kadar belirgin bir düşüş kaydedilmiştir.

Dahil edilen çalışmaların büyük kısmı nörolojik rehabilitasyon alanına odaklanmıştır. Ortopedik ve kas-iskelet sistemi hastalıkları ikinci sırada yer almaktadır (Tablo 2).

Tablo 2. Klinik alanlara göre dağılım

Klinik alan	Çalışma sayısı (n)	Yüzde (%)
Nörolojik rehabilitasyon	159	57.8
Ortopedik rehabilitasyon	62	22.5
Pediatrik rehabilitasyon	18	6.5
Kardiyopulmoner rehabilitasyon	14	5.1
Diğer	22	8.1

Yapay zekâ uygulamaları en sık tedavi planlaması ve değerlendirme süreçlerinde kullanılmıştır (Tablo 3).

Tablo 3. Yapay zekâ kullanım alanları

Kullanım alanı	Çalışma sayısı (n)	Yüzde (%)

Tedavi	65	23.6
Prognoz	48	17.4
Değerlendirme	45	16.3
Tanı	36	13.1
İzlem	34	12.4
Diğer	47	17.2

Çalışmalarda en sık kullanılan yöntem makine öğrenmesi algoritmalarıdır. Derin öğrenme yöntemleri özellikle 2020 sonrası dönemde artış göstermiştir (Tablo 4).

Tablo 4. Kullanılan yöntemler

Yöntem türü	Çalışma sayısı (n)	Yüzde (%)
Makine öğrenmesi	118	42.9
Derin öğrenme	76	27.6
Görüntü işleme	41	14.9
Hibrit sistemler	25	9.1
Diğer	15	5.5

TARTIŞMA

Bu derlemede, 2016–2026 yılları arasında fiziksel tıp ve rehabilitasyon alanında yapay zeka uygulamalarına yönelik çalışmalar incelenmiş ve alandaki eğilimler değerlendirilmiştir. Bulgular, yapay zekâ kullanımının özellikle son yıllarda belirgin şekilde arttığını göstermektedir. Bu artış, dijital sağlık teknolojilerindeki ilerlemeler ve veri işleme kapasitesindeki gelişmeler ile ilişkilendirilmektedir (Rajkomar et al., 2019; Topol, 2019). Özellikle 2020 sonrası dönemde gözlenen ivmelenme, klinik uygulamalarda veri temelli yaklaşımların önem kazanmasıyla paralellik göstermektedir (Esteva et al., 2019).

Nörolojik rehabilitasyon sürecinde sanal gerçeklik ve robotik rehabilitasyon gibi yaklaşımlar uzun zamandır klinik pratikte yer almaktadır (Lee, 2013; Sergi et al., 2011; Takahashi, Der-Yeghiaian, Le, Motiwala, & Cramer, 2008). Yapay zekâ kullanımının artmasıyla rehabilitasyonun bu alanında kullanılan araçlarda da gelişmeler gözlenmiştir. Bu yaklaşımlar, başta yürüme ve denge gibi kaba motor fonksiyonlar ile üst ekstremite becerilerinin geliştirilmesinde kullanılırken; dil-konuşma, kognitif ve kardiyopulmoner rehabilitasyon gibi alanlarda da uygulanmaya başlanmıştır. Yapay zekâ sayesinde bireye özgü tedavi programları oluşturulabilmekte, özellikle pandemi sonrası artan telerehabilitasyon uygulamaları ile hasta takibi ve tedaviye katılım güçlenmektedir.

Özden ve ark. yaptığı bir çalışmada web tabanlı telerehabilitasyon programlarının sunduğu en büyük avantajlardan birinin uygulamalarda hastalara görsel ve işitsel geri bildirimler sunulması ve bu sayede konvansiyonel yöntemlerin öğrenme ve hatırlama güçlüğü ile ilgili dezavantajlarının ortadan kaldırlmış olması şeklinde belirtmişlerdir. Bu tip yazılımların sadece klinisyenin kontrolünde kullanılan bir yardımcı teknoloji olarak ele alınması gerektiğini, bununla birlikte, konu ile ilgili etik çerçevelerin oluşturulmasının uygun olacağını vurgulamışlardır (ÖZDEN, ARIK, & TUĞAY, 2020).

Çalışmaların önemli bir kısmının nörolojik rehabilitasyon alanında yoğunlaştığı görülmektedir. İnme ve Parkinson hastalığı gibi durumlarda fonksiyonel kaybın objektif olarak ölçülmesi gerekliliği, yapay zekâ uygulamalarının bu alanda daha fazla kullanılmasına neden olmuştur (Heo et al., 2019; Lanotte, O'Brien, & Jayaraman, 2023). Özellikle yürüme analizi, hareket takibi ve motor fonksiyon değerlendirmelerinde makine öğrenmesi algoritmalarının yüksek doğruluk oranlarına ulaştığı bildirilmektedir (Kanko, Laende, Davis, Selbie, & Deluzio, 2021). Buna karşılık ortopedik rehabilitasyon alanında çalışmaların daha sınırlı olması, bu alanın gelecekteki araştırmalar açısından önemli bir potansiyel taşıdığını göstermektedir.

Yapay zekânın kullanım alanları incelendiğinde, başlangıçta daha çok değerlendirme ve tanı süreçlerinde kullanıldığı, ancak son yıllarda tedavi planlaması ve hasta takibinde de aktif rol almaya başladığı görülmektedir (Jiang et al., 2017). Özellikle kişiselleştirilmiş rehabilitasyon programlarının oluşturulması ve tedaviye yanıtın öngörülmesi gibi alanlarda önemli gelişmeler kaydedilmiştir. Ayrıca telerehabilitasyon uygulamaları ile yapay zekânın entegrasyonu, hastaların uzaktan izlenmesini ve tedaviye erişimin artırılmasını mümkün kılmaktadır (J. Chen et al., 2015).

Kullanılan yöntemler açısından değerlendirildiğinde, makine öğrenmesi algoritmalarının en yaygın yöntem olduğu, ancak son yıllarda derin öğrenme tekniklerinin kullanımında belirgin bir artış olduğu dikkat çekmektedir (Esteva et al., 2019; Ravi et al., 2016). Derin öğrenme yöntemleri, özellikle görüntü işleme ve insan hareketinin otomatik tanınması gibi karmaşık veri yapılarında daha başarılı sonuçlar sunmaktadır. Bununla birlikte, birçok çalışmada veri setlerinin sınırlı olması ve modellerin dış doğrulama süreçlerinden geçmemesi, elde edilen sonuçların genellenebilirliğini kısıtlayan önemli faktörler arasında yer almaktadır (Liu, Chen, Krause, & Peng, 2019).

Bu derlemede ortaya konan önemli bulgulardan biri de metodolojik sınırlılıklardır. Literatürde yer alan çalışmaların önemli bir kısmında randomize kontrollü tasarımın bulunmaması, kontrol gruplarının yetersizliği ve örneklem büyüklüklerinin küçük olması dikkat çekmektedir (Liu et al., 2019; Mark P. Sendak et al., 2020). Ayrıca yapay zekâ modellerinin çoğunlukla "kara kutu" (black-box) yapıda olması, klinik karar verme süreçlerinde güvenilirlik ve açıklanabilirlik açısından önemli bir sorun oluşturmaktadır . Bu durum, klinisyenlerin yapay zekâ sistemlerini benimsemesini zorlaştıran temel etkenlerden biri olarak değerlendirilmektedir (Rudin, 2019).

Gelecek perspektif açısından, fiziksel tıp ve rehabilitasyon alanında yapay zekâ uygulamalarının daha büyük ve çok merkezli veri setleri ile desteklenmesi gerekmektedir. Açıklanabilir yapay zekâ modellerinin geliştirilmesi, klinik entegrasyonu kolaylaştıracak önemli bir adım olacaktır (Rudin, 2019). Bunun yanı sıra, giyilebilir teknolojiler ve gerçek zamanlı veri analizi ile entegre sistemlerin yaygınlaşması, rehabilitasyon süreçlerinin daha etkin, erişilebilir ve bireyselleştirilmiş hale gelmesine katkı sağlayacaktır.

Bu derleme çalışmasının bazı önemli sınırlılıkları bulunmaktadır. Öncelikle literatür taraması yalnızca PubMed ve Scopus veritabanları ile sınırlandırılmış olup, diğer veri tabanlarında yer alan çalışmaların dışlanmış olma ihtimali bulunmaktadır. Ayrıca taramanın yalnızca İngilizce dilinde yayımlanan çalışmalarla sınırlandırılması, dil yanlılığına (language bias) neden olabilir. Çalışmaya dahil edilen araştırmaların önemli bir kısmında örneklem büyüklüklerinin sınırlı olması ve metodolojik heterojenitenin yüksek olması, elde edilen bulguların genellenebilirliğini kısıtlamaktadır. Bununla birlikte, dahil edilen çalışmalar arasında yapay zekâ yöntemleri, veri setleri ve klinik uygulama alanları açısından belirgin farklılıklar bulunması, sonuçların doğrudan karşılaştırılmasını güçleştirmiştir. Ayrıca birçok çalışmada dış doğrulama eksikliği ve randomize kontrollü

tasarımın sınırlı olması, elde edilen sonuçların klinik güvenilirliği açısından dikkatle yorumlanmasını gerektirmektedir. Son olarak, 2026 yılına ait verilerin yılın tamamını kapsamaması, yayın eğilimlerinin değerlendirilmesinde kısmi bir sınırlılık oluşturmaktadır.

SONUÇ

Bu derleme, 2016–2026 yılları arasında fiziksel tıp ve rehabilitasyon alanında yapay zeka uygulamalarına ilişkin literatürü sistematik bir yaklaşımla inceleyerek alandaki güncel eğilimleri bütüncül biçimde ortaya koymaktadır. Elde edilen bulgular, yapay zekâ uygulamalarının özellikle nörolojik rehabilitasyon başta olmak üzere farklı klinik alanlarda giderek yaygınlaştığını, değerlendirme süreçlerinin ötesine geçerek tedavi planlaması ve hasta takibinde de etkin biçimde kullanılmaya başlandığını göstermektedir. Çalışmanın geniş zaman aralığını kapsaması, sistematik tarama yaklaşımı ve PRISMA 2020 rehberine uygun yürütülmesi önemli güçlü yönler arasında yer almaktadır. Bununla birlikte literatürdeki metodolojik heterojenite, sınırlı örneklem büyüklükleri ve dış doğrulama eksiklikleri dikkate alındığında, gelecekte daha güçlü tasarımlara sahip, çok merkezli ve klinik entegrasyonu yüksek çalışmalara ihtiyaç olduğu açıktır; bu doğrultuda yapay zekânın rehabilitasyon pratiğinde daha etkin ve güvenilir şekilde yer alması beklenmektedir.

KAYNAKÇA

Chen, J., Jin, W., Zhang, X.-X., Xu, W., Liu, X.-N., & Ren, C.-C. (2015). Telerehabilitation Approaches for Stroke Patients: Systematic Review and Meta-analysis of Randomized Controlled Trials. *Journal of Stroke and Cerebrovascular Diseases*, *24*(12), 2660–2668. doi:10.1016/j.jstrokecerebrovasdis.2015.09.014

Chen, Y.-P., Lin, C.-Y., Tsai, M.-J., Chuang, T.-Y., & Lee, O. K.-S. (2020). Wearable Motion Sensor Device to Facilitate Rehabilitation in Patients With Shoulder Adhesive Capsulitis: Pilot Study to Assess Feasibility. *Journal of Medical Internet Research*, *22*(7), e17032. doi:10.2196/17032

Choo, Y. J., & Chang, M. C. (2022). Use of Machine Learning in Stroke Rehabilitation: A Narrative Review. *Brain & NeuroRehabilitation*, *15*(3), e26. doi:10.12786/bn.2022.15.e26

Dubey, A., Uldin, H., Khan, Z., Panchal, H., Iyengar, K. P., & Botchu, R. (2025). Role of Artificial Intelligence in Musculoskeletal Interventions. *Cancers*, *17*(10), 1615. doi:10.3390/cancers17101615

Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., … Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, *25*(1), 24–29. doi:10.1038/s41591-018-0316-z

Heo, J., Yoon, J. G., Park, H., Kim, Y. D., Nam, H. S., & Heo, J. H. (2019). Machine Learning–Based Model for Prediction of Outcomes in Acute Stroke. *Stroke*, *50*(5), 1263–1265. doi:10.1161/STROKEAHA.118.024293

Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., … Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, *2*(4), 230–243. doi:10.1136/svn-2017-000101

Kanko, R. M., Laende, E. K., Davis, E. M., Selbie, W. S., & Deluzio, K. J. (2021). Concurrent assessment of gait kinematics using marker-based and markerless motion capture. *Journal of Biomechanics*, *127*, 110665. doi:10.1016/j.jbiomech.2021.110665

Kanko, R. M., Laende, E. K., Strutzenberger, G., Brown, M., Selbie, W. S., DePaul, V., … Deluzio, K. J. (2021). Assessment of spatiotemporal gait parameters using a deep learning algorithm-based markerless motion capture system. *Journal of Biomechanics*, *122*, 110414. doi:10.1016/j.jbiomech.2021.110414

Lanotte, F., O'Brien, M. K., & Jayaraman, A. (2023). AI in Rehabilitation Medicine: Opportunities and Challenges. *Annals of Rehabilitation Medicine*, *47*(6), 444–458. doi:10.5535/arm.23131

Lee, G. (2013). Effects of Training Using Video Games on the Muscle Strength, Muscle Tone, and Activities of Daily Living of Chronic Stroke Patients. *Journal of Physical Therapy Science*, *25*(5), 595–597. doi:10.1589/jpts.25.595

Liu, Y., Chen, P.-H. C., Krause, J., & Peng, L. (2019). How to Read Articles That Use Machine Learning. *JAMA*, *322*(18), 1806. doi:10.1001/jama.2019.16489

Louie, D. R., & Eng, J. J. (2016). Powered robotic exoskeletons in post-stroke rehabilitation of gait: a scoping review. *Journal of NeuroEngineering and Rehabilitation*, *13*(1), 53. doi:10.1186/s12984-016-0162-5

Mark P. Sendak, D'Arcy, J., Sehj Kashyap, Michael Gao, Marshall Nichols, Kristin Corey, … Suresh Balu. (2020). A Path for Translation of Machine Learning Products into Healthcare Delivery. *EMJ Innovations*, *4*(1). doi:10.33590/emjinnov/19-00172

ÖZDEN, F., ARIK, A. F., & TUĞAY, N. (2020). Current Telerehabilitation Approaches in Orthopaedic Physiotherapy. *Turkiye Klinikleri Journal of Health Sciences*, *5*(2), 354–360. doi:10.5336/healthsci.2019-70990

Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine Learning in Medicine. *New England Journal of Medicine*, *380*(14), 1347–1358. doi:10.1056/NEJMra1814259

Ravi, D., Wong, C., Lo, B., & Yang, G.-Z. (2016). *Deep learning for human activity recognition: A resource efficient implementation on low-power devices*. In *2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN)* (pp. 71–76). IEEE. doi:10.1109/BSN.2016.7516235

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, *1*(5), 206–215. doi:10.1038/s42256-019-0048-x

Sergi, F., Krebs, H. I., Groissier, B., Rykman, A., Guglielmelli, E., Volpe, B. T., & Schaechter, J. D. (2011). *Predicting efficacy of robot-aided rehabilitation in chronic stroke patients using an MRI-compatible robotic device*. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 7470–7473). IEEE. doi:10.1109/IEMBS.2011.6091843

Takahashi, C. D., Der-Yeghiaian, L., Le, V., Motiwala, R. R., & Cramer, S. C. (2008). Robot-based hand motor therapy after stroke. *Brain*, *131*(2), 425–437. doi:10.1093/brain/awm311

Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, *25*(1), 44–56. doi:10.1038/s41591-018-0300-7

İş sağlığı uygulamalarında yapay zeka kullanımı: kullanım alanları, fırsatlar, sınırlılıklar ve etik boyutlar

Seda Budak[1], Nergis Kayacan Başer[2*]

[1]İş Sağlığı Güvenliği Yüksek Lisansı Tezli Yüksek Lisans Öğrencisi, Bandırma Onyedi Eylül Üniversitesi Lisans Üstü Eğitim Enstitüsü, Bandırma, Balıkesir. email: sedabdk204@gmail.com ORCID: 0009-0001-2419-6154

[2]Dr. Öğretim Üyesi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi Halk Sağlığı ABD, Bandırma, Balıkesir. email: nkayacan@bandirma.edu.tr ORCID: 0000-0003-1922-5835. *corresponding author

Özet

İş sağlığı uygulamalarında yapay zeka (YZ) kullanımı son yıllarda hızla genişlemiş; risk tahmini, tehlike saptama, ergonomik değerlendirme, sağlık gözetimi, meslek hastalıklarının erken tanısı ve psikososyal risklerin izlenmesi gibi çok sayıda alanda yeni olanaklar ortaya çıkarmıştır. Sensör tabanlı izlem sistemleri, giyilebilir teknolojiler, bilgisayarlı görü, doğal dil işleme ve makine öğrenmesi yöntemleri; iş kazalarının önlenmesi, çevresel maruziyetlerin daha dinamik biçimde değerlendirilmesi ve karar destek süreçlerinin güçlendirilmesi açısından dikkat çekmektedir. Bununla birlikte, veri kalitesi, dış doğrulama eksikliği, algoritmik yanlılık, mahremiyet ihlali, sürekli gözetim riski ve hukuki sorumluluk paylaşımı gibi sorunlar YZ'nin iş sağlığı alanında yaygın ve güvenli kullanımının önündeki başlıca engellerdir. Bu derlemede, iş sağlığı uygulamalarında YZ'nin güncel kullanım alanları yarı sistematik anlatı derlemesi yaklaşımıyla ele alınmış; potansiyel yararlar, uygulama sınırlılıkları ve etik yönetişim gereksinimleri tartışılmıştır. Mevcut kanıtlar, YZ'nin iş sağlığı profesyonellerinin yerini almaktan çok, risk temelli kararları destekleyen ve önleyici yaklaşımı güçlendiren bir araç olarak konumlandırılması gerektiğini göstermektedir. Başarılı uygulama için insan denetimi, açıklanabilirlik, yüksek kaliteli veri altyapısı ve çalışan haklarını gözeten yönetişim çerçevesi esastır.

Anahtar kelimeler: Etik, İş Güvenliği, İş Sağlığı, Sağlık Gözetimi

Abstract

The use of artificial intelligence (AI) in occupational health practice has expanded rapidly in recent years, creating new opportunities in a wide range of areas, including risk prediction, hazard detection, ergonomic assessment, health surveillance, early diagnosis of occupational diseases, and monitoring of psychosocial risks. Sensor-based monitoring systems, wearable technologies, computer vision, natural language processing, and machine learning methods have attracted increasing attention for their potential to prevent occupational accidents, enable more dynamic assessment of environmental exposures, and strengthen decision-support processes. However, issues such as data quality, lack of external validation, algorithmic bias, privacy violations, the risk of continuous surveillance, and the distribution of legal responsibility remain major barriers to the widespread and safe implementation of AI in occupational health. In this review, the current application areas of AI in occupational health practice were examined using a semi-systematic narrative review approach, and its potential benefits, implementation limitations, and ethical governance requirements were discussed. Current evidence suggests that AI should be positioned not as a replacement for occupational health professionals, but rather as a tool that supports risk-based decision-making and strengthens preventive approaches. Successful implementation requires human oversight, explainability, high-quality data infrastructure, and governance frameworks that protect workers' rights.

Keywords: Ethics, Occupational Safety, Occupational Health, Health Surveillance

Giriş

İş sağlığı, çalışanların fiziksel, ruhsal ve sosyal iyilik hâlinin korunmasını ve geliştirilmesini amaçlayan çok disiplinli bir uygulama alanıdır. Klasik iş sağlığı pratiği; risk değerlendirmesi, ortam ölçümleri, periyodik sağlık muayeneleri, iş kazası incelemeleri ve meslek hastalığı izlemi üzerine kuruludur. Ancak çalışma yaşamının dijitalleşmesiyle birlikte sensörler, giyilebilir cihazlar, görüntüleme sistemleri, elektronik sağlık kayıtları ve idari veri tabanları üzerinden üretilen veri miktarı hızla artmıştır. Bu veri yoğunluğu, örüntü tanıma, sınıflama ve tahmin yapma kapasitesi yüksek olan yapay zeka (YZ) uygulamalarını iş sağlığı alanı açısından giderek daha cazip hâle getirmiştir (Williams, 2023; Shah & Mishra, 2024; El-Helaly, 2024; Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025).

YZ, iş sağlığı bağlamında yalnızca teknolojik yenilik değil, aynı zamanda önleyici sağlık yaklaşımını yeniden şekillendirme potansiyeli taşıyan bir araçtır. Güncel literatür, YZ'nin iş kazası ve yaralanma riskinin tahmini, güvensiz davranışların saptanması, ergonomik zorlanmanın değerlendirilmesi, radyolojik taramaların desteklenmesi, uzun süreli iş göremezlik riskinin modellenmesi ve işyeri sağlık geliştirme programlarının kişiselleştirilmesi gibi farklı kullanım alanlarında geliştiğini göstermektedir (Shah & Mishra, 2024; El-Helaly, 2024; Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025). Bununla birlikte, yüksek doğruluk oranları bildiren çalışmaların önemli bir bölümü hâlâ kontrollü veri setlerine dayanmakta; gerçek yaşam koşullarında etkinlik, genellenebilirlik ve etik uygunluk açısından daha güçlü kanıta ihtiyaç duyulmaktadır (Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025).

Bu derlemenin amacı, iş sağlığı uygulamalarında YZ'nin güncel kullanım alanlarını kapsamlı biçimde değerlendirmek; bu teknolojilerin sunduğu fırsatları, temel sınırlılıklarını ve etik-hukuki sonuçlarını güncel ve erişilebilir literatür temelinde tartışmaktır.

Yapay Zeka ve İş Sağlığı

YZ, insan zekâsı gerektiren belirli bilişsel süreçlerin veri temelli algoritmalarla yürütülmesi olarak tanımlanabilir. İş sağlığında en sık karşılaşılan alt alanlar; makine öğrenmesi, derin öğrenme, doğal dil işleme ve bilgisayarlı görüdür. Makine öğrenmesi, geçmiş veri örüntülerinden hareketle geleceğe ilişkin tahmin yapmayı; derin öğrenme, özellikle görüntü ve karmaşık sensör verilerinin analizinde yüksek performans göstermeyi; doğal dil işleme ise olay kayıtları, klinik notlar veya serbest metin raporlarının yapılandırılmasını sağlamaktadır. Bu yöntemler iş sağlığında maruziyet, olay, hastalık ve davranış verilerinin birlikte değerlendirilmesine olanak tanımaktadır (Williams, 2023; Shah & Mishra, 2024; El-Helaly, 2024; Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025).

İş sağlığı uygulamalarında YZ'nin değeri, yalnızca teknik doğruluğundan değil; önleyici kararları destekleme kapasitesinden kaynaklanır. Başka bir deyişle, YZ'nin en anlamlı rolü "kim risk altında olabilir?", "hangi iş süreçleri öncelikli müdahale gerektiriyor?" ve "hangi çalışan gruplarında daha sıkı sağlık gözetimi gerekebilir?" gibi sorulara daha erken yanıt üretebilmesidir. Bu nedenle iş sağlığında YZ, klinik kararın yerine geçen otonom bir sistem olarak değil, profesyonel değerlendirmeyi güçlendiren bir karar destek altyapısı olarak konumlandırılmalıdır (Shah & Mishra, 2024; El-Helaly, 2024; Chaudhry & Choudhury, 2024).

İş Sağlığı Uygulamalarında Başlıca Kullanım Alanları

1. Risk tahmini ve tehlike saptama

İş sağlığında YZ'nin en sık vurgulanan kullanım alanlarından biri, iş kazası ve tehlike riskinin tahmin edilmesidir. Sistematik derlemeler, kamera tabanlı izleme sistemleri, sensör verileri, olay kayıtları ve üretim akış bilgileri kullanılarak güvensiz davranışların, tehlikeli bölge ihlallerinin ve potansiyel olayların öngörülebildiğini göstermektedir. Özellikle derin öğrenme ve bilgisayarlı görü temelli sistemler, kişisel koruyucu donanım kullanımının izlenmesi ve tehlikeli durumların otomatik saptanması açısından dikkat çekmektedir (Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025). Bununla birlikte, yakın tarihli bir sistematik derleme, YZ kullanan iş sağlığı ve güvenliği araçlarının işçi yaralanması veya hastalık yükü üzerinde ölçülebilir etkisini gösteren çalışma sayısının halen sınırlı olduğunu bildirmiştir. Bu durum, teknik performans ile sahadaki gerçek sağlık etkisi arasında hâlâ önemli bir boşluk bulunduğunu göstermektedir (Jetha et al., 2025).

Bu alandaki temel avantaj, klasik risk değerlendirmesinin çoğu zaman periyodik ve insan gözlemine bağımlı olmasına karşılık, YZ destekli sistemlerin daha sürekli ve daha hassas izlem yapabilmesidir. Ancak iş sağlığı açısından asıl belirleyici soru, modelin yalnızca riski sınıflandırması değil, bunun gerçekten olay sıklığını ve şiddetini azaltıp azaltmadığıdır. Bu nedenle bundan sonraki araştırmaların algoritma doğruluğuna ek olarak prospektif etki analizlerine yönelmesi gerekmektedir (Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025).

2. Giyilebilir teknolojiler ve sürekli izlem

Giyilebilir cihazlar, iş sağlığında YZ kullanımının en dinamik alanlarından biridir. Bu sistemler; hareket, postür, ivme, kas aktivitesi, sıcaklık, gürültü, hava kalitesi ve konum gibi değişkenleri sürekli olarak kaydedebilmektedir. 2024 tarihli sistematik derleme, işle ilişkili kas-iskelet sistemi risklerinin değerlendirilmesinde giyilebilir sistemlerin giderek arttığını ve nicel veri üretme kapasitesi nedeniyle ergonomik risk değerlendirmesine önemli katkı sunduğunu ortaya koymuştur (Motta et al., 2024). 2025 yılında yayımlanan başka bir sistematik derleme ise yük kaldırma ve taşıma görevlerinin sınıflandırılmasında giyilebilir sensörler ile makine öğrenmesi algoritmalarının birlikte kullanımının, fiziksel yük ve göreve özgü zorlanmanın nesnel biçimde değerlendirilmesine olanak sağladığını göstermiştir (Peters et al., 2025).

Bu teknolojilerin iş sağlığı açısından önemi, gözle fark edilmesi güç mikro düzey hareket örüntülerini yakalayabilmesidir. Böylece ergonomik zorlanma, tekrarlayan yüklenme ve uygunsuz postür gibi riskler yalnızca uzman gözlemine değil, sürekli veri akışına dayalı olarak analiz edilebilir. Bununla birlikte çalışan kabulü, mahremiyet, cihaz konforu ve verinin hangi amaçla kullanılacağı gibi unsurlar bu teknolojilerin benimsenmesinde belirleyicidir. 2024 tarihli bir kesitsel saha çalışması, çalışanların giyilebilir sensörlere yaklaşımında güven, veri kullanımı ve izlenme hissinin kritik rol oynadığını göstermiştir (Mueller et al., 2024). Bu bulgu, teknik doğruluğun tek başına yeterli olmadığını, sosyal kabulün de iş sağlığı teknolojilerinde temel bir belirleyici olduğunu göstermektedir.

3. Bilgisayarlı görü ve ergonomik risk değerlendirmesi

Bilgisayarlı görü temelli ergonomik değerlendirme, iş sağlığında YZ'nin somut ve uygulanabilir alanlarından biridir. İnsan poz tahmini teknikleri kullanılarak RULA ve REBA benzeri geleneksel gözlemsel araçların otomatikleştirilmesi mümkün hâle gelmiştir. 2025 tarihli derleme, insan poz tahmini tabanlı ergonomik risk değerlendirmesinde 2D ve 3D yöntemlerin, derin öğrenmenin ve hareket takibi algoritmalarının giderek daha fazla kullanıldığını bildirmektedir (Deshpande et al., 2025). Bu sistemler, aynı iş istasyonunda

yinelenen gözlemlerin standardize edilmesi, gözlemciler arası değişkenliğin azaltılması ve yüksek riskli görevlerin daha nesnel karşılaştırılması açısından değerlidir.

Ancak ergonomik değerlendirmede saha koşulları önemli güçlükler yaratmaktadır. Yetersiz aydınlatma, vücut bölümlerinin birbirini kapatması, çoklu çalışan etkileşimi, kişisel koruyucu ekipmanların görüntüyü bozması ve iş süreçlerinin çeşitliliği algoritmaların performansını düşürebilir. Bu nedenle YZ tabanlı ergonomik analiz, tek başına nihai karar verici değil; ergonomist ve işyeri hekiminin değerlendirmesini destekleyen bir araç olarak kullanılmalıdır (Peters et al., 2025; Deshpande et al., 2025).

4. Meslek hastalıklarının taranması ve tanısal destek

Meslek hastalıklarında YZ'nin en dikkat çekici uygulama alanı radyolojik görüntülemedir. Özellikle pnömokonyoz için geliştirilen derin öğrenme modelleri, dijital akciğer grafilerinde yüksek doğruluk ve ayırt edicilik gösterebilmiştir. 2024 yılında yayımlanan bir çalışmada 49.872 akciğer grafisi ile eğitilen bir modelin doğruluk oranı %95, duyarlılığı %100 ve AUC değeri %94,7 olarak bildirilmiştir (Li et al., 2024). Başka bir 2024 çalışması da dijital akciğer grafileri üzerinden geliştirilen derin öğrenme yaklaşımlarının pnömokonyozun taranması ve tanısal sınıflandırılmasında umut verici performans sergilediğini göstermiştir (Zhang et al., 2024).

Bu bulgular, YZ'nin özellikle meslek hastalıkları taramalarında ikinci okuyucu veya ön eleme aracı olarak kullanılabileceğini düşündürmektedir. Ancak meslek hastalığı tanısı, yalnızca görüntü bulgusuna dayanmaz; iş anamnezi, maruziyet düzeyi, klinik muayene, fonksiyon testleri ve ayırıcı tanının birlikte değerlendirilmesini gerektirir. Bu nedenle tanısal destek sistemlerinin işlevi, klinik kararı otomatikleştirmekten çok, uzman değerlendirmesini hızlandırmak ve standardize etmektir (Shah & Mishra, 2024; Chaudhry & Choudhury, 2024; Li et al., 2024; Zhang et al., 2024).

5. İşe dönüş, devamsızlık ve psikososyal risklerin modellenmesi

İş sağlığında YZ'nin gelişen başka bir alanı, devamsızlık, işe dönüş ve psikososyal risklerin öngörülmesidir. Güncel literatür, YZ uygulamalarının yalnızca fiziksel risklere değil; ruh sağlığı, iş stresi, tükenmişlik ve uzun süreli iş göremezlik gibi sonuçlara da yöneldiğini göstermektedir (Chaudhry & Choudhury, 2024; Lange et al., 2024; Varje et al., 2026). 2025 yılında yayımlanan büyük ölçekli bir çalışma, Brief Job Stress Questionnaire verilerini kullanarak ruhsal bozukluklara bağlı uzun süreli iş göremezliği tahmin etmeye çalışmış ve makine öğrenmesi modellerinin öngörü potansiyeli olduğunu, ancak performansın hâlâ sınırlı kaldığını bildirmiştir (Iwasaki et al., 2025). Bunun anlamı, psikososyal risk alanında YZ'nin yardımcı bir araç olabileceği, ancak kurumsal ya da klinik kararın tek belirleyicisi hâline gelmemesi gerektiğidir.

İşte ruh sağlığına odaklanan 2026 tarihli kapsam incelemesi, yayın sayısında özellikle 2020 sonrasında belirgin artış olduğunu, fakat çalışmaların çoğunun kesitsel nitelikte kaldığını ve dış doğrulama açısından sınırlı olduğunu vurgulamıştır (Varje et al., 2026). Bu durum, iş sağlığında psikososyal risk tahmininin halen metodolojik olarak gelişmekte olduğunu ve daha güçlü epidemiyolojik tasarımlara ihtiyaç bulunduğunu göstermektedir.

6. İşyeri sağlık geliştirme ve önleme programları

YZ, işyeri sağlık geliştirme programlarının kişiselleştirilmesinde de kullanılmaktadır. Sistematik kapsam incelemesi, YZ'nin bu alanda davranış değişikliği stratejilerini uyarlama, kişiselleştirilmiş öneriler sunma ve önleyici programları bireysel risk profiline göre şekillendirme amacıyla kullanıldığını göstermiştir (Lange et al., 2024). Bu yaklaşım, özellikle kronik hastalık riskleri, uyku düzeni, fiziksel aktivite ve ruh sağlığı gibi başlıklarda

kurumsal programların daha hedefli hâle gelmesine yardımcı olabilir. Bununla birlikte işyeri sağlık geliştirme ile işveren gözetimi arasındaki sınırın bulanıklaşmaması kritik önemdedir. Çalışanın yararına tasarlanan dijital sistemlerin performans kontrolüne dönüşmesi, iş sağlığı etiği açısından ciddi sakıncalar doğurabilir (Lange et al., 2024; Niehaus et al., 2022; Röttgen et al., 2024; Nilsson et al., 2025; International Labour Organization, 2025).

Yapay Zekânın Sunduğu Fırsatlar

YZ'nin iş sağlığına sunduğu en büyük fırsat, önleyici yaklaşımı güçlendirmesidir. Riskin olaydan önce tahmin edilmesi, maruziyetin gerçek zamanlı izlenmesi ve yüksek riskli süreçlerin erken belirlenmesi sayesinde müdahaleler daha hedefli hâle gelebilir. Ayrıca giyilebilir sistemler, çevresel sensörler ve elektronik sağlık kayıtlarının birlikte kullanılması; çok katmanlı risk profillerinin oluşturulmasına ve sınırlı kaynakların öncelikli alanlara yönlendirilmesine katkı sağlayabilir (Shah & Mishra, 2024; El-Helaly, 2024; Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Motta et al., 2024; Peters et al., 2025).

Diğer önemli fırsat ise, standardizasyon ve iş yükünün azaltılmasıdır. Ergonomik değerlendirme, radyolojik tarama ve olay sınıflandırması gibi emek yoğun süreçlerde YZ, yineleyen görevleri hızlandırabilir, gözlemciler arası değişkenliği azaltabilir ve uzmanların daha karmaşık klinik ve yönetsel kararlara odaklanmasını sağlayabilir. Özellikle iş sağlığı hizmetlerine erişimin sınırlı olduğu alanlarda ön eleme ve risk önceliklendirme sistemleri yararlı olabilir. Bununla birlikte bu yarar, yalnızca insan uzmanlığını tamamlayan ve şeffaf biçimde çalışan sistemlerle sürdürülebilir hâle gelebilir (Williams, 2023; Chaudhry & Choudhury, 2024; Li et al., 2024; International Labour Organization, 2025).

Sınırlılıklar ve Uygulama Güçlükleri

İş sağlığında YZ'ye ilişkin literatürün en önemli zayıflıklarından biri, çalışma tasarımlarındaki heterojenliktir. Çoğu araştırma tek merkezli, sınırlı örneklemli veya kontrollü veri setlerine dayalıdır. Kullanılan veri türleri, hedef sonuçlar ve performans ölçütleri büyük farklılık göstermekte; bu da sonuçların karşılaştırılmasını ve genellenmesini güçleştirmektedir. Güncel sistematik derlemeler, dış doğrulama eksikliği, açıklanabilirlik yetersizliği ve gerçek saha koşullarında test azlığını rutine geçişin önündeki temel engeller olarak tanımlamaktadır (Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025).

Yüksek doğruluk oranları iş sağlığı açısından tek başına yeterli değildir. Yanlış negatif sonuçlar ciddi maruziyetlerin, yaklaşan iş kazalarının veya meslek hastalıklarının gözden kaçmasına neden olabilir; yanlış pozitif sonuçlar ise gereksiz yönlendirme, aşırı tarama ve kurumsal kaynak kaybı yaratabilir. Bu nedenle performans değerlendirmesinde yalnızca AUC veya doğruluk gibi metriklere değil, gerçek uygulama sonuçlarına da odaklanmak gerekir. İş sağlığında YZ'nin değeri, algoritmanın ne kadar doğru olduğundan çok, çalışan sağlığını gerçekten iyileştirip iyileştirmediği ile ölçülmelidir (Chaudhry & Choudhury, 2024; Jetha et al., 2025; Iwasaki et al., 2025).

Etik, Hukuki ve Sosyal Boyut

İş sağlığında YZ kullanımının belki de en kritik yönü etik yönetişimdir. Giyilebilir cihazlar, konum verisi, video analizi ve davranış örüntülerinin algoritmik olarak değerlendirilmesi; mahremiyet, özerklik ve sürekli gözetim tartışmalarını beraberinde getirmektedir. "Human in control" yaklaşımı üzerine yapılan çalışmalar, otomasyon arttıkça çalışan kontrolünün ve özerkliğinin zayıflayabileceğini; bunun da psikososyal sağlık üzerinde etkiler yaratabileceğini göstermektedir (Niehaus et al., 2022). Güncel çalışmalar ve kavramsal incelemeler de algoritmik yönetimin iş yoğunluğu, düşük kontrol, psikolojik sıkıntı, kas-

iskelet sistemi ağrıları ve iş kazaları ile ilişkili olabileceğini bildirmektedir (Röttgen et al., 2024; Nilsson et al., 2025).

Bu nedenle YZ, iş sağlığı açısından yalnızca koruyucu bir teknoloji değil, aynı zamanda yeni bir maruziyet ve yeni bir düzenleme alanıdır. ILO'nun 2025 küresel raporu, otomasyon, akıllı izleme sistemleri ve algoritmik yönetimin hem fırsatlar hem de yeni iş sağlığı riskleri yarattığını vurgulamaktadır (International Labour Organization, 2025). WHO'nun sağlık alanında YZ etik rehberi, insan özerkliğinin korunması, şeffaflık, hesap verebilirlik, kapsayıcılık ve kamu yararını temel ilkeler olarak tanımlamıştır (World Health Organization, 2021). WHO'nun 2025 tarihli büyük çok modlu modellere ilişkin rehberi de veri güvenliği, önyargı, yanlış bilgi üretimi ve yönetişim gereksinimleri üzerinde özellikle durmaktadır (World Health Organization, 2025). İş sağlığı uygulamaları açısından bu belgelerin ortak mesajı açıktır: çalışan verileri amaç sınırlılığı ile işlenmeli, veri minimizasyonu gözetilmeli, algoritmik karar süreçleri denetlenebilir olmalı ve profesyonel insan kararı süreç dışına itilmemelidir (International Labour Organization, 2025; World Health Organization, 2021, 2025).

Gelecek Perspektifi

Önümüzdeki dönemde iş sağlığında YZ'nin en değerli kullanım biçimi, insan uzmanlığının yerine geçmek değil; onu güçlendiren hibrit karar destek sistemleri sunmak olacaktır. Gerçek zamanlı sensör verileri, elektronik sağlık kayıtları, ergonomik görüntü analizi ve psikososyal göstergelerin birlikte kullanılmasıyla daha hassas ve çok boyutlu risk profilleri geliştirilebilir. Ancak bunun için çok merkezli veri tabanları, ortak raporlama standartları, farklı sektörlerde saha doğrulaması ve açıklanabilir modelleme yaklaşımları gereklidir (Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025; Motta et al., 2024; Peters et al., 2025; Varje et al., 2026).

Ayrıca gelecekteki araştırmaların yalnızca "hangi algoritma daha doğru?" sorusuna değil, "hangi sistem çalışan sağlığını gerçekten iyileştiriyor?" sorusuna yanıt araması gerekir. Bu nedenle prospektif, çok merkezli, uygulama bilimi yaklaşımını içeren ve klinik-sonuç odaklı çalışmalar öncelikli olmalıdır. Özellikle düşük ve orta gelirli ülkelerde maliyet-etkililik, uygulanabilirlik ve çalışan kabulü konuları daha fazla araştırılmalıdır (Chaudhry & Choudhury, 2024; Jetha et al., 2025; International Labour Organization, 2025).

Sonuç

Mevcut kanıtlar, YZ'nin iş sağlığı uygulamalarında güçlü fakat dikkatle yönetilmesi gereken bir dönüşüm aracı olduğunu göstermektedir. Risk tahmini, ergonomik analiz, giyilebilir sistemlerle izlem, radyolojik karar desteği ve psikososyal risk modellemesi gibi alanlarda önemli ilerlemeler kaydedilmiştir. Bununla birlikte alan henüz tüm sektörlerde ve tüm uygulama düzeylerinde olgunlaşmış değildir. Çok merkezli doğrulama, prospektif saha araştırmaları, etki değerlendirmesi ve etik yönetişim açısından önemli araştırma boşlukları devam etmektedir (Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; Jetha et al., 2025; Varje et al., 2026; International Labour Organization, 2025).

Sonuç olarak YZ, işyeri hekiminin, iş güvenliği uzmanının veya ergonomistin yerini alan bir teknoloji olarak değil; önleyici iş sağlığı yaklaşımını güçlendiren, daha erken uyarı sağlayan ve karar desteği sunan bir araç olarak değerlendirilmelidir. Bu dönüşümün güvenli, adil ve sürdürülebilir olabilmesi için teknik performans kadar insan denetimi, veri koruma, çalışan katılımı ve şeffaf yönetişim de merkezi öneme sahiptir (Williams, 2023; Shah & Mishra, 2024; El-Helaly, 2024; Chaudhry & Choudhury, 2024; Armenteros-Cosme et al., 2025; International Labour Organization, 2025; World Health Organization, 2021, 2025).

Kaynakça

Armenteros-Cosme, P., Arias-González, M., Alonso-Rollán, S., et al. (2025). Advancements in artificial intelligence and machine learning for occupational risk prevention: A systematic review on predictive risk modeling and prevention strategies. *Sensors, 25*(17), 5419. doi:10.3390/s25175419

Chaudhry, Z. S., & Choudhury, A. (2024). Clinical applications of artificial intelligence in occupational health: A systematic literature review. *Journal of Occupational and Environmental Medicine, 66*(12), 943–955. doi:10.1097/JOM.0000000000003212

Deshpande, U. U., Araujo, S. D. C. S., Deshpande, S., Kangralkar, V., Patil, R., Chate, R. A. A., et al. (2025). A review of machine learning techniques for ergonomic risk assessment based on human pose estimation. *Discover Artificial Intelligence, 5*, 287. doi:10.1007/s44163-025-00566-5

El-Helaly, M. (2024). Artificial intelligence and occupational health and safety, benefits and drawbacks. *La Medicina del Lavoro, 115*(2), e2024014. doi:10.23749/mdl.v115i2.15835

International Labour Organization. (2025). *Revolutionizing health and safety: The role of AI and digitalization at work: Global report*. Geneva, Switzerland: Author. doi:10.54394/KNZE0733

Iwasaki, S., Deguchi, Y., Okura, S., Maekubo, K., Matsunaga, A., & Inoue, K. (2025). Machine learning prediction of long-term sickness absence due to mental disorders using Brief Job Stress Questionnaire data. *Scientific Reports, 16*(1), 2908. doi:10.1038/s41598-025-32857-3

Jetha, A., Bakhtari, H., Irvin, E., Biswas, A., Smith, M. J., Mustard, C., et al. (2025). Do occupational health and safety tools that utilize artificial intelligence have a measurable impact on worker injury or illness? Findings from a systematic review. *Systematic Reviews, 14*(1), 146. doi:10.1186/s13643-025-02869-1

Lange, M., Löwe, A., Kayser, I., & Schaller, A. (2024). Approaches for the use of AI in workplace health promotion and prevention: Systematic scoping review. *JMIR AI, 3*, e53506. doi:10.2196/53506

Li, X., Xu, M., Yan, Z., Xia, F., Li, S., Zhang, Y., et al. (2024). Deep convolutional network-based chest radiographs screening model for pneumoconiosis. *Frontiers in Medicine, 11*, 1290729. doi:10.3389/fmed.2024.1290729

Motta, F., Varrecchia, T., Chini, G., Ranavolo, A., & Galli, M. (2024). The use of wearable systems for assessing work-related risks related to the musculoskeletal system: A systematic review. *International Journal of Environmental Research and Public Health, 21*(12), 1567. doi:10.3390/ijerph21121567

Mueller, W., Smith, A., Kuijpers, E., Pronk, A., & Loh, M. (2024). Worker perspectives on improving occupational health and safety using wearable sensors: A cross-sectional survey. *Annals of Work Exposures and Health, 68*(8), 867–873. doi:10.1093/annweh/wxae057

Niehaus, S., Hartwig, M., Rosen, P. H., & Wischniewski, S. (2022). An occupational safety and health perspective on human in control and AI. *Frontiers in Artificial Intelligence, 5*, 868382. doi:10.3389/frai.2022.868382

Nilsson, K. H., Bodin, T., Strauss, P., Matilla-Santander, N., Badarin, K., Brulin, E., et al. (2025). Algorithmic management is associated with psychological distress, musculoskeletal

pain, and occupational accidents: A cross-sectional study in logistics. *International Archives of Occupational and Environmental Health, 98*(9–10), 929–942. doi:10.1007/s00420-025-02180-5

Peters, M., Potthast, W., Wischniewski, S., & Komnik, I. (2025). Wearable sensors for classification of load-handling tasks with machine learning algorithms in occupational safety and health: A systematic literature review. *Ergonomics*, 1–21. doi:10.1080/00140139.2025.2486193

Röttgen, C., Herbig, B., Weinmann, T., & Müller, A. (2024). Algorithmic management and human-centered task design: A conceptual synthesis from the perspective of action regulation and sociomaterial systems theory. *Frontiers in Artificial Intelligence, 7*, 1441497. doi:10.3389/frai.2024.1441497

Shah, I. A., & Mishra, S. (2024). Artificial intelligence in advancing occupational health and safety: An encapsulation of developments. *Journal of Occupational Health, 66*(1), uiad017. doi:10.1093/joccuh/uiad017

Varje, P., Väänänen, A., Haavisto, O., et al. (2026). Machine learning in the analysis of mental health at work: A scoping review. *Journal of Occupational Health, 68*(1), uiag014. doi:10.1093/joccuh/uiag014

Williams, N. (2023). Artificial intelligence in occupational health. *Occupational Medicine, 73*(7), 449. doi:10.1093/occmed/kqad040

World Health Organization. (2021). *Ethics and governance of artificial intelligence for health*. Geneva, Switzerland: Author.

World Health Organization. (2025). *Ethics and governance of artificial intelligence for health: Guidance on large multi-modal models*. Geneva, Switzerland: Author.

Zhang, Y., Zheng, B., Zeng, F., Cheng, X., Wu, T., Peng, Y., et al. (2024). Potential of digital chest radiography-based deep learning in screening and diagnosing pneumoconiosis: An observational study. *Medicine, 103*(25), e38478. doi:10.1097/MD.0000000000038478

Beyin morfolojisinde yapay zekânın rolü: literatür derlemesi

Eda Nur Dönmez[1], Muhammet Bora Uzuner[1]

Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Anatomi ABD

Özet

Beyin, enfeksiyonlar, travmalar, inme ve tümörler gibi çeşitli hastalıklardan etkilenebilen kritik bir organdır. Klinik sonuçların değişkenliği erken tanının önemini ortaya koymaktadır. Beyin morfolojisinin değerlendirilmesinde manyetik rezonans görüntüleme (MRG) yaygın olarak kullanılmakta; kortikal kalınlık ve hacim ölçümleri önemli bilgiler sunmaktadır. Ancak bu ölçümlerin klasik yöntemlerle yapılması zaman alıcı, gözlemciye bağımlı ve tekrarlanabilirliği sınırlıdır. Bu noktada yapay zekâ (YZ) temelli yaklaşımlar nörogörüntüleme analizinde önemli katkılar sunmaktadır. Bu çalışmada, beyin morfolojisinin analizinde YZ uygulamalarının rolü literatür taraması ile değerlendirilmiştir. PubMed, Scopus ve Google Scholar veri tabanlarında belirlenen anahtar kelimeler kullanılarak ilgili çalışmalar incelenmiştir. Literatür, YZ tabanlı yöntemlerin yüksek doğruluk ve tutarlılık sağladığını göstermektedir. Ayrıca bu yöntemlerin kortikal kalınlık ölçümlerinde başarılı olduğu ve nörodejeneratif hastalıkların erken tanısına katkı sağladığı ifade edilmektedir. Bununla birlikte, veri setlerinin sınırlı olması ve modellerin yorumlanabilirliğine ilişkin sorunlar önemli sınırlılıklar arasında yer almaktadır. Sonuç olarak, yapay zekâ temelli yaklaşımların nörogörüntüleme analizinde önemli katkılar sunduğu ve gelecekte klinik uygulamalarda daha yaygın kullanılacağı öngörülmektedir.

Anahtar Kelimeler: yapay zekâ, beyin morfolojisi, manyetik rezonans görüntüleme, derin öğrenme, segmentasyon

Giriş

İnsan yaşamı için kritik öneme sahip olan beyin, enfeksiyonlar, travmalar, inme, nöbetler ve tümörler gibi çeşitli hastalıklardan etkilenebilmektedir. Bu hastalıkların klinik sonuçları tür, yerleşim ve şiddete bağlı olarak değişkenlik göstermekte olup, erken tanı ve tedavinin önemini ortaya koymaktadır. Beyin morfolojisinin analizi, yalnızca patolojik süreçlerin değil, aynı zamanda normal beyin fonksiyonlarının değerlendirilmesinde de önemli bir yer tutmaktadır (Yao et al., 2024).

Manyetik rezonans görüntüleme (MRG), beyin yapısının yüksek çözünürlükte incelenmesini sağlayan temel görüntüleme yöntemlerinden biridir. Kortikal kalınlık, gri madde yoğunluğu ve subkortikal hacimler gibi morfometrik parametreler nörolojik ve nörodejeneratif süreçlerin değerlendirilmesinde yaygın olarak kullanılmaktadır. Bununla birlikte, bu parametrelerin klasik yöntemlerle ölçülmesi çoğunlukla zaman alıcı, gözlemciye bağımlı ve tekrarlanabilirliği sınırlı süreçler içermektedir (Lundervold & Lundervold, 2019).

Bu noktada yapay zekâ, özellikle derin öğrenme temelli yaklaşımlar aracılığıyla nörogörüntüleme analizinde önemli katkılar sunmaktadır (Litjens et al., 2017; Shen et al., 2017; Ottoni et al., 2025).

Yöntem

Bu çalışma literatür taraması niteliğindedir. PubMed, Scopus ve Google Scholar veri tabanlarında ilgili çalışmalar sistematik olarak incelenmiştir. Literatür taramasında ‘“brain morphometry artificial intelligence”, “cortical thickness deep learning”, “MRI segmentation

CNN brain", "neuroanatomy artificial intelligence", "voxel-based morphometry AI" ve "brain MRI machine learning" anahtar kelimeleri kullanılmıştır.

Elde edilen çalışmalar; kullanılan yapay zekâ yöntemleri, analiz edilen morfometrik parametreler ve klinik uygulama alanları açısından değerlendirilmiş olup, özellikle yapısal MRG verilerinde kullanılan derin öğrenme temelli yaklaşımlar üzerine odaklanılmıştır. Yinelenen çalışmalar ve konu dışı yayınlar çalışma dışı bırakılmıştır.

Derleme

Yapay zekâ ve nörogörüntüleme

Yapay zekâ yöntemleri, tıbbi görüntüleme alanında büyük veri setlerinin hızlı ve doğru analizine olanak tanımaktadır. Özellikle derin öğrenme yaklaşımları, görüntü verilerinden otomatik özellik çıkarımı yaparak analiz süreçlerini iyileştirmektedir (Shen et al., 2017; Litjens et al., 2017). Son yıllarda kendi kendine denetimli öğrenme yaklaşımlarının gelişmesi, sınırlı etiketli veri ile yüksek performans elde edilmesini mümkün kılmıştır (Azizi et al., 2021).

Segmentasyon süreçleri

Beyin morfometrik analizlerin temel bileşenlerinden biri olan segmentasyon süreçlerinde, yapay zekâ yöntemlerinin etkinliği özellikle dikkat çekmektedir. Convolutional Neural Network (CNN) tabanlı modellerin yapısal MRG verilerinde anatomik yapıların segmentasyonunda etkin olduğu, nöroanatomik yapıların otomatik belirlenmesinde yüksek doğruluk ve güvenilirlik sağladığı ve analiz süreçlerini önemli ölçüde hızlandırdığı bildirilmektedir (Wachinger et al., 2018; Khan et al., 2023).

Morfometrik analiz yöntemleri

VBM ve SBM, gri madde yapısını incelemek amacıyla kullanılan nörogörüntüleme teknikleri arasında yer almaktadır. Voksel tabanlı morfometri (VBM), gri maddenin yerel hacim ve yoğunluğunun voksel bazında karşılaştırılmasına dayanan otomatik bir tüm beyin morfometrik analiz yöntemidir. Bu teknik, özellikle substantia grisea, substantia alba ve beyin omurilik sıvısındaki (BOS) hacimsel değişikliklerin değerlendirilmesinde kullanılmaktadır (Rezaeyan et al., 2023). Bu analizlerin gerçekleştirilmesinde volBrain, Computational Anatomy Toolbox, FMRIB Software Library, Statistical Parametric Mapping gibi çeşitli yazılımlar kullanılmaktadır (Çetin et al., 2025; Gaser et al., 2024).

Yüzey tabanlı morfometri (SBM) ise kortikal morfolojinin hacim, kortikal kalınlık, yüzey alanı gibi parametrelerinin analiz edilmesine olanak sağlamaktadır. Bu yöntem, özellikle kortikal yüzeyde meydana gelen morfolojik değişikliklerin incelenmesinde kullanılmaktadır (Goto et al., 2022). Yüzey tabanlı morfometri için BrainSuite, CIVET, CAT12, FreeSurfer gibi yazılımlar kullanılmaktadır (Hassan et al., 2023; Kim et al., 2024).

Region of Interest (ROI) tabanlı analiz ise beynin tamamı yerine önceden belirlenen spesifik anatomik bölgelerin değerlendirilmesine dayanan morfometrik ve fonksiyonel bir analiz yöntemidir. Bu yaklaşım, belirli beyin bölgelerindeki yapısal veya fonksiyonel değişikliklerin incelenmesini sağlamaktadır (Etzel et al., 2009).

Yapay zekâ yöntemleri

Support Vector Machine (SVM); verileri belirli sınıflara ayırmak için kullanılan bir makine öğrenmesi yöntemidir. Özellikle hasta / sağlıklı ayrımı, sınıflandırma analizleri için kullanılmaktadır.

Random Forest; çok sayıda karar ağacının birlikte çalışmasına dayanan bir makine öğrenmesi yöntemidir. Veriler arasındaki ilişkileri analiz ederek sınıflandırma ve tahmin

işlemleri gerçekleştirir (Chowdhury, 2024; Avcı et al., 2023; Valkenborg et al., 2023; Roy & Chakraborty, 2023).

Derin Öğrenme (Deep Learning) yöntemlerinin kortikal kalınlık gibi hassas ölçümlerde başarılı sonuçlar verdiği ve klasik yöntemlere kıyasla daha hızlı ve tekrarlanabilir çıktılar sunduğu gösterilmiştir (Rebsamen et al., 2020; Kumar & Singh, 2016). Literatür incelendiğinde FastSurfer, SynthSeg, TotalSegmentator gibi deep learning tabanlı yapay zekâ destekli araçlar, otomatik segmentasyon ve yapısal görüntü analizi süreçlerinde yaygın olarak kullanıldığı görülmektedir (Akinci et al., 2025; Shang et al., 2026; Suh et al., 2023; Zughayyar et al., 2025).

Yapay zekâ tabanlı yaklaşımlar, nörolojik hastalıkların değerlendirilmesinde ve özellikle nörodejeneratif süreçlerin erken tanısında önemli bir potansiyele sahiptir (Ersoy et al., 2025; Faria et al., 2024).

Sınırlılıklar ve gelecek perspektif

Yapay zekâ tabanlı yöntemlerin farklı popülasyonlar ve görüntüleme koşulları altındaki performansı henüz yeterli düzeyde ortaya konmamıştır. Veri setlerinin sınırlı olması ve farklı görüntüleme protokollerinin kullanılması, elde edilen sonuçların genellenebilirliğini kısıtlayan başlıca faktörler arasında yer almaktadır (Ottoni et al., 2025). Ayrıca, bu modellerin yorumlanabilirliğinin sınırlı olması ve karar süreçlerinin tam olarak açıklanamaması klinik güvenilirlik açısından önemli bir sınırlılıktır (Shen et al., 2017). Gelişmiş makine öğrenimi modellerinde sık karşılaşılan temel sorunlardan biri, "kara kutu" problemi olarak tanımlanan sınırlı yorumlanabilirlik durumudur. Modellerin karar süreçlerinin tam olarak açıklanamaması, elde edilen sonuçların değerlendirilmesini ve klinik açıdan yorumlanmasını zorlaştırabilmektedir (Xu & Shuttleworth, 2024).

Bu doğrultuda, SHAP (Shapley Additive Explanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi Açıklanabilir Yapay Zekâ (Explainable Artificial Intelligence, XAI) yöntemleri, yapay zekâ modellerinin karar süreçlerinin daha anlaşılır hale getirilmesi amacıyla geliştirilmektedir (Takefuji et al., 2026; Chowdhury et al., 2021; Ashraf et al., 2024).

Sonuç

Yapay zekâ, nörogörüntüleme analizinde temel bir yaklaşım haline gelmektedir. Hız, doğruluk ve tekrarlanabilirlik açısından sunduğu avantajlar, bu yöntemlerin giderek daha yaygın kullanılmasına olanak tanımaktadır (Ottoni et al., 2025). Gelecekte, daha geniş veri setleri ve klinik doğrulaması yapılmış çalışmalar ile bu yöntemlerin klinik uygulamalarda daha etkin kullanılacağı öngörülmektedir (Ersoy et al., 2025).

Referanslar

Ashraf, K., Nawar, S., Hosen, M. H., Islam, M. T., & Uddin, M. N. (2024, March). Beyond the black box: employing LIME and SHAP for transparent health predictions with machine learning models. In *2024 International Conference on Advances in Computing, Communication, Electrical, and Smart Systems (iCACCESS)* (pp. 1-6). IEEE.

Akinci D'Antonoli, T., Berger, L. K., Indrakanti, A. K., Vishwanathan, N., Weiss, J., Jung, M., ... & Wasserthal, J. (2025). TotalSegmentator MRI: robust sequence-independent segmentation of multiple anatomic structures in MRI. *Radiology*, *314*(2), e241613.

Avcı, C., Budak, M., Yağmur, N., & Balçık, F. (2023). Comparison between random forest and support vector machine algorithms for LULC classification. *International Journal of Engineering and Geosciences, 8*(1), 1–10.

Azizi, S., Mustafa, B., Ryan, F., Beaver, Z., Freyberg, J., Deaton, J., et al. (2021). Big self-supervised models advance medical image classification. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 3458–3468. https://doi.org/10.1109/ICCV48922.2021.00346

Chowdhury, M. S. (2024). Comparison of accuracy and reliability of random forest, support vector machine, artificial neural network and maximum likelihood method in land use/cover classification of urban setting. *Environmental Challenges, 14*, 100800.

Chowdhury, K. R., Sil, A., & Shukla, S. R. (2021, April). Explaining a black-box sentiment analysis model with local interpretable model diagnostics explanation (LIME). In *International conference on advances in computing and data sciences* (pp. 90-101). Cham: Springer International Publishing.

Çetin, S. (2025). *Radıologıcal Map Of Anatomy: Measurement Technıques From Imagıng*. Health Scıences, 139.

Ersoy, S., Ersoy, E. H., Danış, A., & Türkoğlu, S. A. (2025). Trends and global productivity in artificial intelligence research in clinical neurology and neuroimaging: A bibliometric analysis from 1980 to 2024. *Cerebral Cortex, 35*(6), bhaf148. https://doi.org/10.1093/cercor/bhaf148

Etzel, J. A., Gazzola, V., & Keysers, C. (2009). An introduction to anatomical ROI-based fMRI classification analysis. *Brain Research, 1282*, 114–125.

Faria, A. L., Almeida, Y., Branco, D., Câmara, J., Cameirão, M., Ferreira, L., et al. (2024). NeuroAIreh@b: An artificial intelligence-based methodology for personalized and adaptive neurorehabilitation. *Frontiers in Neurology, 14*, 1258323. https://doi.org/10.3389/fneur.2023.1258323

Gaser, C., Dahnke, R., Thompson, P. M., Kurth, F., Luders, E., & Alzheimer's Disease Neuroimaging Initiative. (2024). CAT: A computational anatomy toolbox for the analysis of structural MRI data. *GigaScience, 13*, giae049.

Hassan, A. A. A., Azab, A. O., Ahmed, H. M., Mohamed, L. M. A. M., Adel, M., & El-Basmy, A. A. (2023). Cross-platform comparison of precision and time effectiveness of automated versus semi-automated brain volumetric measurements in healthy Egyptian adults. *Egyptian Journal of Radiology and Nuclear Medicine, 54*(1), 144.

Khan, M. K. H., Guo, W., Liu, J., Dong, F., Li, Z., Patterson, T. A., & Hong, H. (2023). Machine learning and deep learning for brain tumor MRI image segmentation. *Experimental Biology and Medicine, 248*(21), 1974–1992. https://doi.org/10.1177/15353702231214259

Kim, Y., Joshi, A. A., Choi, S., Joshi, S. H., Bhushan, C., Varadarajan, D., ... & Shattuck, D. W. (2024). BrainSuite BIDS App: containerized workflows for MRI analysis. *bioRxiv*, 2023–03.

Kumar, A., & Singh, P. (2016). Deep learning for image processing applications. *Procedia Computer Science, 93*, 41–48. https://doi.org/10.1016/j.procs.2016.09.407

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep

learning in medical image analysis. *Medical Image Analysis, 42*, 60–88. https://doi.org/10.1016/j.media.2017.07.005

Lundervold, A. S., & Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on MRI. *Zeitschrift für Medizinische Physik, 29*(2), 102–127. https://doi.org/10.1016/j.zemedi.2018.11.002

Ottoni, M., Kasperczuk, A., & Tavora, L. M. N. (2025). Machine learning in MRI brain imaging: A review of methods, challenges, and future directions. *Diagnostics, 15*(21), 2692. https://doi.org/10.3390/diagnostics15212692

Rebsamen, M., Rummel, C., Suter, Y., Wiest, R., Reyes, M., & Bach Cuadra, M. (2020). Direct cortical thickness estimation using deep learning-based anatomy segmentation and cortex parcellation. *Human Brain Mapping, 41*(17), 4804–4814. https://doi.org/10.1002/hbm.25159

Rezaeyan, A., Asadi, S., Kamrava, S. K., & Zare-Sadeghi, A. (2023). Brain structural analysis in patients with post-traumatic anosmia: Voxel-based and surface-based morphometry. *Journal of Neuroradiology, 50*(5), 482–491.

Roy, A., & Chakraborty, S. (2023). Support vector machine in structural reliability analysis: A review. *Reliability Engineering & System Safety, 233*, 109126.

Shang, Z., Kaandorp, M., Payette, K., Garcia, M. F., Licandro, R., Langs, G., ... & Jakab, A. (2026). Towards contrast-and pathology-agnostic clinical fetal brain MRI segmentation using SynthSeg. *NeuroImage*, 121729.

Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering, 19*, 221–248. https://doi.org/10.1146/annurev-bioeng-071516-044442

Suh, P. S., Jung, W., Suh, C. H., Kim, J., Oh, J., Heo, H., ... & Kim, S. J. (2023). Development and validation of a deep learning-based automatic segmentation model for assessing intracranial volume: comparison with NeuroQuant, FreeSurfer, and SynthSeg. *Frontiers in Neurology*, *14*, 1221892.

Takefuji, Y. (2026). Beyond the black box: Enhancing feature explainability in machine learning with SHAP and complementary approaches. *Computers and Electronics in Agriculture*, *240*, 111226.

Valkenborg, D., Rousseau, A. J., Geubbelmans, M., & Burzykowski, T. (2023). Support vector machines. *American Journal of Orthodontics and Dentofacial Orthopedics, 164*(5), 754–757.

Wachinger, C., Reuter, M., & Klein, T. (2018). DeepNAT: Deep convolutional neural network for segmenting neuroanatomy. *NeuroImage, 170*, 434–445. https://doi.org/10.1016/j.neuroimage.2017.02.035

Xu, H., & Shuttleworth, K. M. J. (2024). Medical artificial intelligence and the black box problem: a view based on the ethical principle of “do no harm”. *Intelligent Medicine*, *4*(1), 52-57.

Yao, Z., Wang, Z., Xie, W., Zhan, Y., Wu, X., Dai, Y., ... & Zhang, G. (2024). Applications of generative artificial intelligence in brain MRI image analysis for brain disease diagnosis. *Neuropharmacology and Therapy, 1*(2), 65–77.

Zughayyar, I., Bauer, M., Güttler, C., de Almeida Marcelino, A. L., Kühne, F., Buss, C., ... & Dell'Orco, A. (2025). A FastSurfer Database for Age-Specific Brain Volumes in

Healthy Children: A Tool for Quantifying Localized and Global Brain Volume Alterations in Pediatric Patients. *Brain and Behavior*, *15*(7), e70689.

Uterusun mezenkimal tümörü; Leiomyosarkom olgu tanısında yaşanan zorluklar

Dr.Öğretim Üyesi Yasemin Ercan Değirmenci,

Bandırma 17 Eylül Üniversitesi, Tıp Fakültesi, Kadın Hastalıkları ve Doğum Bölümü,

ydegirmenci@bandirma.edu.tr. https://orcid.org/0009-0001-5591-7997

Dr.Öğretim Üyesi Sultan Deniz Altındağ,

Bandırma 17 Eylül Üniversitesi Tıp Fakültesi, Patoloji Bölümü,

saltindag@bandirma.edu.tr. https://orcid.org/0000-0002-7167-2432

Özet

Uterusun mezenkimal tümörleri endometrial adenokarsinomlardan sonra en sık görülen uterus corpus tümörleridir. Uterusun mezenkimal tümörleri en çok düz kas kökenli sarkomlardır. Bunlar içinde de leiomyosarkomlar %63'ünü oluştururken, diğerleri de sırasıyla endometrial stromal sarkomlar ve diğer daha nadir uterin mezenkimal tümörler oluşturmaktadır. 68 yaşında postmenapozal kanama nedeniyle başvuran hastanın yapılan jinekoljik muayenesi ve terapötik küretaj yöntemi ile uterusun mezenkimal tümörü tanısı konulamamıştır. Hekim hastanın postmenapozal kanama boyutunun fazla olması ve patoloji raporunda düz kas metaplazisi veya myom ön tanısı konması ve net bir raporlama olmaması nedeniyle histerektomi kararı almıştır. Net tanı konmaması hastanın ameliyatı kabul etme sürecini uzatmış ve ameliyat ancak altı ay sonra yapılabilmiştir. Histerektomi sonrası patoloji incelemesinde immünhistokimyasal boyama olmaması nedeni ile tanı yine net konulamamış uterusun mezenkimal tümörü tanısı alabilmiştir. Yaklaşık altı ay sonra leiomyosarkom tanısı alabilmiştir. Malignite olguların da şikayetten tanıya neredeyse bir sene gibi sürecin uzunluğuna dikkat çekmek ve endometrial örnekleme yöntemlerinde yaşanan sorunlara değinmek istedik.

Anahtar kelimeler: Postmenapozal kanama, Uterin mezenkimal tümörler, Leiomyosarkom

Giriş

Uterusun mezenkimal tümörleri çeşitli biyolojik potansiyeller gösteren ve histopatolojik olarak birbiriyle örtüşen özellikler gösteren, epitel dışı bir neoplazm grubudur. Endometrial adenokarsinomlardan sonra en sık görülen uterus corpus tümörü olup, korpus tümörlerinin %8'i uterusun mezenkimal tümörleridir (Who classification of tumours editoriol board.,2020& Croce S et al.,2022). Uterusun mezenkimal tümörleri en çok düz kas kökenli sarkomlardır; leiomyosarkomlar %63' ünü oluştururken, endometrial stromal sarkomlar %21'i ve geri kalanları diğer mezenkimal tümörler oluşturmaktadır (Croce S et al.,2022). Histopatolojik olarak birbirine benzeyen özellikler taşıması ve immünhistokimyasal boyama gibi spesifik işlemlerle tanı konabilmektedir. Bu yüzden klinik süreçte tanı ve tedavide zorluklar yaşanabilmektedir. Bu olgu sunumunda tanı sürecindeki zorlukları tekrardan ele alarak nadir karşılaşılan bu süreçlerde yol göstermesi amaçlanmıştır.

Vaka sunumu

68 yaşında postmenapozal kanama nedeniyle kliniğimize başvuran hasta, gravida 3, parite 2, abort 1olmakla beraber hasta normal spontan doğum yapmıştı. 54 yaş civarında menapoza giren, perimenapozal dönemde de yoğun ve uzun kanamaları olan hastanın yapılan jinekolojik muayenesinde disfonksiyone uterin kanama tanısı almıştır. Sonrasında 2019 yılında postmenapozal kanama nedeniyle tekrar kliniğimize başvuran hastaya, Ekim 2019' da terapötik küretaj yapılmış ve patoloji sonucu endometrial polip çıkan hasta takibe

alınmıştır. Hasta 2023 yılı Temmuz ayında yoğun vajinal kanama ve halsizlik şikayeti ile kliniğimize tekrardan başvurmuştur. Transvajinal ultrasonografide 15*13mm' lik submuköz myom yönünde bir ön tanı alan hastanın hemoglobinin 8 gelmesi üzerine eritrosit süspansiyonu takılmasını takiben, hastaya terapötik küretaj yapılmıştır. Terapötik küretaj patoloji sonucunda kesitlerde endometrium, endoserviks ve ekzoservikse ait epitel parçaları, mukus, fibrin, kanın şekilli elemanları yanısıra bazıları iğsi bazıları oval- yuvarlak nükleuslu eozinofilik sitoplazmalı hücrelerden oluşan birbiriyle çaprazlaşan, tek tük mitotik aktivitenin izlendiği gruplar görülmüştür. Histokimyasal olarak Metil yeşil- Pironin (MGP) boyası ile boyanmış ve nükleik asitlerin dağılımı incelenmiştir. Patoloji yorumunda izlenen histopatolojik bulgularla ayırıcı tanıya 'Düz kas metaplazisi', 'intraendometrial leiomyom' ve 'submuköz myom' düşünülmüş olup materyalde doku bütünlüğü izlenmediği için ileri yorum yapılamadığı belirtilmiştir. Hastanın patoloji sonucunda malignite yönünde net bir bulgu olmamasına rağmen hastaya total laparoskopik histerektomi ve bilateral salfingooferektomi önerilmiştir. Hasta kanamalarının devam etmesi üzerine Aralık ayında, yaklaşık 6 ay sonra operasyonu kabul etmiş ve Total Laparoskopik Histerektomi ve Bilateral Salfingooferektomi yapılmıştır. Hastanın TLH+BSO materyalinin patoloji bölümümüzce incelenmiştir. Raporda 9*6*2,5cm' lik uterus, serviks, biateral tuba ve overlerin olduğu materyal gözlenmiştir. Kavum açıldığında endometriumda tüm endometriumu dolduran 5*2,5*2,5 cm ölçüde polipoid lezyon izlenmiştir. Polipoid lezyonun tamamı örneklenmiş olduğu belirtilmiştir. Mikroskobik olarak kesitlerde orta- şiddetli fokal atipi, mitoz artışı(şekil4) izlenen hiperselüler, iğsi hücreli proliferasyon(şekil3) izlenmiştir. Lamların birinde bizar hücreler (Şekil 1) ve kogülatif nekroz (şekil 2) şüpheli alan, bir diğerinde endometrial gland yakınında bizar hücreler ve bir diğerinde 10 büyük büyütmede 8 mitoz izlendiği belirtilmiştir. Patoloji tanı olarak mezenkimal neoplazm olmakla beraber mezenkimal tümörün tipi ve malignite potansiyelini belirleyemedikleri için ileri bir merkeze konsültasyonu önerilmiştir. Hastanın 21 adet parafin bloğu Bursa Şehir Hastanesi patoloji birimine sevki yapılmıştır. 21 Mayıs 2024 tarihinde hasta patolojisi raporlanabilmiştir. İmmünohistokimyasal boyama ile Kaldesman, SMA, PanCK, P53 (wild tip), CD10 (fokal+), Desmin, 10 büyük büyütmede 25 adet pHH3 gözlenmesi ile tanı konulabilmiştir. Raporda tümörün histolojik yapısı Leiomyosarkom, hücre tipi iğsi, lenfovasküler invazyon izlenmemiş, nekroz mevcut, 10 büyük büyütmede 18 adet mitoz izlenmiş olarak belirtilmiştir. Bu vaka sunumunda; şikayetten kesin tanıya yaklaşık bir sene geçmesi ve ameliyatın zamanı ve şikayet başlangıcı arasındaki sürenin beş ay olması maligniteler için uzun bir süre olmasına dikkat çekmek istedik. Aynı zamanda terapötik küretaj ile bu tür malignitelerde tanı yönteminin yetersiz kalındığı gözlenmektedir.

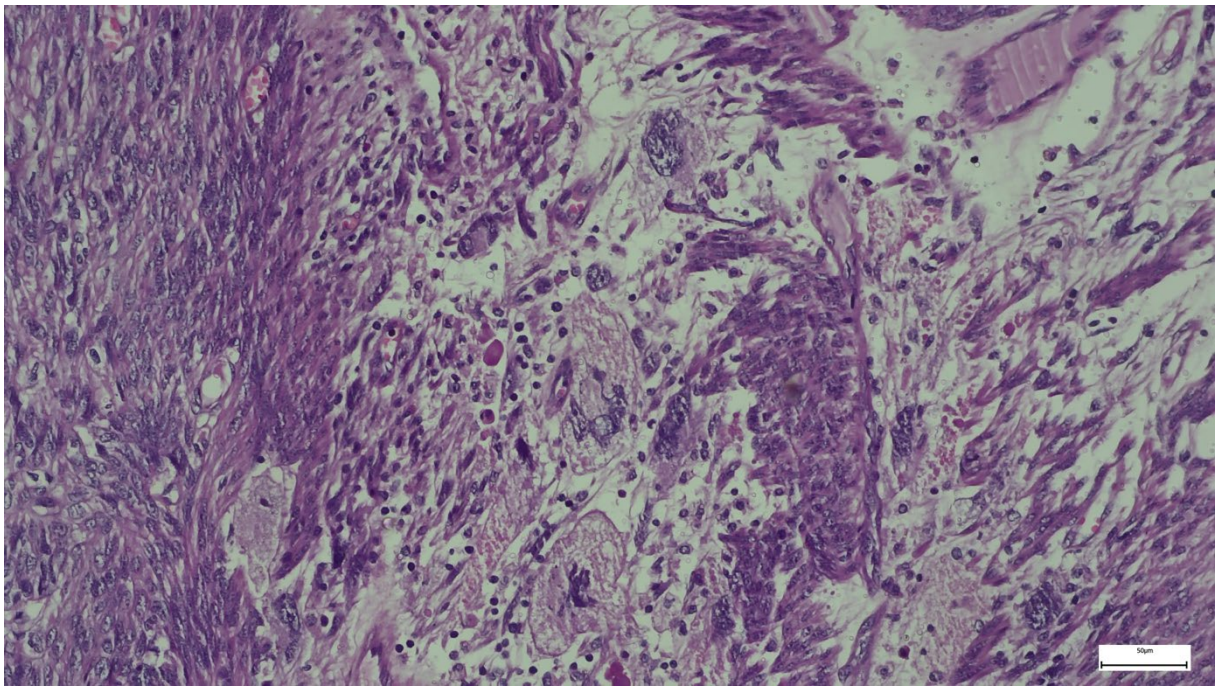

Şekil 1. Uterin mezenkimal tümör, atipik bizar hücreler

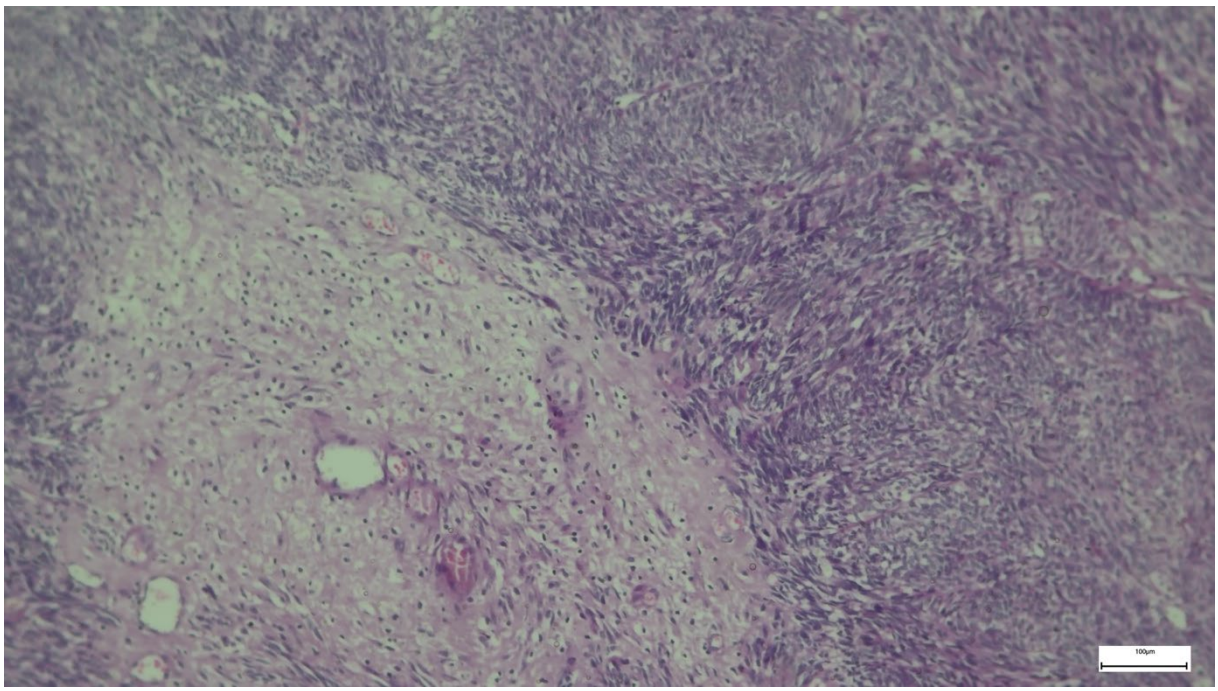

Şekil 2. Uterusta Mezenkimal tümör, solda tümör nekrozu

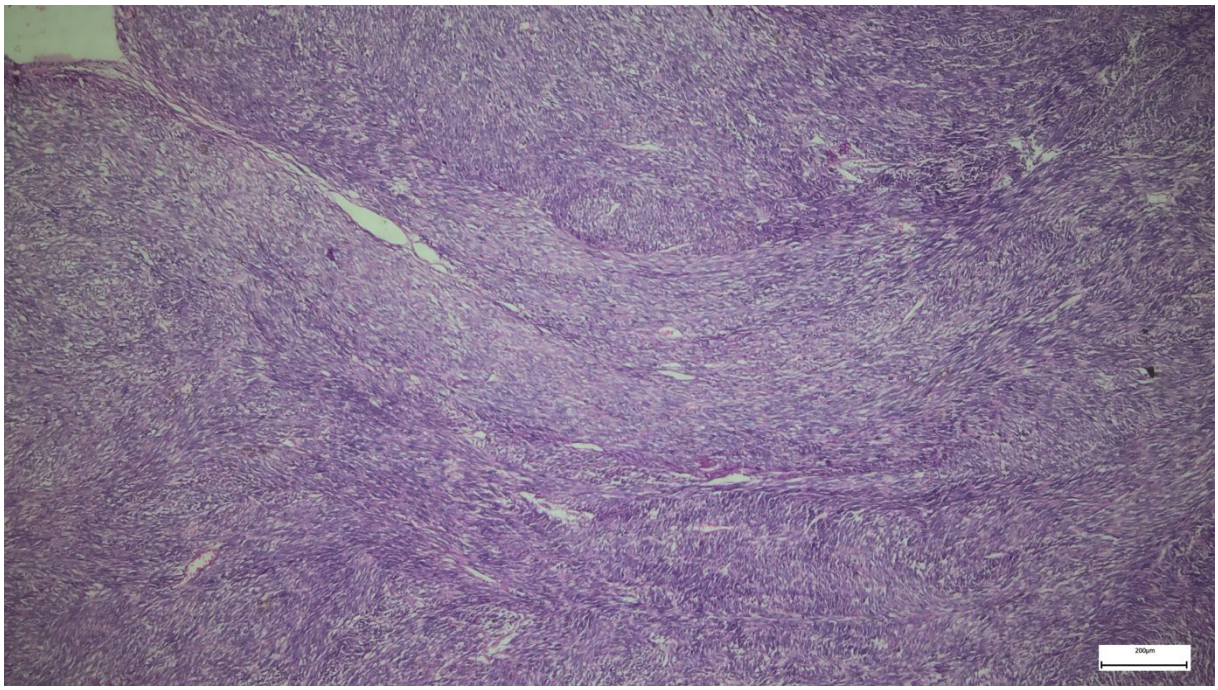

Şekil 3. Uterusta mezenkimal tümör, yoğun selülarite.

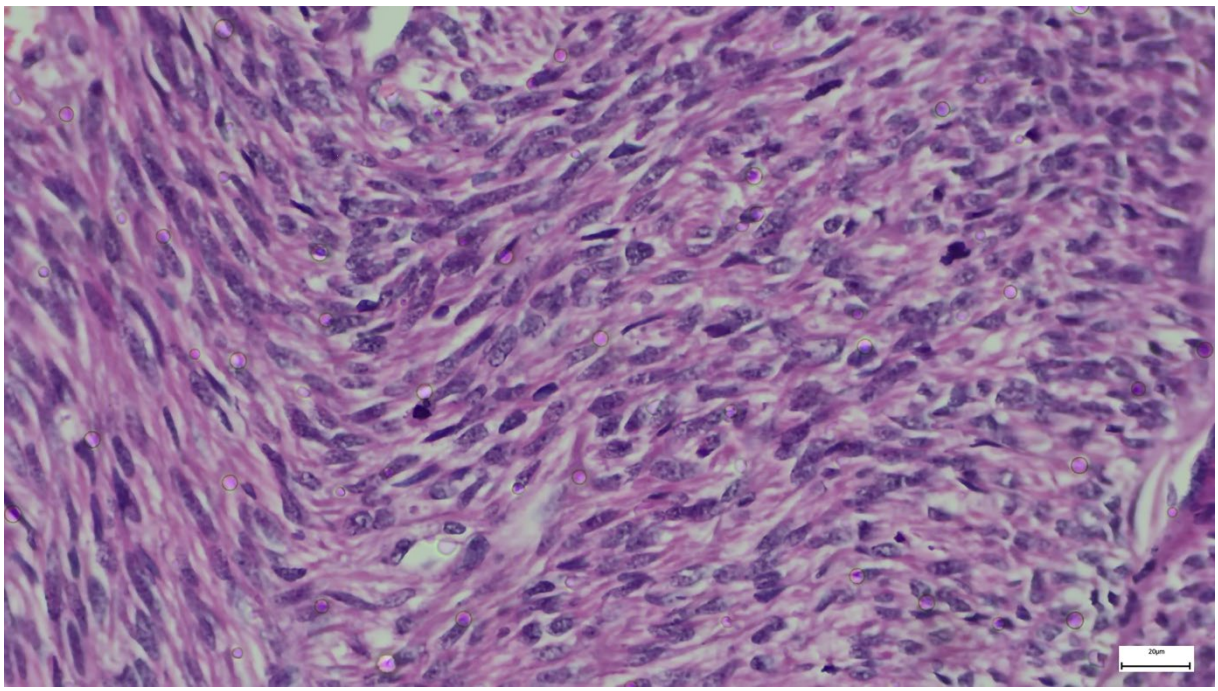

Şekil 4. Uterusta mezenkimal tümör, mitoz.

Tartışma

Uterusun mezenkimal tümörleri çeşitli biyolojik potansiyeller gösteren ve histopatolojik olarak birbiriyle örtüşen özellikler gösteren, epitel dışı bir neoplazm grubudur. Mezenkimal tümörler üç ana gruba ayrılır; düz kas hücreli tümörler, endometrial stromal kaynaklı tümörler ve mezenkimal kökenli diğer tümörlerdir. Düz kas kökenli tümörler leiomyom, leiomyosarkom ve belirsiz malingnensi potansiyeli taşıyan düz kas hücreli tümörlerdir. Endometrial stromal kaynaklı tümörler endometrial stromal nodül, low grade endometrial stromal sarkom, high grade endometrial stromal sarkom ve undiferransiye uterin sarkom

olarak sınıflandırılmaktadır. Mezenkimal kökenli diğer tümörler ise overin sex kord stromal tümörü bulunan uterin tümör, perivasküler epithelioid cell tümör (PEComa) ve inflamatuar myofibroblastik tümördür. Yumuşak doku sarkomlarının yaygın bir alt tipi olan leiomyosarkomlar tüm sarkomların %10-20' sini oluşturmaktadır (Devaud N et al.,2022). Düz kas hücreleri ve mezenkimal hücrelerden kaynaklanabilen leiomyosarkom, öncelikle retroperiton olmak üzere sırasıyla uterus ve ekstremitelerde gözlenmektedir (Serrano C et al.,2013). Klinik tablo tümörün yerine bağlı değişmektedir. Prognozu ise tümörün yeri, büyüklüğü ve tümörün hücresel derecesine göre değişmektedir. Öncelikli tedavi cerrahi olmakla beraber kemoterapi ve radyoterapi yardımcı tedavilerdir (Swallow CJ et al.,2021). Kötü diferransiye hücre taşıyan sarkomların multidisipliner merkezlerde tedavisi başarı oranlarını yükseltmektedir (Adam MA et al.,2019). Bu vakada tanı aslen histerektomi sonrasında patoloji değerlendirmesi sonucunda kesin tanı alınmakla beraber sarkom tanısı immünhistokimyasal boyanma ile ancak beş ay sonra konulabilmiştir. Piyesin total olarak kesilmesiyle bütün kaviteyi dolduran endometrial polipi andıran yapı makroskobik olarak izlenmiştir. Hastanın operasyon öncesi yapılan ultrasonografisinde endometriumu deplase eden submuköz myom veya endometrial polip ayrımı net yapılamayan bir değerlendirme yapıldığı gözlenmektedir. Hastanın anemi geliştirecek kadar postmenapozal kanamasının olması nedeni ile terapötik küretaj yapılmıştır. Küretaj materyalinin patolojik değerlendirilmesinde kesitlerde endometrium, endoserviks ve ekzoservikse ait epitel parçaları, mukus, kan, fibrin elemanları yanısıra iğsi, bazıları oval- yuvarlak nükleuslu eozinifilik sitoplazmalı hücrelerden oluşan birbiriyle çaprazlaşan, tek tük mitotik aktivitenin izlendiği grubların izlendiği raporlandırılmıştır. Tanı olarak doku bütünlüğünün yetersizliği nedeniyle düz kas metaplazisi veya submuköz myom olabileceği yönünde raporlanmışdır. Terapötik küretajlar körleme yapılan işlemler olup görsel yöntemlerle desteklenmiş histereskopi eşliğinde yapılan örneklemeye göre daha düşük başarı oranına sahiptir (Öztürk F et al.,2025). Körleme yapılan işlemde lezyonun yeri net olarak belirlenemediği için yetersiz materyale neden olarak hastalığın atlanması veya tanı konamamasına neden olabilmektedir. Tanı için probe küretaj sıklıkla yapılmaktadır. Bu işlemler sırasında odaksal lezyonların yakalayamama riski %10-20 civarındadır. Maligniteler söz konusu olduğunda bu durum hastalar için ve hekimler için büyük risk oluşturmaktadır. Bu vakada da myom tanısı bile net konulamazken hekimin postmenapozal kanamadan rahatsız olması ve kanamanın devam etmesi üzerine yaklaşık altı ay sonrasında histerektomi yapılabilmiştir. Terapötik küretaj patoloji sonucuna bakarak histerektomi endikasyonu bile tartışmalı olan hastanın menapozda olması nedeni ile hekim histerektomi kararı alması cerrahi müdahalenin gecikmesine kısmen engel olmuştur. Doğru yöntemlerle alınabilecek biopsi sonuçları ile daha hızlı bir şekilde tedavi kararı verilebilir. Histerektomi sonrası hastanemiz patoloji kliniğinde makroskobik olarak endometriyal polip, endometrial stromal sarkom izlenimi veren patoloji hücresel incelemede kesitlerde orta-şiddetli fokal atipi, mitoz artışı izlenen hiperselüler iğsi hücreli proliferasyon izlenmiştir. Bizar hücreler ve koagülatif nekroz şüpheli alanlar, endometrial gland komşuluğunda bizar hücreler izlenmekle beraber 10 büyük büyütmede 8 mitoz izlendiği raporlanmıştır. Hastanemiz bünyesindeki patoloji bölümünce uterusun mezenkimal tümörü tanısı konulmasına rağmen tümörün cinsi ve buna bağlı malignite, prognozun belirlenebilmesi için materyalin immünohistokimyasal boyama yapılabilen bir merkeze yönlendirilmesi önerilmiştir. Altı ay sonrasında Bursa Şehir Hastanesinde yapılan immünhistokimyasal boyamalarla vaka Leiomyosarkom tanısı alabilmiştir.

Sonuç

Bu vakada şikayetten tanı ve tedaviye yaklaşık bir sene geçtiğini düşünürsek malignite olgusu için olumsuz sonuçlara yol açabilme riski taşımaktadır. Bu yüzden probe küretaj veya

terapötik küretajlarda körlemesine yapılabilen işlemler olduğu için tanı ve tedavide olumsuz sonuçlar gelişebilmektedir. Tanıya ulaşılamadığı durumlarda ve normal rutinden farklı gözlenen tablolarda histereskopik biopsi, kontrastlı pelvik MRG veya malignensi şüphesinde PET yöntemlerinden faydalanmak tanı ve tedavide gecikmeyi önleyebilecektir. Aynı zamanda patoloji sırasında immünhistokimyasal boyanmanın çok önemli olduğu şikayet ve tanı arasındaki bağı çok güçlendirdiği ve tedavinin erken yapılabilmesine olanak sağladığı gözlenmektedir.

Kaynakça

Adam, M. A., Moris, D., Behren, S., Nussbaum, D. P., Jawitz, O., Turner, M., ... & BLAZER III, D. A. N. (2019). Hospital volume threshold for the treatment of retroperitoneal sarcoma. *Anticancer research*, *39*(4), 2007-2014.

International Agency for Research on Cancer (Ed.). (2020). *Female genital tumours*. International Agency for research on Cancer.

Croce, S., Devouassoux-Shisheboran, M., Pautier, P., Ray-Coquard, I., Treilleux, I., Neuville, A., ... & Genestie, C. (2022). Uterine sarcomas and rare uterine mesenchymal tumors with malignant potential. Diagnostic guidelines of the French Sarcoma Group and the Rare Gynecological Tumors Group. *Gynecologic Oncology*, *167*(2), 373-389.

Devaud, N., Vornicova, O., Razak, A. R. A., Khalili, K., Demicco, E. G., Mitric, C., ... & Gladdy, R. A. (2022). Leiomyosarcoma: current clinical management and future horizons. *Surgical Oncology Clinics*, *31*(3), 527-546.

Serrano, C., & George, S. (2013). Leiomyosarcoma. *Hematology/Oncology Clinics*, *27*(5), 957-974.

Swallow, C. J., Strauss, D. C., Bonvalot, S., Rutkowski, P., Desai, A., Gladdy, R. A., ... & Transatlantic Australasian RPS Working Group (TARPSWG). (2021). Management of Primary Retroperitoneal Sarcoma (RPS) in the Adult: An Updated Consensus Approach from the Transatlantic Australasian RPS Working Group: CJ Swallow et al. *Annals of surgical oncology*, *28*(12), 7873-7888.

Öztürk, F., Sağnıç, S., Fırtına Tuncer, S., & Tuncer, H. A. (2025). Diagnostic efficiency of endometrial sampling methods and risk factors for endometrial carcinoma and precursor lesions in premenopausal women. *Journal of Clinical Medicine*, *14*(11), 3658.

Toplumda yapay zekânın sağlık hizmetlerinde faydalı olacağına ilişkin görüşler ve ilişkili faktörler

Yazarlar: Dr. Öğr. Üyesi Murat AYSİN, Prof. Dr. Sultan ESER, Dr. Öğr. Üyesi Duygu LÜLECİ, Dr. Öğr. Üyesi Emine AYHAN AKMAN, Arş. Gör. Dr. Çağdaş SONAT, Arş. Gör. Dr. Dursun Yasemin YAYLA KESKİN, Arş. Gör. Dr. Alikemal BAŞOL, Prof. Dr. Ali CEYLAN

Balıkesir Üniversitesi Tıp Fakültesi Halk Sağlığı Anabilim Dalı, Türkiye

Özet

Giriş: Yapay zekâ, sağlık hizmetlerinde tanı, tedavi planlaması, hastalık öngörüsü, hasta bakım yönetimi ve klinik karar destek süreçlerinde giderek daha fazla kullanım alanı bulmaktadır. Bu teknolojilerin sağlık sistemine başarılı biçimde entegre edilebilmesi, toplumun yapay zekâyı güvenilir ve faydalı bulmasıyla yakından ilişkilidir. Bu çalışmanın amacı, Balıkesir Altıeylül ilçesinde yaşayan yetişkinlerin yapay zekânın tıpta faydalı olacağına ilişkin görüşlerini ve ilişkili faktörleri belirlemektir.

Gereç-Yöntem: Kesitsel tipteki çalışma, Temmuz 2024'te Balıkesir Altıeylül ilçesi merkez mahallelerinde yaşayan 18 yaş ve üzeri yetişkinlerde yürütüldü. Çok aşamalı küme örnekleme yöntemiyle 715 kişiye ulaşıldı. Veriler yüz yüze anket yöntemiyle Google Forms üzerinden toplandı. Veriler SPSS 26.0 programında analiz edildi; kategorik değişkenler için ki-kare testi kullanıldı. Anlamlılık düzeyi $p<0,05$ kabul edildi.

Bulgular: Katılımcıların yaş ortalaması 40,3±15,3 olup %52,9'u kadındı. Katılımcıların %64,5'i yapay zekânın tıpta faydalı olacağını düşünmekteydi. Katılımcıların %44,8'i yapay zekânın doğru tanılar sunacağını düşünürken, %57,3'ü kişisel verilerin güvenliği ile ilgili endişe duymaktaydı. Cinsiyet dışında incelenen tüm değişkenler ile yapay zekâyı faydalı bulma durumu arasında anlamlı ilişki saptandı. Yapay zekâyı faydalı bulma oranı; 50 yaş altındakilerde, bekârlarda, önlisans ve üzeri öğrenim düzeyindekilerde, çalışanlarda, hane geliri yoksulluk sınırı ve üzerinde olanlarda, çocuk sahibi olmayanlarda, kronik hastalığı ve ilaç kullanımı olmayanlarda ve teletıp deneyimi bulunanlarda daha yüksekti.

Sonuç-Öneriler: Yapay zekâya yönelik fayda algısı yaş, eğitim, gelir, sağlık durumu ve dijital sağlık deneyiminden etkilenmektedir. Dijital sağlık okuryazarlığını artıran, veri güvenliği kaygılarını azaltan ve dezavantajlı grupları önceleyen bilgilendirme çalışmaları planlanmalıdır.

Anahtar kelimeler: Sağlık Hizmeti, Yapay Zekâ, Teletıp

Giriş

Yapay zekâ, insan zekâsını gerektiren öğrenme, akıl yürütme, problem çözme, örüntü tanıma ve karar verme gibi bilişsel süreçlerin bilgisayar sistemleri aracılığıyla gerçekleştirilebilmesini sağlayan teknolojileri ifade etmektedir. Makine öğrenmesi, derin öğrenme ve doğal dil işleme alanlarındaki gelişmelerle birlikte yapay zekâ, son yıllarda birçok alanda hızla yaygınlaşmış; sağlık sektörü de bu dönüşümden en fazla etkilenen alanlardan biri olmuştur (Fahim, Hasani, Kabba ve Ragab, 2025; OECD, 2024).

Sağlık hizmetlerinde yapay zekâ; tanı, tedavi planlaması, hastalık öngörüsü, ilaç geliştirme, kişiselleştirilmiş sağlık hizmetleri, hasta bakım yönetimi ve klinik karar destek süreçlerinde kullanılma potansiyeli taşımaktadır. Ayrıca halk sağlığı alanında salgınların erken tespiti, risk gruplarının belirlenmesi ve sağlık kaynaklarının planlanması gibi konularda önemli fırsatlar sunmaktadır (Alum ve Ugwu, 2025; DSÖ, 2025; Kaplan, Çakar ve Bingöl, 2024; Panteli ve diğerleri, 2025).

Bununla birlikte, yapay zekânın sağlık hizmetlerine başarılı biçimde entegre edilebilmesi yalnızca teknik doğrulukla değil, toplumun bu teknolojileri güvenilir ve faydalı bulmasıyla da yakından ilişkilidir. Daha hızlı hizmet, doğru tanı ve kolay erişim beklentileri olumlu algıyı artırırken; mahremiyet, veri güvenliği, hatalı karar verme ve etik sorunlar kaygı yaratabilmektedir (Beets, Newman, Howell, Bao ve Yang, 2023; Gundlack ve diğerleri, 2025). Bu bağlamda çalışmanın amacı, toplumun yapay zekânın tıp alanında faydalı olacağına ilişkin görüşlerini belirlemek ve bu görüşleri etkileyen faktörleri incelemektir.

Gereç-Yöntem

Kesitsel tipteki bu çalışma, Temmuz 2024'te Balıkesir Altıeylül ilçesi merkez mahallelerinde yaşayan 18 yaş ve üzeri yetişkinlerde gerçekleştirildi. Araştırmanın evrenini Balıkesir ili Altıeylül ilçesinde yaşayan 18 yaş ve üzeri 107.052 yetişkin oluşturdu. Örneklem büyüklüğü Epi Info 7.2 programı kullanılarak; %95 güven aralığı, %5 hata payı, %50 sıklık, 1.5 desen etkisi ve %20 yedek ile 702 kişi olarak hesaplandı ve çok aşamalı küme örnekleme yöntemiyle 715 kişiye ulaşıldı. Veriler yüz yüze anket yöntemiyle Google Forms üzerinden toplandı. Araştırmanın bağımlı değişkeni; tıpta yapay zekâ kullanımının faydalı olacağını düşünme durumu; bağımsız değişkenler ise sosyodemografik özellikler, sağlık durumu ve teletıp ile ilgili görüşlerdir. Toplanan veriler SPSS 26.0 programıyla çözümlendi. Tanımlayıcı veriler sayı ve yüzde ile sunuldu. Kategorik değişkenlerin analizi için ki-kare testi kullanıldı. Anlamlılık düzeyi $p<0.05$ kabul edildi. Etik kurul onayı; Balıkesir Üniversitesi Sağlık Bilimleri Girişimsel Olmayan Araştırmalar Etik Kurulundan alındı (25/06/2024 tarih 2024/95 sayı).

Bulgular

Çalışmada 715 yetişkine ulaşıldı. Katılımcıların yaş ortalaması 40,25 ± 15,3 olup %52,9'u kadın, %54'ü 50 yaş altında, %50,8'i evli ve %54,4'ü önlisans ve üzeri öğrenim düzeyine sahipti. Katılımcıların %53,6'sı herhangi bir işte çalışmakta, %82,8'inin hane geliri yoksulluk sınırının altındaydı. %55'inin çocuğu olup %35,5'i en az bir kronik hastalığa sahipti ve %34,8'i düzenli ilaç kullanıyordu. Katılımcıların %19,6'sı teletıp deneyimi yaşamış olup %64,5'i yapay zekânın tıpta faydalı olacağını düşünmekteydi. %44,8'i tıpta yapay zekanın doğru teşhisler sunacağını düşünmekte ve %57,3'ü tıpta yapay zekanın kullanımının kişisel verilerin güvenliği ile ilgili endişe duymaktaydı. Tablo 1, tıpta yapay zekâ kullanımının faydalı olacağını düşünen (n=461) ve düşünmeyen (n=254) bireylerin sosyodemografik özellikleri, sağlık durumu ve teletıp deneyimine göre karşılaştırmalı analizini göstermektedir. Buna göre, cinsiyet dışında incelenen tüm değişkenler ile tıpta yapay zekâ kullanımının faydalı olacağını düşünme durumu arasında istatistiksel olarak anlamlı farklılıklar bulunmuştur. Yapay zekânın tıpta faydalı olacağını düşünen bireylerin yaş ortalaması (37,2 ± 14,4) düşünmeyenlere (45,7 ± 15,5) göre daha düşüktü. Faydalı olacağını düşünme oranı 50 yaş altındakilerde %73,8 iken, 50 yaş ve üzerindekilerde %53,5'tir. Bekâr bireylerde (%69,9), önlisans ve üzeri eğitim düzeyine sahip olanlarda (%72,8), çalışanlarda (%68,9) ve hane geliri yoksulluk sınırı ve üzerinde olanlarda (%78,0)

yapay zekâyı faydalı bulma oranı daha yüksektir. Benzer şekilde çocuk sahibi olmayanlarda (%77,6), kronik hastalığı olmayanlarda (%70,3) ve ilaç kullanmayanlarda (%70,0) olumlu görüş daha sık görülmekteydi. Teletıp deneyimi olan bireylerde yapay zekânın tıpta faydalı olacağını düşünme oranı (%77,1), deneyimi olmayanlara (%61,4) göre daha yüksekti.

Tablo 1. Tıpta Yapay Zekâ Kullanımının Faydalı Olacağını Düşünme Durumlarına Göre Sosyodemografik Faktörlerin, Sağlık Durumunun ve Teletıp Deneyiminin Dağılımı

Değişkenler		Sayı (%)	Tıpta Yapay Zekâ Kullanımının Faydalı Olacağını Düşünme Durumu		p değeri
			Evet (n=461)	Hayır (n=254)	
Yaş*		40,25 ± 15,3*	37,2 ± 14,4*	45,7 ± 15,5*	**0,001**
Yaş	50 yaş altı	386 (%54,0)	285 (%73,8)	101 (%26,2)	**0,001**
	50 yaş ve üzeri	329 (%46,0)	176 (%53,5)	153 (%46,5)	
Cinsiyet	Erkek	337 (%47,1)	216 (%64,1)	121 (%35,9)	0,837
	Kadın	378 (%52,9)	245 (%64,8)	133 (%35,2)	
Medeni durum	Bekar	352 (%49,2)	246 (%69,9)	106 (%30,1)	**0,003**
	Evli	363 (%50,8)	215 (%59,2)	148 (%40,8)	
Eğitim düzeyi	Lise ve altı	326 (%45,6)	178 (%54,6)	148 (%45,4)	
	Önlisans ve üzeri	389 (%54,4)	283 (%72,8)	106 (%27,2)	**0,001**
Meslek	Çalışmıyor	332 (%46,4)	197 (%59,3)	135 (%40,7)	**0,008**
	Çalışıyor	383 (%53,6)	264 (%68,9)	119 (%31,1)	
Hane geliri	Yoksulluk sınırının altı	592 (%82,8)	365 (%61,7)	227 (%38,3)	
	Yoksulluk sınırı ve üzeri	123 (17,2)	96 (%78,0)	27 (%22,0)	**0,001**
Çocuk varlığı	Hayır	322 (%45,0)	250 (%77,6)	72 (%22,4)	**0,001**
	Evet	393 (%55,0)	211 (%53,7)	182 (%46,3)	
Kronik hastalık	Hayır	461 (%64,5)	324 (%70,3)	137 (%29,7)	**0,001**
	Evet	254 (%35,5)	137 (%53,9)	117 (%46,1)	
İlaç kullanımı	Hayır	466 (%65,2)	326 (%70,0)	140 (%30,0)	**0,001**
	Evet	249 (%34,8)	135 (%54,2)	114 (%45,8)	
Teletıp deneyimi olma durumu	Hayır	575 (%80,4)	353 (%61,4)	222 (%38,6)	**0,001**
	Evet	140 (%19,6)	108 (%77,1)	32 (%22,9)	

*Ortalama ± standart sapma

Sonuç ve Öneriler

Çalışmamızda tıpta yapay zekâ kullanımının faydalı olacağını düşünme durumu; yaş, medeni durum, eğitim düzeyi, meslek, hane geliri, çocuk varlığı, kronik hastalık, ilaç

kullanımı ve teletıp deneyimi ile anlamlı farklılık göstermiştir. Bu bulgulara göre; tıpta yapay zekâ uygulamalarına yönelik tek yönlü bir kabul yaklaşımı yerine, toplumun farklı gruplarının beklenti ve kaygılarını dikkate alan daha dengeli bir yaklaşım benimsenebilir. Özellikle ileri yaştakiler, düşük eğitim ve gelir düzeyine sahip bireyler, kronik hastalığı olanlar ve düzenli ilaç kullananlar için anlaşılır ve kanıta dayalı bilgilendirme çalışmaları yapılabilir. Bu çalışmalarda yapay zekânın sağlık hizmetlerinde sağlayabileceği olası katkıların yanı sıra, veri güvenliği, mahremiyet, etik sorumluluk, hata riski ve insan denetiminin gerekliliği de ele alınabilir. Böylece toplumda yapay zekâya ilişkin görüşleri koşulsuz kabul ya da tamamen reddetme yerine, bilinçli, eleştirel ve güven temelli bir zeminde oluşması desteklenebilir.

Kaynakça

Alum, E. U. ve Ugwu, O. P.-C. (2025). Artificial intelligence in personalized medicine: Transforming diagnosis and treatment. *Discover Applied Sciences*, *7*(3), 193. doi:10.1007/s42452-025-06625-x

Beets, B., Newman, T. P., Howell, E. L., Bao, L. ve Yang, S. (2023). Surveying Public Perceptions of Artificial Intelligence in Health Care in the United States: Systematic Review. *Journal of Medical Internet Research*, *25*(1), e40337. doi:10.2196/40337

DSÖ. (2025, 20 Mart). Ethics and governance of artificial intelligence for health: Guidance on large multi-modal models. 27 Nisan 2026 tarihinde https://www.who.int/publications/i/item/9789240084759 adresinden erişildi.

Fahim, Y. A., Hasani, I. W., Kabba, S. ve Ragab, W. M. (2025). Artificial intelligence in healthcare and medicine: Clinical applications, therapeutic advances, and future perspectives. *European Journal of Medical Research*, *30*(1), 848. doi:10.1186/s40001-025-03196-w

Gundlack, J., Thiel, C., Negash, S., Buch, C., Apfelbacher, T., Denny, K., … Frese, T. (2025). Patients' Perceptions of Artificial Intelligence Acceptance, Challenges, and Use in Medical Care: Qualitative Study. *Journal of Medical Internet Research*, *27*(1), e70487. doi:10.2196/70487

Kaplan, M., Çakar, F. ve Bingöl, H. (2024). Sağlık Alanında Yapay Zekanın Kullanımı: Derleme. *Muş Alparslan Üniversitesi Sağlık Bilimleri Dergisi*, *4*(3), 75-85.

OECD. (2024). *Explanatory memorandum on the updated OECD definition of an AI system* (OECD Artificial Intelligence Papers No: 8). OECD Artificial Intelligence Papers (C. 8). doi:10.1787/623da898-en

Panteli, D., Adib, K., Buttigieg, S., Goiana-da-Silva, F., Ladewig, K., Azzopardi-Muscat, N., … McKee, M. (2025). Artificial intelligence in public health: Promises, challenges, and an agenda for policy makers and public health institutions. *The Lancet. Public Health*, *10*(5), e428-e432. doi:10.1016/S2468-2667(25)00036-2

Makine öğrenmesi modellerinde hata profili analizi: diyabet verisi üzerinden tanımlayıcı bir analiz

Damla ÖZYÜREK[1,2], Aslı SUNER[2]

[1] Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı, Balıkesir, Türkiye, dozyurek@bandirma.edu.tr

[2] Ege Üniversitesi, Tıp Fakültesi, Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı, İzmir, Türkiye, asli.suner@ege.edu.tr

ÖZET

Makine öğrenmesi modelleri, sağlık verilerinde karmaşık yapıları öğrenme özelliği ile sınıflandırma ve tahminde kullanılmaktadır. Bu araştırmada, açık erişimli bir diyabet veri setinde, lojistik regresyon (LR), rastgele orman (RO), destek vektör makineleri (DVM) ve XGBoost modellerinin hata profilinin tanımlayıcı özelliklerinin incelenmesi amaçlanmıştır. Bu veri setinden glukoz, vücut kitle indeksi ve diyabet soyağacı fonksiyonu değişkenleri ele alınarak, kullanılan modellerle diyabet sonucu tahmin edilmiştir. Model performanslarının belirlenmesinde duyarlılık, özgüllük, dengeli doğruluk ve F1 performans ölçütleri hesaplanırken, tüm modellerde ortak olan yanlış negatif ve yanlış pozitif tahminlerin tanımlayıcı özellikleri raporlanmıştır. Elde edilen bulgularda, modellerin benzer dengeli doğruluk değerlerine sahip olmasına rağmen, duyarlılık ve özgüllük açısından farklılaştığını göstermektedir. RO modeli en yüksek duyarlılığı sağlarken, LR daha yüksek özgüllük sergilemiştir. F1 skoru bakımından LR ve DVM benzer performans göstermiştir. Hata profili analizi, modellerin yalnızca genel performans ölçütleriyle yeterince değerlendirilemeyeceğini ortaya koymuştur. Yanlış sınıflandırılan gözlemler incelendiğinde, özellikle glukoz, vücut kitle indeksi ve diyabet soyağacı fonksiyonu gibi değişkenlerin belirli eşik değerleri etrafında hataların yoğunlaştığı belirlenmiştir. Modellerin sınırda değerlere sahip bireyleri ayırt etmekte zorlandığı, yüksek değerlerde ise yanlış pozitif sınıflandırma eğiliminin arttığı görülmüştür. Ayrıca bazı gözlemlerin tüm modeller tarafından ortak şekilde hatalı sınıflandırılması, veri yapısına bağlı zor ayırt edilen alt grupların varlığına işaret etmektedir. Veride yanlış sınıflandırılma olasılığının yüksek olduğu belirsizlik bölgelerinde, karar vericilere modelin tahmin güveni ve olası hata riski hakkında bilgi sunulması önerilmektedir.

Anahtar Kelimeler: *makine öğrenmesi, hata profili analizi, diyabet tahmini*

ABSTRACT

Machine learning models are widely used for classification and prediction tasks in healthcare data due to their ability to learn complex patterns. In this study, it was aimed to examine the descriptive characteristics of the error profiles of logistic regression (LR), random forest (RF), support vector machines (SVM), and XGBoost models using an open-access diabetes dataset. From this dataset, the variables of glucose, body mass index (BMI), and the diabetes pedigree function were selected, and diabetes outcomes were predicted using the aforementioned models. To evaluate model performance, sensitivity, specificity, balanced accuracy, and F1-score metrics were calculated. Additionally, the descriptive characteristics of false negative and false positive predictions common across all models were analyzed and reported. The findings indicated that although the models exhibited similar balanced

accuracy values, they differed in terms of sensitivity and specificity. The RF model achieved the highest sensitivity, whereas LR demonstrated higher specificity. In terms of F1-score, LR and SVM showed comparable performance. Error profile analysis revealed that overall performance metrics alone are insufficient for a comprehensive evaluation of the models. Examination of misclassified instances showed that errors were particularly concentrated around certain threshold values of glucose, BMI, and the diabetes pedigree function. It was observed that the models had difficulty distinguishing individuals with borderline values, while a tendency toward false positive classification increased at higher values. Furthermore, the presence of observations misclassified consistently across all models suggests the existence of inherently difficult-to-separate subgroups within the dataset. In regions of uncertainty where the likelihood of misclassification is high, it is recommended that decision-makers be provided with information regarding model prediction confidence and potential error risk.

Keywords: *machine learning, error profiling, diabetes prediction*

1. GİRİŞ

Sağlık bilimlerinde, makine öğrenmesi yöntemleri sınıflandırma ve tahmin etme amacıyla kullanılmaktadır. Bu yöntemler, dağılım varsayımlarına daha az bağımlıdır ve doğrusal olmayan ilişkileri yakalayabilmektedir (Rajula vd., 2020). Makine öğrenmesi modelleri veri içindeki karmaşık yapıları otomatik olarak öğrenmektedir (Janse vd., 2025). Klasik istatistik yöntemleri değişkenler arasındaki ilişkiyi ortaya koyarken, makine öğrenmesi yöntemleri tahmini optimize etmeye odaklanmaktadır (Bzdok, Altman ve Krzywinski, 2018).

Sağlık alanında artan veri çeşitliliği ile birlikte daha karmaşık modeller geliştirilmektedir (An vd., 2023). Geliştirilen modellerin performansı genellikle doğruluk (accuracy), duyarlılık (sensitivite), özgüllük (spesifite), F1 skoru ve alıcı işletim karakteristiği (ROC) eğrisi altında kalan alan (AUC) gibi ölçütler kullanılarak değerlendirilmektedir. Bu ölçütler modelin genel ayırt edicilik gücünü özetlemekle birlikte, farklı performans boyutlarını yansıttıkları için ölçütlerin birlikte ele alınmaları önerilmektedir (Varoquaux ve Colliot, 2023). Makine öğrenmesi modellerinde performansı değerlendiren ölçütler, modellerin genel ayırt edicilik gücünü özetlemek açısından önemli olmakla birlikte, modellerin veri üzerindeki davranışını tam olarak yansıtmayabilmektedir. Aynı performans değerlerine sahip modellerin farklı hata desenleri sergileyebileceği ve bu durumun klinik ya da uygulama bağlamında farklı sonuçlara yol açabileceği literatürde gösterilmiştir (Oakden-Rayner vd., 2020).

Hata profili analizi yaklaşımları, modellerin yanlış negatif ve yanlış pozitif tahminlerinin özelliklerini inceleyerek model davranışının kapsamlı değerlendirilmesini sağlamaktadır (Evans ve Snead, 2024). Bu araştırmada, lojistik regresyon-LR, rastgele orman-RO (random forest), destek vektör makineleri-DVM (support vector machine) ve XGBoost modellerinin, herkese açık bir veritabanından elde edilen diyabet veri setinde uygulanarak, hata profillerinin karşılaştırılması amaçlanmıştır.

2. YÖNTEM

Bu araştırma, diyabet tahminine yönelik makine öğrenmesi modellerinin performanslarının ve hata profillerinin karşılaştırıldığı metodolojik bir analizdir. Araştırmada, 768 kişinin diyabetle ilişkili değişkenlerini ve diyabet tanı durumunu içeren “Pima Indians Diabetes

Database" veri seti kullanılmıştır (Smith vd., 1988; Kaggle, 2016). Veriler 20.04.2026 tarihinde Kaggle internet adresinden indirilmiştir. Bu veri setinden glukoz, vücut kitle indeksi (VKİ) ve diyabet soyağacı fonksiyonu değişkenleri diyabet sonucu üzerindeki istatistiksel anlamlılık ve klinik öneme uygun olarak seçilmiştir. Bağımlı değişken olarak diyabet varlığı (var/yok) kullanılmıştır.

Veri ön işleme aşamasında eksik değerler, ilgili değişkenlerin ortanca değerleri ile imputasyon yöntemi kullanılarak tamamlanmıştır. Değişken tipleri düzenlenmiş ve kategorik değişkenler uygun şekilde faktör olarak tanımlanmıştır. Veri seti, model geliştirme ve değerlendirme süreçlerinde kullanılmak üzere rastgele olarak eğitim (%80) ve test (%20) veri setlerine ayrılmıştır.

Bu araştırmada, LR, RO, DVM ve XGBoost modelleri kullanılmıştır. LR modeli doğrusal ilişkiyi modellemek amacıyla kurulurken, RO ve XGBoost modelleri ağaç tabanlı topluluk yöntemleri olarak kullanılmıştır. DVM modeli ise doğrusal olmayan ilişkileri yakalayabilen kernel tabanlı bir yöntem olarak uygulanmıştır. Modeller eğitim veri seti üzerinde eğitilmiş ve performans değerlendirmeleri test veri seti üzerinden yapılmıştır. Her model için olasılık tahminleri elde edilmiş ve ROC analizi ile en uygun eşik değeri belirlenmiştir. Bu eşik değerler kullanılarak sınıflandırmalar yapılmıştır. Model performansları duyarlılık, özgüllük, dengeli doğruluk, F1 ölçütleri ile değerlendirilmiştir. Dört model için ayrı ayrı ve ortak yanlış negatif ve yanlış pozitif tahmin edilen gözlemler belirlenerek ortanca, en küçük değer ve en büyük değerleri raporlanmıştır. LR modeli R yazılımının 4.5.1 versiyonunda *stats* paketi içerisinde yer alan *glm* fonksiyonu (R Core Team, 2026) kullanılarak kurulmuştur. RO modeli *caret* (Kuhn, 2008), DVM modeli *e1071* (Meyer vd., 2025) ve XGBoost modeli *xgboost* (Chen ve Gestrin, 2026) paketleri kullanılarak oluşturulmuştur. Grafik, *ggplot* (Wickham, 2016) paketi kullanılarak oluşturulmuştur.

3. BULGULAR

Araştırma kapsamındaki veri setinde diyabet durumu, yaş, gebelik sayısı, açlık kan şekeri, kan basıncı, deri kalınlığı, insülin, VKİ, diyabet soyağacı fonksiyonu değişkenlerine ait tanımlayıcı özellikler Tablo 1'de sunulmuştur. Diyabet soyağacı fonksiyonu, veri setinde aile geçmişine dayalı risk skoru olarak tanımlanmış sürekli bir değişkendir.

Tablo 1. Veri Seti Tanımlayıcı Özellikleri

Değişkenler (n=768)	**Düzeyler**	**Tanımlayıcı İstatistikler**
Diyabet Durumu n(%)	Var	268 (34,90)
	Yok	500 (65,10)
Yaş (yıl)	x̄±Standart Sapma	33,24±11,76
	Ortanca (Min-Maks)	29 (21-81)
Gebelik Sayısı	x̄±Standart Sapma	3,85±3,37
	Ortanca (Min-Maks)	3 (0-17)
Açlık Kan Şekeri (mg/dl)	x̄±Standart Sapma	121,66±30,43
	Ortanca (Min-Maks)	117 (44-199)
Kan Basıncı (mmHg)	x̄±Standart Sapma	72,39±12,09
	Ortanca (Min-Maks)	72 (24-122)
Deri Kalınlığı (mm)	x̄±Standart Sapma	29,11±8,79
	Ortanca (Min-Maks)	29 (7-99)
İnsülin (µU/mL)	x̄±Standart Sapma	140,67±86,38
	Ortanca (Min-Maks)	125 (14-846)
VKİ (kg/m²)	x̄±Standart Sapma	32,45±6,87
	Ortanca (Min-Maks)	32,30 (18,20-67,10)
Diyabet Soyağacı Fonksiyonu	x̄±Standart Sapma	0,47±0,33
	Ortanca (Min-Maks)	0,37 (0,07-2,42)

Dört model için hesaplanan performans ölçütleri (Tablo 2) incelendiğinde, duyarlılık açısından en yüksek değer RO (0,88) modelinde elde edilirken, onu XGBoost (0,84) ve DVM (0,81) modelleri takip etmektedir. LR modeli ise 0,77 değeri ile görece daha düşük bir duyarlılık sergilemiştir. Özgüllük değerleri incelendiğinde tüm modellerde görece daha düşük sonuçlar elde edilmiş olup, en yüksek özgüllük LR modelinde (0,67) görülürken, en düşük değer RO modelinde (0,56) aittir. Dengeli doğruluk metrikleri tüm modeller için oldukça benzer olup yaklaşık 0,71–0,72 aralığında gerçekleşmiştir. F1 skoru açısından ise LR ve DVM modelleri (0,71) en yüksek performansı gösterirken, XGBoost ve RO sırasıyla 0,69 ve 0,68 skoru elde etmiştir.

Tablo 2. Model Ölçütleri

Uygulanan makine öğrenmesi modelleri	**LR**	**RO**	**DVM**	**XGBoost**
Duyarlılık	0,77	0,88	0,81	0,84
Özgüllük	0,67	0,56	0,64	0,59

Dengeli doğruluk	0,72	0,72	0,72	0,71
F1	0,71	0,68	0,71	0,69

Modellerde yanlış negatif ve yanlış pozitif saptanan verilere ilişkin tanımlayıcı özellikler Tablo 3'te sunulmuştur. Glukoz değişkeni açısından yanlış negatif örneklerin ortanca değerleri tüm modellerde 95–114,5 aralığında yer alırken, yanlış pozitif örneklerde 81–126 aralığında olduğu tespit edilmiştir. Benzer şekilde VKİ değerleri incelendiğinde, yanlış negatiflerde ortanca değerler 28,30–32,15 aralığında iken, yanlış pozitiflerde bu değerler 34–34,85 aralığında yer almaktadır. XGBoost modelinde yanlış negatiflerde ortanca değeri 0,246–0,339 aralığında değişirken, yanlış pozitiflerde 0,341–0,555 aralığında olduğu belirlenmiştir. Ayrıca model bazında değerlendirildiğinde, yanlış negatif sayılarının en düşük LR modelinde, en yüksek ise DVM modelinde olduğu; yanlış pozitif sayılarının ise tüm modellerde benzer düzeylerde (36–44 aralığında) gerçekleştiği görülmektedir. En yüksek yanlış negatif (n=10), en düşük yanlış pozitif (n=36) DVM modelinde saptanmıştır. En düşük yanlış negatif (n=5) LR modelinde tespit edilmiştir. RO modelinde, doğru, yanlış pozitif ve yanlış negatif tahminlerin tanımlayıcı özelliklerinin gösterimi Grafik 1'de gösterilmiştir.

Tablo 3. Modellerde Yanlış Negatif ve Yanlış Pozitif Tahmin Edilen Değişkenlerin Tanımlayıcı Özellikleri

Değişkenler	**Uygulanan makine öğrenmesi modelleri**	**Yanlış Negatif**		**Yanlış Pozitif**	
		n	Ortanca (Min-Maks)	n	Ortanca (Min-Maks)
Glukoz	LR	5	95 (78-107)	40	81 (129-193)
	RO	6	101 (78-139)	44	124,5 (77-193)
	DVM	10	114,5 (78-139)	36	129 (77-193)
	XGBoost	8	112 (78-155)	41	126 (77-193)
VKİ	LR	5	32 (22,90-35,00)	40	34,70 (24,10-46,30)
	RO	6	28,30 (22,90-35,00)	44	34,10 (25,60-46,30)
	DVM	10	32,15 (22,90-35,00)	36	34,85 (25,60-46,70)
	XGBoost	8	28,80 (22,90-35,00)	41	34,00 (25,60-46,70)
Diyabet Soyağacı	LR	5	0,248 (0,161-0,825)	40	0,555 (0,123-1,174)
	RO	6	0,262 (0,161-0,678)	44	0,426 (0,123-1,699)

Fonksiyonu	DVM	10	0,246 (0,161-0,678)	36	0,594 (0,123-1,699)
	XGBoost	8	0,339 (0,161-0,678)	41	0,341 (0,123-1,699)

Grafik 1. RO modelinde, doğru, yanlış pozitif ve yanlış negatif tahminler

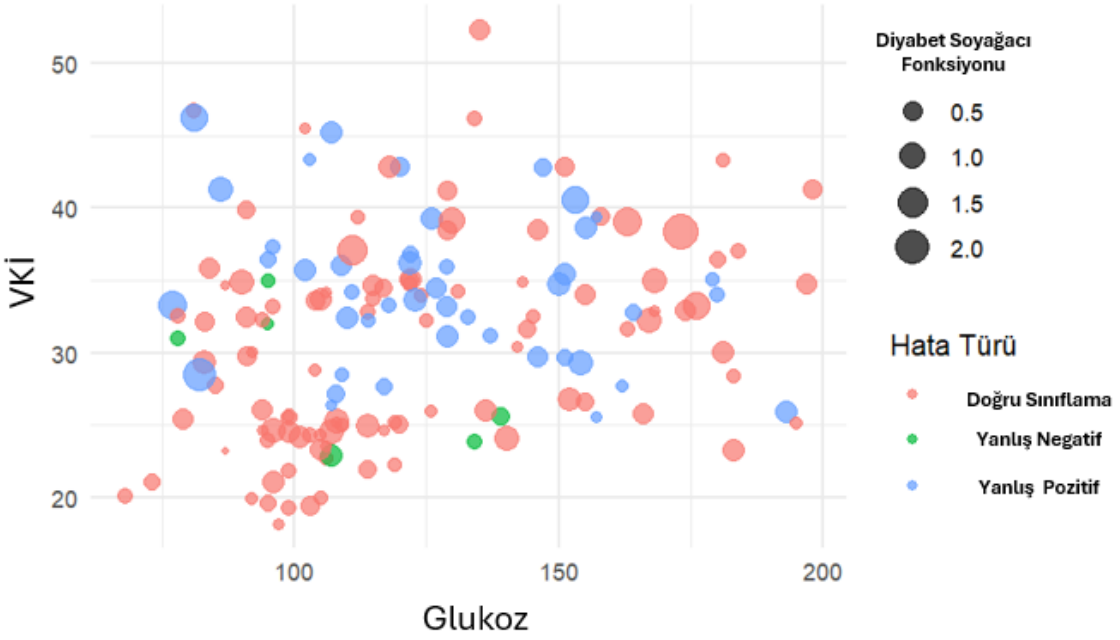

Dört modelde de diyabet durumu hatalı olarak tahmin edilen kişilerin özellikleri Tablo 4'te sunulmuştur. Bulgulara göre, yanlış negatif olarak sınıflandırılan bireylerde glukoz ortanca değeri 95 (78–107) iken, yanlış pozitif bireylerde 137 (102–193) olarak belirlenmiştir. VKİ değerleri incelendiğinde, yanlış negatif grupta ortanca değer 31,5 (22,9–35,0) iken, yanlış pozitif grupta 34,5 (25,6–45,3) olarak saptanmıştır. Diyabet soy ağacı fonksiyonu açısından da yanlış pozitif bireylerin ortancaları 0,564 (0,123-0,839), yanlış negatif bireylerde 0,240 (0,161-0,678) olarak tespit edilmiştir.

Tablo 4. Dört modelin diyabet durumunu yanlış tahmin ettiği hastaların tanımlayıcı özellikleri

	Yanlış Negatif Tahminler (n=4) **Ortanca (Min-Maks)**	**Yanlış Pozitif Tahminler (n=29)** **Ortanca (Min-Maks)**
Glukoz	95 (78-107)	137 (102-193)
VKİ	31,5 (22,9-35,0)	34,5 (25,6-45,3)
Diyabet Soyağacı Fonksiyonu	0,240 (0,161-0,678)	0,564 (0,123-0,839)

TARTIŞMA VE SONUÇ

Diyabet tanısında, modellerin performans özelliklerinin karşılaştırılması model kararı verilmesi yönünden önemlidir (Özkan, Yürekli ve Suner, 2022). Bu araştırmada elde edilen bulgular, makine öğrenmesi modellerinin performans ölçütlerinin farklılık gösterebileceğini belirtmektedir. Özellikle RO modelinin yüksek duyarlılık değeri, pozitif vakaları yakalama konusunda daha başarılı olduğunu göstermektedir. Literatürde de benzer şekilde RO modelinin diğer modellere göre yüksek duyarlılık sağlayabildiği rapor edilmiştir (Gao vd., 2021). Buna karşın, aynı modelin düşük özgüllük değeri, yanlış pozitif oranının daha yüksek olabileceğini düşündürmektedir. Sağlık verilerinde sık karşılaşılan sınıf dengesizliği probleminin makine öğrenmesi modellerinin belirli sınıflara yönelik yanlı öğrenme davranışı sergilemesine neden olabileceği ve bu durumun yanlış sınıflandırma oranlarını artırabileceği belirtilmektedir (Turhan vd., 2020). RO yönteminde duyarlılık ve özgüllük arasındaki bu fark sınıf dengesizliği yönünde değerlendirilmiştir. Bu durum, klinik uygulamalarda gereksiz ileri testlere yol açabileceğinden, önemli bir sınırlılık olarak değerlendirilebilmektedir. LR modelinin ise daha yüksek özgüllük göstermesi, negatif vakaları doğru sınıflandırmada daha dengeli bir yaklaşım sunduğunu desteklemektedir (Nakano vd., 2025). F1 skoru, yanlış pozitiflerin ve yanlış negatiflerin etkisini birlikte ele alması yönünden önemlidir (Hand, Kristien ve Krielle, 2021). DVM modelinin de F1 skoru açısından LR ile benzer performans sergilemesi, bu iki modelin genel doğruluk ve hata dengesi açısından benzer özellik gösterdiğini desteklemektedir (Fong et al., 2021).

Yanlış sınıflandırılan gözlemler incelendiğinde, değerlendirilen model sonuçlarında yanlış negatif bireylerde glukoz ortanca değerlerinin daha düşük, yanlış pozitif bireylerde ise daha yüksek olduğu görülmüştür. Bu bulgu, modellerin özellikle sınırda glukoz değerlerine sahip bireyleri ayırt etmekte zorlandığını, buna karşılık yüksek glukoz değerlerini daha agresif bir şekilde diyabet olarak sınıflandırma eğiliminde olduğunu göstermektedir. Bu durum, modelin duyarlılığı artırma pahasına yanlış pozitif oranını yükseltebileceğini düşündürmektedir. Literatürde makine öğrenmesi modellerinin karar sınırına yakın gözlemlerde belirsizlik yaşadığı ve bu tür sınır bölgelerde yanlış sınıflandırmaların arttığı belirtilmektedir (Oakden-Rayner vd., 2020). Ayrıca, diyabet gibi klinik verilerde sürekli değişkenlerin belirli eşik değerler etrafında sınıflandırma hatalarına daha yatkın olduğu gösterilmiştir (Rajula vd., 2020). Bu kanıtlarla uyumlu olarak elde edilen bulgular modellerin özellikle sınır değerlerde karar vermekte zorlandığını ve yüksek değerleri daha güçlü bir sınıflandırma sinyali olarak değerlendirdiğini desteklemektedir.

Yanlış pozitiflerde VKİ değeri, yanlış negatife göre daha yüksek saptanmıştır, bu durum Zhu ve arkadaşlarının 2020 yılında sınırda VKİ değerlerinin obeziteye yanlış pozitif olarak tahmin edebileceğini gösterdiği araştırmayla aynı yöndedir (Zhu vd., 2020). Diyabet soyağacı fonksiyonu açısından yanlış sınıflandırılan gözlemler incelendiğinde, yanlış negatif bireylerde ortanca değerlerin daha düşük, yanlış pozitif bireylerde ise daha yüksek olduğu görülmüştür. Bu bulgu, modellerin genetik yatkınlığı önemli bir belirleyici olarak değerlendirildiğini, ancak bu değişkenin yüksek olduğu durumlarda yanlış pozitif sınıflandırmaların arttığını göstermektedir. Buna karşılık, genetik riskin düşük olduğu diyabet vakalarında modelin hastalığı tespit etmekte zorlandığı anlaşılmaktadır. Literatürde de diyabet tahmininde kullanılan makine öğrenmesi modellerinde aile öyküsü ve genetik yatkınlık gibi değişkenlerin güçlü belirleyiciler olduğu ve model kararlarını önemli ölçüde etkilediği belirtilmektedir (Xie vd., 2019). Ayrıca, bu tür güçlü belirleyici değişkenlerin model tarafından aşırı ağırlıklandırılması durumunda yanlış pozitif sınıflandırmaların artabileceği ve duyarlılık–özgüllük dengesinin bozulabileceği gösterilmiştir (Qin vd., 2022). Bu modellerde elde edilen bulgular modelin diyabet soyağacı fonksiyonunu güçlü bir risk göstergesi olarak kullandığını, ancak bu değişkenin yüksek olduğu bireylerde aşırı duyarlılık nedeniyle özgüllüğün azalabileceğini

düşündürmektedir. Bu durum, model performansının yalnızca genel ölçütler ile değil, değişken bazlı hata profilleri dikkate alınarak değerlendirilmesi gerektiğini ortaya koymaktadır.

Üç modelde ortak olarak yanlış sınıflandırılan gözlemler incelendiğinde, belirli bir hasta grubunun tüm modeller tarafından benzer şekilde hatalı sınıflandırıldığı görülmüştür. Bu durum, söz konusu bireylerin sınıflar arası ayrımın zor olduğu bir bölgede yer aldığını ve modelden bağımsız olarak sınıflandırılması güç bir alt grup oluşturduğunu düşündürmektedir. Literatürde makine öğrenmesi modellerinin belirli alt gruplarda sistematik hatalar yapabildiği gösterilmiştir (Subbaswamy vd., 2024). Elde edilen bulgular yalnızca model seçiminin değil, veri yapısının ve değişkenlerin ayırt edicilik gücünün de sınıflandırma başarısı üzerinde belirleyici olduğunu ortaya koymaktadır.

Bu araştırma, makine öğrenmesi modellerinin yalnızca genel performans ölçütleri üzerinden değerlendirilmesinin model davranışını tam olarak yansıtmadığını, buna karşılık hata profili analizlerinin modellerin karar mekanizmalarını daha derinlemesine anlamada kritik bir rol oynadığını göstermektedir. Farklı modeller benzer doğruluk düzeylerine sahip olsalar dahi, veri üzerindeki hata örüntülerinin farklılaştığı ve bazı gözlem gruplarının modelden bağımsız olarak sınıflandırılmasının güç olduğu anlaşılmaktadır. Bu bulgular, klinik karar destek sistemlerinde model değerlendirmesinin daha kapsamlı ele alınması gerektiğine işaret etmektedir. Özellikle, hata profili analizleriyle belirlenen ve modellerin ortak olarak yanlış sınıflandırdığı yüksek belirsizlik bölgelerinde, karar vericilere modelin tahmin güveni ve olası hata riski hakkında bilgi sunulması önerilmektedir.

TEŞEKKÜR

Bu araştırmanın yazarlarından Damla Özyürek TÜBİTAK 2210 – Yüksek Lisans Burs Programı tarafından desteklenmektedir.

KAYNAKÇA

An, Q., Rahman, S., Zhou, J., & Kang, J. J. (2023). A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions, Opportunities and Challenges. Sensors (Basel, Switzerland), 23(9), 4178. https://doi.org/10.3390/s23094178

Bzdok, D., Altman, N., & Krzywinski, M. (2018). Statistics versus machine learning. Nature methods, 15(4), 233–234. https://doi.org/10.1038/nmeth.4642

Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785-794).

Evans, H., & Snead, D. (2024). Understanding the errors made by artificial intelligence algorithms in histopathology in terms of patient impact. NPJ digital medicine, 7(1), 89. https://doi.org/10.1038/s41746-024-01093-w

Fong, A., Scoulios, N., Blumenthal, H. J., & Anderson, R. E. (2021). Using Machine Learning to Capture Quality Metrics from Natural Language: A Case Study of Diabetic Eye Exams.

Methods of information in medicine, 60(3-04), 110–115. https://doi.org/10.1055/s-0041-1736311

Gao, Y., Jia, S., Li, D., Huang, C., Meng, Z., Wang, Y., Yu, M., Xu, T., Liu, M., Sun, J., Jia, Q., Zhang, Q., Gao, Y., Song, K., Wang, X., & Fan, Y. (2021). Prediction model of random forest for the risk of hyperuricemia in a Chinese basic health checkup test. Bioscience reports, 41(4), BSR20203859. https://doi.org/10.1042/BSR20203859

Hand DJ, Christen P, Kirielle N. F*: an interpretable transformation of the F-measure. Mach Learn. 2021;110(3):451-456. doi: 10.1007/s10994-021-05964-1. Epub 2021 Mar 15. PMID: 33746357; PMCID: PMC7958589.

Janse, R. J., Abu-Hanna, A., Vagliano, I., Stel, V. S., Jager, K. J., Tripepi, G., Zoccali, C., Dekker, F. W., & van Diepen, M. (2025). When the whole is greater than the sum of its parts: why machine learning and conventional statistics are complementary for predicting future health outcomes. Clinical Kidney Journal, 18(4), sfaf059. https://doi.org/10.1093/ckj/sfaf059

Kaggle, Pima Indians Diabetes Database, Son güncelleme: 2016. https://www.kaggle.com/datasets/uciml/pima-indians-diabetes-database. Erişim Tarihi:22.04.2026

Kuhn, M. (2008). "Building Predictive Models in R Using the caret Package." Journal of Statistical Software, 28(5), 1–26. doi:10.18637/jss.v028.i05, https://www.jstatsoft.org/index.php/jss/article/view/v028i05.

Meyer D, Dimitriadou E, Hornik K, Weingessel A, Leisch F (2025). e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R package version 1.7-17, https://CRAN.R-project.org/package=e1071.

Nakano, F. K., Van Aerde, N., Coppens, G., Vanhorebeek, I., Vens, C., Van den Berghe, G., & Grandas, F. G. (2025). Development and validation of a machine learning model for early prediction of intensive care unit acquired weakness. Intensive care medicine experimental, 13(1), 98. https://doi.org/10.1186/s40635-025-00810-3

Oakden-Rayner, L., Dunnmon, J., Carneiro, G., & Ré, C. (2020, April). Hidden stratification causes clinically meaningful failures in machine learning for medical imaging. In Proceedings of the ACM conference on health, inference, and learning (pp. 151-159).

Özkan, Y., Yürekli, B. S., & Suner, A. (2022). Diyabet tanısının tahminlenmesinde denetimli makine öğrenme algoritmalarının performans karşılaştırması. Gümüşhane Üniversitesi Fen Bilimleri Dergisi, 12(1), 211-226.

R Core Team (2026). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. https://www.r-project.org/

Rajula, H. S. R., Verlato, G., Manchia, M., Antonucci, N., & Fanos, V. (2020). Comparison of Conventional Statistical Methods with Machine Learning in Medicine: Diagnosis, Drug Development, and Treatment. Medicina (Kaunas, Lithuania), 56(9), 455. https://doi.org/10.3390/medicina56090455

Smith, J.W., Everhart, J.E., Dickson, W.C., Knowler, W.C., & Johannes, R.S. (1988). Using the ADAP learning algorithm to forecast the onset of diabetes mellitus. In Proceedings of the Symposium on Computer Applications and Medical Care (pp. 261--265). IEEE Computer Society Press.

Subbaswamy, A., Sahiner, B., Petrick, N., Pai, V., Adams, R., Diamond, M. C., & Saria, S. (2024). A data-driven framework for identifying patient subgroups on which an AI/machine learning model may underperform. NPJ digital medicine, 7(1), 334. https://doi.org/10.1038/s41746-024-01275-6

Turhan, S., Özkan, Y., Yürekli, B. S., Suner, A., & Doğu, E. (2020). Sınıf dengesizliği varlığında hastalık tanısı için kolektif öğrenme yöntemlerinin karşılaştırılması: Diyabet tanısı örneği. Turkiye Klinikleri Journal of Biostatistics, 12(1), 16-26.

Qin, Y., Wu, J., Xiao, W., Wang, K., Huang, A., Liu, B., Yu, J., Li, C., Yu, F., & Ren, Z. (2022). Machine Learning Models for Data-Driven Prediction of Diabetes by Lifestyle Type. International journal of environmental research and public health, 19(22), 15027. https://doi.org/10.3390/ijerph192215027

Varoquaux G, Colliot O. Evaluating Machine Learning Models and Their Diagnostic Value. 2023 Jul 23. In: Colliot O, editor. Machine Learning for Brain Disorders [Internet]. New York, NY: Humana; 2023. Chapter 20. Available from: https://www.ncbi.nlm.nih.gov/books/NBK597473/?utm_source=chatgpt.com

Wickham H (2016). ggplot2: Elegant Graphics for Data Analysis. Springer-Verlag New York. ISBN 978-3-319-24277-4, https://ggplot2.tidyverse.org.

Zhu Q, Huang B, Li Q, Huang L, Shu W, Xu L, Deng Q, Ye Z, Li C, Liu P. Body mass index and waist-to-hip ratio misclassification of overweight and obesity in Chinese military personnel. J Physiol Anthropol. 2020 Aug 24;39(1):24. doi: 10.1186/s40101-020-00236-8. PMID: 32831152; PMCID: PMC7444050.

Sağlık Yönetiminde Yapay Zeka Uygulamaları: Bir Sağlık Yönetimi Perspektifinden İnceleme

Maida UZUNER[1]

[1] PhD, Bandırma Onyedi Eylül Üniversitesi Lisans Üstü Eğitim Enstitüsü İşletme Anabilim Dalı Doktora Programı, email: mada.melani.uzuner@gmail.com, https://orcid.org/0000-0001-5064-9594

Özet

Sağlık sektöründe dijitalleşmenin hız kazanmasıyla birlikte, yapay zeka teknolojilerinin tanı, tedavi planlaması ve operasyonel verimlilik üzerindeki rolü stratejik bir önem kazanmıştır. Bu makale, sağlık yönetimi disiplini çerçevesinde yapay zeka'nin sunduğu potansiyeli ve kullanım alanlarını literatür taraması yöntemiyle sistematik bir şekilde analiz etmektedir.

Çalışma, yapay zekâ uygulamalarını on ana kategoride yapılandırarak kapsamlı bir literatür taraması sunmaktadır. Bu kapsamda, klinik karar destek sistemleri ve tıbbi görüntüleme teknolojilerinin tanı doğruluğu ile klinik karar verme süreçlerini nasıl iyileştirdiği incelenirken; aynı zamanda hastane operasyonları, kaynak yönetimi, hasta akışı, öngörücü analitik, idari süreçlerin otomasyonu, kalite ve risk yönetimi ile tedarik zinciri ve envanter yönetimi gibi kritik alanlara odaklanılmaktadır. Ardından, hastane operasyonları, kaynak yönetimi ve hasta akışı optimizasyonu gibi yönetsel süreçlerde yapay zeka'nin sağladığı verimlilik artışları tartışılmaktadır. Ayrıca, idari süreçlerin otomasyonu, ilaç geliştirme ve tedarik zinciri yönetimi gibi alanlarda maliyetlerin düşürülmesi ve kaynakların etkin kullanımı vurgulanmaktadır. Sanal sağlık asistanları, sohbet botları ve toplum sağlığı yönetimi başlıkları altında ise teknolojinin hasta deneyimi ve proaktif sağlık hizmetleri üzerindeki etkileri değerlendirilmektedir.

Literatür taraması sonucunda, yapay zekanın insan analiziyle gözden kaçabilecek karmaşık veri kalıplarını belirleyerek sağlık profesyonellerine ve yöneticilerine kritik içgörüler sunduğu görülmektedir. Tahmine dayalı tıp ve geliştirilmiş klinik karar verme yetenekleri, yapay zekayı tıbbi inovasyonun ön saflarına taşımaktadır. Bununla birlikte çalışma, yapay zekanın benimsenmesi sürecindeki mevcut durumu analiz ederek, sağlık ekosistemindeki yeteneklere ilişkin kritik araştırma boşluklarını tespit etmeyi ve gelecekteki araştırmalara rehberlik etmeyi amaçlamaktadır. Sonuç olarak, yapay zekânın sağlık yönetiminde sadece teknik bir araç değil, aynı zamanda operasyonel mükemmellik, kişiselleştirilmiş tıp ve sürdürülebilir sağlık hizmeti sunumu için temel bir yapı taşı durumuna geleceği ifade edilebilir.

Anahtar Kelimeler: Sağlık Yönetimi, Yapay Zekâ, Klinik Karar Destek Sistemleri, Hastane Otomasyonu, Öngörücü Analitik.

Giriş

Yapay zeka (YZ), 21. yüzyıl sağlık sistemlerinde verimliliği artıran teknolojik bir araç olmanın ötesine geçerek, operasyonel ve stratejik yönetimin vazgeçilmez bir bileşeni haline gelmiştir (Chu & Lam, 2026; Karcıoğlu, 2025). Modern sağlık işletmeleri, her geçen gün büyüyen karmaşık sağlık verilerini işleme, klinik hataları minimize etme ve kısıtlı kaynakları optimize etme baskısı altındadır (Gürcü & Erbir, 2026; Udegbe et al., 2024). Bu bağlamda yapay zeka, sağlık idarecilerine reaktif bir yönetim modelinden, veri temelli proaktif bir yönetim modeline geçiş yapma kabiliyeti sunmaktadır (Faiyazuddin et al., 2025; Gürcü & Erbir, 2026).

Son yıllarda güncel sağlık yönetimi literatürü, özellikle "**üretken yapay zeka** ve **büyük dil modellerinin"** dökümantasyon süreçlerinde ve hasta etkileşiminde yarattığı devrimsel dönüşüme odaklanmaktadır (Krishnan et al., 2023). Bu teknolojiler, sağlık personelinin üzerindeki idari yükü hafifleterek tükenmişlik oranlarını azaltırken, idarecilere ise hizmet kalitesini standardize etme noktasında yeni imkanlar tanımaktadır

et al., 2021). Sağlık yönetiminde yapay zekanın kullanımı; klinik karar destek sistemlerinden tedarik zinciri yönetimine, hasta akışı optimizasyonundan risk yönetimine kadar geniş bir yelpazeyi kapsamaktadır (Bharti et al., 2024; Udegbe et al., 2024). Literatür bulguları, yapay zekanın teşhis doğruluğunu artırmada %91,5'e varan oranlarda destek sağladığını ve operasyonel darboğazları gidermede kritik rol oynadığını göstermektedir (Giavina-Bianchi et al., 2024; Santamato et al., 2024). Ancak bu potansiyelin hayata geçirilmesi, üst yönetimin stratejik desteği ve personelin teknolojik okuryazarlığı ile doğrudan ilişkilidir (Göde, 2025; Gürcü & Erbir, 2026).

Bu çalışma, sağlık yönetimi perspektifinden yapay zeka uygulamalarını sistematik olarak incelemeyi amaçlamaktadır. Bu çalışmanın temel amacı , sağlık idarecileri ve çalışanları için yapay zekanın sunduğu fırsatları ve beraberinde getirdiği etik/yönetimsel zorlukları güncel veriler ışığında ortaya koymaktır.

Sağlık Sektöründe Yapay Zeka Uygulamaları ve Kullanım Alanları Literatür Taraması

Yapay zekânın sağlık hizmeti sunumunda devrim yaratma potansiyeli yaygın olarak kabul edilmekte olup, tanı, tedavi protokolleri ve genel hasta bakımında iyileştirmeleri kapsayan uygulamalara sahiptir (Anakal & Soumya, 2024). Bu dönüştürücü potansiyel, tahmine dayalı tıp ve geliştirilmiş klinik karar verme de dahil olmak üzere çeşitli uygulamalar aracılığıyla giderek daha fazla gerçekleştirilmektedir (Secinaro vd., 2021). Dijital veri toplama yöntemlerinin yaygınlaşması ve hesaplama altyapısındaki gelişmeler, yapay zekanın, insan analiziyle gözden kaçabilecek hasta verilerindeki ince kalıpları ve eğilimleri belirleyerek karmaşık sağlık sorunlarının üstesinden gelmesini daha da güçlendirmiştir (Ramírez, 2024; Zahlan vd., 2023). Bu yetenekler, yapay zekayı tıbbi inovasyonun ön saflarına taşıyarak daha doğru teşhisler, kişiselleştirilmiş tedavi stratejileri ve proaktif hastalık önleme olanağı sağlamıştır (Alhur vd., 2023). Bununla birlikte, yapay zekanın benimsenmesinin mevcut durumunu belirlemek, kritik araştırma boşluklarını tespit etmek ve sağlık ekosistemindeki yeteneklerine ilişkin gelecekteki araştırmalara rehberlik etmek için mevcut literatürün kapsamlı bir şekilde anlaşılması zorunludur (Ferede, 2025).

Çalışmanın bu bölümünde sağlık yönetiminde yapay zeka uygulamaları ve kullanım alanları 10 ana başlıkta derlenmiştir.

1. Klinik Karar Destek Sistemleri (KDS)

Modern sağlık işletmelerinde KDS'ler artık sadece teknik araçlar değil, kurumsal karar kapasitesini güçlendiren stratejik yönetim enstrümanlarıdır (Gürcü & Erbir, 2026). YZ tabanlı KDS'ler, geleneksel sistemlerden farklı olarak öğrenme ve adaptasyon yetenekleri sayesinde proaktif öneriler sunmakta; finansal sürdürülebilirlik ve kurumsal risk yönetimi alanlarında yönetsel kazanımlar sağlamaktadır (Gürcü & Erbir, 2026). Örnek olarak; **IBM Watson:** Doğal dil işleme yeteneğiyle klinik veri setlerini analiz eden bir sistemdir (Iliashenko et al., 2019), **VisualDx:** Görüntüleri ve aranabilir klinik özellikleri kullanarak tanı koyma sürecinde hekimlere yardımcı olan bir araçtır (Krishnan et al., 2023), **Isabel DDx Companion:** Hastanın semptomlarını ve tıbbi geçmişini analiz ederek tanı doğruluğunu artırmaya yardımcı olur (Krishnan et al., 2023).

2. Tıbbi Görüntüleme ve Tanı

2026 projeksiyonunda YZ, teşhis doğruluğunu artırmanın ötesine geçerek operasyonel verimliliğin ana unsuru haline gelmiştir (Shinde, 2026). Özellikle derin öğrenme algoritmaları, radyoloji ve patoloji süreçlerinde tanı sürelerini %80'e varan oranlarda kısaltarak idari maliyetleri düşürmektedir (Udegbe et al., 2024). Örnek olarak; **Aidoc:** BT taramalarındaki kritik bulguları işaretleyerek radyologların vakaları önceliklendirmesine olanak tanır

kalp yetmezliği gibi bulguları tespit etmek için eğitilmiş bir derin öğrenme teknolojisidir (Krishnan et al., 2023), **Viz.ai:** Klinik verileri analiz ederek acil vakaların hızlandırılmasını sağlayan bir yazılım platformudur (Krishnan et al., 2023), **Radiology AI:** X-ışını, BT ve MRI görüntülerini analiz ederek kafa içi kanama veya pulmoner emboli gibi kritik bulguları bayraklar (Krishnan et al., 2023), B**otkin AI / Third opinion / Face2Gene / DeepMind Health:** Görüntü işleme ve tanı desteği sağlayan diğer yapay zeka projeleridir (Iliashenko et al., 2019).

3. Hastane Operasyonları ve Kaynak Yönetimi

YZ, hastane kaynaklarını (yatak kapasitesi, ameliyathane kullanımı) stratejik, taktik ve operasyonel olmak üzere üç düzeyde analiz ederek optimize eder (Gürcü & Erbir, 2026). Bu sistemlerin başarısı; üst yönetim desteğine ve kurumsal dijital yetkinliklere doğrudan bağlıdır (Göde, 2025; Gürcü & Erbir, 2026). Örnek olarak; **Qventus:** Hastanelerdeki acil servisler ve ameliyathaneler dahil olmak üzere operasyonel zorlukları çözmek için tasarlanmış, verimliliği artırmayı hedefleyen bir yapay zeka platformudur (Iliashenko et al., 2019).

4. Hasta Akışı ve Öngörücü Analitik

Sistematik incelemeler, makine öğrenimi modellerinin acil servis yoğunluğunu ve hasta yatış sürelerini öngörmede kritik rol oynadığını göstermektedir (Santamato et al., 2024). Bu modeller, sezgisel reaktif yönetimden veri temelli proaktif yönetime geçişi sağlar (Gürcü & Erbir, 2026). Örnek olarak; **Qventus:** Karar alma süreçlerini gerçek zamanlı olarak optimize ederek hasta güvenliğini ve operasyonel akışı iyileştirir (Iliashenko et al., 2019).

5. İdari Süreçlerin Otomasyonu

2024–2026 döneminin en belirgin gelişmesi olan **Üretken Yapay Zeka** ve **Büyük Dil Modelleri**, idari dökümantasyon yükünü devrimsel bir şekilde azaltmaktadır. Suki gibi YZ sesli asistanları ve özelleşmiş LLM protokolleri, sağlık personelinin not tutma ve elektronik sağlık kaydı yönetimi sürelerini minimize ederek personel tükenmişliğini önlemektedir (Krishnan et al., 2023). Örnek olarak; **Suki:** Hekimlerin ve personelin not tutmasına ve elektronik sağlık kayıtlarını yönetmesine yardımcı olan bir yapay zeka sesli asistanıdır (Krishnan et al., 2023).

6. Sanal Sağlık Asistanları ve Sohbet Botları

LLM tabanlı sohbet botları (örn. Ada, Your.MD), sadece semptom sorgulama değil, aynı zamanda hastalarla sürekli iletişim kurarak sağlık hizmetlerine erişimi demokratik hale getirmektedir (Iliashenko et al., 2019). Bu araçlar, sağlık kurumlarının çağrı merkezi yükünü azaltan yönetsel bir çözüm olarak konumlanmaktadır. Örnek olarak; **Ada / Your.MD:** Semptom sorgulama ve sağlık takibi yapan hasta odaklı uygulamalardır (Iliashenko et al., 2019), **Woebot:** Bilişsel davranışçı terapi ilkelerini kullanarak kullanıcılara ruh sağlığı desteği sunan bir sohbet botudur (Anyanwu et al., 2024).

7. Toplum Sağlığı Yönetimi

Türkiye sağlık sisteminde, kamu ve özel sektör kurumlarının dijital dönüşüm dinamikleri farklılık göstermektedir (Göde, 2025). T.C. Sağlık Bakanlığı'nın güncel regülasyonları ve "Kişisel Verilerin Korunması Kanunu" çerçevesinde, YZ uygulamalarının başarısı "veri yönetişimi" ve kurumsal hazırbulunuşluk düzeyine bağlıdır

8. İlaç Geliştirme ve Araştırma Yönetimi

YZ, ilaç keşif süreçlerini ve kişiselleştirilmiş ilaç dağıtım sistemlerini (drug delivery) optimize ederek hastane eczane yönetiminde maliyet etkinliği sağlamaktadır (Ahmad et al., 2024; Serrano et al., 2024). İncelenen kaynaklarda bu alanda faaliyet gösteren genel şirketlerden bahsedilmekle birlikte, doğrudan bir yazılım veya program markası ismi verilmemiştir.

9. Kalite ve Risk Yönetimi

Hasta güvenliğinde YZ; klinik verilerdeki algoritmik önyargıları (algorithmic bias) ve "kara kutu" sorunlarını yönetmeyi gerektirir (Gürcü & Erbir, 2026). Nesnelerin İnterneti ile entegre YZ sistemleri, riskli hastaları uzaktan izleyerek kalite standartlarını yükseltmektedir (Anyanwu et al., 2024). Örnek olarak; **Current Health:** Nesnelerin İnterneti cihazlarını yapay zeka ile birleştirerek hastaların uzaktan izlenmesini ve risk takibini sağlar (Anyanwu et al., 2024).

10. Tedarik Zinciri ve Envanter Yönetimi

Tedarik zincirinde YZ ve blokzincir entegrasyonu (örn. Chekkit), ilaçların orijinalliğini doğrulamakta ve envanter yönetiminde akıllı seçim mekanizmaları sunarak israfı önlemektedir (Long et al., 2023; Periáñez et al., 2024). Örnek olarak; **Field's Supply:** Tedarik zinciri süreçlerini kolaylaştıran ve veri depolayan bir yazılımdır (Periáñez et al., 2024), **Chekkit:** Tüketicilerin ilaçların orijinalliğini doğrulamasına imkan tanıyan blokzincir tabanlı bir çözümdür (Periáñez et al., 2024).

Metodoloji

Bu çalışma, sağlık yönetiminde yapay zeka uygulamalarının mevcut durumunu, potansiyelini ve ortaya çıkardığı zorlukları kapsamlı bir şekilde incelemeyi amaçlamaktadır. Bu doğrultuda, literatür taraması yoluyla yapay zekâ uygulamalarının sağlık sektöründeki kullanım alanları, sağlık yönetimindeki etkileri ve bu teknolojilerin organizasyonel performans ile ilişkileri ele alınmaya çalışılacaktır. Çalışma PubMed, Scopus ve TR Dizin gibi veri tabanlarında yapılmıştır. Çalışmada anahtar kelime olarak "yapay zeka", "sağlık yönetimi", "dijital sağlık", "klinik karar destek sistemleri", "sağlıkta operasyonel verimlilik ve kaynak yönetimi ve yapay zeka", "stratejik planlama ve karar destek ve yapay zeka", " "sağlıkta hasta güvenliği ve bakım kalitesinin yönetimi ve yapay zeka", sağlıkta iş gücü ve insan kaynakları yönetimi ve yapay zeka", sağlıkta yönetimsel zorluklar ve etik sorumluluk ve yapay zeka" gibi terimler kullanılarak "yapay zeka" ile ilişkili akademik veri tabanları taranarak inceleme yapılmıştır.

Bulgular ve Tartışma

Bu kapsamlı tarama neticesinde, yapay zeka ve derin öğrenmenin sağlık bilişiminde dönüştürücü bir etkiye sahip olduğu, sağlık hizmetlerinin sunum, yönetim ve karar verme süreçlerini yeniden şekillendirdiği belirlenmiştir (Çelik & Tüfekçi, 2025). Bu dönüşüm, özellikle dijital hastane uygulamaları, robotik cihazlar, teletıp ve mobil sağlık çözümleri gibi teknolojik ilerlemelerle desteklenmekte olup, sağlık yöneticilerinin bu değişimlere öncülük etme becerilerini zorunlu kılmaktadır (Gül et al., 2022). Bu bağlamda, yapay zekâ destekli yönetim sistemleri ve dijital sağlık ekosistemleri, hastane operasyonel süreçlerinin optimizasyonu, hasta akış yönetimi ve kaynak planlaması gibi alanlarda önemli verimlilik artışları sağlayarak, geleneksel yönetim anlayışının ötesinde transformatif liderlik yaklaşımlarını gerekli kılmaktadır (Dirik et al., 2024; Sönmez, 2026).

Yapay zekanın bu alandaki entegrasyonu, öngörücü analitikler aracılığıyla talep tahminlerini iyileştirerek, personel ve ekipman tahsisini optimize etmekte ve böylece operasyonel süreçlerdeki darboğazları azaltmaktadır. Bu entegrasyon aynı zamanda envanter yönetimi ve tedarik zinciri optimizasyonunda da önemli avantajlar sunarak, sağlık kuruluşlarının maliyet etkinliğini ve hizmet sunum kapasitesini artırmaktadır (Karcıoğlu,

2025). Bu çerçevede yapay zeka algoritmaları, büyük veri kümelerini analiz ederek ve geleneksel istatistiksel analiz yöntemleriyle tespit edilemeyen örüntüleri ortaya çıkararak afet yönetimi gibi kriz durumlarında da sağlık hizmetleri yönetimini kökten değiştirebilme potansiyeline sahiptir (Öztürk ve Kırca, 2023). Özellikle yapay zeka destekli sistemler, halk sağlığı hizmetlerinin daha iyi planlanmasına ve kaynakların daha verimli kullanılmasına olanak tanıyarak, hastane yönetiminin ve liderliğinin stratejik dönüşümünde kilit bir rol oynamaktadır (GÖDE, 2024; Kocaman, 2025). Bu sistemler, yapay zekanın sağlık yönetiminde operasyonel, stratejik ve acil durum müdahale alanlarındaki etkilerini detaylı bir şekilde analiz eden bütünleşik yaklaşımlarla, hem süreç verimliliğini artırmakta hem de hasta sonuçlarını iyileştirmektedir (Chu & Lam, 2026; Santamato et al., 2024). YZ; randevu planlaması, teletıp uygulamaları ve idari görevlerin otomasyonu yoluyla operasyonel darboğazları gidermekte ve maliyet tasarrufu sağlamaktadır (Chelimi et al., 2025; Zangana et al., 2025). Bu optimizasyonlar, acil servislerde hasta bekleme sürelerini doğru tahmin eden yapay zeka modelleri geliştirilerek tıbbi etkinlik ve hasta memnuniyetini önemli ölçüde artırırken (Keleş, 2022;Wang et al., 2025), bireylerin genetik yapısı, yaşam tarzı ve sağlık geçmişine dayalı kişiselleştirilmiş tedavi planları oluşturarak kronik hastalıkların yönetiminde de dönüştürücü bir rol üstlenmektedir (GÖDE, 2024). Ayrıca YZ, doktorları, hemşireleri ve idarecileri destekleyerek bilgi güncellemeleri, hasta iletişimi koordinasyonu ve rutin işlerin otomatikleştirilmesi gibi faydalar sağlayarak yönetim ve işletme alanında önemli katkılar sunmaktadır (Gündüz & Eren, 2024). bu alanda sunduğu katkılara örnek verilecek olunursayapay zeka algoritmaları, hastanede kalış süresini %7 oranında azaltarak yatak sayısı ve kaynakların optimize edilmesine olanak tanımıştır (Keleş, 2022). Bu tür uygulamalar aynı zamanda ameliyathane planlamaları, yoğun bakım yatak yönetimi ve ilaç tedarik süreçlerinde de manuel yöntemlere kıyasla daha hızlı ve doğru karar verme kapasitesi sunmaktadır (Bulut, 2025). Yapay zeka tabanlı sistemler, büyük hacimli tıbbi veri setlerinden algoritmalar üreterek, hastane sunucularına bağlı hasta verilerini analiz edip sorgu algoritmaları aracılığıyla bekleme sürelerini azaltmakta ve yanlış teşhis riskini minimize etmektedir (Başcıllar et al., 2022) Titiz metodolojik yaklaşımlardan elde edilen doğrulama sonuçları, yapay zeka modellerinin sağlık hizmetleri operasyonlarını optimize etmedeki sağlamlığını doğrulamaktadır (Saini vd., 2025). Özellikle, yapay zeka destekli planlama algoritmaları, özellikle temel verimsizliklerin genellikle daha yüksek olduğu kamu hastanelerinde, hasta bekleme sürelerinde önemli azalmalar ve yatak doluluk oranlarında iyileşmeler göstermiştir (Karcıoğlu, 2025). Bu algoritmalar, gecikmiş cerrahi işlemlerle ilişkili cezaları azaltarak planlamada maliyet düşüşleri sağlamaktadır (Lopes vd., 2024). Destek Vektör Regresyon algoritmalarının uygulanması gibi tahmine dayalı modellemedeki daha ileri gelişmeler, cerrahi süre tahminlerinin doğruluğunu artırarak ameliyathane kaynaklarının daha verimli tahsis edilmesini ve vardiya israfının en aza indirilmesini sağlamıştır (Ferreira vd., 2019). Örneğin, cerrahi süre için tahmine dayalı analizlerin uygulanması, hasta ve cerrahi özellik entegrasyonunun iyileştirilmesi yoluyla, planlı ve acil cerrahi gecikmelerinde sırasıyla %28 ve %9 oranında önemli azalmalara yol açmıştır (Nikolova-Simons vd., 2023). Planlamanın ötesinde, yapay zeka modelleri, sıralı akıl yürütme ve bağlamsal anlayış gerektiren görevlerde üstün performans sergileyerek, özellikle prosedürlerin son aşamalarında cerrahi sürelerini tahmin etmede oldukça yetenekli hale gelmektedir (Bellini vd., 2024). Bu gelişmiş tahmin yeteneği, cerrahi üniteler içinde daha hassas kaynak tahsisine ve iyileştirilmiş hasta akışına olanak tanır (Meisami, 2018).

Sağlık kurumlarının yönetiminde yapay zeka, üst düzey yöneticiler ve idareciler için sadece operasyonel bir araç değil, veriye dayalı stratejik liderliği mümkün kılan bir karar destek mekanizmasıdır (Chu & Lam, 2026; Santamato et al., 2024). Geleneksel yönetim modelleri genellikle geçmiş verilere dayalı reaktif bir yaklaşım sergilerken, YZ destekli sistemler tahmine dayalı analitik (predictive analytics) yoluyla proaktif bir yönetim modeli sunmaktadır

optimize edilmesinde kritik rol oynar. Makine öğrenimi algoritmaları; mevsimsel hastalık trendlerini, acil servis yoğunluklarını ve yatak doluluk oranlarını yüksek doğrulukla tahmin ederek personelin (sağlık memurları ve yardımcı personel) stratejik olarak konuşlandırılmasını sağlar (Faiyazuddin et al., 2025; Santamato et al., 2024). İdareciler, YZ'den gelen öngörüler doğrultusunda tıbbi cihaz yatırımları, ilaç stok yönetimi ve finansal bütçeleme gibi konularda daha isabetli kararlar alabilmektedir (Chu & Lam, 2026; Karcıoğlu, 2025). Yardımcı sağlık personeli ve sağlık memurlarının yönetimi açısından karar destek sistemleri, iş gücü verimliliğini maksimize eder. YZ, hasta bakım ihtiyaçlarının karmaşıklığını analiz ederek, hangi birimde ne kadar yardımcı personele ihtiyaç duyulacağını gerçek zamanlı olarak öngörebilir (Chu & Lam, 2026; Mamieh et al., 2025). Bu durum, idarecilerin personel tükenmişliğini önlemek ve iş yükünü adil bir şekilde dağıtmak için somut verilere dayalı stratejiler geliştirmesine yardımcı olur (Chelimi et al., 2025; Santamato et al., 2024).

Sağlık kurumlarında hasta güvenliği ve bakım kalitesi, yönetimsel başarının en temel göstergeleridir. Yapay zeka, bu iki alanda reaktif yaklaşımlardan proaktif risk yönetimine geçişi sağlayarak bir "güvenlik ağı" görevi görmektedir (Chelimi et al., 2025; Karcıoğlu, 2025). İdareciler için YZ, klinik hataları minimize eden ve bakım standartlarını yükselten stratejik bir yatırım aracıdır (Udegbe et al., 2024; Zangana et al., 2025). YZ tabanlı sistemler, hasta verilerini sürekli analiz ederek düşme riskleri, sepsis belirtileri veya vital bulgulardaki kritik değişimleri yardımcı sağlık personeline ve sağlık memurlarına anında bildirmektedir (Karcıoğlu, 2025; Udegbe et al., 2024). Bu durum, personelin dikkatinin dağıldığı veya iş yükünün arttığı anlarda teknolojinin bir denetleyici mekanizma olarak çalışmasını sağlar (Faiyazuddin et al., 2025). YZ, hastanın tıbbi geçmişini ve anlık verilerini kullanarak bireysel ihtiyaçlara özel bakım planları oluşturur; bu da iyileşme sürelerini hızlandırarak genel bakım kalitesini artırır (Chelimi et al., 2025; Zangana et al., 2025). İdareciler, YZ'den gelen veriler sayesinde bakım süreçlerindeki darboğazları tespit edebilir ve hizmet sunumunda klinik mükemmelliği sağlamak için personeli daha verimli yönlendirebilir (Faiyazuddin et al., 2025; Mamieh et al., 2025). Hasta güvenliğinde YZ kullanımı, yardımcı sağlık personelinin üzerindeki bilişsel yükü hafifleterek onların "doğrudan hasta bakımına" odaklanmasına imkan tanır (Chu & Lam, 2026). İdareciler açısından bu teknolojilerin entegrasyonu, sadece hasta çıktılarını iyileştirmekle kalmaz, aynı zamanda hastanenin akreditasyon standartlarını ve hasta memnuniyet skorlarını da yükseltir (Karcıoğlu, 2025; Santamato et al., 2024). Ancak, bu başarının sürdürülebilir olması için idarenin, personeli bu sistemlerin kullanımı konusunda sürekli eğitmesi ve teknolojiye olan güveni tesis etmesi kritik önem taşımaktadır (Chelimi et al., 2025; Zangana et al., 2025). Bununla beraber Algoritmalar, ilaç etkileşimlerini ve dozaj hatalarını uygulama aşamasından önce tespit ederek, hemşire ve teknisyenlerin hata yapma riskini minimize eder (Zangana et al., 2025).

Yapay Zekanın sağlık yönetimine entegrasyonu, geleneksel iş gücü yönetimi ve insan kaynakları yönetimi paradigmalarını derinden yeniden tanımlamaktadır. Bu teknolojik yakınlaşma, optimize edilmiş iş gücü planlaması, işe alım, eğitim ve çalışan bağlılığını kolaylaştırarak, sağlık kuruluşlarında verimliliği artırır ve operasyonel maliyetleri düşürür (Vemana vd., 2025). Özellikle, yapay zeka destekli çözümler, planlama yeteneklerini geliştirmek, yetenek edinme süreçlerini kolaylaştırmak ve performans değerlendirme sistemlerini iyileştirmek için tahmine dayalı analiz ve makine öğreniminden yararlanarak, personel eksikliği ve idari yükler gibi zorlukların üstesinden gelir (Saeed vd., 2025). Dahası, yapay zeka, kalıpları belirlemek ve gelecekteki personel ihtiyaçlarını tahmin etmek için geniş veri kümelerini analiz edebilir ve böylece daha geniş sağlık krizine katkıda bulunan doktor eksikliği ve yaşlanan iş gücü gibi sorunları hafifletebilir (Petre, 2025). Yapay zekanın bu stratejik uygulaması, insan kaynakları sistemlerindeki mevcut algoritmaları iyileştirmeye, böylece optimum kaynak tahsisi ve karar verme için öneri sistemlerinin performansını

artırmaya kadar uzanır (Ramezani vd., 2023). Ancak bu dijital dönüşüm, karmaşıklıklardan da yoksun değildir; kuruluşlar, çalışanların endişeleri, yapay zeka kullanımının etik sonuçları ve personel arasında yapay zeka okuryazarlığını geliştirmek için güçlü eğitim programlarının gerekliliği gibi zorlukların üstesinden gelmelidir (Kushwaha, 2025; Purandare ve Salunkhe, 2024). Bu zorluklara rağmen, sağlık sektöründe insan kaynakları yönetiminde yapay zekanın stratejik olarak benimsenmesi, kaynak tahsisini optimize ederek ve rutin görevleri otomatikleştirerek kurumsal rekabet gücünü önemli ölçüde artırabilir (Mohamad vd., 2023). Önemli ölçüde genişlemesi beklenen sağlık sektöründeki yapay zeka pazarı, insan kaynakları yönetiminin yetenek kıtlığı ve yüksek çalışan devri gibi kritik iş gücü sorunlarını ele almak için bu gelişmiş teknolojileri stratejik olarak entegre etme zorunluluğunu vurgulamaktadır (Gautam, 2025; Jabeen & Rajyalaxmi, 2025). Bu entegrasyon, yalnızca insan kaynakları operasyonlarını kolaylaştırmakla kalmaz, aynı zamanda iş gücü dinamikleri ve yetenek yönetimine ilişkin veri odaklı iç görüler sağlayarak stratejik karar alma süreçlerini de geliştirir (Olaniyan vd., 2023). Bu, İK profesyonellerinin idari görevlerden daha stratejik rollere geçiş yapmalarını, örgütsel çevikliğe ve iş gücü hazırlığına odaklanmalarını sağlar (Popo-Olaniyan vd., 2022).

Yapay zekanın sağlık sistemlerine entegrasyonu, uygulama stratejileri, kaynak tahsisi ve iş akışı optimizasyonunun dikkatli bir şekilde değerlendirilmesini gerektiren çok yönlü yönetimsel zorluklar ortaya koymaktadır. Bu geçiş, yapay zeka kullanımının kanıta dayalı olmasını, net bir yatırım getirisi göstermesini ve kullanıcılar arasında güven oluşturmasını sağlamak için stratejik planlama gerektirmektedir (Dwivedi vd., 2019). Bununla birlikte, önemli bir engel, yöneticilerin yapay zekayı tam olarak benimsemekte tereddüt etmeleridir; bu durum büyük ölçüde uygulamanın başlangıç aşamasında olmasından ve yapay zeka modelleri ve işlevleri hakkında yaygın bir anlayış ve özel eğitim eksikliğinden kaynaklanmaktadır (Alves vd., 2024). Bu endişe, etkili yapay zeka dağıtımı için kritik bir bileşen olan veri paylaşımına karşı örgütsel direnç ve yapay zeka geliştirme için stratejik planlardaki eksiklikle daha da artmaktadır (Sun & Medaglia, 2018). Ayrıca, sağlam BT altyapı desteğinin olmaması, yetersiz yatırım ve insan hedefleri ile makine çıktıları arasındaki uyumsuzluk bu zorlukları daha da artırarak yaygın yapay zeka entegrasyonunu engellemektedir (Vishwakarma vd., 2023). Bu altyapısal ve bilgi eksikliklerinin ötesinde, yapay zekâ odaklı kararların sorumluluğunun belirlenmesi ve veri gizliliğinin sağlanması gibi yasal ve etik hususlar, entegrasyon ortamını daha da karmaşık hale getirmektedir (Sarker, 2023; Udegbe vd., 2024). Özellikle, parçalanmış veri sistemleri, birlikte çalışabilirlik sorunları ve veri gizliliği endişeleri, çeşitli sağlık hizmeti ortamlarında yapay zekâ sistemlerinin entegrasyonuna önemli engeller oluşturmakta ve genellikle veri yönetimi ve algoritma doğrulaması için sağlam çerçeveler gerektirmektedir (Nair vd., 2024). Bu sorunlar, sağlık hizmetlerinde yapay zekâ uygulamasıyla ilgili düzenleyici, etik ve güven endişelerini ele almak için kapsamlı yönetim çerçevelerine duyulan kritik ihtiyacın altını çizmektedir (Islam, 2024). Dahası, sağlık hizmetlerinde yapay zekânın etik sonuçları, özellikle hasta güvenliği, algoritmik önyargı ve şeffaflık konularında, önemli bir kamuoyu ve meslek tartışmasına yol açmış ve yapay zekâ uygulamalarına rehberlik edecek açık etik ve hak temelli çerçevelerin geliştirilmesini gerektirmiştir (Bouderhem, 2024; Wang vd., 2021). Temel yönetimsel zorluklardan biri, yapay zekanın klinik uygulamaya entegrasyonu için net kriterlerin bulunmaması ve farklı sağlık kuruluşlarındaki parçalı BT sistemleri ve değişen veri ambarı stratejileri nedeniyle sağlık verilerinin toplanması ve paylaşılmasındaki önemli zorluklardır (Neher vd., 2023). Kontrollü ortamlarda gösterilen etkinliğe rağmen, yapay zeka/makine öğrenimi sistemlerinin gerçek dünya klinik ortamlarında sınırlı genelleştirilebilirliği, bu isteksizliğe daha da katkıda bulunmakta ve çeşitli senaryolarda iyileştirilmiş hasta sonuçları için daha sağlam doğrulama kanıtlarına ihtiyaç duyulmasını gerektirmektedir (Bellini vd., 2024). Sağlık profesyonelleri arasında, yalnızca küçük bir kısmının yapay zeka uzmanı olarak tanımlanmasıyla oluşan bu bilgi açığı, yapay zekanın potansiyelinin etkin kullanımını önemli ölçüde engellemektedir (Atalla vd., 2024). Bu durum,

sağlık liderleri ve profesyonelleri arasında yapay zeka teknolojileriyle ilgili uzmanlık açığını kapatmak için geliştirilmiş eğitim girişimlerine ve özel eğitim programlarına duyulan kritik ihtiyacı vurgulamaktadır (Petersson vd., 2022). Dahası, açıklanabilirlik sorunları, algoritmik önyargı ve yapay zeka modellerinin doğrulanmasındaki zorluklar gibi yapay zekanın doğasında var olan sınırlamalar, güvenli ve adil bir uygulama sağlamak için sistematik dikkat gerektiren önemli teknolojik ve etik engeller oluşturmaktadır (Abd-Alrazaq vd., 2025; Husnain vd., 2023).

Sonuç

Bu çalışma kapsamında yapılan analiz neticesinde, yapay zekanın sağlık yönetiminde dönüştürücü potansiyelini vurgulamakta ancak aynı zamanda etkin entegrasyon için aşılması gereken karmaşık yönetimsel, etik ve teknik zorlukları da ortaya koymaktadır. Bu zorluklar arasında veri toplama, kalitesi, güvenliği, farklı işletim sistemleri arasındaki birlikte çalışabilirlik, sağlıkta eşitlik ve adillik gibi teknik, etik ve düzenleyici engeller bulunduğu sonucuna varılmaktadır. Özellikle, veri entegrasyonu ve sürekliliği eksikliği, veri toplama standartlarının yetersizliği ve giriş verilerinin niceliği ile kalitesi yapay zeka çözümlerinin faydalarını doğrulamayı zorlaştırabilir. Sonuç olarak, sağlık yönetiminde yapay zeka uygulamaları, idareciler için yalnızca bir teknolojik modernizasyon aracı değil; veriye dayalı stratejik karar alma, operasyonel mükemmellik ve hasta güvenliğini standardize eden kritik bir kaldıraç olarak ifade edilebilir. Ancak, yapay zekanın sunduğu bu potansiyelden tam anlamıyla yararlanabilmek için idarecilerin; etik sorumlulukları gözetmesi, veri gizliliğini koruması ve insan-makine iş birliğini destekleyen kurumsal bir eğitim kültürü inşa etmesi, sürdürülebilir bir sağlık sistemi için hayati önem taşımaktadır.

Kaynakça

- Abd-Alrazaq, A., Solaiman, B., Mekki, Y. M., Al-Thani, D., Farooq, F., Alkubeyyer, M., ... & Ahmed, A. (2025). Hype vs reality in the integration of artificial intelligence in clinical workflows. JMIR Formative Research, 9, e70921.
- Ahmad, S. S., Ghalib, M. R., Gallimore, M., & Al-Mousa, A. (2024). Role of AI and futuristic technology in drug discovery for smart hospitals. In *Converging Pharmacy Science and Engineering in Computational Drug Discovery* (pp. 212-234). IGI Global Scientific Publishing.
- Ali Mohamad, T., Bastone, A., Bernhard, F., & Schiavone, F. (2023). How artificial intelligence impacts the competitive position of healthcare organizations. *Journal of Organizational Change Management*, *36*(8), 49-70.
- Alves, M., Seringa, J., Silvestre, T., & Magalhães, T. (2024). Use of Artificial Intelligence tools in supporting decision-making in hospital management. BMC Health Services Research, 24(1), 1282.
- Anakal, S., & Soumya, S. (2024). Literature Review: The Use of AI in Healthcare. Journal of Scientific Research and Technology, 81-84.
- Anas Ali Alhur, Afrah Ali Alhur, Salem Jabbar Hamdan Alghamdi, Zakaria Ibrahim Asiri, Salman Khaloofh Saeed Alzamil, Sultan Alfateih, Said Saidan Misfer Al Fataih, Ali Hamdan Alfahad, Salem Mohammed Mahdi Alzmanan, Mohammed Masaid Faiz Alghamdi, Abdullah Saed Misfer Aldawsri, Hamad Hadi Jahair Alfataih, Falah Mofareh Mohammed. Al Shadqaa, Saleh Ali Saad Alyami, & Abdullah Falah Abdulllah Alyami. (2023). ADVANCING THE FRONTIERS OF ARTIFICIAL INTELLIGENCE IN TRANSFORMING HEALTHCARE: A COMPREHENSIVE

LITERATURE REVIEW. Journal of Population Therapeutics and Clinical Pharmacology, 30(19), 2107-2112. https://doi.org/10.53555/jptcp.v30i19.4744

- Anyanwu, E. C., Okongwu, C. C., Olorunsogo, T. O., Ayo-Farai, O., Osasona, F., & Daraojimba, O. D. (2024). Artificial intelligence in healthcare: a review of ethical dilemmas and practical applications. International Medical Science Research Journal, 4(2), 126-140.
- Atalla, A. D. G., El-Ashry, A. M., & Mohamed Sobhi Mohamed, S. (2024). The moderating role of ethical awareness in the relationship between nurses' artificial intelligence perceptions, attitudes, and innovative work behavior: a cross-sectional study. BMC nursing, 23(1), 488.
- Başcıllar, M., Karataş, M., & Güre, M. D. P. (2022). Dijital çağda sosyal algoritmalar: yapay zekâ ve sosyal hizmet. Sosyal Politika Çalışmaları Dergisi, 22(56), 539-565.
- Bellini, V., Russo, M., Domenichetti, T., Panizzi, M., Allai, S., & Bignami, E. G. (2024). Artificial intelligence in operating room management. Journal of medical systems, 48(1), 19.
- Bharti, I., Chauhan, K., & Aggarwal, P. (2024). Unveiling the future of ai in healthcare management: Analyzing trends of tomorrow rooted in the literature of yesterday. In Healthcare Administration and Managerial Training in the 21st Century (pp. 175-210). IGI Global Scientific Publishing.
- Bouderhem, R. (2024). Shaping the future of AI in healthcare through ethics and governance. Humanities and social sciences communications, 11(1), 1-12.
- Bulut, C. (2025). SAĞLIK KURUMLARINDA YAPAY ZEKÂ DESTEKLİ KARAR DESTEK SİSTEMLERİNİN KULLANIMI. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, *11*(1), 27-37.
- Chu, W. W., & Lam, J. L. (2026). Transforming healthcare management: The impact of artificial intelligence on leadership and operations. Management in Healthcare, 10(3), 253-265.
- Chu, W. W., & Lam, J. L. (2026). Transforming healthcare management: The impact of artificial intelligence on leadership and operations. Management in Healthcare, 10(3), 253-265.
- Çelik, Ö., & Tüfekci, N. (2024). Yapay Zeka ve Derin Öğrenmenin Sağlık Bilişimi Üzerine Etkisi: Literatür Tabanlı Bir İnceleme. *Türkiye Sağlık Bilimleri ve Araştırmaları Dergisi*, *8*(2), 11-27.
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., ... & Williams, M. D. (2021). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. International journal of information management, 57, 101994.
- Faiyazuddin, M., Rahman, S. J. Q., Anand, G., Siddiqui, R. K., Mehta, R., Khatib, M. N., ... & Sah, R. (2025). The impact of artificial intelligence on healthcare: a comprehensive review of advancements in diagnostics, treatment, and operational efficiency. Health science reports, 8(1), e70312.
- Ferede, D. (2025). Artificial intelligence (AI) and healthcare capabilities: a systematic literature review. F1000Res, 14, 158477.

- Ferreira, J., Portela, F., Machado, J., & Santos, M. F. (2019, March). Adaptive business intelligence in healthcare-A platform for optimising surgeries. In *World Conference on Information Systems and Technologies* (pp. 611-620). Cham: Springer International Publishing.
- Gautam, D. K. (2025). ARTIFICIAL INTELLIGENCE IN HRM: A NEW ERA OF EFFICIENCY. International Journal of Advanced Research in Commerce Management & Social Science, 8(1), 79–83. https://inspirajournals.com/home/viewdetails/?id=7124
- Giavina-Bianchi, M., Amaro Jr, E., & Machado, B. S. (2024). Medical expectations of physicians on AI solutions in daily practice: cross-sectional survey study. *JMIRx med*, *5*(1), e50803.
- Göde, A. (2025). Sağlık Hizmetlerinde Yapay Zekâ Okuryazarlığı ve Kurumsal Hazırbulunuşluk: Yönetimsel Bir Bakış. In: Öztürk, B. (ed.), Dijital Çağda Yönetim Bilimi: Yeni Paradigmalar. Özgür Yayınları. DOI: https://doi.org/10.58830/ozgur.pub1071.c4236
- Gül, İ., Yeşiltaş, A., & Yılmaz, V. (2022). BİREYSEL YENİLİKÇİLİĞİN GİRİŞİMCİLİK POTANSİYELİ ÜZERİNDEKİ ETKİSİ: SAĞLIK YÖNETİMİ BÖLÜMÜ ÖĞRENCİLERİ ÖRNEĞİ. *Hacettepe Sağlık İdaresi Dergisi*, *25*(4), 775-796.
- Gündüz, T., & Eren, F. (2024). Sağlıkta yapay zekâ: Bibliyometrik bir analiz. *Sağlık Akademisyenleri Dergisi*, *11*(2), 277-285.
- Gürcü, M., & Erbir, M.. Sağlık İşletmelerinde Yapay Zekâ Tabanlı Karar Destek Sistemleri: Yönetimsel Kullanım Alanları, Avantajlar/Zorluklar ve Stratejik Perspektifler. İşletmelerde Yapay Zeka ve Yapay Zeka Uygulamaları, SERİNİKLİ NİLÜFER, Editör, Özgür Yayınları, Gaziantep, ss.49-66, 2026
- Husnain, A., Rasool, S., Saeed, A., Gill, A. Y., & Hussain, H. K. (2023). AI'S healing touch: examining machine learning's transformative effects on healthcare. *Journal of World Science*, *2*(10), 1681-1695.
- Iliashenko, O., Bikkulova, Z., & Dubgorn, A. (2019). Opportunities and challenges of artificial intelligence in healthcare. In E3S Web of Conferences (Vol. 110, p. 02028). EDP Sciences.
- Islam, M. M. (2024). Exploring the impact of artificial intelligence in healthcare. *Journal of Artificial Intelligence General science (JAIGS) ISSN: 3006-4023*, *2*(1), 228-238.
- Jabeen, G., & Rajyalaxmi, M. (2025, November). Data-Driven HRM: Using AI to Improve Strategic Workforce Allocation in the Healthcare Industry. In *2025 2nd Global AI Summit-International Conference on Artificial Intelligence and Emerging Technology (AI Summit)* (pp. 1150-1155). IEEE.
- Karasu, E. & Karasu, L. (2025). Sağlık Hizmetlerinde Yapay Zekâ Kullanımı: Dönüşüm, Yenilik ve Gelecek Öngörüleri. In: Altıntaş, M. (ed.), Küresel Dönüşüm Çağında Yönetim ve Organizasyon . Özgür Yayınları. DOI: https://doi.org/10.58830/ozgur.pub1078.c4266
- Karcıoğlu, U. B. (2025). THE ROLE OF ARTIFICIAL INTELLIGENCE IN HEALTHCARE MANAGEMENT ON PATIENT SAFETY AND OPERATIONAL EFFICIENCY: A META-ANALYTIC EVALUATION. Journal of Healthcare Management and Leadership, (1), 8-21.

- Karcıoğlu, U. B. (2025). THE ROLE OF ARTIFICIAL INTELLIGENCE IN HEALTHCARE MANAGEMENT ON PATIENT SAFETY AND OPERATIONAL EFFICIENCY: A META-ANALYTIC EVALUATION. *Journal of Healthcare Management and Leadership*, (1), 8-21.
- Keleş, H. (2022). Artificial intelligence applications in medicine. *Journal of Kırıkkale University Faculty of Medicine*, *24*(3), 604-613.
- Keleş, H. (2022). Tipta Yapay Zeka uygulamalari. *The Journal of Kırıkkale University Faculty of Medicine*, *24*(3), 604-613.
- Kocaman, E. (2025). YAPAY ZEKÂ DESTEKLİ HASTANE YÖNETİMİ VE LİDERLİĞİ: BİBLİYOMETRİK BİR ANALİZ. *EUropean Journal of Managerial Research (EUJMR)*, *9*(17), 83-111.
- Krishnan, G., Singh, S., Pathania, M., Gosavi, S., Abhishek, S., Parchani, A., & Dhar, M. (2023). Artificial intelligence in clinical medicine: catalyzing a sustainable global healthcare paradigm. *Frontiers in artificial intelligence*, *6*, 1227091.
- Kushwaha, P. (2025). THE ROLE OF HUMAN RESOURCES IN IMPLEMENTING ARTIFICIAL INTELLIGENCE IN HOSPITAL MANAGEMENT. International Scientific Journal of Engineering and Management, 4(5), 1–9. https://isjem.com/download/the-role-of-human-resources-in-implementing-artificial-intelligence-in-hospital-management/
- Long, P., Lu, L., Chen, Q., Chen, Y., Li, C., & Luo, X. (2023). Intelligent selection of healthcare supply chain mode–an applied research based on artificial intelligence. *Frontiers in Public Health*, *11*, 1310016.
- Lopes, J., Guimarães, T., Duarte, J., & Santos, M. (2025). Enhancing surgery scheduling in health care settings with metaheuristic optimization models: algorithm validation study. *JMIR Medical Informatics*, *13*(1), e57231.
- Mamieh, A. A., Chermahini, S. H., hatim hummaida Eltayeb, H., ahmed mohammed Istaitia, N., & Mallat, Z. O. (2025, April). Revolutionizing Healthcare Management Through Artificial Intelligence: A Comprehensive Literature Review. In 2025 Eighth International Women in Data Science Conference at Prince Sultan University (WiDS PSU) (pp. 256-261). IEEE.
- Meisami, A. (2018). *Integrated machine learning and optimization frameworks with applications in operations management* (Doctoral dissertation).
- Nair, M., Svedberg, P., Larsson, I., & Nygren, J. M. (2024). A comprehensive overview of barriers and strategies for AI implementation in healthcare: Mixed-method design. *Plos one*, *19*(8), e0305949.
- Neher, M., Petersson, L., Nygren, J. M., Svedberg, P., Larsson, I., & Nilsen, P. (2023). Innovation in healthcare: leadership perceptions about the innovation characteristics of artificial intelligence—a qualitative interview study with healthcare leaders in Sweden. *Implementation science communications*, *4*(1), 81.
- Nikolova-Simons, M., Keldermann, R., Peters, Y., Compagner, W., Montenij, L., de Jong, Y., & Bouwman, R. A. (2023). Predictive analytics for cardio-thoracic surgery duration as a stepstone towards data-driven capacity management. *NPJ Digital Medicine*, *6*(1), 205.
- Öztürk, M., & Kırca, M. (2023). Kahramanmaraş merkezli depremler sonrası için akademik öneriler. *Özgür Yayınları*, (s 56).

- Periáñez, Á., Fernández Del Río, A., Nazarov, I., Jané, E., Hassan, M., Rastogi, A., & Tang, D. (2024). The digital transformation in health: How AI can improve the performance of health systems. Health Systems & Reform, 10(2), 2387138.
- Petersson, L., Larsson, I., Nygren, J. M., Nilsen, P., Neher, M., Reed, J. E., ... & Svedberg, P. (2022). Challenges to implementing artificial intelligence in healthcare: a qualitative interview study with healthcare leaders in Sweden. *BMC health services research*, *22*(1), 850.
- Petre, A. G. (2025). Redefining human resource management in the healthcare sector through artificial intelligence. In *Proceedings of the 18th International Management Conference* (pp. 99-106).
- Popo–Olaniyan, O., Elufioye, O. A., Okonkwo, F. C., Udeh, C. A., Eleogu, T. F., & Olatoye, F. O. (2022). Ai-driven talent analytics for strategic hr decision-making in the United States Of America: A Review. *International Journal of Management & Entrepreneurship Research*, *4*(12), 607-622.
- Popo-Olaniyan, O., James, O. O., Udeh, C. A., Daraojimba, R. E., & Ogedengbe, D. E. (2022). Future-Proofing human resources in the US with AI: A review of trends and implications. *International Journal of Management & Entrepreneurship Research*, *4*(12), 641-658.
- Purandare, S. and Salunkhe (2024). Integrating Artificial Intelligence in Healthcare Human Resource Management: Challenges and Strategic Solutions. African Journal of Biomedical Research, 431–436. https://doi.org/10.53555/ajbr.v27i1.8334
- Ramezani, M., Takian, A., Bakhtiari, A., Rabiee, H. R., Ghazanfari, S., & Sazgarnejad, S. (2023). Research agenda for using artificial intelligence in health governance: interpretive scoping review and framework. *BioData mining*, *16*(1), 31.
- Ramírez, J. G. C. (2024). AI in healthcare: revolutionizing patient care with predictive analytics and decision support systems. *Journal of Artificial Intelligence General Science (JAIGS)*, *1*(1), 31-37.
- Saeed, M., Jalil, M. S., Dahwal, F. M., Mehedy, M. T. J., & Snigdha, E. Z. (2025). The impact of AI on healthcare workforce management: business strategies for talent optimization and IT integration. *The American Journal of Medical Sciences and Pharmaceutical Research*, *7*(3), 136-156.
- Saini, B., Singh, D., Sharma, K. C., & Saini, D. K. (2025). AI-enhanced telemedicine: transforming resource allocation and cost-efficiency analysis via advanced queueing model. *Scientific Reports*, *15*(1), 31551.
- Santamato, V., Tricase, C., Faccilongo, N., Iacoviello, M., & Marengo, A. (2024). Exploring the impact of artificial intelligence on healthcare management: a combined systematic review and machine-learning approach. *Applied Sciences*, *14*(22), 10144.
- Sarker, M. (2023). Assessing the integration of AI technologies in enhancing patient care delivery in US hospitals. *Journal of Knowledge Learning and Science Technology ISSN: 2959-6386 (online)*, *2*(2), 338-351.
- Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: a structured literature review. *BMC medical informatics and decision making*, *21*(1), 125.

- Serrano, D. R., Luciano, F. C., Anaya, B. J., Ongoren, B., Kara, A., Molina, G., ... & Lalatsa, A. (2024). Artificial intelligence (AI) applications in drug discovery and drug delivery: revolutionizing personalized medicine. *Pharmaceutics*, *16*(10), 1328.

- Serrano, D. R., Luciano, F. C., Anaya, B. J., Ongoren, B., Kara, A., Molina, G., ... & Lalatsa, A. (2024). Artificial intelligence (AI) applications in drug discovery and drug delivery: revolutionizing personalized medicine. *Pharmaceutics*, *16*(10), 1328.

- Shinde., D. G.(2026), “The Impact of Artificial Intelligence on Diagnostic Accuracy and Operational Efficiency in Modern Healthcare". International Journal of Innovative Science and Research Technology (IJISRT) IJISRT26FEB700 1578-1582 DOI: 10.38124/ijisrt/26feb700
- Sowjanya, C., Basha, S. S., & Yadav, M. S. (2025). AI's Healing Touch: Transforming Healthcare from Diagnosis to Recovery. Jordan Journal of Pharmaceutical Sciences, 18(3).
- Sun, T. Q., & Medaglia, R. (2019). Mapping the challenges of Artificial Intelligence in the public sector: Evidence from public healthcare. *Government information quarterly*, *36*(2), 368-383.
- Udegbe, F. C., Ebulue, O. R., Ebulue, C. C., & Ekesiobi, C. S. (2024). The role of artificial intelligence in healthcare: A systematic review of applications and challenges. International Medical Science Research Journal, 4(4), 500-508.
- Vemana, V. C., Kalluri, N., Bajaj, Er. A., & Garg, M. (2025). AI applications in healthcare HR management for driving efficiency and cost reduction: A Literature Review. Journal of Carcinogenesis. Https://carcinogenesis.com/index.php/JOC/article/view/496
- Vishwakarma, L. P., Singh, R. K., Mishra, R., & Kumari, A. (2025). Application of artificial intelligence for resilient and sustainable healthcare system: Systematic literature review and future research directions. International Journal of Production Research, 63(2), 822-844.
- Wang, W., Chen, L., Xiong, M., & Wang, Y. (2023). Accelerating AI adoption with responsible AI signals and employee engagement mechanisms in health care. Information Systems Frontiers, 25(6), 2239-2256.
- Zahlan, A., Ranjan, R. P., & Hayes, D. (2023). Artificial intelligence innovation in healthcare: Literature review, exploratory analysis, and future research. *Technology in society*, *74*, 102321.
- Zangana, H. M., Sallow, Z. B., & Salih, B. A. (2025). The impact of artificial intelligence on healthcare: A systematic review of Innovations, Challenges, and ethical considerations. *Journal of Computers and Digital Business*, *4*(1), 1-9.

Menopozal ve perimenopozal dönemde hormon tedavisi: biyoeşdeğer formlar, uygulama yolları ve klinik yaklaşımlardaki tarihsel dönüşüm

Güzide Ece Akıncı, Op.Dr., Sancaktepe Şehit Prof. Dr. İlhan Varank EAH, geceakinci@gmail.com

Özet

Menopozal hormon tedavisi (MHT), 2002 yılında yayımlanan Women's Health Initiative (WHI) çalışmasının ardından yıllarca yanlış değerlendirilmiş, küresel ölçekte milyonlarca kadın gereksiz yere tedavisiz bırakılmıştır. Bugün ise güncel kanıtlar, MHT'nin semptomatik kadınlar için hala en etkili ve kılavuzlarca desteklenen birinci basamak tedavi olduğunu açıkça ortaya koymaktadır. Tedavinin güvenilirliği ve etkinliği; tedavinin başlama zamanına, uygulama yoluna, hormon tipine ve bireysel risk profiline göre değişmektedir.

Bu derleme, perimenapoz ve menapoz döneminde kullanılan MHT'nin tarihsel arka planını, WHI çalışmasının metodolojik sınırlılıklarını ve sonrasındaki yeniden değerlendirmeleri, biyoeşdeğer hormon formlarını (Amerikan Gıda ve İlaç Dairesi (FDA) onaylı ile kompound formlar arasındaki temel farkı), MHT'nin yarar-zarar dengesini ve başlıca uluslararası kılavuzların güncel önerilerini kapsamlı bir şekilde ele almaktadır. Ayrıca non-hormonal tedavi seçeneklerine ilişkin güncel veriler ve özel hasta gruplarına yönelik klinik yaklaşımlar da tartışılmaktadır.

Anahtar Kelimeler: menopoz, perimenopoz, menopozal hormon tedavisi (MHT), biyoeşdeğer hormon

1. Giriş ve Epidemiyoloji

Menopoz en az 12 aylık amenore ile tanımlanan fizyolojik bir süreçtir ve ortalama 51 yaşında ortaya çıkmaktadır. (Gold, 2011; Martin, Kathryn A, Barbieri, 2026) Perimenopoz olarak adlandırılan menopoz öncesi dönem; düzensiz menstrüel döngüler ve belirgin biçimde dalgalanan östrojen seviyeleriyle karakterizedir. Kadınların en çok şikayetçi olduğu vazomotor semptomlar (VMS) ise en çok perimenopoz döneminde başlamaktadır.(Panay et al., 2025; Rencoret, Neyro, & Palacios, 2024)

Küresel epidemiyoloji açısından değerlendirildiğinde, 2025 itibarıyla dünya genelinde bir milyarı aşkın kadın premenopozal dönem ya da sonrasında bulunmakta, ortalama yaşam süresi uzadıkça bir kadın hayatının yaklaşık yarısını postmenopozal evrede geçirmektedir.(Guo, 2025; Panay et al., 2025) Bu epidemiyolojik gerçeklik menopoz yönetimini modern kadın sağlığının merkezine taşıyan temel etkenlerden biri olarak öne çıkmaktadır.

Menopoz geçişi ile ortaya çıkan östrojen yoksunluğu, VMS, depresif ve anksiyöz belirtiler, bilişsel dalgalanmalar, eklem ağrıları ve ürogenital atrofi gibi birçok akut semptomun ötesinde iki kritik kronik hastalık riskini doğrudan artırmaktadır: osteoporoz ve kardiyovasküler hastalık (KVH). Bu akut semptomların yönetimi de yalnızca yaşam kalitesi açısından değil, uzun dönem sağlık üzerindeki olumlu etkileri bakımından da önem taşımaktadır. (Cho et al., 2023; The Menapouse Society (NAMS), 2022) IMS 2024 White Paper, perimenopoz döneminin hormon düzeyi dalgalanmaları nedeniyle yönetiminin zor olmakla birlikte hormon tedavisinin bu dönemde de uygulanabileceğini ve karşılanmamış gereksinim sorununun aşılması için semptom odaklı yaklaşımın evre odaklı yaklaşımın evre odaklı yaklaşımın önüne geçmesi

gerektiğini vurgulamaktadır.(Panay et al., 2024)

2. Tarihsel Arka Plan: WHI Öncesi, WHI Sonrası Ve Yeniden Değerlendirme

2.1. WHI Öncesi Dönem (1960'lar-2002)

1960'ların ortasından 2002'ye değin hormon replasman tedavisi (HRT), menopozun evrensel tedavisi olarak konumlandırılmış, kardiyovasküler koruma, kemik mineral yoğunluğunun korunması ve genel yaşam kalitesinin iyileştirilmesi gerekçesiyle geniş çevrelere önerilmiştir.(Cagnacci & Venier, 2019) 1976-1996 yılları arasında gerçekleştirilen 25 gözlemsel araştırmanın güncel meta-analizinde HRT kullanan kadınlarda koroner kalp hastalığı (KKH) için rölatif riskin 0.70 olduğu gösterilmiş olup, bu bulgu kılavuzlarda kardiyoprotektif bir etki olarak yorumlanmaktaydı.(Dubey, Imthurn, Zacharia, & Jackson, 2004) Ancak söz konusu tablonun büyük ölçüde "sağlıklı kullanıcı etkisi"nden kaynaklandığı sonradan anlaşılmıştır: HRT kullanan kadınların düzenli egzersiz yapma, sağlıklı beslenme, alkolden kaçınma ve sağlıklı bir kiloyu koruma gibi davranışlara daha yatkın olduğu gösterilmiştir. Bu kadınlar genel olarak daha varlıklı, daha zayıf, daha yüksek eğitim düzeyine sahip, tedavi uyumu güçlü ve sağlık hizmetlerine erişimi daha kolay olan bireyler olup antihipertansif ya da hipolipidemik ajan kullanımı ile kan basıncı ve kolesterol takibi gibi koruyucu uygulamalara katılım oranları daha yüksekti.(Shrank, Patrick, & Brookhart, 2011) Bu farklar gözlemsel ve deneysel çalışmalar arasındaki sonuç ayrışmasını kısmen açıklamakta, seçim yanlılığı ve diğer kısıtlamalar gözlemsel araştırmalarda faydanın abartılı olarak tahmin edilmesine yol açmış olabilir.

2.2 WHI Çalışması ve Sonuçları (2002)

Temmuz 2002'de yayımlanan WHI çalışması, günlük konjuge at östrojeni (CEE 0,625 mg/gün) ile medroksiprogesteron asetat (MPA 2.5 mg/gün) kombinasyonunu değerlendiren kolu, planlanan 8,5 yıllık izlem süresini, artmış meme kanseri, koroner kalp hastalığı, inme ve venöz tromboemboli (VTE) riski gerekçesiyle 5,2 yıl olarak erken sonlandırmıştır.(Writing Group for the Women's Health Initiative Investigators, 2002) Bu açıklamanın uluslararası medyada geniş yankı uyandırması üzerine HRT kullanımı küresel ölçekte gerilemiştir. WHI sonuçlarının yayımlanmasının ardından İngiltere'de 50-74 yaş kadınlarda MHT kullanım oranı 2001'deki %29'dan 2005'te %10-11 bandına gerilemiş benzer büyük düşüşler (%46) ve Kanada'da (%28) da gözlemlenmiştir.(Petra Stute, Marsden, Salih, & Cagnacci, 2023)

WHI çalışmasında hesaplanan göreceli riskler mutlak riske dönüştürüldüğünde tablo o kadar da vahim görülmemektedir. Kombinasyon tedavisine atfedilen 10000 kişi-yılı başına mutlak fazla riskler şöyle sıralanmaktadır: 7 ek KKH olayı, 8 ek inme, 8 ek pulmoner emboli ve 8 ek invaziv meme kanseri vakası. Buna karşılık mutlak risk azalmaları ise 10000 kişi-yılı başına 6 daha az kolorektal kanser ve 5 daha az kalça kırığı olarak hesaplanmıştır.(Manson et al., 2024; Writing Group for the Women's Health Initiative Investigators, 2002) Bu koruyucu bulgular ise kamuoyunda görmezden gelinmiştir.

2.3. WHI'nın Metodolojik Sınırlılıkları

WHI sonrasında yapılan analizler, bulguların genellenebilirliğini ciddi biçimde sorgulamıştır. Birincisi, kohortun ortalama yaşı östrojen + progesteron kolunda 63,3'tür; 50-54 yaş grubundaki katılımcıların oranı yalnızca %3,5 ile son derece sınırlı kalmıştır. Oysa ki bu yaş aralığı, klinik pratikte kadınların hormon tedavisine başlamayı en sık değerlendirdiği

dönemdir.(Rencoret et al., 2024; Petra Stute et al., 2023) Dahası katılımcılar ortalama 12 yıldır menopozdaydı.(Writing Group for the Women's Health Initiative Investigators, 2002) Bu demografik tablo, günlük pratikte MHT'yi semptom yönetimi amacıyla kullanan, daha genç ve erken postmenopozal kadın profilini temsil etmemektedir.

İkincisi, çalışma sadece tek bir oral kombine formülasyonu (CEE 0,625 mg/gün + MPA 2,5 mg/gün) incelemiş, ancak sonuçlar transdermal preperatlar, düşük doz formülasyonlar ve farklı progestogen içeren tüm MHT rejimleri dahil olmak üzere tüm hormon tedavisine genellenmiştir.(Petra Stute et al., 2023) WHI çalışmasındaki progestogen MPA, bugün klinik açıdan olumsuz profili sebebiyle büyük ölçüde terkedilen sentetik bir bileşiktir. Son olarak yayında veriler mutlak risk yerine göreceli risk olarak sunulmuş, bu durum risk algısını olduğundan yüksek göstermiştir. Mutlak risk artışının gerçekte ne denli küçük olduğu net olarak aktarılmamıştır.

2.4. Yeniden Değerlendirme: Zamanlama Hipotezi (2007-Günümüz)

WHI verilerinin alt grup analizleri, hormon tedavisinin kardiyovasküler etkilerinin, tedaviye başlama zamanına bağlı olarak belirgin biçimde değiştiğini ortaya koymuştur. Rossouw ve ark. tarafından yürütülen 2007 JAMA analizinde, menopozdan sonraki 10 yıl içinde hormon tedavisine başlayan kadınların konjuge equin östrojen (KEÖ) kolunda plaseboya kıyasla %52 daha düşük KKH riski sergilediği saptanmış, geç başlayanlarda risk artışı gözlenmiştir.(Rossouw et al., 2007) Her iki tedavi kolu birleştirildiğinde de menopozdan itibaren 10 yıldan önce tedaviye başlayan kadınlarda %24 daha düşük KKH riski ve %30 daha düşük genel mortalite oranı gösterilmiştir.(Manson et al., 2013) Tüm bu bulgular "zamanlama hipotezi" ya da "fırsat penceresi" kavramı çerçevesinde ele alınmaktadır. Hipoteze göre, hormon tedavisinin kardiyovasküler etkisi menopozdan ne kadar süre sonra başladığına bağlıdır. Henüz sağlıklı olan vasküler endotel üzerinde östrojen koruyucu etki gösterirken, ilerlemiş aterosklerotik plaklarda unstabilizasyon riskini artırabilmektedir.(Mehta, Chester, & Kling, 2019)

ELITE (Early versus Late Intervention Trial with Estradiol) çalışması zamanlama hipotezini doğrudan sınamak amacıyla tasarlanmış tek randomize kontrollü çalışmadır. Menopozun erken döneminde (ortalama ilk 6 yıl) transdermal östradiol başlanan kadınlarda geç başlayanlara kıyasla karotis intima-media kalınlığının (CIMT) plaseboya göre daha az ilerlediği gösterilmiş, ateroskleroz gelişimi anlamlı ölçüde yavaşlamış bulundu.(Hodis et al., 2016)

Güncel kılavuzlar genel olarak 60 yaş altı veya menopozdan itibaren 10 yıl içinde MHT başlanmasını önermektedir. Ancak, Lancet Diabetes & Endocrinology'de yayımlanan bir analizde ise mevcut 10 yıl/<60 yaş başlama sınırının artık aşırı kısıtlayıcı olduğu ve bu sınırın dışında kalan semptomatik kadınların da bireysel değerlendirme ile tedaviden yararlanabileceği ileri sürülmüş, özellikle oral olmayan östrojen formları için bu sınırları destekleyen kanıtların oldukça kısıtlı olduğunu savunmaktadır.(Taylor & Davis, 2025)

3. Geçmiş ve Güncel Klinik Yaklaşımlar: Sistematik Karşılaştırma

3.1. Karşılaştırma

WHI çalışmasının ardından günümüzde hormon tedavisi pratiği köklü biçimde değişmiştir. 2002-2015 dönemine damgasını vuran kısıtlayıcı yaklaşımların yerini, kanıta dayalı ve bireyselleştirilmiş bir çerçeve almaktadır. Bu dönüşüm 8 başlık altında Tablo1'de özetlenmiştir.

Tablo 1. WHI sonrası ve Günümüzde MHT yaklaşımlarının karşılaştırılması

	WHI sonrası (2002-2015)	Kanıta dayalı öneri (2022 ve sonrası)
Başlama zamanı	Kontrendike veya ertelendi; yaş ve süre sınırı gözetmeksizin kısıtlamalar	Fırsat penceresi: menopozdan itibaren <10yıl veya <60yaş öncelikli, semptom şiddeti ve bireysel risk profili belirleyici (Taylor & Davis, 2025; The Menapouse Society (NAMS), 2022)
Uygulama yolu	Ağırlıklı olarak oral; karaciğerin ilk geçiş etkisiyle sistemik aktivasyon	Transdermal tercih; oral östrojene kıyasla VTE riski RR 1.9 → 1.0, inme riski anlamlı düzeyde düşük(Canonico et al., 2007; Scarabin, 2018)
Progestogen tipi	Sentetik progestin (MPA) standart; endometrial koruma amaçlı kullanıldı	Mikronize progesteron tercih; sentetik progestine kıyasla meme kanseri riski RR 0.67 (SS: %95 GA 0.55–0.81) (Abenhaim et al., 2022; Asi et al., 2016)
Tedavi süresi	Maksimum 5 yıl, ardından kesin kesilme önerildi	Semptomlar devam ettiği sürece devam; yıllık bireysel yarar-zarar değerlendirilmesi sabit süre sınırı yok(The Menapouse Society (NAMS), 2022)
Yaş >60	Mutlak kontrendikasyon olarak benimsendi, yaşlı kadınlar tedaviden dışlandı	KVH riski düşük, sağlıklı kadınlarda bireysel değerlendirme ile kullanım mümkün, (Mukherjee & Davis, 2025; Taylor & Davis, 2025)
Risk algısı	Tüm kullanıcılar için yüksek risk, MHT tehlikelidir algısı klinik yaklaşımda esas	<60 yaş, sağlıklı ama semptomatik kadınlarda yarar- zarar dengesine göre değerlendirme, çoğu kullanıcıda bireysel mutlak risk <%1(The Menapouse Society (NAMS), 2022)
Perimenopoz yönetimi	Büyük ölçüde göz ardı edildi, düzensiz kanama varlığında tedavi ertelendi.	Özgün yönetim gerekli: sekansiyel östrojen + progesteron tedavisi, levonorgestrel rahim içi araç (LNG-RIA) +transdermal östrojen veya düşük doz kombine oral kontraseptif (KOK) seçenekler arasında yer alır. (Kim et al., 2025; National Institute for Health and Care Excellence., 2024)
Kardiyovasküler amaç	Kronik hastalık önleme aracı olarak kullanıldı; primer/ sekonder KKH profilaksisi beklentisi yaygındı	Kronik hastalık önleme endikasyonu yoktur, temel hedef semptom yönetimidir. Uygun hastada, menopoza yakın dönemde başlanınca kardiyovasküler açıdan nötr olabilir ve olası fayda gösterebilir.(Hodis & Mack, 2022; The Menapouse Society (NAMS), 2022)

3.2. Klinik Yansımalar

Fırsat penceresi hipotezi; östrojenin endotelyal ve kardiyovasküler koruyucu etkilerini

gösterebilmesi için vasküler yaşlanma süreci henüz yerleşmeden önce, yani menopoza yakın dönemde başlanması gerektiğini öne sürmektedir. (Hodis & Mack, 2022; Mehta et al., 2019) Menopozun erken evresinde damar endoteli östrojen reseptörlerine yanıt verebilir durumdadır ve östrojen endotelyal esnekliği, lipid profilini ve inflamatuar belirteçleri olumlu yönde etkiler. Buna karşın uzun süreli östrojen yoksunluğunun ardından gelişen ileri ateroskleroz, plak stabilizasyonunu bozarak trombotik olaylara zemin hazırlayabilmektedir.(Mehta et al., 2019)

NAMS 2022 kılavuzu, östrojenin kardiyovasküler etkisini belirleyen temel değişkenin başlama zamanı olduğunu açıkça vurgulamaktadır. Bu çerçevede değerlendirildiğinde, önceden benimsenen 10yıl/60 yaş sınırının özellikle oral olmayan formülasyonlar için kanıt temeli bulunmadığından, semptomatik kadınların bu sınır gerekçesiyle bireysel risk profili gözetilmeden tedaviden mahrum bırakılmasının klinik açıdan sorunlu olduğunu açıkça ortaya koymaktadır.(Taylor & Davis, 2025; The Menapouse Society (NAMS), 2022)

3.3 Perimenopoz: Özgün Yönetim Gereksinimi

Perimenopozal dönem, düzensiz kanama, değişken hormon seviyeleri ve fertilite potansiyelinin sürmesi sebebiyle postmenopozdan farklı bir tedavi yaklaşımı gerektirmektedir. Kore Menopoz Derneği 2025 kılavuzu ve NAMS 2022 bildirisi bu dönem için sekansiyel östrojen + progesteron, düşük doz KOK veya LNG-RIA + transdermal östrojen kombinasyonunu uygun seçenekler olarak tanımlanmaktadır. (Kim et al., 2025; National Institute for Health and Care Excellence., 2024; The Menapouse Society (NAMS), 2022) Özellikle LNG-RIA + transdermal östrojen kombinasyonu, endometrial korumayı sistemik progestin yüküne gerek kalmadan sağlayabilen ve semptomlarla birlikte kontrasepsiyon ihtiyacı bulunan kadınlarda öne çıkan bir seçenektir. Kronik hastalık önleme, MHT için geçerli bir endikasyon değildir ancak erken başlamada kardiyovasküler nötralite veya olası fayda gözlemlenebilir. Semptom yönetimi ise MHT için birincil endikasyondur. Vazomotor semptomlar, GSM ve yaşam kalitesi üzerindeki etkileri bireysel risk değerlendirmesiyle tedavi kararının temel belirleyicisidir.

4. MHT Tipleri, Formülasyonlar ve Uygulama Yolları

4.1. Östrojen Tedavisi (ET)

Histerektomi uygulanmış kadınlarda progesteron eklenmeksizin tek başına östrojen tedavisi (ET) uygulanabilir. Oral ve transdermal 17β-östradiol formülasyonları VMS, kemik mineral yoğunluğu ve yaşam kalitesi üzerindeki klinik etkinlik açısından karşılaştırılabilir sonuçlar verse de metabolik etkileri, tromboembolik risk profili ve inme riski bakımından belirgin farklılıklar göstermektedir.(Goldštajn et al., 2022; The Menapouse Society (NAMS), 2022)

Oral östrojen, emilimin ardından portal dolaşıma geçerek hepatik ilk geçiş metabolizmasına uğrar. Bu süreçte koagülasyon faktörleri (FV, FVII, FX), trombin üretimi ve aktive protein C direnci olumsuz yönde etkilenirken trigliserit düzeylerinde de artış gözlemlenir. Transdermal östradiol ise bu metabolik yolağı devre dışı bırakıp fizyolojik koşullara daha yakın serum östradiol düzeyleri sağlar ve pıhtılaşma parametrelerini minimal düzeyde etkiler. (Renoux, Dell'Aniello, Garbe, & Suissa, 2010) Canonico ve ark.'ın çalışmasında ve ardından yayımlanan meta-analizlerde oral östrojen kullanımında VTE riski transdermal kullanıma kıyasla yaklaşık iki kat artarken transdermal rejimlerde anlamlı bir artış saptanmamıştır.(Canonico et al., 2007; Scarabin, 2018) IMS 2024 White Paper ve NAMS 2022 kılavuzu, tromboemboli riski yüksek kadınlarda (obezite, VTE öyküsü, trombofili öyküsü) transdermal östrojenin öncelikli seçenek olması gerektiğini vurgulamaktadır. (Panay et al., 2024; The Menapouse Society (NAMS), 2022) Tablo 2'de oral ve transdermal östrojen kıyaslaması özet olarak gösterilmektedir.

Tablo 2 Oral vs. Transdermal östrojen karşılaştırılması

	Oral östradiol	Transdermal östradiol
Hepatik ilk geçiş	ü	û
VTE riski	RR 1,9 (oral vs. transdermal,)	RR1,0 (plaseboyla aynı)
İnme riski	Yüksek dozda artış	Anlamlı artış yok
Trigliserid	Arttırabilir	Nötr etki
LDL	Düşürür	Benzer etki, daha hafif
Klinik tercih	Risk faktörü yok ise uygun	Tüm gruplarda, Özellikle yüksek riskli kadınlarda tercih

Östrojen dozlaması, bireysel semptom şiddeti, menopoz yaşı, kardiyovasküler risk profili ve tedavi hedefine göre geniş bir yelpazededir. Güncel kılavuzlar semptom kontrolü ve uzun dönem kemik koruması için mümkün olan en düşük etkin dozla başlamayı önerilmektedir.(The Menapouse Society (NAMS), 2022; Yu et al., 2024) Tablo 3'te veriliş yoluna göre östrojen dozları ve klinik hedefler gösterilmiştir.

Tablo 3 Veriliş yollarına göre östradiol dozları ve klinik hedefler

	Oral östradiol	Transdermal östradiol	Klinik hedef
Ultra düşük doz	0,5 mg/gün	14-25 µg/gün (yama)	Kemik koruması, hafif VMS
Düşük doz	1 mg/gün	25-37.5 µg/gün	Semptom kontrolü, standart VMS
Konvansiyonel doz	2mg/gün	50 µg/gün	Orta- şiddetli VMS, GSM, kemik
Yüksek/ fizyolojik doz	2-4 mg/gün (POY)	75-100 µg/gün (POY)	Prematür ovaryan yetmezlik (POY)

Yu ve ark.'ın faz 3 çalışmalarının analizinde ultra düşük doz östradiol 0,5 mg+ didrogesteron 2.5 mg kombinasyonunun postmenopozal kadınlarda VMS'yi plaseboya kıyasla anlamlı biçimde azalttığı gösterilmiştir.(Yu et al., 2024) Transdermal yol için ise IMS 2024 White Paper, 25-50 µg/gün'lük yamaların kemik koruması için yeterli olduğunu, VMS kontrolü için ise 37,5 µg/gün'den başlanarak semptom yanıtına göre titrasyonu önermektedir.(Panay et al., 2024) Sonuç olarak, ne kadar düşük doz kullanılırsa güvenli alanda kalma ihtimali artacak ancak semptom kontrolü de aynı ölçüde zayıflayabileceğinden tedavi uyumsuzluğunu ve korunma yoksunluğunu da beraberinde getireceği unutulmamalıdır.

Östrojen kullanımından bahsedilirken prematür ovaryan yetmezlikten (POY) de bahsetmek gerekmektedir. Bu tabloda 40 yaş öncesinde ortaya çıkan ovaryan fonksiyon kaybı temel postmenopozal tedavi stratejilerinden farklı bir yaklaşıma ihtiyaç duyar. Yeterli tedavi yapılmayan POY'da uzun süreli reprodüktif düzeyin altında kalan östrojen düzeyleri, osteoporoz, kardiyovasküler hastalık, bilişsel gerileme ve artmış mortalite ile ilişkilidir. Bu nedenle kontrendikasyon yoksa doğal menopoz yaşına ulaşılıncaya kadar tedavi önerilmektedir. ('ESHRE Guideline: management of women with premature ovarian insufficiency', 2016; Pravatta-Rezende et al., 2025) Güncel kılavuzlar, fizyolojik serum östradiol düzeylerine (~100 pg/mL) ulaşabilmek için MHT'den daha yüksek östrojen dozlarını

önermektedir.

4.2. Kombine Östrojen + Progesteron Tedavisi (EPT)

Uterusu olan kadınlarda östrojen tedavisine progesteron eklenmesi zorunludur. Sistemik östrojenin endometrial hiperplazi ve karsinom geliştirme riskini progestagenler azaltır. Bu sebeple tedavinin vazgeçilmez bir bileşenidir. (Hamoda, 2022; Panay et al., 2024) Güncel kılavuzlar, endometrial korumanın yeterliliğini progestogenin tipine, dozuna ve uygulama süresine bağlı olarak değerlendirmektedir.

Sekansiyel rejimlerde menstrüel siklus modeline yakın şekilde, östrojen sürekli uygulanırken progesteron siklusun luteal fazına karşılık gelen döenmlerde eklenmektedir. BMS 2022 kılavuzu, sekansiyel rejimlerde progestogenin ayda en az 12-14 gün süreyle uygulanması gerektiğini, daha az progestogen maruziyetinin endometrial hiperplazi ve karsinom riskini arttırdığını açıkça belirtmektedir.(Hamoda, 2022) Sürekli kombine rejimlerde ise her iki hormon da kesintisiz uygulanmaktadır. Sekansiyel rejim perimenopoz ve postmenopozal dönemde tercih edilirken sürekli kombine rejim daha çok postmenopozal dönemde tercih edilmektedir. Sekansiyel ve sürekli kombine rejim karşılaştırılması Tablo 4'te gösterilmiştir.

EPT'den bahsederken tartışılması gereken bir başka konu da kullanılan progestogen tipi ve güvenlik profilidir. Progestogenler arasındaki en temel klinik ayrım, biyokimyasal benzerlik ile reseptör bağlanma özgüllüğü üzerinedir. Sentetik progestinler (medroksiprogesteron asetat (MPA), noretisteron asetat (NETA), levonorgestrel (LNG)) androjen, glukokortikoid ve mineralokortikoid reseptörlere çapraz bağlanabilmekte ve bu durum kardiyometabolik profil ve meme dokusu üzerinde olumsuz etkiler doğurabilmektedir. Mikronize progesteron (MP) ve didrogesteron ise progesterona biyokimyasal olarak daha yakın olduğundan bu çapraz bağlanma etkileşiminden büyük ölçüde kaçınır. (Asi et al., 2016; P. Stute, Wildt, & Neulen, 2018)

Tablo 4 sekansiyel ve sürekli kombine rejimlerin karşılaştırılması

	Sekansiyel	**Sürekli kombine**
Östrojen uygulaması	Kesintisiz her gün	Kesintisiz her gün
Progestogen uygulaması	Ayda 12-14 gün (luteal faz modeli	Her gün düşük dozda kesintisiz
Kanama profili	Düzenli çekilme kanaması beklenir	Zamanla amenore hedeflenir, ilk aylarda düzensiz lekelenme olabilir
Tercih edilen dönem	Perimenopoz ve erken postmenopozal dönem (<12 ay amenore)	Postmenopoz (son adet üzerinden >12 ay)
Endometrial koruma	Yeterli ancak >5 yıl kullanımda endometrial kalınlaşma riski artabilir.(Mukherjee & Davis, 2025)	Sürekli progestogen maruziyetiyle endometrium atrofik kalır, hiperplazi riski düşük.(Hamoda, 2022)
Meme kanseri riski (5 yıl, 1000 kadın)(Collaborative Group on Hormonal Factors in Breast	+14 ek vaka (sekansiyel EPT)	+20 vaka (sürekli kombine EPT)

Cancer., 2019)

Özellikle perimenopozal dönemde düzensiz vajinal kanama, kontrasepsiyon gereksinimi ve hormonal dalgalanmaların yönetimi için önerilen bir diğer yöntem de kontinue östrojen (tercihen transdermal) tedavisine ek olarak LNG-RIA kullanımıdır.(Depypere & Inki, 2015; Hampton et al., 2005) LNG-RIA endometrial korumayı lokal progestogen salınımı ile sağladığından sistemik progestin maruziyetini minimize ederek sistemik yan etkilerden kaçınmayı da sağlar.(The Menapouse Society (NAMS), 2022) Tablo 5'te progestogenlerin kullanım yolları, dozları ve yan güvenlik profilleri karşılaştırılmalı olarak verilmiştir.

WHI çalışmasında kullanılan MPA, bugün meme kanseri riski üzerindeki olumsuz etkileri sebebiyle sorgulanmaktadır. Buna karşın mikronize progesteron (MP), endojen progesterona özdeş kimyasal yapıya sahip olduğundan yanetki profili olarak MPA'ya göre daha kullanılabilir görünmektedir. (Hamoda, 2022; Rencoret et al., 2024) Güncel çalışmalarda, kombine östrojen+MP tedavisinin meme kanseri riskinin, kombine östrojen+progestin tedavisine kıyasla anlamlı ölçüde daha düşük olduğunu göstermiştir (RR 0,67; %95 GA 0,55-0,81). (Rencoret et al., 2024)

Tablo 5 MHT'de Kullanılan Progestogenler: Önerilen Dozlar, Uygulama Yolları ve Güvenlik Profilleri (Guo, 2025; Hamoda, 2022; Rencoret et al., 2024; Petra Stute et al., 2023; The Menapouse Society (NAMS), 2022)

İlaç (ticari ad)	Sınıf	Sekansiyel doz (12–14 gün/ay)	Sürekli kombine doz (her gün)	Uygulama yolu	Meme kanseri riski	KV/VTE profili
Mikronize progesteron (mp) Utrogestan®, prometrium®	Doğal	Standart östrojen: 200 mg/gün, 12–14 gün/ay Yüksek doz östrojen (POY): 300 mg/gün, 12 gün/ay	Standart: 100 mg/gün Yüksek doz östrojen: 200 mg/gün	Oral, vajinal, Transdermal yetersiz	≤5 yıl: artış yok >5 yıl: sınırlı veri ● **Düşük**	VTE nötral; lipid profili koruyucu, en elverişli profil
Didrogeston Duphaston®	Progesteron türevi	E2 1–2 mg ile: 10 mg/gün, 14 gün/ay	E2 0.5 mg ile: 2.5 mg/gün E2 1 mg ile: 5 mg/gün	Oral	Anlamlı artış yok (E3N kohortu) ● **Düşük**	Nötr; HDL'ye minimal etki, glukoz metabolizması elverişli
Medroksiprogesteron asetat (mpa) Provera®	Androjen türevi	10 mg/gün, 10–14 gün/ay	2.5 mg/gün Alternatif: 5 mg/gün	Oral	WHI'da artmış risk (CEE+MPA, >5 yıl) ○ **Yüksek**	HDL'yi düşürür; TG artırabilir, glukokortikoid etkisi var
Noretisteron asetat (neta) — oral Kliogest®, activelle® (kombine)	Androjen türevi	Min. 1 mg/gün, en az 10 gün/ay	Min. 0.5 mg/gün Standart: 1 mg/gün	Oral	Gözlemsel çalışmalarda artmış risk ○ **Yüksek**	Güçlü androjen etkisi; HDL azalır, VTE riski artabilir

Noretisteron asetat (neta) — transdermal Estalis® (kombine yama)	Androjen türevi	Kombine yamada: 140–250 µg/gün (haftada 2×)	Sürekli yama: 140 µg/gün	Transdermal yama	Oral NETA'ya kıyasla daha az veri; orta risk ◑ **Orta**	Oral NETA'ya göre daha elverişli VTE profili
Levonorgestrel — transdermal yama Climara pro® (kombine)	Androjen türevi	Sürekli kombine: 6 µg/gün (E2 45 µg ile)	6 µg/gün	Transdermal yama	Sınırlı uzun dönem veri ◑ **Orta**	Transdermal; oral LNG'ye göre düşük VTE riski
Levonorgestrel ria (lng-ria) Mirena® 52 mg	İntrauterin	Lokal salınım: ~20 µg/gün (ilk yıl) Sistemik östrojenle birlikte kullanılır	4–5 yıl kesintisiz lokal etki UK: 4 yıl lisanslı (HT endikasyonu)	İntrauterin (Sistemik progestogen yok)	Minimal sistemik maruziyet Meme riski tartışmalı; lokal etki baskın ● **Düşük**	Sistemik androjenik etki minimal; VTE riski ihmal edilebilir
Drospirenon Angeliq® (e2 1mg + drsp 2mg)	Progesteron türevi	— (sekansiyel form mevcut değil)	2 mg/gün (E2 1 mg ile)	Oral	Sınırlı uzun dönem veri ◑ **Orta**	Antimineralokortikoid etki: kan basıncına olumlu; VTE riski dikkat

KV: Kardiyovasküler; VTE: Venöz Tromboembolizm; RİA: Rahim İçi Araç; TG: Trigliserid; HDL: Yüksek Yoğunluklu Lipoprotein; E2: 17β-estradiol; POY: Prematür Ovaryan Yetmezliği; CEE: Konjuge Equin Östrojen; MPA: Medroksiprogesteron Asetat; NETA: Noretisteron Asetat; MP: Mikronize Progesteron; DRSP: Drospirenon.

4.3. Lokal / Vajinal Östrojen Tedavisi

Genitoüriner menopoz sendromu (GSM), 2014 yılında Uluslararası Kandın Cinsel Sağlığı Derneği (ISSWSH) ve NAMS'ın ortak konsensusu ile benimsenen güncel bir terminolojidir. Östrojen yoksunlupuna bağlı vulvovajinal atrofi, vajinal kuruluk, disparoni, tekrarlayan idrar yolu enfeksiyonları, üriner urgency ve dizüriyi kapsayan bu tablonun postmenopozal kadınların %50-70'ini etkilediği tahmin edilmektedir. (Da Silva, Baines, Araklitis, Robinson, & Cardozo, 2021; Portman & Gass, 2014) Bu sıklığa karşın GSM, hala yetersiz tanınan ve tedavi edilen bir sendrom olarak kalmaya devam etmektedir. Etkilenen kadınların tüm bu semptomları yaşlanmanın bir sonucu olarak kabullenmesi ve yardım isteme konusundaki çekingenlikleri bu tablonun klinik pratikte gözden kaçmasına zemin hazırlamaktadır.(Da Silva et al., 2021; The Menapouse Society (NAMS), 2022)

GSM semptomları, sistemik MHT'nin aksine kullanım kesildikten sonra da iyileşme eğilimi göstermez ve zamanla ilerleyebilir. Bu nedenle ICSM 2024 kılavuzu, tedaviye erken başlanmasının, anatomik değişikliklerin yerleşmesini önlemek adına daha etkin bir strateji olduğunu vurgulamaktadır. (Simon et al., 2026)

Düşük doz lokal vajinal östrojen preparatları GSM tedavisinde birinci seçenek farmakolojik ajan olarak tanımlanmaktadır. (Panay et al., 2024; Simon et al., 2026) Bu preparatların temel klinik üstünlüğü, lokal etkinliği sistemik maruziyetten büyük ölçüde bağımsız olmasıdır. Farmakokinetik çalışmalar, düşük doz (7.5–10 μg östradiol) vajinal tablet ve halka formülasyonlarının kronik kullanımda, serum östradiol düzeylerini postmenopozal referans aralığının (≤20 pg/mL) belirgin üstüne çıkarmadığını göstermektedir.(Lethaby, Ayeleke, & Roberts, 2016) Vajinal atrofinin düzeldiği dönemde akut emilim piki azalmakta, bu da uzun dönem kullanımda sistemik maruziyetin başlangıca kıyasla daha da azaldığını göstermektedir.

Vajinal östrojen ürünlerinin etkinliğini değerlendiren 53 randomize kontrollü çalışmayı kapsayan sistemik bir derlemede, krem, tablet ve halka formülasyonların tamamının vajinal pH, olgunlaşma indeksi, disparoni ve vajinal kuruluk üzerinde plaseboya kıyasla üstün olduğu saptanmış, 4 μg kadar düşük östradiol dozlarının klinik etkinliği sürdürebildiği bildirilmiştir.(Rahn et al., 2014) Güncel kılavuzlar, yalnızca vajinal semptomu olan ve VMS bulunmayan kadınlarda lokal tedaviyi önermekte, ayrıca düşük doz vajinal östrojen kullanımında endometrial hiperplazi riski olmadığını ve uterusu korunmuş kadınlarda dahi beraberinde progestogen eklenmesine ihtiyaç olmadığını belirtmektedir.(Panay et al., 2024; The Menapouse Society (NAMS), 2022) Endometrial güvenlik verileri uzun dönem kullanım sonuçlarından yoksun olduğundan yıllık klinik değerlendirme önerilmektedir.

Lokal östrojene ek olarak farklı iki mekanizma ile etki gösteren yeni tedavi seçenekleri klinik pratiğe girmiştir. Vajinal DHEA (prasterone), vajinal hücrelerde intraselüler olarak östrojen ve androjene dönüştürülen bir prekürsör hormondur. Bu dönüşümün lokal enzim sistemi tarafından düzenlenmesi sayesinde sistemik hormonlarda anlamlı bir artış gözlemlenmemektedir. Klinik çalışmalarda ise vajinal DHEA kullanımının disparoni, epitelyal olgunlaşma ve vajinal pH üzerinde etkinliği kanıtlanmış olup, NAMS ve ICSM kılavuzları bu ajan için orta düzey öneri sunmaktadır.(Simon et al., 2026; The NAMS 2020 GSM Position Statement Editorial Panel, 2020) Ospemifen ise oral yolla alınan ve vajinal epitelde östrojen agonist etki gösteren bir selektif östrojen reseptör modülatörüdür(SERM). Vajinal uygulamada zorlanan kadınlarda pratik bir alternatif olarak düşünülmektedir.(Simon et al., 2026) Önemli bir not olarak, ospemifenin VTE riski açısından diğer SERM'lere benzer bir profil taşıdığı ve meme kanseri öyküsünde kontrendike olduğu unutulmamalıdır.(The NAMS 2020 GSM Position Statement Editorial Panel, 2020)

Meme kanseri tanısı almış kadınlarda GSM sıklığı, aromataz inhibitörleri ve kemoterapi kaynaklı erken menopoza bağlı olarak, genel popülasyona oranla daha yüksektir. Sistemik

MHT bu grupta uzun süre kontrendike sayılmış ancak düşük doz vajinal östrojen, minimal sistemik emilimi nedeniyle tartışılmaktadır.

McVicker ve ark.'ın 2024 yılında yayımladığı geniş ölçekli kohort çalışmasında vajinal östrojen kullanımının meme kanserine spesifik mortalite üzerinde olumsuz bir etki oluşturmadığı gösterilmiştir.(McVicker et al., 2024) Benzer bir derlemede ise meme kanseri geçirmiş kadınlarda vajinal östrojen kullanımının nüks riski, meme kanseri spesifik mortalite ve genel mortalite üzerinde anlamlı bir artışla ilişkili olmadığını ortaya koymuştur.(Beste, Kaunitz, McKinney, & Sanchez-Ramos, 2025) NAMS, ACOG ve IMS; nonhormonal tedavilere yanıt alınamayan semptomatik kadınlarda onkologla ortaklaşa paylaşımlı karar verme sürecini önermektedir. Bu yaklaşım meme kanseri öyküsünü mutlak kontrendikasyon olmaktan çıkarmakta, kişiselleştirilmiş yarar-zarar değerlendirmesini merkeze almaktadır.(McVicker et al., 2024; Panay et al., 2024; The NAMS 2020 GSM Position Statement Editorial Panel, 2020)

5. Biyoeşdeğer Hormon Tedavisi

5.1. Tanım ve Kavramsal Çerçeve

Biyoeşdeğer hormon tanımı, insan vücudunun ürettiği hormonlarla aynı kimyasal ve moleküler yapıya sahip bileşikleri tanımlamaktadır.(National Academies of Sciences, 2020) Bu tanım hem ticari preparatları hem de eczanelerde özel formülasyon olarak hazırlanan kompound ürünleri kapsamaktadır. Kavramsal kargaşanın özü de bu noktada başlamaktadır. Pazarlama dilinde 'biyoeşdeğer' terimi doğrudan kompound ile özdeşleştirilerek bu preparatların doğal, daha güvenli ya da daha etkili olduğu izlenimi yaratılsa da bu iddialar bilimsel kanıtlarla desteklenmemektedir.('Compounded Bioidentical Menopausal Hormone Therapy', 2023; Panay et al., 2024)

5.2. Biyoeşdeğer HT Preparatları

Biyoeşdeğer preparatlar kural olarak standartlaştırılmış üretim koşullarına sahip, piyasaya sunulmadan önce bağımsız güvenlik ve etkinlik çalışmalarından geçmiş, öngörülebilir dozlamlara sahip ve prospektüsleri aracılığıyla risk bilgisi sunulan preparatlardır. ('Compounded Bioidentical Menopausal Hormone Therapy', 2023; Endocrine Society, 2019)Bu kategorideki başlıca preparatlar, oral östradiol (0.5–2 mg), transdermal östradiol yamaları (14–100 µg) ve jeller, vajinal östradiol krem/tablet/halka, oral mikronize progesteron (100–200 mg) ile vajinal mikronize progesteron formülasyonlarını kapsamaktadır.

NAMS, IMS, ACOG ve Endocrine Society; FDA onaylı biyoeşdeğer formları öncelikli seçenek olarak belirtmekte ve yeterli onaylı seçenek mevcut olduğundan, kompound preparatlara başvurulmasını açıkça önermemektedir.('Compounded Bioidentical Menopausal Hormone Therapy', 2023; Panay et al., 2024; Rapkin & Akopians, 2012; The Menapouse Society (NAMS), 2022)

5.3. Kompound Biyoeşdeğer HT (cBHT) ve Güvenlik Sorunları

Kompund preparatlar kontrol mekanizmalarının dışında kaldığından doz tutarsızlığı ve emilim değişkenliği sorunlarıyla karşımıza çıkmaktadır. Stanczyk ve ark.'ın çalışmasında, bu formların reçete edilen miktarın dışında aktif madde içerebildiği belgelenmiştir.(Stanczyk, Niu, Azen, Mirkin, & Amadio, 2019)ACOG Klinik Konsensüs No. 6 (2023) bu bulguyu teyit ederek kompound formülasyonlardaki değişken biyoyararlanım ve biyoaktivite nedeniyle hem düşük

hem de yüksek dozajın olası olduğunu vurgulamaktadır.(‘Compounded Bioidentical Menopausal Hormone Therapy’, 2023)

Bunun yanı sıra kompound ürünler için standart bir risk bilgilendirme prospektüsü bulunmamakta, advers olay bildirimi de yasal olarak zorunlu tutulmamaktadır. Ulusal Bilim Akademisi (NASEM) 2020 raporunun kapsamlı literatür taramasında, cBHT güvenlik ve etkinliğine ilişkin mevcut verilerin büyük bölümünün ağırlıklı olarak hasta raporları ve reçete eden hekimlerin tanıklıklarından oluştuğu ve iyi tasarlanmış, yeterince kontrol edilmiş klinik çalışmaların olmadığı sonucuna varılmıştır. Bu bağlamda NASEM, östradiol ve progesteron başta olmak üzere pek çok kompound biyoeşdeğer hormonu FDA'nın "Kompound Edilmesi Güç İlaçlar Listesi" için aday olarak tanımlamıştır.(National Academies of Sciences, 2020)

5.4. Tükürük Bazlı Hormon Testi

Kompound HT pratiğinde yaygın biçimde uygulanan tükürük bazlı hormon düzeyi ölçümüne dayalı doz ayarlama stratejisi hem kanıtlanmamış hem de fizyolojik olarak temelsizdir. Bu yaklaşımın geçersizliğinin üç temel nedeni bulunmaktadır. Birinci neden, hormon düzeylerinin biyolojik değişkenliğidir. Özellikle Perimenopozal dönemde hormon seviyeleri, aynı menstrüel döngü içinde bile belirgin dalgalanmalar gösterilebilir. Ayrıca günün saati, beslenme düzeni ve kullanılan diğer ilaç gibi faktörler de bu düzeyleri etkileyebilir. Bu nedenle hormon ölçümleri hem aynı bireyde farklı zamanlarda hem de farklı bireyler arasında değişkenlik gösterebilir.(Stuenkel, 2021; The Menapouse Society (NAMS), 2022)

Dolayısıyla tek bir tükürük ölçümü, bir kadının uzun dönem hormon maruziyetini güvenilir biçimde yansıtmaz. İkinci önemli neden ise tükürükteki hormon düzeylerinin seruma göre oldukça düşük olmasıdır. Buna ek olarak, tükürük farklı hücre tipleriyle kontamine olabilir. Bu durum, ölçümlerin güvenilirliğini ciddi oranda azaltır.(Stuenkel, 2021)Üçüncü ve belki de en önemli neden, tükürük hormon düzeyleri ile menopozal semptomlar arasında kanıtlanmış bir ilişki bulunmamasıdır. Başka bir deyişle, tükürükte ölçülen hormon değeri hastanın vazomotor semptomları, uyku bozukluğu ya da diğer menopoz semptomlarının şiddetini doğrudan yansıtmaz. Bu testler hormon tedavisi doz ayarlaması için güvenilir ve kanıtlanmış bir yöntem değildir. (Guo, 2025)

ACOG kılavuzunda, tükürük hormon testinin klinik yararını destekleyen yeterli kanıt bulunmadığı açıkça belirtilmektedir. Ayrıca bu ölçümlerin hem doğruluk hem de güvenilirlik açısından şüpheli olduğu vurgulanmaktadır.(Stuenkel, 2021) Benzer şekilde, NAMS da tükürük testlerini hormon tedavisi izlemi için anlamlı bir yöntem olarak kabul etmemekte, bu test sonuçlarına göre doz ayarlamasını klinik açıdan uygun bulmamaktadır.(The Menapouse Society (NAMS), 2022)

IMS 2024 White Paper da benzer bir noktaya dikkat çekmektedir. Kamuoyu figürleri ve bazı fonksiyonel tıp hekimleri tarafından öne sürülen pazarlama söylemlerine rağmen, kompound biyoeşdeğer hormon preparatlarının daha etkili ya da daha güvenli olduğuna dair güçlü bir kanıt bulunmamaktadır. Bu nedenle kompound preparatların kullanımı ancak mevut bir ürüne karşı alerji varlığı, ticari preparatlarda bulunmayan özel bir doz ihtiyacı veya birden fazla hormonun tek formda verilmesini gerektiren sınırlı ve özel durumlarda düşünülebilir. (Panay et al., 2024; The Menapouse Society (NAMS), 2022) Biyoeşdeğer ve kompound hormon tedavisi karşılaştırması Tablo 6’da verilmiştir.

Tablo 6 Biyoeşdeğer ve kompound hormon tedavisi karşılaştırması(‘Compounded Bioidentical Menopausal Hormone Therapy’, 2023; Endocrine Society, 2019; Panay et al., 2024; The Menapouse Society (NAMS), 2022)

	Biyoeşdeğer HT	**Kompound BHT**
Güvenlik ve etkinlik kanıtı	Onay öncesi >12 hafta plasebo kontrollü RKÇ zorunlu	Yetersiz, mevcut veriler anekdot niteliğinde
Doz tutarlılığı	Standardize	Değişken
Emilim profili	Kanıtlı farmakokinetik verilerle desteklenmiş	Kişiden kişiye ve formülasyonlara göre farklılık
Risk bilgilendirmesi	Zorunlu prospektüs	Hasta bilgilendirmesi reçeteleyene bağlı
Tükürük testi ile doz ayarı	Uygulanmaz	Yaygın ancak geçersiz
Kılavuz önerisi	NAMS, IMS, ACOG, Endocrine Society	Yok

GMP: İyi Üretim Uygulamaları (Good Manufacturing Practice); RKÇ: Randomize Kontrollü Çalışma; FDA: Amerikan Gıda ve İlaç Dairesi.

6. Tartışma ve Sonuç

MHT için son 20 yıl, büyük bir değişime sahne olmuştur. 2002 WHI yayınının ardından oluşan kısıtlayıcı konsensus, çalışmanın metodolojik sınırlılıkları üzerine inşa edilmişti. Günümüz yönetimi ise kanıta dayalı, kişiselleştirilmiş bir yönetim anlayışı olarak yeniden konumlandırılmıştır. Bu dönüşümün temeli tek bir çalışmanın sınırlılıklarını aşan ve birbirini destekleyen bir kanıt bütünüdür. WHI kohortunun demografik yapısının günümüz MHT uygulamalarını temsil etmediği bir gerçektir. Çalışmada kullanılan oral konjuge equin östrojen + MPA da artık büyük ölçüde terk edilmiş kombinasyonlar arasında yer aldığı bilinmektedir. Bu çerçevede günümüz pratiğinde tercih edilen transdermal östradiol + mikronize progesteron kombinasyonu WHI çalışmasında bahsedilen risk profilinin dışında değerlendirilmelidir.

WHI verilerinin alt grup analizleri, menopozdan itibaren geçen sürenin ve başlama zamanının kardiyovasküler risk üzerinde belirleyici bir rol oynadığını ortaya koymuştur. (The Menapouse Society (NAMS), 2022) ELITE çalışması bu bulguyu karotis ateroskleroz ilerlemesi ile değerlendirmiş, menopozun erken döneminde transdermal östradiol başlayan kadınlarda, intima-media kalınlığı geç başlayanlara kıyasla anlamlı biçimde yavaş ilerlediğini ortaya koymuştur.(Hodis et al., 2016) Zamanlama hipotezi ve fırsat penceresi kavramları ise bu çalışmalardan sonra günümüz kılavuzlarının temelini oluşturmuştur. 2025’te Lancet Diabetes&Endocrinology’de yayımlanan bir çalışmada ise önceden benimsenen 10 yıl/60 yaş sınırının özellikle transdermal formülasyonlar için kısıtlayıcı olabileceğini ortaya koyarak bu tartışmayı daha da ileriye taşımıştır.(Taylor & Davis, 2025)

Bu derlemenin ikinci temel ekseni, farmakolojik seçimin klinik sonuçlar üzerindeki belirleyici etkisini ortaya koymaktır. WHI’nin önerileri yalnızca zamanlama sorunuyla değil, tercih edilen formülasyon ile de tartışmalıdır. Oral östrojen preparatlarının karaciğer ilk geçiş metabolizmasına bağlı etkileri ve MPA’nın meme dokusu üzerindeki proliferatif aktivitesi göz önüne alındığında uzun yıllar standart kabul edilen rejimin aslında sorunlu bir güvenlik profili ortaya koyduğunu göstermektedir. Transdermal 17ß-östradiolün oral formlara kıyasla VTE

riskinin plasebo düzeyinde olduğu, inme riski için de benzer bir güvenlik profili gösterdiği güncel çalışmalarda kanıtlanmıştır.(Renoux et al., 2010; Scarabin, 2018) Progestogen seçimi için ise E3N kohort verileri ve sonrasındaki meta-analizlerde, mikronize progesteronun sentetik formlara kıyasla meme kanseri riskini anlamlı biçimde azalttığı gösterilmiştir.(Asi et al., 2016)

Mikronize progesteronun farmakobiyolojisi ise bu noktada ayrıca önemlidir. Allopregnanolon metaboliti aracılığıyla GABA-A reseptörleri üzerinden yaptığı modülasyon ile endometrial korumanın ötesinde nöropsikiyatrik olarak da olumlu etkiye sahiptir. Gordon ve ark.'ın randomize kontrollü çalışmasında, mikronize progesteron kombinasyonlarında perimenopozal depresyon gelişiminin plaseboya kıyasla anlamlı olarak önlediği gösterilmiştir.(Gordon et al., 2018)

Bir başka önemli nokta ise perimenopozal dönemin yönetimidir. Sekansiyel EPT rejimleri, LNG-RIA +sistemik östrojen ve düşük doz KOK seçenekleri bu dönem için ayrı bir klinik çerçeve gerektirmektedir.(Mukherjee & Davis, 2025; The Menapouse Society (NAMS), 2022) POY yönetiminde ise risk- yarar dengesi postmenopozal dönemden ayrılmakta uzun süreli hipoöstrojenizmin getirdiği kardiyovasküler, kemik ve bilişsel sonuçları fizyolojik hormon replasmanını doğal menopoz yaşına kadar sürdürmeyi gerektirmektedir.(Pravatta-Rezende et al., 2025)

GSM ise postmenopozal kadınların çoğunu etkileyen ve yaşam kalitesi üzerinde en az kronik hastalıklar kadar etkili olan bir tablodur.(Portman & Gass, 2014) Düşük doz vajinal östrojen preparatlarının sistemik emiliminin minimal olması, bu tedavinin daha önce kontrendikasyon kabul edilen bir çok durumda uygulanabilir kılmaktadır. Güncel literatürde, meme kanseri öyküsü olan kadınlarda düşük doz vajinal östrojenin onkolojik sonuçları olumsuz etkilemediğini gösteren geniş ölçekli kohort ve meta-analizler mevcuttur.(Beste et al., 2025; McVicker et al., 2024)

Hormon tedavisi tartışmasının paralel bir cephesi olarak, kompound biyoeşdeğer hormon preparatları için kamuoyu algısı ve klinik gerçeklik arasında büyük bir uçurum vardır. Biyoeşdeğer teriminin kompound preparatlarla özdeşleştirilmesi ve bu ürünlerin ticari preparatlara kıyasla daha doğal, daha güvenli ya da daha etkili izleniminin yaratılması, bilimsel kanıtlardan uzaktır. ('Compounded Bioidentical Menopausal Hormone Therapy', 2023; Santoro et al., 2016) Stanczyk ve ark.'ın çalışmasında kompound kapsül ve kremlerin reçete edilen miktarın dışında aktif madde içerebildiği ortaya konmuş, bu preparatlardaki doz tutarsızlığı sorununu somutlaştırmıştır.(Stanczyk et al., 2019) ACOG ise 2023'te yayınladığı klinik konsensusta FDA onaylı seçenek bulunduğu sürece kompound preparatların rutin olarak reçete edilmemesini önermiştir.('Compounded Bioidentical Menopausal Hormone Therapy', 2023)

Bu derlemede sunulan kanıtların tamamı, MHT'nin artık tek tip bir protokol ya da evrensel bir risk etiketiyle ele alınamayacağını, başlama zamanı, uygulama yolu, hormon tipi ve bireysel klinik profil göz önünde tutularak değerlendirilmesi gereken çok boyutlu bir karar sürecinden geçmesi gerektiğini ortaya koymaktadır. Güncel kılavuzlar ve literatür önerileri bireysel ihtiyaç ve risk-yarar dengesine göre MHT'nin şekillendirilmesi gerektiğini vurgulamaktadır.

Semptomatik ve kontrendikasyonu bulunmayan kadınlar için tercihen menopozdan itibaren ilk 10 yıl içinde başlanan transdermal östradiol ve mikronize progesteron içeren bir tedavi rejimi günümüzde en uygun yaklaşım olarak öne çıkmaktadır. GSM tedavisinde ise düşük doz lokal vajinal östrojen ilk seçenek olarak görülmektedir. Hormonal kontrendikasyon varlığında ise non-hormonal tedavi ajanları, etkinlik ve kabul edilebilir güvenlik profili ile tedavi için iyi bir seçenek olarak literatürde yerini almaktadır.

GSM'nin yetersiz tedavi edilmesi, perimenopozun göz ardı edilmesi ve POY'un geç tanınması

gibi klinik bakım açıkları günümüzde de sürmektedir. Bu açıkların kapatılması klinisyenlerin güncel kanıtları takip etmesi, hastaların yanıltıcı bilgi ortamından arındırılmış bir bilinç düzeyine ulaşması ve menopoz araştırmalarına ayrılan kaynakların arttırılması ile mümkün olacaktır. MHT'nin geleceği "tedavi et ya da etme" ikileminde değil; "kimi, ne zaman, hangi formülasyonla ve ne kadar süre tedavi etmelisin?" sorularına bilimsel ve bireyselleştirilmiş yanıtlar bulmakta yatmaktadır. Bu yanıtların güvenilir olabilmesi için güçlü bir bilimsel kanıt tabanı, şeffaf hasta hekim iletişimi ve sürekli güncellenen klinik yargı ile mümkündür.

7. Kaynakça

Abenhaim, H. A., Suissa, S., Azoulay, L., Spence, A. R., Czuzoj-Shulman, N., & Tulandi, T. (2022). Menopausal Hormone Therapy Formulation and Breast Cancer Risk. *Obstetrics & Gynecology*, *139*(6), 1103–1110. doi:10.1097/AOG.0000000000004723

Asi, N., Mohammed, K., Haydour, Q., Gionfriddo, M. R., Vargas, O. L. M., Prokop, L. J., … Murad, M. H. (2016). Progesterone vs. synthetic progestins and the risk of breast cancer: a systematic review and meta-analysis. *Systematic Reviews*, *5*(1), 121. doi:10.1186/s13643-016-0294-5

Beste, M. E., Kaunitz, A. M., McKinney, J. A., & Sanchez-Ramos, L. (2025). Vaginal estrogen use in breast cancer survivors: a systematic review and meta-analysis of recurrence and mortality risks. *American Journal of Obstetrics and Gynecology*, *232*(3), 262-270.e1. doi:10.1016/j.ajog.2024.10.054

Cagnacci, A., & Venier, M. (2019). The Controversial History of Hormone Replacement Therapy. *Medicina*, *55*(9), 602. doi:10.3390/medicina55090602

Canonico, M., Oger, E., Plu-Bureau, G., Conard, J., Meyer, G., Lévesque, H., … Scarabin, P.-Y. (2007). Hormone Therapy and Venous Thromboembolism Among Postmenopausal Women. *Circulation*, *115*(7), 840–845. doi:10.1161/CIRCULATIONAHA.106.642280

Cho, L., Kaunitz, A. M., Faubion, S. S., Hayes, S. N., Lau, E. S., Pristera, N., … Lindley, K. J. (2023). Rethinking Menopausal Hormone Therapy: For Whom, What, When, and How Long? *Circulation*, *147*(7), 597–610. doi:10.1161/CIRCULATIONAHA.122.061559

Collaborative Group on Hormonal Factors in Breast Cancer. (2019). Type and timing of menopausal hormone therapy and breast cancer risk: individual participant meta-analysis of the worldwide epidemiological evidence. *The Lancet*, *394*(10204), 1159–1168. doi:10.1016/S0140-6736(19)31709-X

Compounded Bioidentical Menopausal Hormone Therapy. (2023). *Obstetrics & Gynecology*, *142*(5), 1266–1273. doi:10.1097/AOG.0000000000005395

Da Silva, A. S., Baines, G., Araklitis, G., Robinson, D., & Cardozo, L. (2021). Modern management of genitourinary syndrome of menopause. *Faculty Reviews*, *10*. doi:10.12703/r/10-25

Depypere, H., & Inki, P. (2015). The levonorgestrel-releasing intrauterine system for endometrial protection during estrogen replacement therapy: a clinical review. *Climacteric*, *18*(4), 470–482. doi:10.3109/13697137.2014.991302

Dubey, R. K., Imthurn, B., Zacharia, L. C., & Jackson, E. K. (2004). Hormone Replacement

Therapy and Cardiovascular Disease. *Hypertension*, *44*(6), 789–795. doi:10.1161/01.HYP.0000145988.95551.28

Endocrine Society. (2019). Compounded Bioidentical Hormone Therapy: Position Statement.

ESHRE Guideline: management of women with premature ovarian insufficiency. (2016). *Human Reproduction*, *31*(5), 926–937. doi:10.1093/humrep/dew027

Gold, E. B. (2011). The timing of the age at which natural menopause occurs. *Obstetrics and Gynecology Clinics of North America*, *38*(3), 425–440. doi:10.1016/j.ogc.2011.05.002

Goldštajn, M. Š., Mikuš, M., Ferrari, F. A., Bosco, M., Uccella, S., Noventa, M., … Garzon, S. (2022). Effects of transdermal versus oral hormone replacement therapy in postmenopause: a systematic review. *Archives of Gynecology and Obstetrics*, *307*(6), 1727–1745. doi:10.1007/s00404-022-06647-5

Gordon, J. L., Rubinow, D. R., Eisenlohr-Moul, T. A., Xia, K., Schmidt, P. J., & Girdler, S. S. (2018). Efficacy of Transdermal Estradiol and Micronized Progesterone in the Prevention of Depressive Symptoms in the Menopause Transition. *JAMA Psychiatry*, *75*(2), 149. doi:10.1001/jamapsychiatry.2017.3998

Guo, Z. (2025). Precision pharmacology in menopause: advances, challenges, and future innovations for personalized management. *Frontiers in Reproductive Health*, *7*. doi:10.3389/frph.2025.1694240

Hamoda, H. (2022). British Menopause Society tools for clinicians: Progestogens and endometrial protection. *Post Reproductive Health*, *28*(1), 40–46. doi:10.1177/20533691211058030

Hampton, N. R. E., Rees, M. C. P., Lowe, D. G., Rauramo, I., Barlow, D., & Guillebaud, J. (2005). Levonorgestrel intrauterine system (LNG-IUS) with conjugated oral equine estrogen: a successful regimen for HRT in perimenopausal women. *Human Reproduction*, *20*(9), 2653–2660. doi:10.1093/humrep/dei085

Hodis, H. N., & Mack, W. J. (2022). Menopausal Hormone Replacement Therapy and Reduction of All-Cause Mortality and Cardiovascular Disease. *The Cancer Journal*, *28*(3), 208–223. doi:10.1097/PPO.0000000000000591

Hodis, H. N., Mack, W. J., Henderson, V. W., Shoupe, D., Budoff, M. J., Hwang-Levine, J., … Azen, S. P. (2016). Vascular Effects of Early versus Late Postmenopausal Treatment with Estradiol. *New England Journal of Medicine*, *374*(13), 1221–1231. doi:10.1056/NEJMoa1505241

Kim, Y., Cho, M. K., Chung, Y.-J., Hong, S.-H., Hwang, K. R., Jeon, G.-H., … Kim, M.-R. (2025). The 2025 Menopausal Hormone Therapy Guidelines - Korean Society of Menopause. *Journal of Menopausal Medicine*, *31*(2), 53. doi:10.6118/jmm.25103

Lethaby, A., Ayeleke, R. O., & Roberts, H. (2016). Local oestrogen for vaginal atrophy in postmenopausal women. *Cochrane Database of Systematic Reviews*, *2016*(11). doi:10.1002/14651858.CD001500.pub3

Manson, J. E., Chlebowski, R. T., Stefanick, M. L., Aragaki, A. K., Rossouw, J. E., Prentice, R. L., … Wallace, R. B. (2013). Menopausal Hormone Therapy and Health Outcomes During the Intervention and Extended Poststopping Phases of the Women's Health Initiative Randomized Trials. *JAMA*, *310*(13), 1353. doi:10.1001/jama.2013.278040

Manson, J. E., Crandall, C. J., Rossouw, J. E., Chlebowski, R. T., Anderson, G. L., Stefanick, M. L., … Prentice, R. L. (2024). The Women's Health Initiative Randomized Trials and

Clinical Practice. *JAMA*, *331*(20), 1748. doi:10.1001/jama.2024.6542

Martin, Kathryn A, Barbieri, R. L. (2026). Menopausal hormone therapy: Benefits and risks. In P. J. Snyder & J. E. Mulder (Eds.), *UpToDate*. Wolters Kluwer. Retrieved from https://www.uptodate.com/contents/menopausal-hormone-therapy-benefits-and-risks?search=menopozlu kadınlar için hormon replasman tedavisi yetişkinler&source=search_result&selectedTitle=1~150&usage_type=default&display_rank=1

McVicker, L., Labeit, A. M., Coupland, C. A. C., Hicks, B., Hughes, C., McMenamin, Ú., … Cardwell, C. R. (2024). Vaginal Estrogen Therapy Use and Survival in Females With Breast Cancer. *JAMA Oncology*, *10*(1), 103. doi:10.1001/jamaoncol.2023.4508

Mehta, J. M., Chester, R. C., & Kling, J. M. (2019). The Timing Hypothesis: Hormone Therapy for Treating Symptomatic Women During Menopause and Its Relationship to Cardiovascular Disease. *Journal of Women's Health*, *28*(5), 705–711. doi:10.1089/jwh.2018.7201

Mukherjee, A., & Davis, S. R. (2025). Update on Menopause Hormone Therapy; Current Indications and Unanswered Questions. *Clinical Endocrinology*. doi:10.1111/cen.15211

National Academies of Sciences, E. and M. H. and M. D. B. on H. S. P. C. on the C. U. of T. P. with C. B. H. R. T. (2020). *The Clinical Utility of Compounded Bioidentical Hormone Therapy*. (D. R. Mattison, R. M. Parker, & L. M. Jackson, Eds.). Washington, D.C.: National Academies Press. doi:10.17226/25791

National Institute for Health and Care Excellence. (2024). Menopause : Diagnosis and Management. Retrieved from https://www.nice.org.uk/guidance/ng23

Panay, N., Ang, S. Bin, Cheshire, R., Goldstein, S. R., Panay, N., Ang, S. Bin, … Nappi, R. E. (2024). Menopause and MHT in 2024: addressing the key controversies – an International Menopause Society White Paper. *Climacteric*, *27*(5), 441–457. doi:10.1080/13697137.2024.2394950

Panay, N., Joffe, H., Maki, P. M., Nappi, R. E., Pinkerton, J. V., Simon, J. A., … Zuurman, L. (2025). Elinzanetant for the Treatment of Vasomotor Symptoms Associated With Menopause. *JAMA Internal Medicine*, *185*(11), 1319. doi:10.1001/jamainternmed.2025.4421

Portman, D. J., & Gass, M. L. S. (2014). Genitourinary syndrome of menopause : new terminology for vulvovaginal atrophy from the International Society for the Study of Women's Sexual Health and The North American Menopause Society. *Menopause*, *21*(10), 1063–1068. doi:10.1097/GME.0000000000000329

Pravatta-Rezende, G., Benetti-Pinto, C. L., Yela, D. A., Rosa e Silva, A. C. J. de S., Nácul, A. P., Marcos dos Reis, F., … Junior, J. M. S. (2025). Premature ovarian insufficiency: Updated concepts in diagnosis and hormonal treatment strategies. *Clinics*, *80*, 100745. doi:10.1016/j.clinsp.2025.100745

Rahn, D. D., Carberry, C., Sanses, T. V., Mamik, M. M., Ward, R. M., Meriwether, K. V., … Murphy, M. (2014). Vaginal Estrogen for Genitourinary Syndrome of Menopause. *Obstetrics & Gynecology*, *124*(6), 1147–1156. doi:10.1097/AOG.0000000000000526

Rapkin, A. J., & Akopians, A. L. (2012). PMS & PMDD: Pathophysiology. *Menopause International*, *18*(2), 52–59.

Rencoret, C., Neyro, J., & Palacios, S. (2024). Menopausal hormone therapy and breast cancer risk: 21 years from the WHI clinical studies. *GREM Gynecological and*

Reproductive Endocrinology & Metabolism, *5*(2), 86–89.

Renoux, C., Dell'Aniello, S., Garbe, E., & Suissa, S. (2010). Transdermal and oral hormone replacement therapy and the risk of stroke: a nested case-control study. *BMJ*, *340*(jun03 4), c2519–c2519. doi:10.1136/bmj.c2519

Rossouw, J. E., Prentice, R. L., Manson, J. E., Wu, L., Barad, D., Barnabei, V. M., … Stefanick, M. L. (2007). Postmenopausal Hormone Therapy and Risk of Cardiovascular Disease by Age and Years Since Menopause. *JAMA*, *297*(13). doi:10.1001/jama.297.13.1465

Santoro, N., Braunstein, G. D., Butts, C. L., Martin, K. A., McDermott, M., & Pinkerton, J. V. (2016). Compounded Bioidentical Hormones in Endocrinology Practice: An Endocrine Society Scientific Statement. *The Journal of Clinical Endocrinology & Metabolism*, *101*(4), 1318–1343. doi:10.1210/jc.2016-1271

Scarabin, P.-Y. (2018). Progestogens and venous thromboembolism in menopausal women: an updated oral versus transdermal estrogen meta-analysis. *Climacteric*, *21*(4), 341–345. doi:10.1080/13697137.2018.1446931

Shrank, W. H., Patrick, A. R., & Brookhart, M. A. (2011). Healthy user and related biases in observational studies of preventive interventions: a primer for physicians. *Journal of General Internal Medicine*, *26*(5), 546–550. doi:10.1007/s11606-010-1609-1

Simon, J. A., Nappi, R. E., Chedraui, P., Clark, A. L., Gompel, A., Nasreen, S. Z. A., … Wolfman, W. (2026). Genitourinary syndrome of menopause (GSM): recommendations from the Fifth International Consultation on Sexual Medicine (ICSM 2024). *Sexual Medicine Reviews*, *14*(1). doi:10.1093/sxmrev/qeaf055

Stanczyk, F. Z., Niu, C., Azen, C., Mirkin, S., & Amadio, J. M. (2019). Determination of estradiol and progesterone content in capsules and creams from compounding pharmacies. *Menopause*, *26*(9), 966–971. doi:10.1097/GME.0000000000001356

Stuenkel, C. A. (2021). Compounded bioidentical hormone therapy: new recommendations from the 2020 National Academies of Sciences, Engineering, and Medicine. *Menopause*, *28*(5), 576–578. doi:10.1097/GME.0000000000001735

Stute, P., Wildt, L., & Neulen, J. (2018). The impact of micronized progesterone on breast cancer risk: a systematic review. *Climacteric*, *21*(2), 111–122. doi:10.1080/13697137.2017.1421925

Stute, Petra, Marsden, J., Salih, N., & Cagnacci, A. (2023). Reappraising 21 years of the WHI study: Putting the findings in context for clinical practice. *Maturitas*, *174*, 8–13. doi:10.1016/j.maturitas.2023.04.271

Taylor, S., & Davis, S. R. (2025). Is it time to revisit the recommendations for initiation of menopausal hormone therapy? *The Lancet Diabetes & Endocrinology*, *13*(1), 69–74. doi:10.1016/S2213-8587(24)00270-5

The Menapouse Society (NAMS). (2022). The 2022 hormone therapy position statement of The North American Menopause Society. *Menopause*, *29*(7), 767–794. doi:10.1097/GME.0000000000002028

The NAMS 2020 GSM Position Statement Editorial Panel. (2020). The 2020 genitourinary syndrome of menopause position statement of The North American Menopause Society. *Menopause*, *27*(9), 976–992. doi:10.1097/GME.0000000000001609

Writing Group for the Women's Health Initiative Investigators. (2002). Risks and Benefits of

Estrogen Plus Progestin in Healthy Postmenopausal Women: Principal Results From the Women's Health Initiative Randomized Controlled Trial. *JAMA: The Journal of the American Medical Association*, *288*(3), 321–333. doi:10.1001/jama.288.3.321

Yu, Q., Stevenson, J. C., Tatarchuk, T., Nappi, R. E., Graziano Custodio, M., Kahler, E., … Ren, M. (2024). Ultra-low-dose estradiol and dydrogesterone for treatment of vasomotor symptoms in Europe and China. *Climacteric*, *27*(5), 494–500. doi:10.1080/13697137.2024.2380364

İleri Yaşta Saptanan Orta Hat Yerleşimli Dev Kranial Lipom: Nadir Bir Tanı

Ayşenur Tıraş[1], Özge Tanişman[1], Erdal Karavaş[1]

[1]*Bandırma Onyedi Eylül Üniversitesi – Bandırma Eğitim ve Araştırma Hastanesi, Radyoloji Anabilim Dalı*

Anahtar Kelimeler: İntrakraniyal lipom, Orta hat lezyonu, Korpus kallosum agenezisi.

Özet: İntrakraniyal lipom, intrakraniyal tümörler arasında oldukça nadir görülür ve oranları %1'in altındadır. Çoğunlukla orta hat yerleşimli olup en sık perikallozal bölgede izlenmekle birlikte, kraniyal kavitenin farklı alanlarında da ortaya çıkabilir. Genellikle tesadüfen saptanan bu lezyonlar çoğu zaman belirti vermez. Nadir durumlarda kitle etkisine bağlı semptomlar gelişebilir; en sık baş ağrısı görülürken, epileptik nöbetler ve hemipleji gibi bulgular da eşlik edebilir. Tanı, beyin BT ve MR görüntüleme ile konulabilmekte olup, radyolojik açıdan ayırıcı tanının dikkatle yapılması gereklidir. Bu lezyonların iyi huylu olması, derin yerleşim göstermesi ve çevre dokularla sıkı ilişkisi nedeniyle cerrahi tedavi genellikle tercih edilmez. Bu çalışmada, insidental olarak saptanan bir olgu, literatür bilgileri eşliğinde sunulmuştur.

Giriş: İntrakraniyal lipom (İKL), beynin sıklıkla insidental olarak saptanan benign lezyonlardır ve embriyolojik gelişim sırasında adipoz dokunun anormal diferansiyasyonu sonucu gelişmektedir. Tüm intrakraniyal tümörler içinde %0,1'den daha az bir orana sahip olduğu düşünülmekle birlikte, gerçek görülme sıklığı tam olarak bilinmemektedir (1). İntrakraniyal lipom en sık perikallozal alanda yerleşim gösterir ve çoğu zaman orta hat gelişim kusurları ile birlikte görülür. Radyolojik serilerde yerleşim dağılımı incelendiğinde, olguların yaklaşık %64'ünün korpus kallozum çevresinde, %13'ünün infundibular-kiazmatik bölgede, çok daha küçük bir kısmının ise serebellopontin köşe (%0,06) ve Silvian fissür (%0,03) düzeyinde izlendiği bildirilmektedir. (2). Patogenezine ilişkin çeşitli teoriler öne sürülmüş olsa da, bu lezyonların genellikle primitif mezenkimal hücrelerden köken alan konjenital kalıntılar olduğu kabul edilmektedir (3). Olguların büyük kısmı asemptomatiktir ve insidental olarak saptanmaktadır. Nadiren kitle etkisine bağlı olarak olgularda klinik bulgulara yol açabilmektedir. Semptomlar arasında en sık; baş ağrısı, epileptik nöbet, bilinç değişikliği ve hemipleji görülmektedir (4).

Olgu: 69 yaşında erkek olgu, vücudunun sağ tarafında güçsüzlük ve uyuşma şikâyeti ile hastanemiz acil servisine başvurmuştur. Hastanın özgeçmişinde kafa travması sonrası operasyon öyküsü ve epilepsi tanısı bulunmaktadır. Hasta acil serviste Beyin Bilgisayarlı Tomografi (BT) ve Diffüzyon Manyetik Rezonans Görüntüleme (MRG) ile değerlendirilmiştir. Beyin Bilgisayarlı Tomografi (BT) görüntülemesinde, orta hatta yerleşimli, her iki hemisfere ve lateral ventriküle uzanımı bulunan periferal kalsifikasyonun eşlik ettiği, yağ dansitesinde; 35x44x43 mm (KKxTRxAP) boyutlu, yer kaplayan lezyon izlenmiştir (Resim1). Ventriküler sistem ve sulkuslar atrofiye sekonder geniş izlenmiştir. Diffüzyon Manyetik Rezonans Görüntüleme (MRG) görüntülemesinde ise sol serebral hemisferde dağınık yerleşimli akut iskemik odaklar saptanmıştır (Resim2). Bununla beraber orta hatta kitle izlenmiştir. Ayırıcı tanılar arasında; orta hat lipomu, dermoid kist, teratom, epidermoid kist, liposarkom, kalsifikasyon içeren tümörler (örn: oligodendrogliom) yer almaktadır. Ayırıcı tanıları dışlamak açısından olgu Kontrastlı Beyin MRG ile ileri tetkik edilmiştir. Yapılan beyin MRG incelemesinde; bilateral serebral hemisferlerde subkortikal beyaz cevherde T2 ve FLAIR sekanslarda hiperintens gliotik sinyal alanları saptanmıştır. Korpus kallozum lojunda 30x47x 44 mm (KKxTRxAP) boyutlarında T1 ve T2 sekanslarda hiperintens kontrastlı serilerde belirgin kontrast fiksasyonu göstermeyen yağ sinyal özelliğinde lezyon izlenmiştir (Resim 3 ve 4). Lezyonun bilateral koroid fissür boyunca intraventriküler uzanımı saptanmıştır. Her iki lateral ventrikül frontal hornunun kitle etkisine sekonder baskılandığı ve her iki lateral ventrikül gövdesinin, bilateral oksipital horn ve sol

temporal hornun normalden geniş olduğu görülmüştür. MRG tetkikinde korpus kallozum izlenmemiş olup ageneziktir. Koronal planda T2 ağırlıklı seride Viking miğferi işareti bulgusu saptanmıştır (Resim 4). Bu lezyon homojen yağ sinyali göstermesi (T1 ve T2 hiperintens), kontrast tutmaması, korpus kallozum agenezisi ile birlikteliği ve tipik yerleşimiyle lipom ile uyumlu bulunmuştur. Hasta, nöroloji servisi yatışı sırasında çekilen BT Anjiografi görüntülemesinde saptanan karotis darlığının takibinin yapılması gerekçesiyle nöroloji poliklinik kontrol önerisiyle taburcu edilmiştir. Hastanın 9 ay sonrası nöroloji poliklinik kontrolünde, fizik muayenesinde lateralize edici herhangi bir bulgu saptanmamıştır.

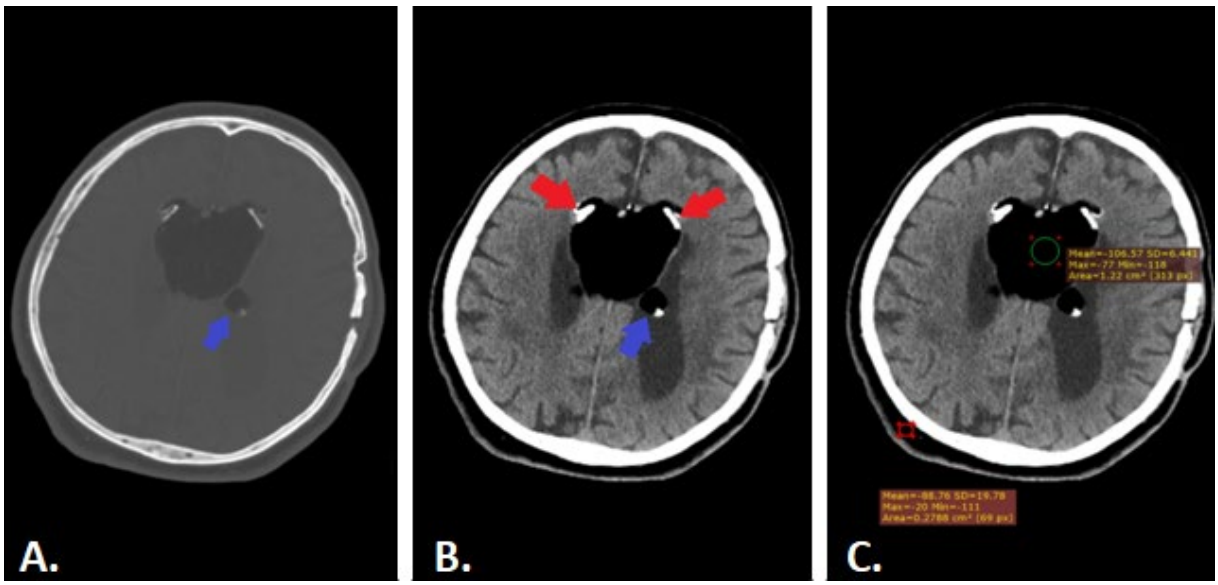

Resim1: Kitlenin kontrastsız Beyin BT görüntüsü. Kemik pencere (A) ve parankim penceresinde (B,C) lezyonun yağ dansitesinde olduğu görülüyor. Periferal kalsifikasyonlar (kırmızı oklar) ve lezyonun intraventriküler komponenti (mavi oklar) izleniyor. Lezyonun dansitesinin (-106 HU), cilt altı yağ doku dansitesi (-88 HU) ile benzer olduğuna dikkat ediniz (C).

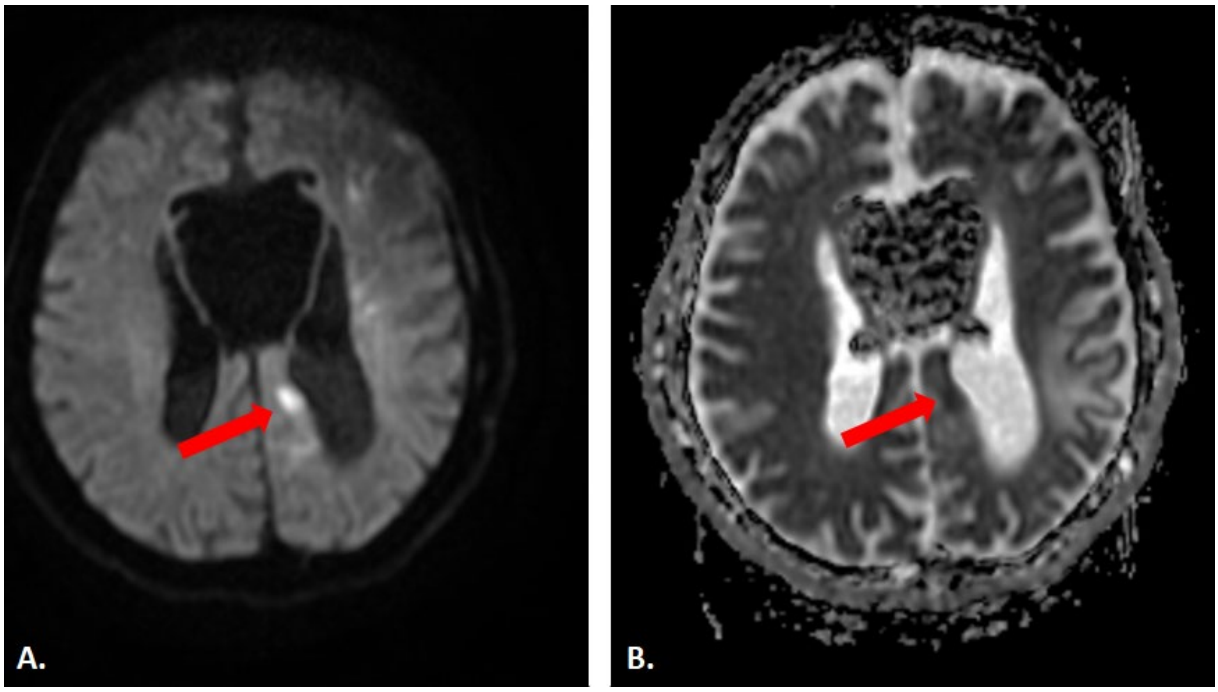

Resim 2: Kitlenin Difüzyon MRG tetkikinde kısıtlı difüzyon bulgusu göstermediği, ancak difüzyon ağırlıklı görüntüde (A) ve ADC haritasında (B) acil başvurusunun sebebi olan iskemik odaklardan biri (kırmızı ok) görülüyor.

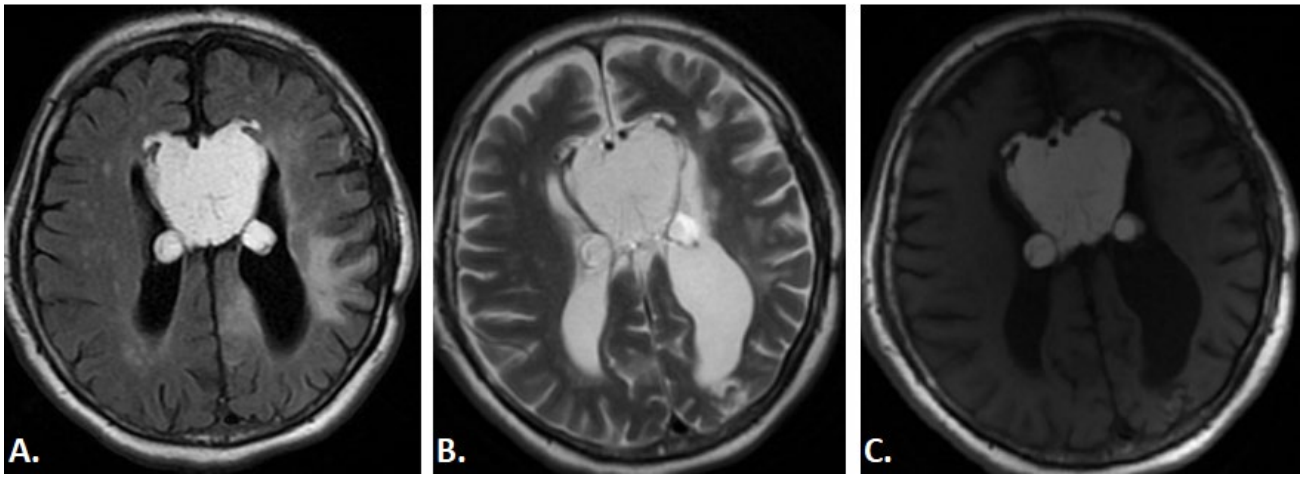

Resim 3: Kitlenin MRG FLAIR(A), T2AG (B) ve T1AG (C) özellikleri. Orta hattan her iki hemisfere ve koroid fissür aracılığı ile lateral ventriküllere uzanımı görülüyor. Lezyonun, yağ doku özellikleri ile uyumlu olarak T2 ağırlıklı (B) ve T1 ağırlıklı (C) sekanslarda hiperintens sinyal karakteri sergilediği izlenmektedir.

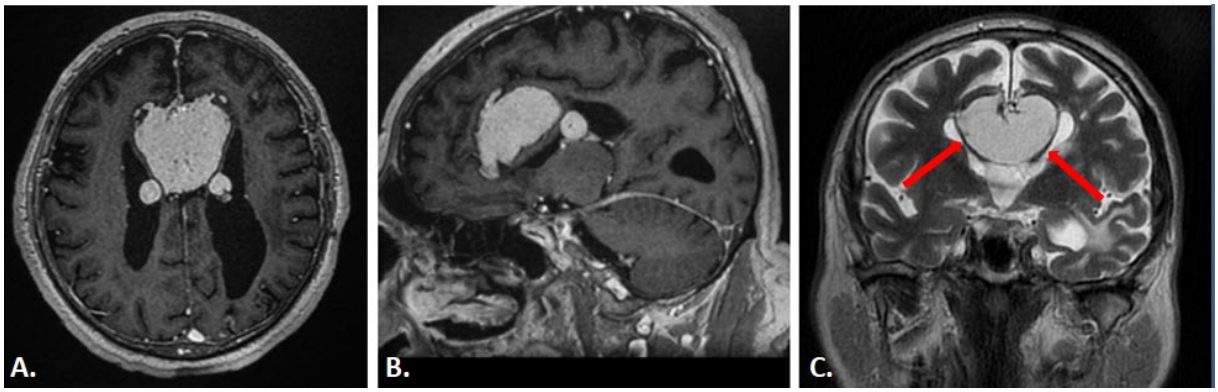

Resim 4: Lezyon postkontrast T1AG sekans aksiyal kesit (A) ve sagittal kesitte (B) kontrastlanmıyor. Prekontrast hiperintens sinyal özelliği sebebi ile hiperintens görülüyor. Kontrastsız koronal plan T2AG seride korpus kallozum agenezisini destekleyen Viking Miğferi bulgusu izlenmektedir (C).

Tartışma: Konjenital kökenli ve benign karakterde olan intrakraniyal lipomlar oldukça nadir izlenmekte olup, çoğunlukla klasik anlamda gerçek bir neoplazi olarak kabul edilmemektedir. İlk olarak 1818 yılında Meckel tarafından kiazma bölgesinde lipom tanımlanmış, 1856 yılında ise Rokitansky korpus kallozum agenezisi ile ilişkili perikallozal lipomları rapor etmiştir (3). Literatürde bu konuya ilişkin en geniş serilerden biri, Truwit ve Barkovich tarafından bildirilen 42 olguluk çalışmadır. Bu lezyonların yerleşim dağılımı incelendiğinde; %64 oranında korpus kallozum, %13 oranında infundibular kiazma ve %0,06 oranında serebellopontin köşe yerleşimi gösterdikleri bildirilmiştir (5).

İntrakraniyal lipomların konjenital kökenli lezyonlar olduğu kabul edilmekte olup, embriyogenez sırasında subaraknoid sisternlerin gelişimi esnasında primitif meninks dokusunun normal farklılaşmasının bozulması veya bu dokunun persiste etmesi sonucu ortaya çıktıkları düşünülmektedir (6). Bu lezyonlar çeşitli konjenital anomalilerle birlikte izlenebilmektedir. Bunlar arasında korpus kallozum agenezisi, serebral kortekste lipom ile ilişkili mikropoligiri, spina bifida, yarık dudak, yüksek kemerli damak, yüz asimetrisi, pektus ekskavatum ve kardiyak septal defektler yer almaktadır (7). Sunulan olguda da korpus kallozum agenezisinin eşlik ettiği izlenmiştir.

İntrakraniyal lipomların klinik prezentasyonuna ilişkin literatürde kapsamlı çalışmalar sınırlıdır. Loddenkemper'in epilepsi hastaları üzerinde gerçekleştirdiği radyolojik incelemede, olguların yalnızca %0,14'ünde intrakraniyal lipom saptanmış ve bu lezyonların büyük ölçüde insidental bulgu niteliğinde olduğu vurgulanmıştır. Gastaut ve arkadaşlarının dört olguluk serisinde ise korpus kallozum lipomu bulunan epileptik hastaların ikisinde elektroensefalografi (EEG) incelemesinde temporal bölgede epileptiform aktivite saptanmıştır (2). Bizim olgumuzda da çocukluk çağından beri epilepsi öyküsü mevcut olup, hasta medikal tedavi almaktadır.

Radyolojik açıdan değerlendirildiğinde, intrakraniyal lipomlar bilgisayarlı tomografi (BT) incelemesinde genellikle kontrast madde tutulumu göstermeyen, homojen ve hipodens lezyonlar olarak izlenmektedir. Manyetik rezonans görüntülemede (MRG) ise sıklıkla T1 ağırlıklı sekanslarda belirgin hiperintens, T2 ağırlıklı sekanslarda ise değişken sinyal intensitesi (çoğunlukla izointens veya hafif hiperintens) gösteren, kontrastlanma izlenmeyen ve düzgün sınırlı kitleler şeklinde değerlendirilmektedir (8). Ayrıca lezyona eşlik eden kapsüler yapı veya fibröz karakterde kalsifik odaklar da tanımlanabilmektedir (7). Sunulan vakada da benzer şekilde kalsifikasyon odakları izlenmiştir.

Radyolojik ayırıcı tanıda orta hat yerleşimli lipomlar başta olmak üzere dermoid kist, teratom, epidermoid kist, liposarkom ve kalsifikasyon içeren diğer tümöral oluşumlar göz önünde bulundurulmalıdır. Dermoid kistler yağ içeriği ve kalsifikasyon gösterebilmekle birlikte genellikle daha heterojen bir yapı sergiler. Teratomlar yağ, kalsifikasyon ve yumuşak doku komponentlerini birlikte içermeleri nedeniyle kompleks ve düzensiz görünümleriyle ayırt edilir. Epidermoid kistlerde tipik olarak yağ dansitesi izlenmez. Liposarkomlar yağ içeriği gösterebilse de invaziv özellikleri ve belirgin heterojen yapıları ile ayrılır. Kalsifiye tümörlerde ise kalsifikasyon sık izlenmekle birlikte tipik olarak yağ dansitesi bulunmaz. Sunulan olguda, BT'de ölçülen Hounsfield üniteleri ile MRG'de T1 ağırlıklı sekanslarda izlenen belirgin hiperintensite bulguları doğrultusunda lezyonun radyolojik olarak lipom ile uyumlu olduğu değerlendirilmiş ve literatürde tanımlanan özelliklerle örtüştüğü görülmüştür.

Lipomların benign doğası nedeniyle çoğu olguda histopatolojik doğrulama gerekmemekte, tanı büyük ölçüde radyolojik bulgulara dayandırılmaktadır. Cerrahi girişimin yüksek morbidite ve mortalite riski taşıması nedeniyle hastanın klinik ve radyolojik izlemine devam edilmesi planlanmıştır.

Kaynakça:

1- Singh, A. M., Adhikari, R. B., Sah, H., & Shrestha, P. (2016). Intracranial lipoma: A rare variant of brain tumor. *Nepal Journal of Neuroscience, 12*(2), 72.

2- Yaldız, C., Kaçıra, T., Kaçıra, Ö. K., & Ceylan, D. (2014). Dev intrakranial lipom olgu sunumu ve literatürün gözden geçirilmesi. *Sakarya Medical Journal, 4*(4), 198–201.

3- Ovalıoğlu AÖ, Yılmaz İ, Öğrenci A ve ark. İntrakranial lipomlar; iki olgu sunumu. Ş.E.E.A.H. Tıp Bülteni 2012;46(4):217-220.

4- Öztürk, C., Kapıtaşı, E., Güngör, Ö., & Uysal Ramadan, S. (2019). Lipomların intrakraniyal yerleşim yerleri. *Akademik Araştırma Tıp Dergisi, 3*(1), 18–21.

5- Çakır, Y., Koç, E., Özsöz, M., & Ak, H. (2025). Travma sonrası rastlantısal tespit edilen intrakraniyal lipom: Olgu sunumu. *Ağrı Medical Journal, 3*(3), 130–133.

6- Güneyli, S., Keleşoğlu, K. S., Sivri, M., Erdoğan, H., & Koplay, M. (2015). İntrakranial lipomlar: Yerleşim yerleri ile birlikte bilgisayarlı tomografi ve manyetik rezonans görüntüleme bulguları. *Genel Tıp Dergisi, 25*(4), 126–131.

7- Kim, E. T., Park, D. W., Ryu, J. A., Park, C. K., Lee, Y. J., & Lee, S. R. (2011). Intracranial convexity lipoma with massive calcification: Case report. *Journal of the Korean Society of Radiology, 65*(6), 533–536.

8- Beşir, F. H., & Özkan, F. (2012). İntrakranial lipomların tanı ve tedavi yönetiminde BT ve MRG. *Abant Medical Journal, 1*(1), 35–36.

Afet Tıbbında Yapay Zekâ Uygulamaları: Erken Uyarıdan Klinik Karar Desteğine Güncel Yaklaşımlar

Zümra Kuru[1], Gamze Demiray[2*]

[1]Dönem 1 Öğrencisi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi, Bandırma, Balıkesir. Email:zumrakuru06@gmail.com

[2]Dr. Öğretim Üyesi, Bandırma Onyedi Eylül Üniversitesi Tıp Fakültesi Halk Sağlığı ABD, Bandırma, Balıkesir. Email:gamze.demiray@bandirma.edu.tr ORCID: 0000-0003-3728-2825. *corresponding author

Özet

Afetler, sağlık sistemleri üzerinde ani ve aşırı bir yük oluşturarak kaynak yetersizliğine ve klinik karar verme süreçlerinin karmaşıklaşmasına yol açmaktadır. Son yıllarda yapay zekâ (YZ), afet yönetiminin tüm aşamalarında dönüştürücü bir araç olarak öne çıkmıştır. Bu derleme, afet tıbbında YZ uygulamalarını erken uyarı sistemleri, afet müdahalesi ve triyaj ile klinik karar destek sistemleri bağlamında mevcut kanıtlar ışığında sentezlemektedir. Dünya Sağlık Örgütü çerçeveleri ve güncel çalışmalar, YZ'nin durumsal farkındalığı artırdığını, risk öngörüsünü geliştirdiğini ve klinik önceliklendirmeyi desteklediğini göstermektedir. Bununla birlikte veri kalitesi, algoritmik yanlılık ve gerçek yaşam uygulamalarındaki sınırlılıklar önemli engeller olarak varlığını sürdürmektedir. Bu nedenle YZ, klinisyenlerin yerini alan bir teknoloji olarak değil, dirençli sağlık sistemleri içinde entegre edilen bir karar destek aracı olarak değerlendirilmelidir.

Anahtar Kelimeler: Afet tıbbı, yapay zekâ, erken uyarı sistemleri, triyaj, klinik karar destek

1. Giriş

Afet tıbbı, afet riski altındaki toplumlarda olumsuz sağlık sonuçlarını önlemek ve azaltmak amacıyla, afet öncesi ve sonrası dönemlerde sağlık hizmetlerinin ve sağlık tesislerinin sürekliliğini sağlamayı hedefleyen disiplinlerarası bir alandır (Koçak vd., 2021). Dünya Sağlık Örgütü tarafından geliştirilen Sağlık Acil ve Afet Risk Yönetimi (Health-EDRM) yaklaşımına göre afetler; önleme, hazırlık, müdahale ve iyileştirme aşamalarını kapsayan bütüncül bir çerçevede ele alınmalıdır (World Health Organization, 2019). Yapay zekâ (YZ), büyük veri setlerinden öğrenerek tahmin ve karar üretme kapasitesine sahip hesaplama sistemlerini ifade eder (OECD, 2024). Sağlık alanında YZ'nin gelişimi; elektronik sağlık kayıtları (EHR), uydu görüntüleri ve gerçek zamanlı sürveyans verilerinin analizini mümkün kılmıştır. YZ'nin afet tıbbındaki önemi, yüksek hacimli ve zaman duyarlı verileri işleyerek hızlı ve doğru karar destek sağlayabilmesinden kaynaklanmaktadır. COVID-19 pandemisi, yapay zekânın epidemiyolojik modelleme, tanı ve sağlık hizmeti planlamasında taşıdığı potansiyeli görünür kılmış; ancak geliştirilen modellerin çoğunda metodolojik kusurlar ve yüksek yanlılık riski bulunduğu bildirilmiştir (Wynants et al., 2020). Sendai Çerçevesi yapay zekâdan doğrudan söz etmese de, riskin anlaşılması, erken uyarı ve bilim temelli karar desteğini vurgulaması nedeniyle YZ uygulamalarıyla kavramsal olarak uyumludur (United Nations, 2015).

Afet Döngüsü ve Yapay Zekâ Uygulamaları

2.1. Önleme

YZ, afet risklerinin belirlenmesi ve azaltılmasında önemli rol oynamaktadır. YZ tabanlı modeller, uzaktan algılama verileri ve coğrafi bilgi sistemleri ile entegre edildiğinde, afet açısından yüksek riskli bölgelerin belirlenmesine ve risk azaltımına yönelik önleyici

planlamanın geliştirilmesine katkı sağlayabilmektedir (Chang et al., 2020). Özellikle sel ve deprem risk analizlerinde makine öğrenmesi algoritmalarının kullanımı giderek artmaktadır (Nachappa vd., 2020; Jena vd., 2020). Bu modeller, çok boyutlu çevresel verileri analiz ederek risk tahminini geliştirebilmekte; ancak performansları veri kalitesi, örnekleme yapısı ve bölgesel özelliklere bağlı olarak değişebilmektedir.

Yapay zekâ, çoklu tehlike erken uyarı sistemlerinde özellikle risk analizi, veri entegrasyonu ve gerçek zamanlı izlem alanlarında giderek daha önemli bir rol üstlenmektedir. Erken uyarı sistemlerinin temel amacı, tehlikeleri zamanında saptayarak risk altındaki toplumların ve sistemlerin hazırlık kapasitesini artırmaktır (WMO & UNDRR, 2023). Bu bağlamda YZ, büyük ve heterojen veri setlerini işleyebilmesi sayesinde daha dinamik ve ölçeklenebilir çözümler sunmaktadır. Özellikle doğal afetler ve enfeksiyon hastalıkları gibi zaman duyarlı durumlarda, YZ tabanlı modeller erken sinyal saptama, risk sınıflandırması ve tahmin doğruluğunun artırılması açısından umut verici görünmektedir (Tiggeloven et al., 2025; Villanueva-Miranda et al., 2025).

2.2. Hazırlık

Hazırlık aşamasında yapay zekâ tabanlı öngörü ve simülasyon modelleri, afet ya da salgın senaryolarında sağlık sistemi yükünün modellenmesine olanak tanımaktadır (Caro et al., 2021; Nas et al., 2019). Bu yaklaşımlar, hastane kapasitesi, yoğun bakım gereksinimi ve genel hasta yükü gibi kritik parametrelerin öngörülmesine katkı sağlayarak afet öncesi planlamayı güçlendirebilir (Caro et al., 2021; Qian et al., 2020). Ayrıca senaryo temelli modellemeler, sınırlı kaynakların daha rasyonel kullanımına ve kapasite yönetimine destek sunmaktadır (Caro et al., 2021; Nas et al., 2019). Bununla birlikte, bu modellerin performansı kullanılan varsayımlara, veri kalitesine ve yerel bağlama bağlı olarak değişmektedir (Qian et al., 2020).

Makine öğrenmesi ve derin öğrenme modelleri, deprem ve salgın gibi zaman duyarlı afetlerin analizinde giderek daha yaygın kullanılmaktadır. PhaseNet ve Earthquake Transformer gibi modeller, sismik sinyallerin tespiti ve analizinde doğruluğu artırmakta; özellikle faz seçimi ve olay tespiti süreçlerinde önemli performans kazançları sağlamaktadır (Zhu & Beroza, 2019; Mousavi et al., 2020). Bununla birlikte bu sistemlerin doğrudan "deprem tahmini" yaptığı düşünülmemelidir; mevcut literatürde bu modeller daha çok erken tespit, sinyal ayıklama ve olay karakterizasyonu alanlarında etkilidir. Benzer şekilde, YZ tabanlı epidemiyolojik modeller; iklim, mobilite, sürveyans ve sağlık hizmeti kullanım verilerini kullanarak salgın hastalıkların erken tahminini mümkün kılmaktadır (Villanueva-Miranda et al., 2025).

2.3. Müdahale

Müdahale fazı, yapay zekânın afet tıbbında öne çıktığı aşamalardan biridir. Görüntü işleme algoritmaları ile uydu verilerinin analizi, özellikle afet sonrası sağlık tesislerindeki hasarın hızlı biçimde değerlendirilmesine katkı sağlayabilmektedir (Ramachandran et al., 2025). Bunun yanında, YZ destekli triyaj sistemleri hasta önceliklendirmesinde karar doğruluğunu artırma ve mortaliteyi azaltma potansiyeli taşımaktadır (Tahernejad et al., 2024). Gerçek zamanlı veri analizi ve karar destek sistemleri de afet sahasında kaynak kullanımının daha etkin planlanmasına yardımcı olabilir. Bununla birlikte, mevcut sistemlerin çoğu gerçek afet koşullarında sınırlı ölçüde doğrulanmıştır ve altyapı kısıtlılıkları uygulamada önemli engeller oluşturmaktadır.

Afetlerde triyaj, sınırlı kaynaklar altında hızlı ve doğru karar verilmesini gerektiren kritik bir süreçtir. YZ tabanlı sistemler, hasta sonuçlarını öngörmede etkili olup geleneksel yöntemlere kıyasla daha yüksek doğruluk sağlayabilmektedir (Tahernejad et al., 2024). Özellikle vital bulgular, yaş, komorbid hastalıklar ve başvuru şikâyeti gibi çok sayıda değişkeni aynı anda değerlendirebilmesi, YZ'nin triyaj süreçlerinde öne çıkan avantajlarından biridir. Bu durum,

yüksek hasta hacmi altında çalışan ekiplerin karar yükünü azaltarak klinik önceliklendirmeyi destekleyebilir.

Kaynak tahsisi açısından bakıldığında, YZ yalnızca bireysel hasta düzeyinde değil, sistem düzeyinde de katkı sunmaktadır. Yoğun bakım yatakları, ventilatörler, personel dağılımı ve sevk planlaması gibi konularda öngörüsel modeller geliştirilebilmekte, böylece kaynakların daha rasyonel kullanımına olanak sağlanmaktadır. Afet koşullarında zamanında ve doğru tahsis edilen kaynaklar, mortalite ve morbidite üzerinde doğrudan etkili olabileceğinden, bu uygulamaların önemi artmaktadır. Bununla birlikte, YZ tabanlı triyaj sistemleri etik açıdan da dikkatle değerlendirilmelidir. Bir algoritmanın hangi hastaya öncelik vereceği sorusu, yalnızca teknik değil aynı zamanda etik bir sorundur. Bu nedenle bu tür sistemlerin insan denetimi altında, şeffaf ve hesap verebilir biçimde kullanılması gerekmektedir.

YZ algoritmaları acil servislerde hasta akışını optimize edebilmekte ve sahra hastanelerinde karar destek aracı olarak kullanılabilmektedir (Kareemi et al., 2025). Acil servislerde geliştirilen modeller; bekleme süresi, yatış olasılığı, yoğun bakım gereksinimi ve kötüleşme riski gibi çıktıları öngörerek hasta akış yönetimine katkıda bulunmaktadır. Bu tür sistemler, özellikle afet sonrası gibi ani gelişen başvuru artışlarında klinik iş akışının daha düzenli yürütülmesine yardımcı olabilir. Sahra hastaneleri ve geçici sağlık tesislerinde ise YZ, daha sınırlı ancak giderek gelişen bir kullanım alanına sahiptir. Mobil cihazlarla entegre çalışan karar destek yazılımları, sahada çalışan ekiplerin temel değerlendirmeleri daha standart biçimde yapmasına katkı sağlayabilir. Ayrıca tele-tıp ile entegre YZ araçları, uzman erişiminin kısıtlı olduğu koşullarda klinik kararları destekleyebilir.

2.4. İyileştirme

İyileştirme sürecinde yapay zekâ, özellikle afet sonrası ruh sağlığı sonuçlarının öngörülmesi ve kırılgan grupların belirlenmesinde kullanılabilmektedir. Afetlerden sonra travma sonrası stres belirtileri, anksiyete, depresif belirtiler ve işlev kaybı gibi psikososyal sonuçlar uzun süre devam edebildiği için, sağlık hizmetlerinin yalnızca akut döneme değil uzun dönem izleme ve destek süreçlerine de odaklanması gerekmektedir. Bu bağlamda makine öğrenmesi yaklaşımları, yüksek psikolojik risk taşıyan bireylerin erken dönemde tanımlanmasına yardımcı olarak izlem ve ruh sağlığı hizmetlerinin daha hedefli planlanmasını destekleyebilir. Nitekim doğal afetler sonrası yapılan çalışmalarda, makine öğrenmesi modellerinin travma sonrası stres belirtileri gibi psikososyal sonuçların tahmininde umut verici performans gösterdiği bildirilmiştir (Rosellini et al., 2018).

Bununla birlikte, afet sonrası ruh sağlığı etkilerinin tüm bireylerde aynı olmadığı, bazı alt grupların çok daha yüksek risk taşıdığı gösterilmiştir. Makine öğrenmesi yöntemleri; sosyodemografik özellikler, maruz kalınan kaybın düzeyi, sosyal destek yetersizliği ve önceki ruhsal kırılganlıklar gibi değişkenleri birlikte değerlendirerek bu heterojen yapının daha iyi anlaşılmasına katkı sağlayabilmektedir (Shiba et al., 2022). Ancak bu alandaki çalışmaların önemli sınırlılıkları vardır. Veri kaynaklarının heterojenliği, çalışma kalitesindeki değişkenlik ve klinik uygulamaya entegrasyon eksikliği, geliştirilen modellerin genellenebilirliğini ve gerçek yaşamdaki kullanımını sınırlamaktadır (Teague et al., 2022).

3. Veri Kaynakları

YZ tabanlı erken uyarı sistemleri; uydu verileri, elektronik sağlık kayıtları, meteorolojik ölçümler ve sosyal medya gibi farklı veri kaynaklarını birlikte kullanmaktadır. Bu çok kaynaklı yaklaşım, afetlerin ve sağlık tehditlerinin yalnızca tek bir veri akışıyla açıklanamayacak farklı boyutlarını değerlendirmeye olanak tanır. Uzaktan algılama çevresel değişiklikleri izlerken, elektronik sağlık kayıtları olağandışı başvuru ve semptom örüntülerini gösterebilmekte; sosyal medya ise özellikle ilk saatlerde erken sinyal ve durumsal farkındalık sağlayabilmektedir.

Bununla birlikte, veri çeşitliliği kalite, güncellik ve uyum sorunlarını da beraberinde getirmektedir (WMO, 2023). Elektronik sağlık kayıtlarıyla entegre YZ sistemleri, vital bulgular, laboratuvar sonuçları ve klinik öyküyü eş zamanlı değerlendirerek gerçek zamanlı karar desteği sağlayabilir. Bununla birlikte, model performansının kurumlar arasında değişebilmesi nedeniyle yerel doğrulama ve sürekli performans izlemi gereklidir (Wong et al., 2026).

4.Sınırlılıklar ve Etik Sorunlar

Yapay zekâ tabanlı erken uyarı, triyaj ve klinik karar destek sistemleri afet tıbbında umut verici olmakla birlikte, önemli sınırlılıklar barındırmaktadır. Öncelikle bu sistemlerin performansı çoğu zaman belirli veri setleri ve sınırlı bağlamlar içinde değerlendirildiğinden, farklı coğrafi ve sağlık sistemi koşullarına ne ölçüde genellenebileceği belirsizdir. Ayrıca mevcut çalışmaların büyük bölümü retrospektif veya simülasyon temelli olup gerçek afet ortamlarında doğrulama sınırlıdır (Villanueva-Miranda et al., 2025; Tahernejad et al., 2024; Kareemi et al., 2025).

Bir diğer temel sorun veri heterojenliğidir. Uydu görüntüleri, klinik veriler, meteorolojik ölçümler ve sosyal medya içerikleri gibi farklı kaynaklardan gelen veriler; kalite, güncellik ve bütünlük açısından önemli farklılıklar gösterebilir. Bu durum model performansını ve yorumlanabilirliği azaltırken, yüksek duyarlılığa sahip sistemlerde yanlış pozitif oranlarını artırarak kaynakların gereksiz kullanılmasına da yol açabilir (Villanueva-Miranda et al., 2025).

Klinik uygulamada alarm yorgunluğu, açıklanabilirlik eksikliği ve iş akışına entegrasyon sorunları da önemli engellerdir. Çok sayıda düşük öncelikli uyarı üreten sistemler klinisyenlerin güvenini azaltabilir; karar mantığı yeterince şeffaf olmayan modellerin benimsenmesi ise güçleşir (Char et al., 2018; Kareemi et al., 2025). Ayrıca algoritmik yanlılık, özellikle dezavantajlı gruplar açısından sağlık eşitsizliklerini derinleştirebilir (Obermeyer et al., 2019).

Bu nedenle afet tıbbında YZ'nin güvenli ve etkili kullanımı için yalnızca teknik doğruluk değil, aynı zamanda şeffaflık, insan denetimi, veri yönetişimi ve yaşam döngüsü boyunca düzenleyici değerlendirme de gereklidir (World Health Organization, 2021; U.S. Food and Drug Administration, 2021).

7. Sonuç ve Gelecek Perspektifler

YZ, afet tıbbında erken uyarıdan klinik karar desteğine kadar geniş bir kullanım alanına sahiptir. Büyük veri analizi, örüntü tanıma ve gerçek zamanlı karar desteği kapasitesi, bu teknolojiyi özellikle kriz ortamlarında değerli kılmaktadır. Bununla birlikte mevcut çalışmaların büyük kısmı erken aşamadadır ve gerçek yaşam verileriyle doğrulanması gerekmektedir.

Gelecekte prospektif çalışmaların artırılması, etik standartların geliştirilmesi ve açıklanabilir YZ modellerinin yaygınlaştırılması önem taşımaktadır. Buna ek olarak, farklı coğrafyalarda ve farklı afet türlerinde geliştirilen sistemlerin karşılaştırmalı olarak değerlendirilmesi, genellenebilirlik açısından kritik olacaktır. Sağlık sistemleri ile teknolojik altyapı arasındaki entegrasyon güçlendirilmeden, YZ'nin potansiyel yararlarının tam olarak hayata geçirilmesi güç görünmektedir.

Sonuç olarak YZ, klinisyenlerin yerini alan bir teknoloji değil, karar süreçlerini destekleyen güçlü bir araçtır. Afet tıbbında etkili, etik ve sürdürülebilir YZ kullanımı için bilimsel kanıtın güçlendirilmesi, çok disiplinli iş birliği ve sağlam yönetim mekanizmaları temel öncelikler olmalıdır.

Kaynaklar

Adams, R., Henry, K. E., Sridharan, A., Soleimani, H., Zhan, A., Rawat, N., Johnson, L., Hager, D. N., Cosgrove, S. E., Markowski, A., Saria, S., & Bourdeaux, C. P. (2022). Prospective, multi-site study of patient outcomes after implementation of the TREWS machine learning-based early warning system for sepsis. Nature Medicine, 28(7), 1455–1460. https://doi.org/10.1038/s41591-022-01894-0

Caro, J. J., Möller, J., & Getsios, D. (2021). Predicting hospital resource use during COVID-19 surges. Value in Health, 24(11), 1615–1623. https://doi.org/10.1016/j.jval.2021.05.023

Chang, Z., Du, Z., Zhang, F., Huang, F., Chen, J., Li, W., & Guo, Z. (2020). Landslide susceptibility prediction based on remote sensing images and GIS: Comparisons of supervised and unsupervised machine learning models. Remote Sensing, 12(3), Article 502. https://doi.org/10.3390/rs12030502

Char, D. S., Shah, N. H., & Magnus, D. (2018). Implementing machine learning in health care-Addressing ethical challenges. The New England Journal of Medicine, 378(11), 981–983. https://doi.org/10.1056/NEJMp1714229

Jena, R., Pradhan, B., Beydoun, G., Nizamuddin, M., & Sofyan, H. (2020). Earthquake hazard and risk assessment using machine learning approaches at Palu, Indonesia. Science of the Total Environment, 749, Article 141582. https://doi.org/10.1016/j.scitotenv.2020.141582

Kareemi, H. K., Dandu, M., Thomas, M., & Wang, R. C. (2025). Artificial intelligence–based clinical decision support systems in emergency department patient care: A scoping review. Academic Emergency Medicine, 32(1), 102–119. https://doi.org/10.1111/acem.15099

Kocak, H., Kinik, K., Caliskan, C., & Aciksari, K. (2021). The science of disaster medicine: From response to risk reduction. Medeniyet Medical Journal, 36(4), 333–342. https://doi.org/10.4274/MMJ.galenos.2021.50375

Mousavi, S. M., Ellsworth, W. L., Zhu, W., Chuang, L. Y., & Beroza, G. C. (2020). Earthquake transformer—An attentive deep-learning model for simultaneous earthquake detection and phase picking. Nature Communications, 11, Article 3952. https://doi.org/10.1038/s41467-020-17591-w

Nachappa, T. G., Piralilou, S. T., Gholamnia, K., Ghorbanzadeh, O., & Blaschke, T. (2020). Flood susceptibility mapping with machine learning, multi-criteria decision analysis and ensemble using Dempster–Shafer theory. Journal of Hydrology, 590, Article 125275. https://doi.org/10.1016/j.jhydrol.2020.125275

Nas, S., Koyuncu, M., & Eren, T. (2019). Emergency department capacity planning: A recurrent neural network and simulation approach. Computational and Mathematical Methods in Medicine, 2019, Article 8465465. https://doi.org/10.1155/2019/8465465

Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. Science, 366(6464), 447–453. https://doi.org/10.1126/science.aax2342

Organisation for Economic Co-operation and Development. (2024). Explanatory memorandum on the updated OECD definition of an AI system. OECD. https://www.oecd.org/content/dam/oecd/en/publications/reports/2024/03/explanatory-memorandum-on-the-updated-oecd-definition-of-an-ai-system_3c815e51/623da898-en.pdf

Qian, Z., Alaa, A. M., van der Schaar, M., Ercole, A., & CPAS Team. (2020). CPAS: The UK's national machine learning-based hospital capacity planning system for COVID-19. BMJ Health & Care Informatics, 27(3), Article e100050. https://doi.org/10.1136/bmjhci-2020-100050

Ramachandran, A., Yadav, A., & Schroeder, A. (2025). Implementation of remote-sensing models to identify post-disaster health facility damage: Comparative approaches to the 2023 earthquake in Turkey. PLOS Digital Health, 4(10), Article e0001060. https://doi.org/10.1371/journal.pdig.0001060

Rosellini, A. J., Dussaillant, F., Zubizarreta, J. R., Kessler, R. C., & Rose, S. (2018). Predicting posttraumatic stress disorder following a natural disaster. Journal of Psychiatric Research, 96, 15–22. https://doi.org/10.1016/j.jpsychires.2017.09.010

Shiba, K., Kawachi, I., Aida, J., Kondo, K., & Kondo, N. (2022). Uncovering heterogeneous associations of disaster-related traumatic experiences with subsequent mental health problems: A machine learning approach. Psychiatry and Clinical Neurosciences, 76(4), 127–136. https://doi.org/10.1111/pcn.13322

Tahernejad, N., Janati, A., Morshedi, H., & Bazyar, M. (2024). Artificial intelligence in disaster triage: A systematic review of applications and implementation challenges. BMC Emergency Medicine, 24, Article 151. https://doi.org/10.1186/s12873-024-01062-4

Teague, S. J., Shatte, A. B. R., Weller, E., Fuller-Tyszkiewicz, M., & Hutchinson, D. M. (2022). Methods and applications of social media monitoring of mental health during disasters: Scoping review. JMIR Mental Health, 9(2), Article e33058. https://doi.org/10.2196/33058

Tiggeloven, T., de Perez, E. C., Kruczkiewicz, A., Albrecht, T. R., Brandenberger, L., Challenor, P., ... & Kreibich, H. (2025). The role of artificial intelligence for early warning systems: Status, applicability, guardrails, and ways forward. iScience, 28(11), Article 112491. https://doi.org/10.1016/j.isci.2025.112491

U.S. Food and Drug Administration. (2021). Artificial intelligence/machine learning (AI/ML)-based software as a medical device action plan. U.S. Food and Drug Administration. https://www.fda.gov/files/medical%20devices/published/AIML-SaMD-Action-Plan.pdf?utm

United Nations. (2015). Sendai framework for disaster risk reduction 2015–2030. United Nations. https://www.undrr.org/publication/sendai-framework-disaster-risk-reduction-2015-2030?utm

Villanueva-Miranda, I., Xiao, G., & Xie, Y. (2025). Artificial intelligence in early warning systems for infectious disease surveillance: A systematic review. Frontiers in Public Health, 13, Article 1609615. https://doi.org/10.3389/fpubh.2025.1609615

Wong, A., Currey, D., Schwinne, M., Park-Egan, B., Meyer, S., Gutting, A., Cao, J., Khan, S., Dantes, R., Pan, T., Buchman, T., Singh, K., Bhavani, S. V., Lyons, P. G., Sjoding, M. W., & Tarabichi, Y. (2026). Multicenter prospective validation of an updated proprietary sepsis prediction model. JAMA Network Open, 9(2), Article e260181. https://doi.org/10.1001/jamanetworkopen.2026.0181

World Health Organization. (2019). Health emergency and disaster risk management framework. World Health Organization. https://iris.who.int/items/5ad1674b-1486-4edf-8b53-3c7026693e29

World Health Organization. (2021). Ethics and governance of artificial intelligence for health: WHO guidance. World Health Organization. https://iris.who.int/items/606b60cf-5e4d-409c-841b-0794c0978a19

World Meteorological Organization, & United Nations Office for Disaster Risk Reduction. (2023). Global status of multi-hazard early warning systems 2023. World Meteorological Organization & UNDRR. https://www.undrr.org/reports/global-status-mhews-2023

Wynants, L., Van Calster, B., Collins, G. S., Riley, R. D., Heinze, G., Schuit, E., ... & van Smeden, M. (2020). Prediction models for diagnosis and prognosis of COVID-19: Systematic review and critical appraisal. BMJ, 369, Article m1328. https://doi.org/10.1136/bmj.m1328

Zhu, W., & Beroza, G. C. (2019). PhaseNet: A deep-neural-network-based seismic arrival-time picking method. Geophysical Journal International, 216(1), 261–273. https://doi.org/10.1093/gji/ggy423

Laparoskopik total histerektomide uterin arterin üreter vizualizasyonu eşliğinde erken ligasyonu: intraoperatif kanama kontrolüne yönelik güvenli bir cerrahi yaklaşım

Oğuzhan Karakoç[1]

[1]Bandırma Onyedi Eylül Üniversitesi, Bandırma Eğitim ve Araştırma Hastanesi, oguzhankarakoc1986@hotmail.com

ÖZET

Anormal uterin kanama, jinekolojik pratikte sık karşılaşılan bir başvuru nedeni olup, eşlik eden myom varlığında cerrahi sırasında artmış kanama riski ile ilişkilidir. Bu olgu sunumunda, anormal uterin kanama nedeniyle değerlendirilen ve intramural myom saptanan 52 yaşında, gravida 2 parite 2 hastada uygulanan total laparoskopik histerektomi sırasında, uterin arterlerin üreter vizualizasyonu eşliğinde erken dönemde ligasyonu ile gerçekleştirilen cerrahi yaklaşım sunulmaktadır. Operasyonun başlangıcında retroperitoneal alan açılarak üreter ile uterin arterin anatomik ilişkisi net olarak ortaya konmuş ve bilateral uterin arterler erken aşamada güvenli şekilde ligate edilmiştir. Bu yaklaşım sonrasında histerektomi adımları kontrollü bir şekilde tamamlanmıştır. Uterin arterin üreter vizualizasyonu eşliğinde erken ligasyonu, özellikle kanama riski yüksek olgularda cerrahi güvenliği artıran ve intraoperatif kanama kontrolünü kolaylaştıran etkili bir yöntemdir.

Anahtar Kelimeler: Uterin arter ligasyonu, Üreter vizualizasyonu, Laparoskopik histerektomi

ABSTRACT

Abnormal uterine bleeding is a common indication in gynecological practice and is associated with an increased risk of intraoperative bleeding, particularly in the presence of uterine myomas. This case report presents a surgical approach involving early ligation of the uterine arteries under direct ureter visualization during total laparoscopic hysterectomy in a 52-year-old gravida 2, para 2 patient diagnosed with an intramural myoma. At the beginning of the procedure, the retroperitoneal space was developed to clearly identify the anatomical relationship between the ureter and the uterine artery, and bilateral uterine arteries were safely ligated at an early stage. Following this step, the hysterectomy was completed in a controlled manner. Early ligation of the uterine artery under ureter visualization is an effective technique that enhances surgical safety and facilitates intraoperative bleeding control, particularly in cases with a higher risk of bleeding.

Keywords: Uterine artery ligation, Ureter visualization, Laparoscopic hysterectomy

GİRİŞ

Anormal uterin kanama, jinekolojik pratiğin en sık karşılaşılan klinik durumlarından biri olup, sıklıkla cerrahi tedavi gerektiren patolojilerle ilişkilidir. Özellikle uterin myom varlığında, cerrahi sırasında artmış vaskülariteye bağlı olarak intraoperatif kanama riski belirgin şekilde artabilmektedir. Bu durum, cerrahi görüşün bozulmasına ve komplikasyon riskinin yükselmesine neden olabilir.

Total laparoskopik histerektomi, minimal invaziv yaklaşımın sağladığı avantajlar nedeniyle yaygın olarak tercih edilen bir cerrahi yöntemdir. Ancak, bu yöntemde kanama kontrolünün etkin sağlanması, cerrahinin güvenliği ve başarısı açısından kritik öneme sahiptir. Bu bağlamda, uterin arterlerin erken dönemde kontrol altına alınması, kanama miktarını azaltmaya yönelik önemli bir strateji olarak öne çıkmaktadır.

Öte yandan, uterin arterin ligasyonu sırasında üreter ile olan yakın anatomik ilişki, cerrahi sırasında dikkat edilmesi gereken en önemli unsurlardan biridir. Üreterin güvenli bir şekilde tanımlanması ve korunması, olası komplikasyonların önlenmesi açısından hayati önem taşımaktadır.

Bu olgu sunumunda, anormal uterin kanama ve uterin myom nedeniyle total laparoskopik histerektomi uygulanan bir hastada, üreter vizualizasyonu eşliğinde uterin arterin erken ligasyonu ile gerçekleştirilen cerrahi yaklaşımın güvenlik ve etkinlik açısından değerlendirilmesi amaçlanmıştır.

OLGU

Anormal uterin kanama şikayeti ile başvuran 52 yaşında, gravida 2 parite 2 olan hastanın yapılan jinekolojik değerlendirmesinde yaklaşık 5 cm intramural myom saptandı ve hastaya total laparoskopik histerektomi ve bilateral salpingooferektomi planlandı.

Genel anestezi altında gerçekleştirilen operasyonda batına giriş ve eksplorasyonun ardından pelvik anatomi değerlendirildi. Uterusun myomatöz yapıya bağlı olarak artmış vaskülarite potansiyeli göz önünde bulundurularak, cerrahinin erken aşamasında kanama kontrolünü optimize etmeye yönelik olarak retroperitoneal yaklaşım tercih edildi. Bu amaçla her iki tarafta round ligament lateralinden periton açılarak retroperitoneal alana girildi.

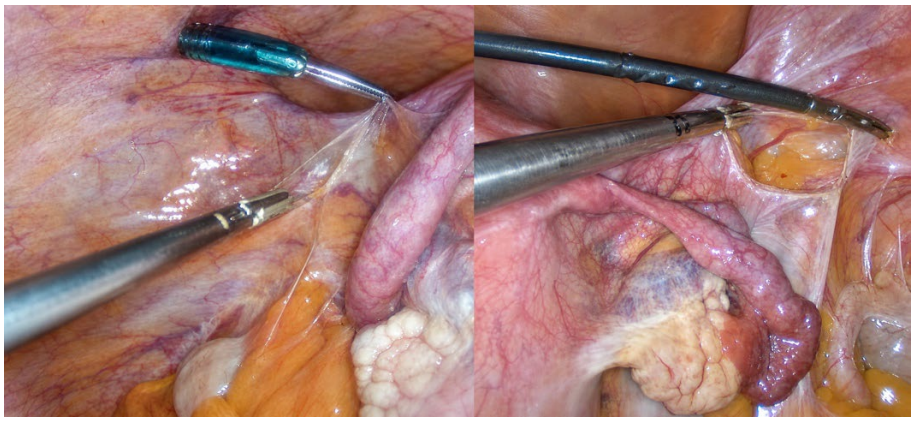

Resim 1. *Her iki tarafta round ligament lateralinden periton açılarak bilateral retroperitoneal alana girişin gösterilmesi*

Retroperitoneal disseksiyon dikkatli bir şekilde ilerletilerek anatomik planlar belirgin hale getirildi. Üreterin pelvik seyri takip edilerek uterin arter ile çaprazlaştığı seviyede her iki yapı net olarak ortaya konuldu. Bu aşamada üreterin lokalizasyonu ve uterin arter ile olan ilişkisi açık şekilde değerlendirilerek güvenli cerrahi sınırlar belirlendi.

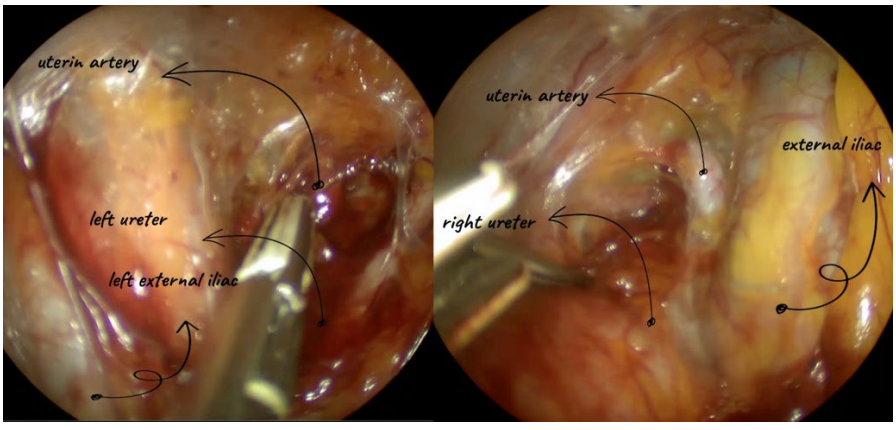

***Resim 2**. Üreter ile uterin arterin çaprazlaştığı seviyede her iki tarafta anatomik yapıların ortaya konulması*

Anatomik yapıların net olarak ortaya konulmasını takiben, bilateral uterin arterler üreter ile olan komşuluğu korunacak şekilde, erken dönemde enerji cihazı kullanılarak kontrollü biçimde ligate edildi.

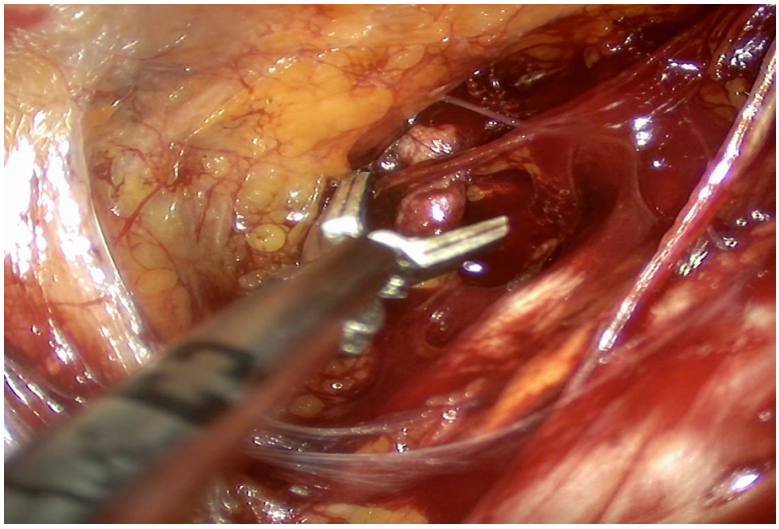

***Resim 3**. Üreter komşuluğu korunarak sol uterin arterin erken dönemde enerji cihazı ile ligasyonu*

Aynı işlem karşı tarafta da uygulanarak her iki uterin arterin kontrolü sağlandı.

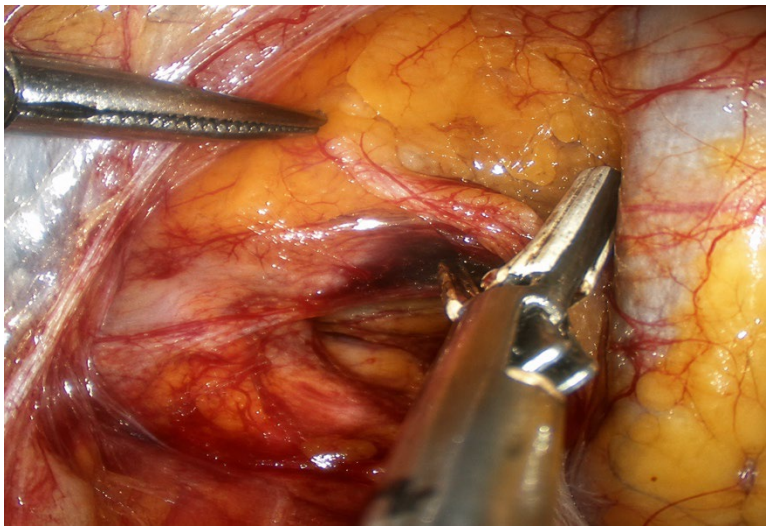

***Resim 4**. Üreter komşuluğu korunarak sağ uterin arterin erken dönemde enerji cihazı ile ligasyonu*

Bu aşama sonrasında cerrahi sahada kanlanmanın belirgin şekilde azaldığı gözlendi ve diseksiyon planlarının daha net hale geldiği değerlendirildi.

Uterin arterlerin erken dönemde kontrol altına alınmasını takiben total laparoskopik histerektomi adımlarına geçildi. Devam eden cerrahi süreç boyunca kanama minimal düzeyde seyretmiş olup, cerrahi görüşün korunması sayesinde prosedür kontrollü ve güvenli bir şekilde tamamlandı. Operasyon sırasında herhangi bir intraoperatif komplikasyon gelişmedi ve hasta stabil şekilde operasyondan çıkarıldı.

TARTIŞMA

Total laparoskopik histerektomi, minimal invaziv cerrahinin sağladığı avantajlar nedeniyle jinekolojik cerrahide yaygın olarak tercih edilen bir yöntemdir. Bununla birlikte, özellikle uterin myom gibi artmış vaskülarite ile ilişkili durumlarda intraoperatif kanama, cerrahi süreci zorlaştıran temel faktörlerden biri olmaya devam etmektedir. Bu nedenle cerrahinin erken aşamalarında etkin kanama kontrolü sağlanması, operasyonun güvenliği ve başarısı açısından kritik öneme sahiptir.

Uterin arterin erken ligasyonu, pelvik cerrahide kanlanmayı azaltarak daha güvenli bir diseksiyon alanı oluşturmayı amaçlayan bir yaklaşımdır. Ancak bu tekniğin uygulanabilmesi için retroperitoneal anatominin iyi bilinmesi ve özellikle üreterin açık şekilde ortaya konularak cerrahi sahada güvenli sınırların belirlenmesi gerekmektedir. Üreterin uterin arter ile yakın komşuluğu göz önünde bulundurulduğunda, körlemesine yapılan vasküler kontrol girişimleri ciddi üreter yaralanmalarına yol açabilir. Bu nedenle uterin arterin, üreter vizualizasyonu eşliğinde kontrol altına alınması cerrahi güvenliği belirgin şekilde artırmaktadır.

Sunulan olguda, myom varlığına bağlı artmış kanama riski öngörülerek cerrahinin başlangıcında retroperitoneal yaklaşım benimsenmiş ve uterin arterler, üreter ile olan anatomik ilişkileri net olarak ortaya konulduktan sonra erken dönemde ligate edilmiştir. Bu yaklaşım sayesinde cerrahi sahada kanlanmanın azaldığı, diseksiyon planlarının daha net hale geldiği ve operasyonun kontrollü bir şekilde sürdürülebildiği gözlenmiştir.

Her ne kadar uterin arterin erken ligasyonu rutin olarak uygulanan bir yöntem olmasa da, seçilmiş olgularda cerrahi konforu artıran ve komplikasyon riskini azaltan etkili bir strateji olarak değerlendirilebilir. Özellikle myomatöz uterus ve artmış vaskülarite ile seyreden durumlarda bu yaklaşımın tercih edilmesi, cerrahinin daha güvenli koşullarda tamamlanmasına katkı sağlayabilir.

Sonuç olarak, uterin arterin üreter vizualizasyonu eşliğinde erken ligasyonu, uygun hasta seçimi ile birlikte uygulandığında total laparoskopik histerektomi sırasında kanama kontrolünü kolaylaştıran ve cerrahi güvenliği artıran etkili bir teknik olarak öne çıkmaktadır.

SONUÇ

Üreter vizualizasyonu eşliğinde uterin arterin erken ligasyonu, total laparoskopik histerektomi sırasında özellikle kanama riski öngörülen olgularda cerrahi kontrolü artıran etkili bir yaklaşımdır. Retroperitoneal anatominin doğru şekilde ortaya konulması ile birlikte uygulandığında, güvenli diseksiyon sınırlarının belirlenmesine katkı sağlar ve cerrahi sürecin daha kontrollü ilerlemesine olanak tanır. Bu nedenle, uygun hasta seçimi ile birlikte değerlendirildiğinde, söz konusu teknik minimal invaziv histerektomi pratiğinde faydalı bir seçenek olarak göz önünde bulundurulabilir.

KAYNAKÇA

1. Poojari, V. G., Bhat, V. V., & Bhat, R. (2014). Total laparoscopic hysterectomy with prior uterine artery ligation at its origin. *International journal of reproductive medicine*, *2014*, 420926. https://doi.org/10.1155/2014/420926
2. Salama,M. H.A., Taha,Y. A.M., Hassan,S. E. and Elskaan,R. G.A. (2025). Total Laparoscopic Hysterectomy with Uterine Artery Clipping Vs. Conventional

Laparoscopic Hysterectomy: A Randomized Controlled Trial. *Journal of Obstetrics, Gynecology and Cancer Research*, *10*(11), 850-859. doi: 10.24200/jogcr.10.11.850

3. Bhattacharjee, R., Shah, D., Ganjiwale, J., Pandey, S., Pindoria, M., & Shahu, S. (2025). Role of uterine artery occlusion at origin during total laparoscopic hysterectomy in non-malignant cases for optimal surgical outcome. International Journal of Gynecology & Obstetrics, 171(3), 1325–1334. https://doi.org/10.1002/ijgo.70265
4. Lampé, R., Margitai, N., Török, P., Lukács, L., & Orosz, M. (2025). A Stepwise Anatomy-Based Protocol for Total Laparoscopic Hysterectomy: Educational Tool with Broad Clinical Utility. *Diagnostics (Basel, Switzerland)*, *15*(14), 1736. https://doi.org/10.3390/diagnostics15141736
5. Xu, J., Xiong, S., Gu, R., Yuan, R., Feng, D., Cong, S., Zhao, S., & Jiang, L. (2026). Prospective cohort study: vascular clamping of uterine artery combined with sacral ligament plication in complex hysterectomy. *BMC women's health*, *26*(1), 106. https://doi.org/10.1186/s12905-025-04212-1

Yapay zekâ destekli sohbet botlarının sigara bırakma uygulamalarında klinik kullanım potansiyelinin değerlendirilmesi

Hilal Tabak[1], Atalay Aktuna[2*]

[1]Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Yazılım Mühendisliği Bölümü, Lisans Öğrencisi

[2]Bandırma Onyedi Eylül Üniversitesi, Tıp Fakültesi, Halk Sağlığı Anabilim Dalı, Öğretim Üyesi

[*]Sorumlu yazar: aaktuna@bandirma.edu.tr

Özet

Tütün bağımlılığı, önlenebilir morbidite ve mortalitenin önde gelen nedenlerindendir. Geleneksel farmakolojik ve psikososyal müdahalelere erişimde yaşanan sistemik bariyerler, dijital sağlık teknolojilerine olan ihtiyacı artırmıştır. Bu derlemenin amacı, tütün bağımlılığı tedavisinde Yapay Zekâ (YZ) destekli sohbet botlarının klinik etkililiğini ve kullanım potansiyelini güncel literatür ışığında değerlendirmektir. PubMed veritabanında, 2020-2025 yılları arasında yayımlanmış, müdahale merkezinde otonom YZ sohbet botu bulunduran ve klinik bırakma başarısını ölçen araştırmalar taranmıştır. İlgili dahil etme/dışlama kriterlerine uygun olarak ulaşılan 4 adet araştırma çalışmaya dahil edilmiştir. İncelenen araştırmalar; YZ destekli sohbet botlarının standart farmakoterapiye ve danışmanlık hizmetlerine eklendiğinde veya tekil müdahale olarak kullanıldığında sigara bırakma başarısını, bırakmaya hazırlık metriklerini ve öz-yeterliği artırma potansiyeline sahip olduğunu göstermektedir. Ayrıca, çalışmalardaki bulgular, etkililiğin merkezinde; klinik kılavuzlara algoritmik uyum, yargılayıcı olmayan empatik dil kullanımı ve açık uçlu sorulara bağlamsal yanıt verebilme becerisinin ortaya çıkardığı terapötik bağın ve sistemle etkileşim süresi ve sıklığının yer alabileceğine işaret etmektedir. Bununla birlikte, YZ'nin sağlık alanında kullanımında sıklıkla tartışılan halüsinasyon ve dijital eşitsizlikler kısıtlılıkları, ayrıca mevcut araştırmaların niteliksel ve niceliksel sınırlılıkları göz önünde bulundurulduğunda, sistemlerin tam otonom yerine insan gözetimli kurgulanması ve uzun erimli yüksek kanıt düzeyine sahip daha fazla çalışma gerçekleştirilmesi önerilir.

Anahtar kelimeler: Sigara bırakma, sohbet botu, yapay zekâ

Giriş

Tütün bağımlılığı, küresel ölçekte ve Türkiye'de en önde gelen önlenebilir morbidite ve mortalite nedenlerinden biridir. Dünya'da her yıl yaklaşık 8 milyon insan, ülkemizde ise her yıl yaklaşık 100 bin kişi başta sigara olmak üzere tütün ürünü kullanımı nedeniyle yaşamını kaybetmektedir (T.C. Sağlık Bakanlığı, 2018; World Health Organization [WHO], 2023). Bu bağlamda tütün bağımlılığı, Dünya Sağlık Örgütü (DSÖ) tarafından yıkıcı bir pandemi olarak tanımlanmış ve bununla mücadele etmek için ülkelere bir makro-strateji olarak MPOWER (M-monitor: Tütün kullanımını ve koruyucu uygulamaları izle, P-protect: toplumu tütün dumanından koru, O-offer: sigarayı bırakmaya yardım et, W-warn: tütünün zararları konusunda uyar, E-enforce: tütün reklam ve tanıtımını yasakla, R-raise: tütün vergilerini artır) politika paketi geliştirilmiştir (WHO, 2008). Söz konusu politika paketinin önemli sacayaklarından biri 'tütünü bırakma konusunda yardım teklif et' stratejisi olup, her tütün kullanıcısının kanıta dayalı bırakma destek hizmetlerine erişiminin temel bir sağlık sistemi zorunluluğu olduğunu vurgulamaktadır (WHO, 2021a).

Tütün bağımlılığının yalnızca fiziksel bir nikotin yoksunluğu değil, aynı zamanda derin bilişsel ve davranışsal şartlanmalar içeren nörobiyolojik bir hastalık olması, farmakolojik ve psikososyal müdahalelerin birleştiği bu ideal klinik yaklaşımı zorunlu kılmaktadır (Benowitz, 2010; Fiore vd., 2008). Bu doğrultuda güncel klinik uygulama kılavuzlarında, ideal ve en yüksek bırakma başarısı oranlarının sağlandığı tedavi protokolü, farmakoterapötik ajanların ve yapılandırılmış psikososyal müdahalelerin kombine edildiği multimodal yaklaşımlar olarak tanımlanmaktadır (Fiore vd., 2008). Bununla birlikte saha pratiğinde bu tedavi protokollerine erişim, istendik düzeylerin oldukça altında kalabilmektedir. Mevcut sağlık hizmeti arzı, tütün ürünü kullanımı ve bırakma isteğinin yaygınlığı göz önünde bulundurulduğunda, ihtiyacın dramatik bir şekilde gerisinde kalmaktadır. Örneğin, DSÖ verilerine göre dünyadaki yaklaşık 1,3 milyar tütün kullanıcısının %60'ı sigarayı bırakmak istemesine rağmen, küresel nüfusun yalnızca yaklaşık üçte biri (%34'ü) maliyeti kamu tarafından karşılanan kapsamlı bırakma destek hizmetlerine erişebilmektedir (WHO, 2021). Nitelikli uzman eksikliği, hizmetin niteliği gereği birey başına hizmet süresinin ve sıklığının yüksek oluşu, danışmanlık hizmetlerinin birinci basamak sağlık sistemlerine entegrasyonundaki yetersizlikler, coğrafi ve sosyoekonomik eşitsizlikler, bağımlılıkla ilişkili damgalanma gibi çok katmanlı sistemik bariyerler, söz konusu sağlık hizmetine erişimi kısıtlamaktadır (Twyman vd., 2014). Bu erişim bariyerleri ve arz-talep dengesizliği, tütün bağımlılarının nitelikli tıbbi ve davranışsal destekten yoksun kalmasına, bireylerin desteksiz bırakma girişimlerine yönelmesine; bu durum da tedavi edilmemiş bağımlılığın doğası gereği %90'ları aşan erken dönem nüks oranlarının görülmesine zemin hazırlamaktadır (Hughes vd., 2004).

Bilgi ve iletişim teknolojilerinde ivme kazanan gelişmeler, mobil sağlık (mHealth) ekosistemini yapılandırarak geleneksel klinik müdahalelerin sınırlılıklarını aşan yenilikçi yaklaşımların geliştirilmesine olanak tanımıştır (Whittaker vd., 2016). Sigarayı bırakmaya yönelik erken dönem dijital müdahaleler ağırlıklı olarak tek yönlü, önceden tanımlanmış statik metin mesajları veya pasif içerik sağlayan web tabanlı arayüzlerle sınırlıyken; günümüzde bu müdahaleler, doğal dil işleme (NLP), makine öğrenimi (ML) ve büyük dil modelleri (LLM) gibi ileri veri bilimi teknolojilerine dayanan yapay zekâ (YZ) tabanlı sohbet botları ve ajanlarını içeren uygulamalara dönüşmektedir (Laranjo vd., 2021; Olano-Espinosa vd., 2022). Bu teknolojik ilerleme, sohbet botlarının yalnızca farmakolojik uyumu destekleyen pasif bildirim araçları olmalarının ötesine geçerek, hastalara zaman ve mekândan bağımsız, anonim, bireyselleştirilmiş ve yüksek ölçeklenebilirliğe sahip bir terapötik destek sağlayarak bağımlılık tedavisinde temel bir paradigma kaymasına yol yol açma potansiyeli ortaya koymaktadır (Bricker vd., 2024; Carrasco-Hernandez vd., 2020). Günümüzde bu sistemler; hastalarla empatik terapötik ittifaklar kurabilen, yoksunluk krizleri sırasında anlık davranışsal müdahalelerde bulunabilen, ambivalans duyguları çözümleyebilen ve klinik karar destek sistemlerine veri akışı sağlayabilen, bir tür aktif sanal terapist formunu almaktadır (Bricker vd., 2024; Liu vd., 2025).

Bu bağlamda, bu derlemenin amacı, tütün bağımlılığı müdahalelerinde YZ destekli sohbet botlarının kullanım potansiyelini ve klinik etkililiğini güncel literatür ışığında incelemektir.

Literatür taraması

Bu derleme araştırması kapsamında gerçekleştirilen literatür taramasında, dijital sağlık teknolojilerinin ve mHealth uygulamalarının eksponansiyel bir büyüme sergilediği ve özellikle LLM'lerin tıp alanına entegre edilmeye başlandığı 2020 ile 2025 yılları arası dönemdeki araştırmalar hedeflenmiştir.

Bu çalışmada literatür tarama stratejisi, incelenen fenomenin hem tıbbi boyutunu hem de teknolojik boyutunu kapsayacak şekilde iki ana kavramsal küme üzerinden kurgulanmıştır. Birinci küme, tıbbi boyut kümesi, sigara ve tütün bırakma eylemini tanımlayan "smoking

cessation", "tobacco cessation" ve "quit smoking” İngilizce anahtar kelimelerinden; ikinci küme ise, sohbet botu kavramını tanımlayan, "chatbot" ve "conversational agent" anahtar kelimelerinden oluşturulmuştur. Bu iki ana küme, PubMed veritabanında "AND" mantıksal bağlacı ile birleştirilmiş; küme içi sinonimler ve eş anlamlı terimler ise "OR" bağlacı ile genişletilmiştir. Araştırmanın kalitesini ve odak noktasını korumak amacıyla, arama sonuçlarında listelenen makaleler, aşağıda belirtilen dahil etme ve dışlama kriterlerine göre değerlendirilmiştir.

Dahil Etme Kriterleri:

- İngilizce dilinde yayımlanmış, hakem değerlendirmesinden geçmiş, deneysel veya gözlemsel tasarımlardan birine sahip orijinal araştırma makalesi olması
- Müdahalenin merkezinde otonom bir YZ sohbet botunun yer alması.
- Çalışmanın birincil veya ikincil sonlanım noktasının sigara bırakma ile ilintili sonuçlara dayandırılmış olması

Dışlama Kriterleri:

- Sadece teorik çerçeve sunan, klinik sonuç verisi içermeyen çalışma protokolleri ve derleme gibi araştırmalar
- Müdahale içeriği, YZ veya otonom diyalog barındırmayan, yalnızca statik kural setleriyle tek yönlü otomatik SMS gönderen geleneksel mHealth programları olduğu araştırmalar
- Tütün kullanımından ziyade genel iyilik hali veya farklı bağımlılıklarına odaklanıp sigara bırakmayı yalnızca marjinal bir alt başlık olarak ele alan araştırmalar
- Özet niteliğinde olan veya tam metnine ulaşılamayan çalışmalar

PubMed veritabanında dışlama kriterlerine uygun olarak filtreli olarak gerçekleştirilen aramalar sonucunda 25 sonuç listelenmiş, bunların 17’si tekrarlayan sonuçlar olması, 3’ü çalışma protokolü olması, 1’i sigara bırakma ile ilintili sonuçlara dayandırılmamış olması nedeniyle dışlanmış; geriye kalan 4 araştırma tam metin erişiminin sağlanabilmesi neticesinde araştırmaya dahil edilmiştir.

Araştırmanın literatür tarama, filtreleme ve nihai seçim sürecine ait metodolojik akış, aşağıdaki Şekil 1'de özetlenmiştir.

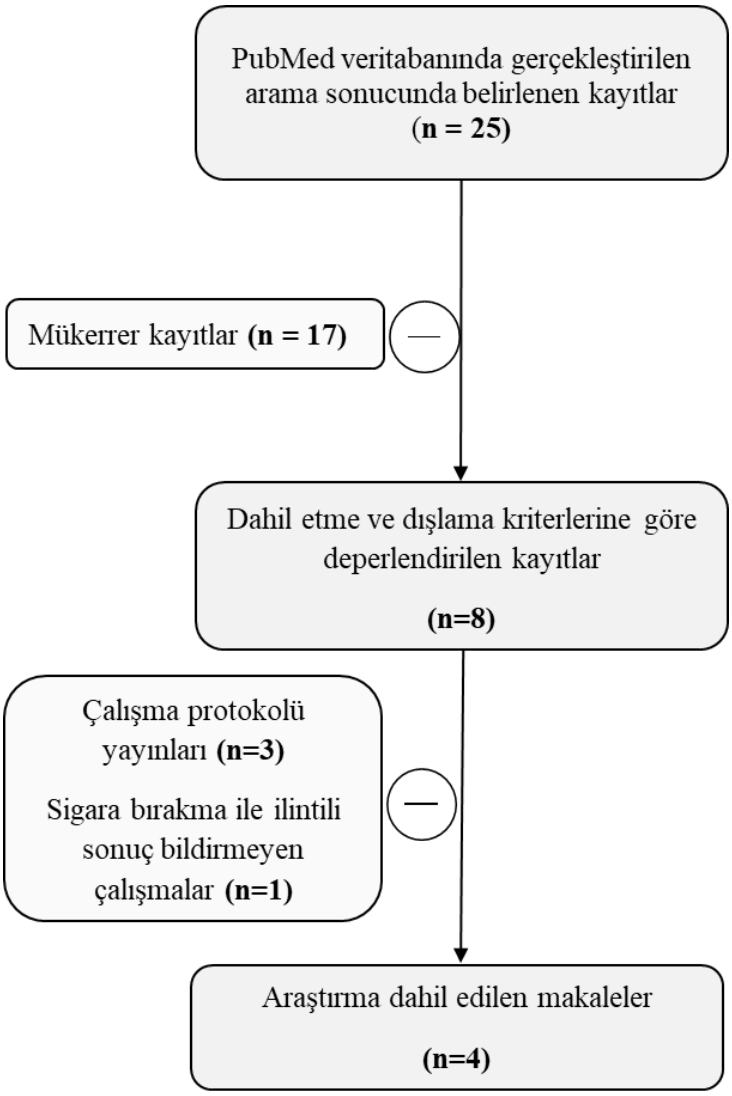

Şekil 1. Literatür taraması ve araştırmaların seçim süreci

Müdahale tasarımları ve sohbet botlarının sigara bırakmada klinik etkililiği

Değerlendirmeye alınan araştırmaların 3'ü randomize kontrollü klinik araştırma tasarımında, 1'i ise gözlemsel ve karma tipte araştırma tasarıma sahip olmakla birlikte; çalışmalarda ele alınan yapay zeka uygulamaları, botların farmakoterapiye eklenen bir dijital asistan olarak kullanımı veya büyük dil modeli tabanlı açık uçlu danışmanlık sistemleri gibi çeşitli yöntemleri içermektedir.

Carrasco-Hernandez ve arkadaşlarının (2020) yürüttüğü "So-Lo-Mo" (Social-Local-Mobile) olarak adlandırılan bir mobil uygulamanın etkinliğinin değerlendirildiği klinik çalışmada, psikofarmakolojik tedavi alan hastaların, yapay zeka (YZ) destekli bir mesajlaşma sistemi ile desteklendiğinde uzun vadeli (1 yıllık) bırakma başarıları değerlendirilmiştir. Toplam 240 katılımcıyla (n=120 müdahale grubu, n=120 kontrol grubu) yürütülen bu randomize kontrollü çalışmada, her iki gruba da yüzyüze danışmanlık takipleri ve vareniklin veya bupropion gibi standart psikofarmakolojik tedaviler sunulmuş; müdahale grubuna ek olarak Davranış Değişimi Transteoretik Modeline (TTM) göre programlanmış bir mesajlaşma aracına erişim sağlanmıştır. Araştırmada müdahale grubunda 1 yıllık sürekli bırakma başarısı %27,5 (%95 GA: 19,5-35,5) seviyesine ulaşırken, kontrol grubunda bu oran %15,0 (%95 GA: 8,6-21,4) olarak gerçekleşmiştir. Hastaların yaş, kullanılan ilaç, bırakma motivasyonu skoru ve nikotin bağımlılık düzeyleri gibi potansiyel karıştırıcı değişkenlere göre yapılan çok değişkenli

düzeltmelerin ardından, müdahale grubunun sigara bırakma olasılığı için Odds Oranı (OR) 3,13 (%95 GA: 1,53-6.71; p=0,002) olarak hesaplanmıştır. Ayrıca, bir hastada istenen klinik faydayı sağlamak için tedavi edilmesi gereken kişi sayısını ifade eden "Number Needed to Treat" (NNT) 8 olarak bulunmuştur. Ek olarak, kendilerine sunulan ideal protokolü uygulayan hastaları kapsayan analizlerde bir yıllık sigara bırakma başarı oranları müdahale grubu için %64,7 (%95 GA: 51,6-77,8), kontrol grubu için ise %40,0 (%95 GA: 25,7-54,3) olarak saptanmıştır (p=0,02; düzeltilmiş OR: 3.45, %95 GA: 1,39-9,13; p=0,01). Protokole uygun hareket eden gruplara özgü analizlerde ise NNT değerinin 4'e düştüğü görülmüştür. Etkililik bulgularına ek olarak, müdahale ve kontrol grupları arasında bildirilen advers etkiler açısından istatistiksel anlamlı bir fark saptanmamıştır (müdahale grubu: %11,7, kontrol grubu: %10,8; p=0,84).

Olano-Espinosa ve arkadaşları (2022) tarafından İspanya'daki 34 farklı birinci basamak sağlık merkezinde toplam 513 hasta (n=242 müdahale grubu; n=271 kontrol grubu) üzerinde yürütülen bir başka randomize klinik araştırmada, Telegram altyapısı üzerinde çalışan ve klinik olarak etkinliği kanıtlı '5A' (Sor, Öner, Değerlendir, Yardım Et, Düzenle) yaklaşımına dayanan "Dejal@bot" adlı Doğal Dil İşleme tabanlı sistemin etkililiği değerlendirilmiştir. Çalışmada sigara bırakmaya yönelik öz-bildirim verisi 6. ayın sonunda CO-oksimetri ölçümleri ile biyokimyasal olarak doğrulanmıştır. Biyokimyasal doğrulamalı 6 aylık sürekli sigara bırakma oranı müdahale grubunda %26,0 (63/242), kontrol grubunda ise %18,8 (51/271) olarak saptanmıştır. Lojistik regresyon modelleri ile hesaplanan OR, bazal CO-oksimetri seviyeleri ve farmakolojik bupropion kullanımı gibi karıştırıcı faktörlere göre düzeltildiğinde 1,52 (%95 GA: 0,99-2,23; p=0,05) olarak raporlanmıştır. Araştırmacılar, elde edilen bu farkın, istatistiksel anlamlı düzeyde olmamasına karşın klinik açıdan önemli bir potansiyele işaret ettiğini belirtmektedir.

Carrasco-Hernandez ve arkadaşlarının (2020) ile Olano-Espinosa ve arkadaşlarının (2022) gerçekleştirmiş olduğu yukarıda bahsi geçen çalışmalarda ortak bir bulgu olarak kullanıcıların etkileşim hacimlerinin de sigara bırakma başarısını tahminleyen bir faktör olarak tespit edilmesi dikkat çekicidir. Carrasco-Hernandez ve arkadaşlarının (2020) So-Lo-Mo çalışmasında, 6. ay değerlendirmelerinde sigara bırakmayı başaran grup ile başaramayan grup arasında botla etkileşim sıklığı bakımından anlamlı farklılık saptanmıştır (p=0,04). Benzer şekilde Olano-Espinosa ve arkadaşlarının (2022) Dejal@bot araştırmasında da sistemi yoğun olarak kullanan (4'ten fazla temas ve toplamda 30 dakikadan fazla etkileşim) gösteren grupta bırakma başarısı %68,6 düzeyindeyken, yoğun kullanım göstermeyen grupta bu oran %40,9 olarak kalmıştır (p=0,02).

Bricker ve arkadaşları (2024) tarafından 4 yıllık bir kullanıcı odaklı tasarım süreci sonucunda geliştirilen "QuitBot", Büyük Dil Modellerinin bağımlılık tedavisindeki kullanımına dair güncel bir başka örnektir. Çalışma kapsamında oluşturulan QuitBot adlı uygulama, 11.000 soru-cevaplık bir tür klinik kütüphaneyi işleyen bir uzman sistem (Azure QnA) ile bu kütüphane dışındaki açık uçlu sorulara yanıt üretebilen ince ayarlı (fine-tuned) GPT-3.5 modelinin entegre çalıştığı hibrit bir altyapı kullanacak şekilde tasarlanmıştır. Bu tasarım, kullanıcıların serbest metin formatında açık uçlu sorular sorabilmesine ve sistemin bağlama uygun yanıtlar üretebilmesine olanak tanımaktadır. Yürütülen pilot randomize kontrollü klinik çalışmada, "kabul ve kararlılık terapisi" ve "çalışma ittifakı" çerçevesini uygulayan QuitBot müdahalesi, Amerika Birleşik Devletleri'nde bir kamu programı olan "SmokefreeTXT" adlı mesajlaşma programı kullanımı ile karşılaştırılmıştır. Sonuçlar, 42 günlük programı tamamlayan katılımcılar arasında 3. ayın sonundaki 30 günlük nokta prevalans sigara bırakma oranının QuitBot grubunda %63 (39/62), kontrol grubunda ise %38,5 (45/117) olduğunu göstermiştir (OR: 2,58, %95 GA: 1,34-4,99; p=0,005). Ancak bu etkililik, programı tamamlayan grupla sınırlı kalmış olup; tüm katılımcılar analiz edildiğinde 3. ayın sonundaki sigara bırakma oranları

QuitBot için %31,1 (59/190), SmokefreeTXT için ise %34,7 (50/144) olarak tespit edilmiş; iki grup arasında istatistiksel olarak anlamlı bir fark saptanmamıştır (p=0,36).

Liu ve arkadaşları (2025) tarafından yürütülen gözlemsel, tek kollu ve karma yöntemli bir diğer fizibilite çalışmasında, GPT-4 altyapısı kullanılarak tasarlanan ve 5A yaklaşımı çerçevesini temel alan "Aipaca" adlı sohbet botunun 30 dakika süreli tek seanslık danışmanlık etkinliği değerlendirilmiştir. Toplam 29 yetişkin sigara içicisinde yürütülen çalışmada; müdahale öncesi ve sonrası hazırlık metriklerinin karşılaştırılmasını içeren niceliksel analizlerin yanı sıra, hasta görüşmeleri ve oturum transkriptlerinin mikro-dizi konuşma analizini içeren niteliksel değerlendirmeler bir arada gerçekleştirilmiştir. Niceliksel verilerin analizi sonucunda; hastaların sigarayı bırakmaya "hazırlık", "öz-yeterlik", tütünün sağlık risklerine ve bırakma yöntemlerine dair bilgi düzeylerini ölçen hazırlık göstergelerinin tamamında istatistiksel olarak anlamlı iyileşmeler saptanmıştır ($p<0,05$; Cohen's d etki büyüklükleri 0,39 ile 1,26 aralığında). Yazarlar, oturum transkriptlerine yönelik mikro-dizi konuşma analizleri neticesinde, botun başarılı bir terapötik diyalog kurabilmesinin altında yatan üç temel mekanizma tanımlamıştır. Birincisi, hastanın paylaştığı bilgilerin daha sonraki aşamalarda empati ve motivasyon amacıyla yeniden kullanıldığı "bağlamsal referans ve süreklilik", ikincisi hastanın verdiği cevapların özetlenerek daha açık uçlu sorulara dönüştürüldüğü "detaylandırma istemleri" ve üçüncüsü sohbetin salt bir bilgi toplama sürecinden çıkıp, kullanıcının eylem planı oluşturmasına (örneğin bırakma tarihi belirlemesine) olanak tanıyan "işbirlikçi planlamaya ilerleme" pratiği olarak tanımlanmıştır. Ayrıca, yarı yapılandırılmış görüşmelerden elde edilen kalitatif bulgular; kullanıcıların Aipaca'yı özellikle yoksunluk krizleri anlarında ve sosyal destek mekanizmalarının bulunmadığı durumlarda her zaman erişilebilir, yargılayıcı olmayan ve güvenilir bir kaynak olarak değerlendirdiğini (örneğin; "Benimle ilgilenen ve bana yardım etmek isteyen gerçek bir insanla konuşuyormuşum gibi hissettirdi.", "Dinlenildiğimi ve cesaretlendirildiğimi hissettim. Her şeyi sorabileceğimi hissettim." gibi ifadelerle) ortaya koymuştur. Bununla birlikte katılımcılar; insan etkileşimindeki ince nüansların eksikliği, uzun vadeli hesap verebilirliğin sınırlı olması, düşük kültürel rezonans ve zaman zaman aşırı amaca yönelik bir diyalog üslubu benimsenmesi gibi sistemin birtakım tasarım kısıtlılıklarına da dikkat çekmişlerdir.

Bu derleme çalışmasına dahil edilen araştırmalara dair araştırmaların kapsamı, müdahale tasarımları elde edilen bulgular Tablo 1'de özetlenmiştir.

Tablo 1. Sigara bırakmada YZ sohbet botu etkinliğinin değerlendirildiği araştırmaların kapsamı, tasarımı ve temel bulguları

Yazar	YZ teknolojisi, altyapısı ve uygulama adı	Teorik çerçeve	Örneklem ve çalışma tasarımı	Temel bulgular	Terapötik etkileşim
Carrasco-Hernandez vd. (2020)	So-Lo-Mo / YZ destekli sağlık tavsiyesi sistemi, ML	TTM	n=240 randomize kontrollü (1/1 oran) ve 1 yıllık izlem	İzlem sonunda sigara bırakma müdahale grubunda %27,5, kontrol grubunda %15,0 (Düzeltilmiş OR=3,13; p=0,002); NNT=8. (İdeal protokol uyumunda NNT=4)	Altıncı ayda sistemle kurulan etkileşim düzeyi ile sigara bırakma arasında istatistiksel olarak anlamlı pozitif yönlü korelasyon mevcut (p=0,04)
Olano-Espinosa vd. (2022)	Dejal@bot / NLP, Telegram	5A Modeli	Çok merkezli, randomize kontrollü, 6 aylık izlem, n=513 (müdahale grubu n=242)	İzlem sonunda biyokimyasal doğrulamalı sigara bırakma, müdahale grubunda %26,0, kontrol grubunda %18,8 (OR=1,52; p=0,05). Sınırda istatistiksel anlamlı fark yok.	Kullanıcıların ortalama etkileşim süresi 121 dakika, yoğun kullanım bırakma başarısı için bir prediktör
Bricker vd. (2024)	QuitBot / Hibrit Sistem (11.000 soru-cevap kütüphanesi ile eğitilmiş Azure QnA Uzman Sistemi + İnce Ayarlı GPT-3.5)	Çalışma ittifakı & Kabul ve kararlılık terapisi	Pilot çalışma, randomize kontrollü, 42 günlük programı tamamlayan n=179	Programı tamamlayanlarda 30-gün bırakma oranı: QuitBot %63 vs SMS %38,5 (OR=2,58; p=0,005). Programı tamamlamayanların dahil edildiği analizlerde anlamlı fark yok.	Açık uçlu sorulara yanıt verebilme yeteneği hasta bağlılığını desteklemekte
Liu vd. (2025)	Aipaca (LLM, GPT-4)	5A Modeli	n=29, gözlemsel tasarım ve karma yöntem; fizibilite çalışması	30 dakikalık danışmanlık seansı öncesi ve sonrasında sigara bırakma konusunda öz-yeterlik ve hazırlık skorlarında anlamlı artış	Kullanıcıların her zaman erişilebilir, yargılayıcı olmayan ve güvenilir bir kaynak olarak tanımlaması

Sonuç ve öneriler

YZ araçları literatürde genel olarak, farklı alanlardaki klinik başarı projeksiyonlarına rağmen, etik sınırlar, kurumsal entegrasyon ve sosyoekonomik boyutların dikkate alınması gerektiği yönünde yaygın bir şekilde tartışılmaktadır (Topol, 2019; WHO, 2021b). Nitekim gerçekten de üretken yapay zekanın danışmanlık süreçlerine dahil olması, olasılığa dayalı dil üretiminden kaynaklanan halüsinasyon, yani hatalı yanıt riskini yoğun bir şekilde barındırmaktadır (Alkaissi & McFarlane, 2023). Bu durum, tıbbi danışmanlık söz konusu olduğunda daha da önemli bir sorun haline gelebilmektedir. Ayrıca, kullanıcı kabulü açısından da bu tür sistemlerin umut vadedici sonuçları ortaya konsa da, literatürde tıbbi güvenilirliğin sağlanmasında insan otoritesinin hala önemli bir belirleyici olduğu belirtilmektedir (Asan vd., 2020). Ayrıca, dijital teknolojilerin; donanım, internet erişimi ve dijital okuryazarlık gerektirmesi, hedef kitlenin önemli bir bölümünü oluşturan düşük ve orta sosyoekonomik düzeydeki popülasyonlar için "dijital uçurum" olarak tanımlanan eşitsizlik tehlikesini beraberinde getirdiği bildirilmektedir (Crawford & Serhal, 2020). YZ araçlarının literatürde bildirilen bu sınırlılıklarına karşın, bu derleme çalışması kapsamında incelenen araştırmalar; kural tabanlı algoritmalardan üretken yapay zekaya evrilen otonom sistemlerin, tütün bağımlılığı tedavisinde standart müdahaleleri destekleyen ve sigara bırakma başarısı oranlarını artırma potansiyeline sahip etkili ve tamamlayıcı araçlar olabileceğini göstermektedir. BDT, TTM ve 5A Modeli gibi klinik davranış bilimleri yaklaşımları, doğal dil işleme ve büyük dil modelleri aracılığıyla yüksek bir algoritmik uyumla modellenebilmekte ve bu durum, özellikle hizmetin sürekliliği ve damgalanma bariyerinin ortadan kaldırılması noktasında erişilebilir bir terapötik destek ağı oluşturulmasına olanak tanımaktadır (Bricker vd., 2024; Carrasco-Hernandez vd., 2020; Liu vd., 2025; Olano-Espinosa vd., 2022). Nitekim, DSÖ'nün güncel belgelerinde, halk sağlığı stratejileri bağlamında bireysel öz yönetim araçları olarak mobil uygulamalar ve YZ tabanlı sistemlerinin dahil edilmesi de, bu çalışma kapsamında değerlendirmeye alınan araştırmaların sonuçları ile tutarlılık göstermektedir (WHO, 2019, 2021b, 2021c).

Bu derleme çalışması kapsamında değerlendirilen araştırmalara ait bulgular ve genel literatür bir arada ele alındığında; tütün bağımlılığı için kurgulanan ideal bir yapay zeka sohbet botunun; empatik ve yargılayıcı olmayan bir diyalog stili benimseyen, klinik kılavuzlarla ve kapalı uzman kütüphaneleriyle eğitilmiş, açık uçlu sorulara esnek ve bağlamsal yanıtlar üretebilen ve düşük veri altyapılarında dahi çalışabilen sosyoekonomik kapsayıcılığa sahip bir yapılandırmada olması gerektiği sonucuna varılmıştır. Ayrıca bulgular, dijital sağlık müdahalelerinde 'doz-yanıt' benzeri bir ilişkinin var olabileceğine ve terapötik etkileşimin önemine işaret etmektedir. Tıpkı farmakolojik bir tedavide olduğu gibi, YZ destekli botların salt reçete edilmesi yeterli olmuyor; klinik başarının elde edilebilmesi için dijital müdahalenin belirli bir dozda (etkileşim süresi ve temas sayısı bağlamında) kullanılması gerekiyor olabilir (Cole-Lewis vd., 2019; Olano-Espinosa vd., 2022). Bununla birlikte, konu hakkında yürütülen randomize kontrollü ve uzun izlem süreli çalışmalar sayıca henüz oldukça kısıtlıdır. Söz konusu teknolojilerin klinik güvenilirliği, hedef kitle üzerindeki uzun vadeli sürdürülebilirliği ve sağlık sistemi entegrasyon dinamiklerine dair eksiklerin giderilmesi adına, çok merkezli ve geniş ölçekli araştırmalara ihtiyaç duyulmaktadır. Bu doğrultuda, YZ müdahalelerinin tam otonom yapılar yerine insan gözetimli sistemler olarak kurgulanması halen daha rasyonel bir yaklaşım olarak görünmektedir.

Kaynakça

Alkaissi, H., & McFarlane, S. I. (2023). Artificial hallucinations in ChatGPT: Implications in scientific writing. *Cureus*, *15*(2), e35179. doi:10.7759/cureus.35179

Asan, O., Bayrak, A. E., & Choudhury, A. (2020). Artificial intelligence and human trust in healthcare: Focus on clinicians. *Journal of Medical Internet Research*, *22*(6), e15154. doi:10.2196/15154

Benowitz, N. L. (2010). Nicotine addiction. *The New England Journal of Medicine*, *362*(24), 2295-2303. doi:10.1056/NEJMra0809890

Bricker, J. B., Sullivan, B., Mull, K., Santiago-Torres, M., & Lavista Ferres, J. M. (2024). Conversational chatbot for cigarette smoking cessation: Results from the 11-step user-centered design development process and randomized controlled trial. *JMIR mHealth and uHealth*, *12*, e57318. doi:10.2196/57318

Carrasco-Hernandez, L., Jódar-Sánchez, F., Núñez-Benjumea, F., Moreno Conde, J., Mesa González, M., Civit-Balcells, A., ... Ortega-Ruiz, F. (2020). A mobile health solution complementing psychopharmacology-supported smoking cessation: Randomized controlled trial. *JMIR mHealth and uHealth*, *8*(4), e17530. doi:10.2196/17530

Cole-Lewis, H., Ezeanochie, N., & Turgiss, J. (2019). Understanding health behavior technology engagement: Pathway to measuring digital behavior change interventions. *JMIR Formative Research*, *3*(4), e14052. doi:10.2196/14052

Crawford, A., & Serhal, E. (2020). Digital health equity and COVID-19: The innovation curve cannot reinforce the social gradient of health. *Journal of Medical Internet Research*, *22*(6), e19361. doi:10.2196/19361

Fiore, M. C., Jaén, C. R., Baker, T. B., Bailey, W. C., Benowitz, N. L., Curry, S. J., ... Wewers, M. E. (2008). *Treating tobacco use and dependence: 2008 update. Clinical practice guideline*. Rockville, MD: U.S. Department of Health and Human Services, Public Health Service. 23 Nisan 2026 tarihinde https://www.ncbi.nlm.nih.gov/books/NBK63952/ adresinden erişildi.

Hughes, J. R., Keely, J., & Naud, S. (2004). Shape of the relapse curve and long-term abstinence among untreated smokers. *Addiction*, *99*(1), 29-38. doi:10.1111/j.1360-0443.2004.00540.x

Laranjo, L., Dunn, A. G., Tong, H. L., Kocaballi, A. B., Chen, J., Bashir, R., ... Lau, A. Y. (2021). Conversational agents in healthcare: A systematic review. *Journal of the American Medical Informatics Association*, *28*(3), 1248-1258. doi:10.1093/jamia/ocy072

Liu, Y., Calle, P., Vadakekut, M., Rubin, D., Nagykaldi, Z., Doescher, M., ... Shao, R. (2025). AI-enabled personalized smoking cessation intervention with the Aipaca chatbot: Mixed methods feasibility study. *JMIR Formative Research*, *9*, e73319. doi:10.2196/73319

Olano-Espinosa, E., Avila-Tomas, J. F., Minue-Lorenzo, C., Matilla-Pardo, B., Serrano Serrano, M. E., Martinez-Suberviola, F. J., ... Dejal@ Group. (2022). Effectiveness of a conversational chatbot (Dejal@bot) for the adult population to quit smoking: Pragmatic, multicenter, controlled, randomized clinical trial in primary care. *JMIR mHealth and uHealth*, *10*(6), e34273. doi:10.2196/34273

T.C. Sağlık Bakanlığı. (2018). *Tütün kontrolü strateji belgesi ve eylem planı 2018-2023*. Ankara: T.C. Sağlık Bakanlığı Yayınları. 23 Nisan 2026 tarihinde https://havanikoru.saglik.gov.tr/depo/Dokumanlar/2018-2023_TUTUN_EP.pdf adresinden erişildi.

Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, *25*(1), 44-56. doi:10.1038/s41591-018-0300-7

Twyman, L., Bonevski, B., Paul, C., & Bryant, J. (2014). Perceived barriers to smoking cessation in selected vulnerable groups: A systematic review of the qualitative and quantitative literature. *BMJ Open*, *4*(12), e006414. doi:10.1136/bmjopen-2014-006414

Whittaker, R., McRobbie, H., Bullen, C., Rodgers, A., & Gu, Y. (2016). Mobile phone-based interventions for smoking cessation. *Cochrane Database of Systematic Reviews*, (4), CD006611. doi:10.1002/14651858.CD006611.pub4

World Health Organization. (2008). *WHO report on the global tobacco epidemic, 2008: The MPOWER package*. Geneva, Switzerland: World Health Organization. 23 Nisan 2026 tarihinde https://www.who.int/publications/i/item/9789241596282 adresinden erişildi.

World Health Organization. (2019). *WHO guideline: Recommendations on digital interventions for health system strengthening*. Geneva, Switzerland: World Health Organization. 23 Nisan 2026 tarihinde https://www.who.int/publications/i/item/9789241550505 adresinden erişildi.

World Health Organization. (2021a). *WHO report on the global tobacco epidemic, 2021: Addressing new and emerging products*. Geneva, Switzerland: World Health Organization. 23 Nisan 2026 tarihinde https://www.who.int/publications/i/item/9789240032095 adresinden erişildi.

World Health Organization. (2021b). *Ethics and governance of artificial intelligence for health: WHO guidance*. Geneva, Switzerland: World Health Organization. 23 Nisan 2026 tarihinde https://www.who.int/publications/i/item/9789240029200 adresinden erişildi.

World Health Organization. (2021c). *Global strategy on digital health 2020-2025*. Geneva, Switzerland: World Health Organization. 23 Nisan 2026 tarihinde https://www.who.int/docs/default-source/documents/gs4dhdaa2a9f352b0445bafbc79ca799dce4d.pdf adresinden erişildi.

World Health Organization. (2023). *WHO report on the global tobacco epidemic, 2023: Protect people from tobacco smoke*. Geneva, Switzerland: World Health Organization. 23 Nisan 2026 tarihinde https://www.who.int/publications/i/item/9789240077164 adresinden erişildi.

Yapay zeka destekli hemşirelik bakımının yaşam kalitesi üzerine etkileri: derleme çalışması

Büşra Dağcı Günal[1], İrem Nur Ceylan [2]

[1] *Arş. Gör. Dr. Bandırma Onyedi Eylül Üniversitesi, Hemşirelik Bölümü, Halk Sağlığı Hemşireliği ABD, bdagci@bandirma.edu.tr*

[2] *Öğrenci Hemşire, Bandırma Onyedi Eylül Üniversitesi, Hemşirelik Bölümü, iremceylan@ogr.bandirma.edu.tr*

Özet

Amaç: Yapay zeka (YZ) teknolojileri son yıllarda sağlık hizmetlerinin birçok alanında kullanılmaya başlanmış ve özellikle hemşirelik bakım süreçlerinde önemli dönüşümler oluşturmuştur. Bu derlemenin amacı, yapay zeka destekli hemşirelik uygulamalarının bireylerin yaşam kalitesi üzerindeki etkilerini güncel literatür doğrultusunda incelemektir.

Yöntem: Bu çalışma anlatı derleme türünde hazırlanmıştır. Literatür taraması PubMed, Scopus, Wiley Online Libraryve DergiPark veri tabanlarında gerçekleştirilmiştir. Tarama sürecinde "artificial intelligence", "nursing care", "quality of life", "tele-nursing", "clinical decision support systems" anahtar kelimeleri kullanılmıştır. 2019–2026 yılları arasında yayımlanan İngilizce ve Türkçe tam metin araştırmalar, sistematik derlemeler ve inceleme çalışmaları değerlendirmeye alınmıştır.

Bulgular: Literatür bulguları, yapay zeka destekli klinik karar destek sistemlerinin erken risk belirleme, semptom yönetimi ve bakım planlamasında hemşirelere önemli katkılar sağladığını göstermektedir. Giyilebilir teknolojiler ve uzaktan hasta izlem sistemleri sayesinde özellikle kronik hastalıklarda düşme riski, kardiyovasküler komplikasyonlar ve yara bakım süreçleri daha etkin yönetilebilmektedir. Tele-hemşirelik uygulamalarının bakım sürekliliğini desteklediği, hastaların öz-yönetim becerilerini geliştirdiği ve yaşam kalitesini olumlu etkilediği bildirilmektedir. Bununla birlikte veri güvenliği, etik sorunlar, algoritmik yanlılık ve dijital okuryazarlık eksiklikleri yapay zeka uygulamalarının önemli sınırlılıkları arasında yer almaktadır.

Sonuç: Yapay zeka destekli hemşirelik uygulamaları, bireylerin yaşam kalitesinin artırılmasında önemli fırsatlar sunmaktadır. Ancak bu teknolojilerin güvenli ve etkili şekilde kullanılabilmesi için hemşirelerin dijital yeterliliklerinin geliştirilmesi, etik düzenlemelerin güçlendirilmesi ve kanıta dayalı çalışmaların artırılması gerekmektedir.

Anahtar Kelimeler: Yapay Zeka, Hemşirelik Bakımı, Yaşam Kalitesi, Klinik Karar Destek Sistemleri, Tele- Sağlık

GİRİŞ

Sağlık hizmetlerinde yaşanan dijital dönüşüm, yapay zeka uygulamalarının klinik bakım süreçlerine entegrasyonunu hızlandırmıştır. Yapay zeka, büyük veri analizi, makine öğrenmesi, derin öğrenme ve doğal dil işleme gibi teknolojileri kullanarak sağlık profesyonellerinin karar verme süreçlerini destekleyen sistemler olarak tanımlanmaktadır (Alowais ve ark., 2023). Özellikle kronik hastalık yükünün artması, yaşlı nüfusun çoğalması ve sağlık insan gücü yetersizliği gibi nedenler sağlık hizmetlerinde yenilikçi teknolojilere olan ihtiyacı artırmaktadır. Bilgi ve iletişim teknolojilerinin tıp ve hemşirelik alanına

entegrasyonuyla tanımlanan ve insan-makine iş birliğini ön plana çıkaran akımları, bakım süreçlerinde yapay zekanın etkinliğini zorunlu kılmaktadır (Vasquez ve ark., 2023).

Hemşirelik, birey ile en uzun süre temas halinde olan sağlık disiplinlerinden biri olması nedeniyle dijital sağlık uygulamalarından doğrudan etkilenen meslek grupları arasında yer almaktadır. Yapay zeka destekli sistemler hasta izlemi, semptom değerlendirmesi, bakım planlaması, klinik karar verme ve hasta eğitimi gibi birçok alanda hemşirelik bakımını desteklemektedir (Martinez-Ortigosa ve ark., 2023). Ayrıca yapay zeka uygulamalarının hemşirelik bakım süreçlerine entegrasyonunun hemşire bilişimi alanında yeni roller ve sorumluluklar oluşturduğu bildirilmektedir (Ronquillo ve ark., 2021). Bu teknolojiler bakım süreçlerinin daha hızlı, kişiselleştirilmiş ve verimli yürütülmesine katkı sağlamaktadır.

Dünya Sağlık Örgütü tarafından bireyin yaşadığı kültür ve değerler ekosistemi bağlamında kendi yaşam durumunu algılama biçimi olarak kavramsallaştırılan yaşam kalitesi, nörodejenereatif süreçler (örn. Parkinson hastalığı), onkolojik patolojiler, kronik obstrüktif akciğer hastalıkları (KOAH) ve diyabet gibi uzun soluklu takip gerektiren durumlarda en temel klinik başarı göstergesidir. Semptom yönetiminin özellikle kronik ağrı, dispne ve emosyonel distres gibi durumlarda yetersiz yapılması, bireylerin fonksiyonel bağımsızlık düzeylerini kısıtlamakta ve psikososyal bileşenleri zedelemektedir (Conte ve ark., 2024). Geleneksel klinik yaklaşımlarda semptom dalgalanmalarının anlık ve objektif olarak takibindeki yetersizlikler, hasta çıktılarının kötüleşmesine neden olabilmektedir.

Yapay zeka, makine öğrenmesi algoritmaları, derin öğrenme sinir ağları ve doğal dil işleme mimarileri, büyük sağlık verilerini işleme yetenekleriyle hemşirelerin klinik karar verme süreçlerini desteklemektedir (Alowais ve ark., 2023). Yapay zeka destekli bakım modellerinin bireylerin semptom yönetimini geliştirmesi, sağlık hizmetine erişimi kolaylaştırması ve öz-yönetim becerilerini desteklemesi nedeniyle yaşam kalitesi üzerinde olumlu etkiler oluşturabileceği düşünülmektedir. Bu doğrultuda derlemenin amacı, yapay zeka destekli hemşirelik uygulamalarının yaşam kalitesi üzerindeki etkilerini güncel literatür doğrultusunda incelemek ve hemşirelik uygulamalarına yönelik öneriler sunmaktır.

YÖNTEM

Bu çalışma anlatı derleme türünde hazırlanmıştır. Literatür taraması PubMed, Scopus ve Wiley Online Library ve DergiPark veri tabanlarında gerçekleştirilmiştir. Tarama sürecinde “artificial intelligence”, “nursing care”, “quality of life”, “tele-nursing”, “machine learning” ve “clinical decision support systems” anahtar kelimeleri kullanılmıştır.

Çalışmaya 2019–2026 yılları arasında yayımlanan İngilizce ve Türkçe tam metin araştırmalar, sistematik derlemeler ve inceleme çalışmaları dahil edilmiştir. Yapay zeka destekli hemşirelik uygulamaları, uzaktan hasta izlem sistemleri, tele-sağlık uygulamaları ve yaşam kalitesi ile ilişkili çalışmalar değerlendirmeye alınmıştır. Yalnızca teknik yazılım geliştirme süreçlerine odaklanan ve hemşirelik bakım çıktılarıyla ilişkisi bulunmayan çalışmalar kapsam dışı bırakılmıştır. Elde edilen çalışmalar içerik açısından değerlendirilmiş ve bulgular tematik başlıklar altında sentezlenmiştir.

BULGULAR VE TARTIŞMA

Yapay Zeka ve Klinik Karar Destek Sistemleri

Yapay zeka destekli klinik karar destek sistemleri, hemşirelerin hasta değerlendirme ve bakım planlama süreçlerinde önemli kolaylıklar sağlamaktadır. Bu sistemler büyük miktardaki klinik veriyi analiz ederek olası komplikasyonları erken dönemde belirleyebilmekte ve hemşirelerin klinik karar verme süreçlerini desteklemektedir (Alowais ve ark., 2023).

Literatürde yapay zeka destekli sistemlerin düşme riski, yara enfeksiyonu, kardiyovasküler

komplikasyonlar ve sepsis gibi klinik durumların erken belirlenmesinde etkili olduğu bildirilmektedir (Martinez-Ortigosa ve ark., 2023). Özellikle kronik yara yönetiminde kullanılan görüntü işleme sistemlerinin yara iyileşme sürecini değerlendirmede önemli katkılar sağladığı belirtilmektedir (Veličković ve ark., 2024). Bu sistemlerin komplikasyonları erken dönemde belirleyebilmesi, hemşirelik bakımında proaktif yaklaşımın güçlenmesine katkı sağlamaktadır. Böylece yalnızca mevcut semptomlara müdahale edilmesi yerine, olası risklerin önceden belirlenmesi ve önleyici bakım stratejilerinin geliştirilmesi mümkün hale gelmektedir. Yapay zeka uygulamalarının hemşirelik bakımında kullanım alanlarının, klinik karar destek sistemleri, elektronik sağlık kayıtları, ilaç yönetimi, hasta triyajı ve uzaktan izlem uygulamaları gibi geniş bir yelpazeye yayıldığı bildirilmektedir (Seibert ve ark., 2021).

Yapay zeka destekli sistemlerin hemşirelerin iş yükünü azaltabileceği, dokümantasyon süreçlerini kolaylaştırabileceği ve doğrudan hasta bakımına ayrılan zamanı artırabileceği bildirilmektedir (Rony ve ark., 2023; Robert, 2019). Ayrıca hemşire bilişimi alanında geliştirilen dijital sistemlerin klinik veri yönetimini desteklediği ve bakım koordinasyonunu güçlendirdiği belirtilmektedir (Topaz ve ark., 2019). Bununla birlikte klinik karar verme sürecinde hemşirenin profesyonel değerlendirmesinin ve bireyselleştirilmiş bakım yaklaşımının önemini koruduğu vurgulanmaktadır.

Kronik Hastalık Yönetiminde Yapay Zeka Kullanımı

Kronik hastalık yönetiminde yapay zeka destekli sistemlerin en önemli avantajlarından biri, bireylerin sürekli izlenebilmesine olanak sağlamasıdır. Geleneksel bakım modellerinde hastalar genellikle yalnızca sağlık kuruluşuna başvurduklarında değerlendirilebilmekteyken, dijital izlem sistemleri sayesinde bireylerin günlük sağlık verileri sürekli takip edilebilmektedir. Bu durum özellikle yaşlı bireylerde, çoklu kronik hastalığa sahip hastalarda ve semptom dalgalanmalarının sık görüldüğü klinik durumlarda bakımın sürekliliğini güçlendirmektedir (Seibert ve ark., 2021; Ronquillo ve ark., 2021).

Kronik hastalıklar bireylerin yaşam kalitesini önemli düzeyde etkileyen sağlık sorunları arasında yer almaktadır. Diyabet, Parkinson hastalığı, kardiyovasküler hastalıklar ve kronik obstrüktif akciğer hastalığı gibi durumlarda sürekli izlem ve etkili semptom yönetimi gerekmektedir. Yapay zeka destekli uzaktan izlem sistemleri sayesinde bireylerin vital bulguları, fiziksel aktivite düzeyleri ve semptom değişiklikleri gerçek zamanlı olarak takip edilebilmektedir. Giyilebilir sensörler aracılığıyla elde edilen veriler analiz edilerek erken uyarı sistemleri oluşturulabilmektedir (Ileşan ve ark., 2022).

Parkinson hastalarında kullanılan yapay zeka destekli yürüyüş analiz sistemlerinin düşme riskini belirlemede etkili olduğu bildirilmektedir. Ayrıca yapay zeka tabanlı analizlerin kronik ağrı, fonksiyonel yetersizlik ve yaşam kalitesi üzerindeki etkilerin değerlendirilmesine katkı sağladığı belirtilmektedir (Conte ve ark., 2024). Diyabet yönetiminde kullanılan dijital sağlık uygulamalarının bireylerin öz-yönetim becerilerini geliştirdiği, tedaviye uyumu artırdığı ve komplikasyonların önlenmesine katkı sağladığı bildirilmektedir (Du ve ark., 2022).

Tele-Hemşirelik ve Uzaktan Hasta İzlemi

Tele-sağlık uygulamaları son yıllarda özellikle kronik hastalık yönetimi ve evde bakım hizmetlerinde yaygınlaşmıştır. Yapay zeka destekli tele-hemşirelik uygulamaları sayesinde hastaların semptomları uzaktan izlenebilmekte, eğitim gereksinimleri belirlenebilmekte ve bakım sürekliliği sağlanabilmektedir. Literatürde tele-hemşirelik uygulamalarının hastaların sağlık hizmetine erişimini kolaylaştırdığı, hastane başvurularını azalttığı ve hasta memnuniyetini artırdığı belirtilmektedir (An ve ark., 2023). Özellikle yaşlı bireylerde ve kırsal bölgelerde yaşayan hastalarda tele-sağlık uygulamalarının önemli avantajlar sağladığı bildirilmektedir.

Yapay zeka destekli dijital danışmanlık sistemleri ve sohbet robotları bireylerin sık karşılaştıkları sağlık sorunlarına hızlı geri bildirim verilmesini sağlayarak öz-bakım süreçlerini desteklemektedir (Xu ve ark., 2021). Bununla birlikte dijital teknolojilere erişim eşitsizliği ve dijital sağlık okuryazarlığı eksikliği tele-sağlık uygulamalarının önemli sınırlılıkları arasında yer almaktadır.

Tele-hemşirelik uygulamaları özellikle sağlık hizmetine erişimin sınırlı olduğu bölgelerde bakım eşitsizliklerinin azaltılmasına katkı sağlayabilmektedir. Bununla birlikte yaşlı bireylerde dijital teknoloji kullanımına ilişkin bilgi eksikliği, internet erişim sorunları ve dijital sağlık okuryazarlığının düşük olması tele-sağlık uygulamalarının sürdürülebilirliği açısından önemli sınırlılıklar oluşturmaktadır. Bu nedenle teknolojik altyapının güçlendirilmesi kadar bireylerin dijital sağlık okuryazarlığının geliştirilmesi de önem taşımaktadır (An ve ark., 2023; Xu ve ark., 2021).

Etik Sorunlar ve Veri Güvenliği

Yapay zeka uygulamalarının sağlık alanında kullanımının artması etik tartışmaları da beraberinde getirmektedir. Hasta verilerinin gizliliği, algoritmik yanlılık, veri güvenliği ve yapay zekanın klinik kararlardaki rolü önemli etik sorunlar arasında yer almaktadır (Kaplan & Litewka, 2021).

Algoritmaların hatalı veri ile eğitilmesi yanlış klinik önerilere neden olabilmektedir. Ayrıca yapay zeka sistemlerinin karar süreçlerinin her zaman şeffaf olmaması sağlık profesyonelleri açısından güven sorunları oluşturabilmektedir (Borji, 2023). Bu nedenle yapay zeka destekli sistemlerin hemşirelik bakımında kullanımında insan denetiminin sürdürülmesi, etik ilkelerin korunması ve veri güvenliği politikalarının güçlendirilmesi gerektiği vurgulanmaktadır (Reddy ve ark., 2020

Ayrıca algoritmik karar mekanizmalarının şeffaf olmaması, yapay zeka sistemlerinin klinik uygulamalardaki güvenilirliği konusunda tartışmalara neden olmaktadır. Özellikle hasta bakımında yapay zeka temelli önerilerin hemşirelerin klinik değerlendirmesinin yerine geçmesi değil, karar verme sürecini destekleyen yardımcı sistemler olarak kullanılması gerektiği vurgulanmaktadır. Bu nedenle insan merkezli bakım yaklaşımının korunması yapay zeka uygulamalarının hemşirelik bakımındaki etik temelini oluşturmaktadır (Kaplan & Litewka, 2021; Reddy ve ark., 2020).

SONUÇ

Bu derleme, yapay zeka destekli hemşirelik uygulamalarının yaşam kalitesinin geliştirilmesinde önemli potansiyele sahip olduğunu göstermektedir. Yapay zeka teknolojileri, erken risk belirleme, semptom yönetimi, uzaktan hasta izlemi ve bakım sürekliliği gibi alanlarda hemşirelik bakımını desteklemektedir. Özellikle kronik hastalık yönetiminde kullanılan dijital sağlık uygulamalarının bireylerin öz-yönetim becerilerini geliştirdiği, bakım süreçlerine aktif katılımı artırdığı ve yaşam kalitesini olumlu yönde etkilediği görülmektedir.

Bununla birlikte yapay zeka uygulamalarının klinik bakım süreçlerine entegrasyonu yalnızca teknolojik altyapı ile sınırlı değildir. Hemşirelerin dijital sağlık teknolojileri konusunda bilgi ve becerilerinin geliştirilmesi, etik farkındalığın artırılması ve insan merkezli bakım yaklaşımının korunması büyük önem taşımaktadır. Yapay zeka sistemlerinin hemşirelik bakımında karar verici değil, klinik karar verme sürecini destekleyici araçlar olarak kullanılması gerektiği düşünülmektedir (Ronquillo ve ark., 2021; Robert, 2019). Gelecekte yapılacak çalışmaların farklı hasta gruplarında yapay zeka destekli hemşirelik uygulamalarının uzun dönem etkilerini değerlendirmesi ve özellikle yaşam kalitesi üzerindeki klinik sonuçlara odaklanması önerilmektedir.

ÖNERİLER

• Hemşirelik eğitim programlarına yapay zeka, dijital sağlık ve hemşirelik bilişimi içeriklerinin entegre edilmesi,

• Klinik uygulamalarda kullanılan yapay zeka sistemlerinin etik ilkelere uygunluğu düzenli olarak değerlendirilmesi,

• Tele-sağlık uygulamalarının etkin kullanılabilmesi için bireylerin dijital sağlık okuryazarlığının geliştirilmesine yönelik eğitim programları planlanması,

• Yapay zeka destekli hemşirelik uygulamalarının yaşam kalitesi üzerindeki etkilerini değerlendiren randomize kontrollü ve uzun dönemli çalışmaların yapılması önerilmekredir.

KAYNAKLAR

Alowais, S. A., Alghamdi, S. S., Alsuhebany, N., Alqahtani, T., Alshaya, A. I., Almohareb, S. N., Aldairem, A., Alrashed, M., Bin Saleh, K., Badreldin, H. A., Al Yami, M. S., Al Harbi, S., & Albekairy, A. M. (2023). Revolutionizing healthcare: The role of artificial intelligence in clinical practice. *BMC Medical Education, 23*, 689. doi:10.1186/s12909-023-04698-z

An, H. J., Kang, J. S., & Choi, G. E. (2023). Technology-based self-management interventions for women with breast cancer: A systematic review. *Korean Journal of Women Health Nursing, 29*(3), 160–178. doi:10.4069/kjwhn.2023.09.07

Borji, A. (2023). *A categorical archive of ChatGPT failures*. arXiv. doi:10.48550/arXiv.2302.03494

Conte, L., Lupo, R., Lezzi, P., Pedone, A., Rubbi, I., Lezzi, A., Vitale, E., Fasano, A., & De Nunzio, G. (2024). Statistical analysis and generative artificial intelligence for assessing pain experience, pain-induced disability, and quality of life in Parkinson's disease patients. *Brain Research Bulletin, 208*, 110893. doi:10.1016/j.brainresbull.2024.110893

Du, Q., Liang, D., Zhang, L., Chen, G., & Li, X. (2022). Evaluation of functional magnetic resonance imaging under artificial intelligence algorithm on plan-do-check-action home nursing for patients with diabetic nephropathy. *Contrast Media & Molecular Imaging, 2022*, 9882532. doi:10.1155/2022/9882532

Ileșan, R. R., Cordoș, C. G., Mihăilă, L. I., Fleșar, R., Popescu, A. S., Perju-Dumbravă, L., & Faragó, P. (2022). Proof of concept in artificial-intelligence-based wearable gait monitoring for Parkinson's disease management optimization. *Biosensors, 12*(4), 189. doi:10.3390/bios12040189

Kaplan, B., & Litewka, S. (2021). Ethical challenges of artificial intelligence in healthcare. *Cambridge Quarterly of Healthcare Ethics, 30*(2), 252–267. doi:10.1017/S0963180120000849

Martinez-Ortigosa, A., Martinez-Granados, A., Gil-Hernández, E., Rodriguez-Arrastia, M., Ropero-Padilla, C., & Roman, P. (2023). Applications of artificial intelligence in nursing care: A systematic review. *Journal of Nursing Management, 2023*, 3219127. doi:10.1155/2023/3219127

Reddy, S., Allan, S., Coghlan, S., & Cooper, P. (2020). A governance model for the application of AI in healthcare. *Journal of the American Medical Informatics Association, 27*(3), 491–497. doi:10.1093/jamia/ocz192

Robert, N. (2019). How artificial intelligence is changing nursing. *Nursing Management, 50*(9), 30–39. doi:10.1097/01.NUMA.0000578988.56622.21

Ronquillo, C. E., Peltonen, L. M., Pruinelli, L., Chu, C. H., Bakken, S., Beduschi, A., Macieira, T. G. R., & Topaz, M. (2021). Artificial intelligence in nursing: Priorities and opportunities from an international invitational think-tank of the Nursing and Artificial Intelligence Leadership Collaborative. *Journal of Advanced Nursing, 77*(9), 3707–3717. doi:10.1111/jan.14855

Rony, M. K. K., Parvin, M. R., & Ferdousi, S. (2023). Advancing nursing practice with artificial intelligence: Enhancing preparedness for the future. *Nursing Open, 11*(2), e2070. doi:10.1002/nop2.2070

Seibert, K., Domhoff, D., Bruch, D., Schulte-Althoff, M., Fürstenau, D., & Biessmann, F. (2021). Application scenarios for artificial intelligence in nursing care: Rapid review. *Journal of Medical Internet Research, 23*(11), e26522. doi:10.2196/26522

Topaz, M., Ronquillo, C., Peltonen, L. M., Pruinelli, L., Sarmiento, R. F., Badger, M. K., et al. (2019). Nurse informaticians report low satisfaction and multi-level concerns with electronic health records: Results from an international survey. *AMIA Annual Symposium Proceedings, 2019*, 824–833.

Vasquez, B. A., Moreno-Lacalle, R., Soriano, G. P., Juntasoopeepun, P., Locsin, R. C., & Evangelista, L. S. (2023). Technological machines and artificial intelligence in nursing practice. *Nursing & Health Sciences, 25*(3), 474–481. doi:10.1111/nhs.13029

Veličković, M. V., Spelman, T., Clark,M., Probst, S., Armstrong, D. G., & Steyerberg, E. (2024). Individualized risk prediction for improved chronic wound management. *Wound Repair and Regeneration, 32*(2), 100299. doi:10.1111/wrr.13102

Xu, L., Sanders, L., Li, K., & Chow, J. C. (2021). Chatbot for health care and oncology applications using artificial intelligence and machine learning: Systematic review. *JMIR Cancer, 7*(4), e27850. doi:10.2196/27850