

DERLEME

Yapay Zeka ve Derin Öğrenmenin Sağlık Bilişimi Üzerine Etkisi: Literatür Tabanlı Bir İnceleme

Ömer ÇELİK¹, Nezihe TÜFEKÇİ²

ÖZ

Yapay zekâ (YZ) ve derin öğrenme (DÖ), sağlık bilişimi alanında dönüştürücü bir etkiye sahiptir ve sağlık hizmetlerinin sunum, yönetim ve karar verme süreçlerini yeniden şekillendirmektedir. Bu çalışma, YZ ve DÖ'nün sağlık bilişimine entegrasyonunu literatür temelinde sistematik bir şekilde incelemektedir. Elektronik sağlık kayıtları (ESK), büyük veri analitiği ve klinik karar destek sistemleri (KKDS) gibi teknolojiler, hasta bakımını kişiselleştirme, teşhis doğruluğunu artırma ve operasyonel verimliliği optimize etme potansiyeli sunmaktadır. Özellikle derin öğrenme, tıbbi görüntüleme ve kronik hastalık risk tahmini gibi alanlarda klinisyenlerin iş yükünü azaltarak teşhis hassasiyetini artırmıştır. Ancak, veri gizliliği, algoritmik önyargı, etik ikilemler ve düzenleyici boşluklar, bu teknolojilerin yaygınlaşmasını zorlaştırmaktadır. Çalışma, YZ'nin sorumlu bir şekilde uygulanması için disiplinler arası iş birliği, algoritma şeffaflığı ve etik çerçevelerin standartlaştırılması gerektiğini vurgulamaktadır. Sonuç, YZ ve DÖ'nün sağlık bilişiminde insan odaklı, adil ve sürdürülebilir bir ekosistem oluşturma potansiyeline sahip olduğunu; ancak, bu fırsatların teknik, etik ve toplumsal boyutlarla dengelenmesi gerektiğini göstermektedir.

Anahtar Kelimeler: Derin öğrenme; Dijital teknoloji; Klinik karar destek sistemleri; Tıbbi bilişim; Yapay zekâ;

The Impact of Artificial Intelligence and Deep Learning on Health Informatics: A Literature-Based Review

Ömer ÇELİK¹, Nezihe TÜFEKÇİ²

ABSTRACT

Artificial Intelligence (AI) and Deep Learning (DL) have a transformative impact on health informatics, reshaping the delivery, management, and decision-making processes of healthcare services. This study systematically examines the integration of AI and DL into health informatics based on a literature review. Technologies such as Electronic Health Records (EHR), big data analytics, and Clinical Decision Support Systems (CDSS) offer the potential to personalize patient care, enhance diagnostic accuracy, and optimize operational efficiency. Notably, deep learning has improved diagnostic precision and reduced clinicians' workload in areas such as medical imaging and chronic disease risk prediction. However, challenges such as data privacy, algorithmic bias, ethical dilemmas, and regulatory gaps hinder the widespread adoption of these technologies. The study emphasizes the need for interdisciplinary collaboration, algorithmic transparency, and standardized ethical frameworks to ensure the responsible implementation of AI. The findings indicate that AI and DL have the potential to create a human-centered, equitable, and sustainable ecosystem in health informatics, provided that technical, ethical, and societal dimensions are balanced.

Keywords: Artificial intelligence; Clinical decision support systems; Deep learning; Digital technology; Medical informatics

¹Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Sağlık Yönetimi Bölümü, Isparta, Türkiye.

² Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Sağlık Yönetimi Bölümü, Sağlık Bilişimi Anabilim Dalı, Isparta, Türkiye.

Sorumlu Yazar: Nezihe TÜFEKÇİ

E-posta adresi: nezihetufekci@sdu.edu.tr

Gönderi Tarihi: 19.05.2025

ORCID No: 0000-0002-8557-7823

Kabul Tarihi: 06.08.2025



GİRİŞ

Sağlık sektörü, dijitalleşme ve teknolojik yeniliklerle hızla dönüşmektedir. Bilgi teknolojilerindeki ilerlemeler hem sağlık hizmetlerinin sunumunu hem de hasta bakım süreçlerini kökten değiştirmektedir. Bu dönüşümde, veri temelli karar mekanizmalarını destekleyen yapay zekâ (YZ) ve derin öğrenme (DÖ) gibi bilişsel teknolojiler belirleyici bir rol üstlenmektedir. Sağlık bilişimi, bu teknolojilerin klinik uygulamalara entegrasyonunu kolaylaştırarak daha erişilebilir, etkin ve kişiselleştirilmiş hizmetlerin önünü açmaktadır.

Elektronik sağlık kayıtları (ESK), giyilebilir cihazlar ve tele-tıp gibi dijital uygulamaların yaygınlaşmasıyla sağlık verilerinin hacmi ve çeşitliliği artmış; geleneksel analiz yöntemleri yetersiz kalmıştır. Bu bağlamda, YZ ve DÖ sistemleri, büyük ve karmaşık veri setlerinden anlamlı çıktılar üretmede önemli avantajlar sunmaktadır. Özellikle klinik karar destek sistemleri (KKDS), tanı ve tedavi süreçlerinde hekimlere yardımcı olarak hataları azaltmayı ve verimliliği artırmayı hedeflemektedir. Bununla birlikte, veri mahremiyeti, algoritmik şeffaflık, etik sorunlar ve veri önyargıları gibi faktörler, bu

teknolojilerin güvenli ve adil kullanımını sınırlandırabilmektedir. Klinik uygulamalarda başarı, teknolojinin insan merkezli tasarımı ve sağlık profesyonellerinin sisteme duyduğu güven ile yakından ilişkilidir.

Bu çalışma, YZ ve DÖ'nün sağlık bilişimine etkilerini literatür temelli bir yaklaşımla incelemektedir. Tarihsel gelişimden başlayarak dijitalleşme, büyük veri, ESK, KKDS ve YZ uygulamaları kapsamlı biçimde değerlendirilmekte; klinik örneklerle somutlaştırılmaktadır. Ayrıca etik ve yasal düzenlemelerin gerekliliği vurgulanmaktadır. Makale beş bölümden oluşmakta; ilk bölümde sağlık bilişiminin tanımı ve çok disiplinli gelişimi, ikinci bölümde dijitalleşme ve büyük verinin rolü, üçüncüde ESK ve KKDS'lerin YZ ile entegrasyonu ele alınmaktadır. Dördüncü bölümde YZ ve DÖ'nün klinik uygulamalardaki etkisi, son bölümde ise etik ve veri güvenliği sorunları tartışılmaktadır. Bu çalışma, sağlık bilişimi ile YZ'nin kesişiminde çalışan araştırmacılara, klinisyenlere ve karar alıcılara kapsamlı bir analiz sunmayı; aynı zamanda insan odaklı ve

sürdürülebilir bir sağlık sistemi inşasına katkıda bulunmayı amaçlamaktadır.

Sağlık Bilişimi: Tanımı ve Gelişimi

Elektronik dijital bilgisayarların tıpta ilk kullanımı, 1950'lerin sonlarında biyomühendislik alanındaki akademik çalışmalarda yer almaya başlamıştır. Bu dönemde "biyomühendislik", biyoloji ile mühendisliğin çeşitli yönlerini kapsayan geniş bir kavram olarak kullanılmıştır. İzleyen yirmi yıl boyunca, bu gelişen alan için "elektronik veri işleme", "otomatik veri işleme", "tıbbi bilişim", "tıbbi bilgisayar bilimi", "bilgisayar tıbbı" gibi farklı terimler kullanılmış; çoğu zaman bu terimler birbiriyle dönüşümlü olarak tercih edilmiştir. Örneğin "tıbbi bilgi bilimi" ile "tıbbi bilgisayar bilimi", bilgi işleme süreçlerini farklı perspektiflerden tanımlamak amacıyla benzer biçimde değerlendirilmiştir (1).

Bilişim; insan, bilgi ve teknolojinin kesişiminde yer alan bir disiplindir. Türk Dil Kurumu (2024), bilişimi "bilginin, özellikle elektronik araçlarla sistematik ve mantıklı biçimde işlenmesini inceleyen bilim dalı" olarak tanımlar. Kavram, 1957'de Karl Steinbuch (Almanya) veya 1962'de Philippe Dreyfus (Fransa) tarafından literatüre

kazandırılmıştır. Avrupa'da başlangıçta hesaplama problemlerine odaklanan bu kavram, bugünkü "sağlık bilişimi" anlayışından farklılık göstermektedir. "Sağlık bilişimi" terimi ilk kez 1973'te, "tıbbi bilişim" ise 1974'te literatürde kullanılmaya başlanmıştır (2).

1970'lerin başında ortak bir terminoloji ihtiyacı doğmuş; bazı uzmanlar yalnızca hastalık tedavisini değil, sağlığın korunmasını da kapsadığı gerekçesiyle "sağlık" terimini tercih etmiştir (1). 2000'li yıllarda disiplinin kapsamı genişledikçe "tıbbi bilişim" yaygınlaşmış; biyoinformatiğin etkisiyle "sağlık bilişimi" ve "sağlık hizmetleri bilişimi" ifadeleri, sadece hekimleri değil tüm sağlık ve yaşam bilimleri profesyonellerini içerecek şekilde öne çıkmıştır (3).


Sağlık bilişimi, tıp, bilgisayar bilimleri ve sağlık kurumları gibi veri yoğun alanların kesişiminde konumlanır. Coiera, bu alanı sağlık hizmetlerinin mantığı olarak tanımlarken; ABD Sağlık Bakanlığı, sağlık bilişimini bilgi teknolojileri tabanlı yeniliklerin tasarımı, uygulanması ve benimsenmesini konu alan disiplinler arası bir alan olarak tarif etmektedir (4).

Dijitalleşmenin ivme kazanması ve veri kaynaklarının çeşitlenmesiyle, bilgi işlem altyapıları sağlıkta bilgi tabanlı sistemlerin kullanımını yaygınlaştırmıştır. Yapay zekâ, makine öğrenmesi, büyük veri analitiği, tele-sağlık, robotik uygulamalar ve siber güvenlik gibi teknolojiler, klinik ve operasyonel süreçleri dönüştürmektedir. Hemşirelik, radyoloji, görüntüleme bilişimi, tüketici sağlık sistemleri ve terminoloji yönetimi gibi alt alanlar bu dönüşümden doğrudan etkilenmektedir. PACS ve dijital görüntüleme sistemleri tanı süreçlerini hızlandırırken, operasyonel ve finansal bilgi sistemleri kurumların verimliliğini artırmakta; simülasyon temelli eğitim

araçları ise sağlık çalışanlarının gelişimine katkı sunmaktadır.

YZ, büyük veri ve klinik karar destek sistemlerinin entegrasyonu, hekimlere daha hızlı ve doğru kararlar alma imkânı tanımakta; böylece mekân ve zamana bağlı sınırlamalar aşılırken maliyetler azalmakta ve hasta memnuniyeti artmaktadır (5).


Bu kapsamda, sağlık bilişimiyle ilgili akademik çıktıların nicel düzeyde değerlendirilmesi önem arz etmektedir. Bu nedenle “sağlık bilişimi”, “dijital sağlık”, “tıp bilişimi”, “sağlık bilgi sistemleri” ve “biyomedikal bilişim” anahtar kavramları çerçevesinde Scopus veri tabanındaki bulgular analiz edilmiştir.




Grafik 1: Scopus Veri Tabanında Sağlık Bilişimi ile İlgili Yapılmış 1962-2024 Yıllar Arası Çalışmaların Sayısı

Grafik 1’de gösterildiği gibi 1962-2024 yılları arasında yukarıda ifade edilen anahtar kelimeler kullanılarak toplam 70 bin 155 çalışmaya ulaşılmıştır. Bu çalışmaların ağırlıklı kısmı son yirmi yılda yapılmıştır. Özellikle 2019 yılından sonra çok yoğun bir şekilde bu alanda akademik yayın yapılmıştır. Grafik 2 ve 3’te alan bazlı olarak

bakıldığında yapılmış çalışmaların %43,6 Tıp alanında olduğu görülmektedir. Yaklaşık %11,6 Mühendislik ve %11,0 Sağlık Profesyonelleri alanlarında yapılmıştır. Ayrıca Bilgisayar Bilimleri, Sosyal Bilimler, Hemşirelik ve Biyokimya, Genetik ve Moleküler Biyoloji alanlarında çalışmaların yapıldığı gösterilmektedir.




Grafik 2: Scopus Veri Tabanında 1962-2024 Yılları Arasında Sağlık Bilişimi Alan Bazlı Gösterimi



Grafik 3: Scopus Veri Tabanında 1962-2024 Yılları Arasında Sağlık Bilişimi Alan Bazlı Gösterimi

Akademik literatür, sağlık ve tıp alanı için bu kadar yaygın kabul gören ve gelişen Sağlık Bilişimi alanını Web of Science'ta da incelemiştir. Web of Science (WoS) veri tabanında 1980-2025 yılları arasında "sağlık bilişimi", "dijital sağlık", "tıp bilişimi", "sağlık bilgi sistemleri" veya "biyomedikal bilişim" gibi anahtar kelimeleri

aratıldığında, yaklaşık 24 bin 503 akademik araştırmanın bulunduğu ve 1980 yılında 5 ilk çalışmanın yayınlandığı görülmüştür. 2017 yılında konuyla ilgili 1084 akademik makale yayınlanırken, takip eden yıllarda yaklaşık dört kat artmıştır.



Grafik 4. Sağlık Bilişimi Araştırma Alanının Web of Science Analizi (1980-2025)

Dijitalleşme ve Büyük Veri Analitiği

Sağlık kuruluşları, sağlık hizmetlerinin kalitesini artırmak ve erişilebilirliği geliştirmek amacıyla büyük veri çözümlerinden faydalanmaktadır. Geniş ve karmaşık veri kümelerinin analizi, genellikle “büyük veri analitiği” olarak adlandırılır ve hasta

bakım standartlarını yükseltmede kritik rol oynar (6). Gartner, büyük veriyi; “gelişmiş içgörü ve karar alma için uygun maliyetli ve yenilikçi bilgi işleme biçimleri gerektiren, yüksek hacimli, hızlı ve çeşitli bilgi varlıkları” olarak tanımlamaktadır (7). Son yıllarda dijital sağlık verilerinde ciddi bir

artış yaşanmıştır. Bu artış, yalnızca yeni tıbbi gelişmelere değil, aynı zamanda giyilebilir teknolojiler, mobil uygulamalar ve sensörler gibi araçların yaygınlaşmasına da dayanmaktadır. Bu teknolojiler, Elektronik Sağlık Kayıtları (ESK) ve Kişisel Sağlık Kayıtları gibi kaynaklardan büyük miktarda veri üretimini mümkün kılmıştır. ESK'ler; muayene notları, laboratuvar sonuçları ve reçeteler gibi sağlık profesyonellerine ait verileri içerirken, Kişisel Sağlık Kayıtları bireyin tıbbi geçmişine ilişkin bilgileri kapsar (6).

Sağlık hizmetlerinde büyük veri yaşam döngüsü; verinin toplanması, güvenli biçimde depolanması, işlenmesi ve anlamlı içgörülere dönüştürülerek hasta sonuçlarını iyileştirecek şekilde analiz edilmesini içeren çok aşamalı ve dikkatli planlama gerektiren bir süreçtir (8).

Büyük Veri Analitiği; makine öğrenmesi, veri madenciliği ve tahmine dayalı analiz gibi yöntemleri içeren, veriyle ilişkili zorlukları aşmaya yönelik bir teknoloji ve yöntemler bütünüdür. Sağlık hizmetlerinde bu yaklaşımlar, veriden anlamlı içgörüler üretmeyi ve karar süreçlerini iyileştirmeyi amaçlamaktadır. Literatürde

genellikle İngilizce altı “V” kavramına atıf yapılır (10):

- Hacim (Volume): Sağlık alanında toplanan büyük miktardaki veriyi ifade eder.
- Çeşitlilik (Variety): Yapılandırılmış, yapılandırılmamış ve yarı yapılandırılmış verilerin çeşitliliğini yansıtır.
- Hız (Velocity): Verinin üretilme, aktarılma ve işlenme hızını belirtir, gerçek zamanlı veri akışına vurgu yapar.
- Doğruluk (Veracity): Verilerin güvenilirliği, tutarlılığı ve kalitesini tanımlar.
- Değer (Value): Verilerden elde edilen bilgi ve içgörünün sağlık hizmetlerine katkısını temsil eder.
- Değişkenlik (Variability): Zaman içinde verinin gösterdiği değişken yapıyı ifade eder.

Bu altı boyut, sağlık hizmetlerinde büyük veriyi anlamak ve etkin şekilde yönetmek için bir çerçeve sunar. Genel olarak, sağlık bilişiminde büyük veri; karmaşık, geniş ve çeşitlilik arz eden veri kümelerini analiz etmeye yönelik yöntem ve araçların bütünüdür. Bu teknolojilerin sunduğu başlıca avantajlar arasında, zamanında ve etkili hasta tedavisi, bireyselleştirilmiş bakım sunumu ve

tüm sağlık sisteminin -yöneticiler, sağlayıcılar, ödeme yapanlar ve hastalar-faydalananabileceği yapılar oluşturması yer almaktadır (6).

Elektronik Sağlık Kayıtları ve Karar Destek Sistemleri

Elektronik Sağlık Kayıtları (ESK), hasta bilgilerini dijital ortamda depolamak, yönetmek ve paylaşmak amacıyla geliştirilen sistemlerdir ve sağlık hizmetlerinin sunum biçiminde köklü değişiklikler yaratmıştır (11). ESK'ler; hastanın geçmiş tıbbi verileri, tanı, tedavi bilgileri, laboratuvar sonuçları, reçeteler ve sevk notlarını içeren temel verileri barındırır (10). Bu veriler, yapılandırılmış, yarı yapılandırılmış veya yapılandırılmamış biçimlerde olabilir (12,13). ESK'lerin etkili biçimde kullanımı, klinik karar destek sistemlerinin geliştirilmesine zemin hazırlar.

Hastane Bilgi Sistemleri (HBS), yalnızca hasta bakımını değil; aynı zamanda idari, finansal ve stratejik işleyişi de destekleyen entegre sistemlerdir (14). Hastanelerin karmaşık yapısı nedeniyle tanı, yönetim ve eğitim süreçlerinde bu sistemlere büyük oranda bağımlı oldukları görülmektedir (15). HBS'ler; klinik bilgi sistemleri, mali-idari

sistemler ve stratejik karar destek modülleri olmak üzere üç temel bileşene ayrılır (16).

Karar Destek Sistemleri (KDS), kullanıcılara bilgiye dayalı öneri, uyarı ve hatırlatmalar sunarak karar alma süreçlerine destek olur. Bu sistemler; veri ambarları, iş zekâsı araçları, çevrimiçi analiz çözümleri ve bireysel-karar destek unsurlarını içerir (17). Geleneksel KDS'ler uzman görüşlerine ve klinik kılavuzlara dayanırken, yapay zekâ tabanlı sistemler istatistiksel modelleme ve desen tanıma yöntemlerini esas alır (18). Derin öğrenme algoritmalarındaki ilerleme ve artan işlem kapasitesi, sağlık alanında YZ uygulamalarına olan ilgiyi artırmış; kamu ve özel sektör yatırımlarını teşvik etmiştir (19).

Bununla birlikte YZ destekli KDS'ler daha çok klinik ve operasyonel süreçlerde kullanılmaktadır. 1997-2018 yılları arasında yayımlanan 3.397 yayını inceleyen bir araştırmada derinlemesine analiz edilen 80 çalışmada, Yapay Sinir Ağlarının (YSA) mikro düzeyde yoğun biçimde kullanıldığı; mezzo ve makro düzeylerde ise sınırlı kaldığı tespit edilmiştir (20).

Klinik Karar Destek Sistemleri (KKDS) ve ESK'ler, karar alma süreçlerini bilgisayar destekli

araçlarla kolaylaştırarak sağlık bakımının kalitesini artırmayı hedefler (15,21,22). KKDS'lerin başarısı; klinik sorunun karmaşıklığı, sistemin görevle uyumu, kullanıcı güveni, veri doğruluğu, modelin genellenebilirliği ve klinik onay süreçlerine bağlıdır (18).

Makine öğrenmesi (ML) destekli KKDS uygulamaları, sağlık çalışanlarına hasta sonuçlarını öngörme konusunda önemli avantajlar sağlar. Bu sistemler, çok sayıda veriye dayalı olarak kişiselleştirilmiş tedavi planları önererek hasta sonuçlarını iyileştirmeyi ve sağlık hizmeti maliyetlerini azaltmayı amaçlar (23).

Yapay Zekânın Tarihsel Gelişimi ve Temel Kavramlar

Yapay Zekâ (YZ), düşünme, muhakeme ve analiz gibi bilişsel süreçleri gerçekleştirebilen makineler geliştirmeyi amaçlayan hızla gelişen bir bilgisayar bilimi dalıdır (24). YZ tabanlı sistemler; görsel algı, desen tanıma, konuşma tanıma, veri analizi, dil çevirisi ve karar alma gibi insan zekâsı gerektiren görevleri yerine getirebilir (18).

YZ'nin gelişimi, Christopher Strachey'nin 1951'deki ilk YZ programıyla başlamış ve 1956'daki Dartmouth Konferansı'nda John

McCarthy tarafından "Yapay Zekâ" teriminin ortaya atılmasıyla ivme kazanmıştır. 1960 ve 1970'lerde kural tabanlı uzman sistemler öne çıkmış, ancak sınırlı veri ve işlem gücü nedeniyle gelişimi kısıtlı kalmıştır (25). Günümüzde ise YZ; klinik karar verme, görüntü analizi, doğal dil işleme (NLP) ve robotik cerrahi gibi birçok tıbbi alanda yaygın şekilde kullanılmaktadır. IBM Watson, ChatGPT, AlphaFold ve DALL·E gibi projeler bu dönüşümün önde gelen örnekleridir (24).

Sağlık verilerinin artması ve analitik tekniklerin gelişmesi, sağlık hizmetlerinde önemli bir paradigma değişimini beraberinde getirmiştir (26). Özellikle radyolojide görüntü analizi ve yorumlamaya dayalı veri odaklı yaklaşımlar, klinisyen destekli uygulamalarda umut verici sonuçlar sunmaktadır (27-29). YZ'nin tanısal radyoloji alanındaki yaygınlaşması, hasta bakım kalitesi ve verimliliğinde önemli artışlar sağlamaktadır (30). Örneğin, Nature Medicine'da yayımlanan 2025 tarihli bir çalışmada Almanya'daki ulusal mamografi tarama programında 463.094 kadının tarandığı ve YZ destekli değerlendirmede meme kanseri tespit

oranının 6.7/1.000 olduğu, bunun da geleneksel yönteme kıyasla %17,6 daha yüksek olduğu bulunmuştur (31). Ayrıca YZ'nin radyologların iş yükünü azaltma potansiyeline sahip olduğu da belirtilmiştir.

YZ'nin sağlık hizmetlerinde hastalık teşhisi, kişiselleştirilmiş tedavi, risk tahmini ve iş akışı yönetimi gibi alanlarda önemli dönüşümler sağladığı belirlenmiştir. Ayrıca robotik sistemler, rehabilitasyon ve cerrahi işlemlerin otomasyonunu kolaylaştırarak bakım kalitesini artırmaktadır (32).

Kanada'daki Humber River Hastanesi örneğinde olduğu gibi, ilaç siparişi ve dağıtım süreçlerinde yüksek teknoloji ve otomasyon sayesinde ilaç hataları %0,0001 oranına kadar düşürülmüştür (33).

Son on yılda giyilebilir cihazlar, tıbbi görüntüleme araçları, kişisel sağlık kayıtları ve kamu sağlığı verileri gibi birçok kaynaktan gelen veri miktarında ciddi artış yaşanmıştır. Bu verilerin işlenmesi, bulut bilişim ve gelişmiş donanımlar (GPU, FPGA, TPU) sayesinde daha etkili hâle gelmiştir. Bu gelişmeler doğrultusunda geliştirilen karmaşık YZ teknikleri, sağlık alanında daha doğru ve hızlı çözümler sunmaktadır (34). YZ'nin etkisi; tıbbi

görüntüleme ve tanı, COVID-19 erken teşhisi, sanal hasta bakımı, ESK yönetimi, hasta katılımı, tedaviye uyum, sağlık çalışanlarının iş yükünün azaltılması, yeni ilaç ve aşı geliştirme, reçete hatalarının önlenmesi ve teknoloji destekli rehabilitasyon gibi çok sayıda alanda gözlemlenmektedir (35).

Makine Öğrenmesi: Sağlıkta Uyum ve Potansiyel

Dijital görüntüleme ve depolama tekniklerinin hızla yayılmasıyla, görüntülerin bilgisayar programlarıyla yorumlanması makine öğrenimi ve uygulamalı araştırmalarda önemli bir ilgi alanı haline gelmiştir (36). Makine öğrenimi, YZ'nin bir alt dalı olarak, algoritmaların verilerdeki örüntülerden tahmin modelleri oluşturmasını sağlar. Temelde, istatistiksel modellerin bilgisayarla verilere uygulanmasıdır. Tıp alanında ise makine öğrenimi, geleneksel istatistik tekniklerinden daha geniş bir yöntem yelpazesi kullanır (37).

Bir çalışmada altı farklı makine öğrenimi yönteminin beş yıllık sağkalım tahminleri incelenmiş ve yüksek performansları sayesinde hem hassas tahmin yapabildikleri hem de hastaya

uygun tedavi önerileri sunabildikleri tespit edilmiştir (38). Başlangıçta sağlık hizmetlerinde YZ, uzman tıbbi bilgi ve katı karar kurallarına dayanırken, günümüzde makine öğrenimi teknikleri karmaşık ilişkileri analiz ederek sağlık verilerini anlamada etkin olarak kullanılmaktadır (33, 39).

Derin Öğrenme: Klinik Verilerin Yeni Yorumu

Bir yükselişi temsil eden diğer bir yapay zeka teknolojisi, çok katmanlı sinir ağlarını içeren makine öğreniminin bir alt dalı olan derin öğrenme modelleridir; bu nedenle "derin" terimi buradan gelir (40). Derin öğrenme, insan beyninin karmaşık karar verme süreçlerini modellemek için çok katmanlı yapay sinir ağlarına dayanan bir makine öğrenimi yöntemidir (41, 42). Yapay Sinir Ağları, derin öğrenmenin temel yapıtaşları olup, büyük veri setlerinden öğrenme kapasitesine sahiptir (43, 44). Bu ağlar, ileri ve geri yayılma olarak adlandırılan süreçlerle tahmin veya sınıflandırma görevlerini adım adım iyileştiren çok sayıda düğümden oluşan katmanlı yapılardır (45). Derin öğrenme modelleri, özellikle ham klinik zaman serisi verileri gibi girdi özniteliklerini kullanırken, diğer yöntemlerden üstün performans sergiler (10).

Geleneksel makine öğrenimi algoritmaları genellikle etiketlenmiş ve biçimlendirilmiş verilere dayanırken, derin öğrenme ham ve yapılandırılmamış verileri işleyebilme yeteneğine sahiptir (46, 47). Bu özellikler, derin öğrenmeyi son derece uyarlanabilir ve güçlü kılar (48). Bu nedenle derin öğrenme, sağlık hizmetleri dahil birçok sektörde yaygın olarak uygulanmış ve hasta bakımını ve hastane protokollerini önemli ölçüde iyileştirmiştir (49, 50).

Klinik Karar Destek Sistemlerinde Derin Öğrenmenin Rolü

Derin öğrenme teknolojileri, özellikle sağlık hizmetlerinde elektronik sağlık kayıtları (ESK) ve diğer ilgili sağlık verilerinin işlenmesinde yaygın şekilde kullanılmaktadır. Bu teknoloji, insan zekasının algılayamadığı örüntü ve eğilimleri tanıyarak tanı, teşhis ve tedavi süreçlerini geliştirme yeteneğine sahiptir (24). Klinik gözlemler, laboratuvar raporları ve görüntüleme testleri gibi hastaya ait veriler, derin öğrenme algoritmaları tarafından analiz edilebilmektedir (49, 51). Böylece sağlık bilişiminde yapay zekanın uygulanması, kanıta dayalı önerilerle klinik karar verme süreçlerini kolaylaştırmaktadır (52, 53).

Derin öğrenmenin sağlık alanındaki en önemli uygulama alanlarından biri tıbbi görüntülemedir (54, 55). Konvolüsyonel sinir ağları (CNN), röntgen, MRI ve BT gibi tıbbi görüntülerin işlenmesinde oldukça etkilidir (56, 57). Bu modeller, anormallikleri yüksek doğrulukla tespit edebilmekte ve insan uzmanlara yakın performans sergilemektedir (31). Örneğin, derin öğrenme diyabetik retinopati, erken evre Alzheimer hastalığı (58) ve meme kanseri gibi hastalıkların tespitinde başarıyla kullanılmaktadır (55). Ayrıca, derin öğrenme otomatik görüntü işleme sayesinde radyologlar ve patologların iş yükünü azaltarak daha karmaşık vakalara odaklanmalarını sağlar ve teşhis verimliliğini artırır (31, 59).

Derin öğrenme modelleri, geçmiş hasta verilerini analiz ederek hastalıkların seyrini ve hasta sonuçlarını tahmin edebilir, böylece erken müdahale ve önlem imkanı sağlar. Örneğin, yapay zeka tabanlı öngörücü modeller, diyabet ve kardiyovasküler hastalıklar gibi kronik hastalık riskine sahip hastaları belirleyerek klinisyenlere önleyici tedbirler konusunda önerilerde bulunabilir (60, 61). Ayrıca derin öğrenme, her hastanın genetik verilerini çözümleyerek tedavilerin

kişiselleştirilmesinde kullanılmakta; bu sayede tedavi etkinliği artırılırken yan etkiler en aza indirilmektedir (62, 63).

Sağlık bilişiminde derin öğrenmenin kullanımı, sağlık hizmetlerinde önemli bir dönüşüm yaratmaktadır. Derin sinir ağlarının gücünden faydalanan sağlık kuruluşları, tanı doğruluğunu artırabilir, operasyonel süreçleri iyileştirebilir ve hasta merkezli bakım sunabilir. Teknolojideki hızlı gelişmelerle birlikte, bu uygulamaların yaygınlaşması ve hastalar için daha iyi sonuçlar sağlaması beklenmektedir. Ancak, sağlık alanında yapay zekanın tam potansiyeline ulaşabilmesi için sağlık çalışanları ve araştırmacılar arasında daha fazla işbirliği gerekmektedir. Çünkü yapay zekanın sağlık hizmetlerine entegrasyonu, hastalık teşhisinden tedavi seçimine kadar pek çok alanda önemli iyileştirmeler sunma potansiyeline sahiptir (24).


Sağlık Yönetimi ve Yapay Zekâ Entegrasyonu

Sağlık yönetimi, sağlık hizmetlerinin planlanması, organize edilmesi, yönetilmesi ve değerlendirilmesini kapsayan disiplinler arası bir alandır. Temel amacı, sağlık hizmetlerinin kalitesini artırırken maliyetleri azaltmak ve hasta

sonuçlarını iyileştirmektedir. Bu hedeflere ulaşmada yapay zekâ (YZ) teknolojilerinin entegrasyonu, klinik süreçlerden operasyonel işleyişe kadar birçok alanda önemli iyileşmeler sağlamaktadır. Günümüzde sağlık yönetimi, dijitalleşme ve teknolojik gelişmelerle birlikte köklü bir dönüşüm sürecindedir.

Bu dönüşümün temel nedenlerinden biri, sağlık bilgi sistemleri aracılığıyla elde edilen verilerin süreklilik arz eden ve kapsamlı biçimde kayıt altına alınmasıdır. Özellikle modern sağlık kurumları, sundukları dijital altyapı sayesinde büyük miktarda veri üretmekte ve adeta birer veri deposu işlevi görmektedir. Bu bağlamda sıklıkla “veri bu çağın yeni petrolüdür” (64) şeklinde tanımlamalar yapılmaktadır. Verinin bu stratejik önemi, sağlık

hizmetlerinin daha etkin planlanması, hızlı organize edilmesi ve verimli şekilde yönetilmesi açısından anlamlıdır. Sağlık sistemlerinde biriken verilerden anlamlı ve güvenilir sonuçlar elde edebilmek, ancak YZ’nin gelişmiş analiz, modelleme ve yorumlama kapasitesiyle mümkün olmaktadır. Zira YZ temelde veri odaklı çalışan bir teknolojidir. YZ, özellikle tanı koyma ve klinik karar destek süreçlerinde büyük veri setlerini analiz ederek sağlık hizmetlerinin yeniden yapılandırılmasına katkı sunmaktadır. Bu yetenek, YZ’nin gelecekte sağlık sistemleri üzerinde dönüştürücü bir etkiye sahip olacağını göstermektedir (65). Şekil 1’de bu bağlamda sağlık yönetimi ile YZ etkileşiminin yoğunlaştığı başlıca alanlar görselleştirilmiştir.



Şekil 1. Sağlık Yönetimi ve Yapay Zekâ

Sağlık yönetiminin temel hedeflerinden biri olan kaliteli sağlık hizmetine ulaşmak, yapay zekâ (YZ) teknolojileri sayesinde daha hızlı ve daha doğru biçimde mümkün hâle gelebilir. Çünkü sağlık hizmetlerinde kaliteyi düşüren birçok unsur, YZ uygulamalarıyla ortadan kaldırılabilir. Örneğin, hastanelerde hasta akışının YZ ile optimize edilmesi, hasta ve sağlık çalışanlarının bekleme sürelerini azaltarak süreçleri daha verimli hâle getirebilir. Ayrıca tanı, teşhis ve tedavi süreçlerinde YZ algoritmalarının kullanımı umut vadeden sonuçlar sunmaktadır. Bu konunun ayrıntıları üçüncü bölümde ele alınmıştır. Sağlık hizmetlerinin işleyişinde Klinik Karar Destek Sistemleri (KKDS) önemli bir rol oynamaktadır. YZ algoritmalarının bu sistemlere entegrasyonu sayesinde hasta verileri daha etkin biçimde analiz edilmekte ve tedavi kararlarında klinisyenlere yardımcı olunmaktadır. 2024 yılında gerçekleştirilen bir sistematik derleme çalışmasında, YZ'nin KKDS'lerde bilişsel bir yardımcı olarak görev yapabileceği, özellikle modern tıbbın karmaşıklıkları içinde klinisyenleri desteklediği sonucuna ulaşılmıştır. Aynı çalışmada, makine öğrenimi, doğal dil işleme (NLP) ve derin öğrenme gibi YZ tekniklerinin

KKDS'lerin kapasitesini ciddi ölçüde artırdığı ve büyük miktarda sağlık verisini yüksek hız ve doğrulukla işleyip yorumladığı belirtilmiştir (66). Sağlık hizmetlerinde önemi giderek artan kişiselleştirilmiş tıp, YZ teknolojileriyle desteklenerek hastaların genetik yapısı, yaşam tarzı ve tıbbi geçmişi gibi faktörlerin analizine dayalı bireysel tedavi planlarının oluşturulmasına katkı sağlamaktadır. Özellikle üretken YZ, tanı doğruluğunu artırmak ve kişiselleştirilmiş tedavi planları geliştirmek amacıyla yüksek kaliteli sentetik veriler üretme kapasitesine sahiptir (67). Üretken YZ, eğitilmiş parametrelerden yeni içerikler oluşturabilen modeller olarak tanımlanır (68). Bu alanda yapılan detaylı bir araştırmada, klinik ortamlarda kullanılan üretken YZ modelleri için bir değerlendirme kontrol listesi dahi oluşturulmuştur (69). YZ'nin sağlık hizmetlerinin sunumunu optimize etme kapasitesi oldukça dikkat çekicidir. Tahmine dayalı analitik yöntemlerle hastane iş akışları iyileştirilebilir, hasta kabul oranları daha doğru tahmin edilebilir ve kaynak tahsisi daha etkin yapılabilir (70). Ayrıca, YZ algoritmaları radyolojik görüntülerde (MR, BT, röntgen) anormallikleri tespit etme konusunda giderek daha başarılı hale gelmektedir. Bunun yanı

sıra, maliyet tahminleri, sigorta süreçleri ve kaynak dağılımı kararlarında da YZ destekli sistemler yaygın olarak kullanılmaktadır.

YZ, sağlık sektöründe giderek artan bir öneme sahip olmakta ve daha kişiselleştirilmiş, verimli bakımın sunulmasına katkı sağlamaktadır. Sağlık çalışanlarının karar alma süreçlerini desteklemenin yanı sıra, hastane yönetimi gibi idari işlevleri de kolaylaştırmaktadır. YZ, insan uzmanlığının yerini almak yerine onu tamamlayıcı bir rol üstlenmekte; adeta bir asistan gibi çalışarak sağlık profesyonellerine daha doğru bilgi ve zaman kazandırmaktadır. Gelecekte bu iş birliğinin daha da güçlenmesi ve hasta bakımında yeni bir dönemin başlaması öngörülmektedir.

Günümüzde birçok sağlık kurumu, hasta bakımını iyileştirmek amacıyla YZ teknolojilerinden yararlanmaktadır. Örneğin, Mayo Clinic, ciddi komplikasyon riski taşıyan hastaları belirlemek için tahmine dayalı analizlerde YZ kullanırken, Cleveland Clinic, hasta iletişimini ve katılımını artırmak amacıyla YZ tabanlı sohbet robotları uygulamaktadır. Bu örnekler, YZ'nin yalnızca teknoloji şirketlerine değil, aynı zamanda hasta sonuçlarını ve hizmet verimliliğini artırmak isteyen

sağlık kuruluşlarının stratejilerine de entegre edildiğini göstermektedir (71).

Öte yandan, YZ teknolojilerinin sağlık yönetiminde yaygınlaşmasıyla birlikte veri gizliliği, algoritmaların şeffaflığı, etik ilkeler ve insan denetimi gibi hususlar da önem kazanmaktadır. Bu çerçevede, gelecekteki sağlık yönetimi anlayışının, insan uzmanlığı ile YZ teknolojilerinin entegre biçimde çalıştığı hibrit modeller etrafında şekilleneceği öngörülmektedir.

Etik Kaygılar ve Veri Güvenliği

Makine öğrenimi (ML) ve derin öğrenme (DL), sağlık hizmetlerinde büyük verilerin işlenmesinde geleneksel biyoistatistiksel yöntemlere kıyasla daha uyarlanabilir ve ölçeklenebilir çözümler sunmaktadır (72, 73). Bu teknolojiler; risk sınıflandırması, teşhis, prognoz ve tedavi planlaması gibi birçok alanda kullanılabilmekte, demografik verilerden laboratuvar sonuçlarına, görüntüleme verilerinden serbest metin klinik notlara kadar farklı veri türlerini analiz edebilmektedir ancak ML ve DL sistemlerinin sağlık alanında uygulanması, yalnızca teknik değil aynı zamanda etik ve pratik zorluklar da içermektedir. Veri gizliliği ve güvenliği, bu

sistemleri kullanacak sağlık profesyonellerinin yetkinliği ve adli süreçlerde kullanıma ilişkin belirsizlikler, başlıca kaygılar arasındadır. Bu nedenle ML ve DL teknolojilerinin etkili şekilde sağlık hizmetlerine entegre edilebilmesi için teknik yeterlilikle birlikte etik bir yaklaşım da zorunludur (35, 74, 75).

YZ tabanlı gelişmiş analitik teknikler sağlık hizmetlerini iyileştirme potansiyeline sahip olsa da bu teknolojilerin kullanımı önemli güvenlik ve etik endişeler doğurmaktadır. Halihazırda YZ'nin sağlık hizmetlerinde geliştirilmesi ve uygulanmasına yönelik uluslararası düzeyde kabul görmüş bir yönetim mekanizması (politika, etik standart, değerlendirme ve düzenleme çerçevesi) bulunmamaktadır. Bu eksiklik, teknik ve sosyal düzeyde zorluklar yarattığı gibi, pazar rekabetini de olumsuz etkileyebilmektedir (76).

Hasta perspektifinden bakıldığında, YZ'nin sağlıkta kullanımına ilişkin heyecan kadar kaygılar da söz konusudur. On beş odak grubuyla yapılan bir çalışmada, hastaların özellikle YZ'nin güvenliği, hasta seçimindeki etkisi, maliyet artışları, veri önyargısı ve veri güvenliği gibi konulara dair endişeleri olduğu tespit edilmiştir

(77). Bu nedenle, etik ilkelere dayalı stratejiler geliştirilmesi, YZ'nin sağlık alanında güvenli ve kabul edilebilir biçimde kullanılabilmesi için gereklidir.

Veri temelli yaklaşımların sağlık sektöründe yaygınlaşmasıyla birlikte, sağlık bilişimi alanında etik meseleler daha da ön plana çıkmaktadır. Sorumlu YZ uygulamaları için veri kalitesi, algoritma yorumlanabilirliği, önyargılar ve düzenleyici çerçeveler gibi temel sorunların ele alınması gerekmektedir. Etik ve etkili bir YZ entegrasyonu için güçlü yasal çerçeveler, insan-YZ iş birliği, güvenlik testleri, kullanıcı eğitimi ve düzenleyici denetim ön plana çıkan ihtiyaçlardır (32).

Özellikle çok modlu sağlık verilerinin analizi, veri dengesizlikleri, eksik temsil ve önyargılı veri etiketleme gibi nedenlerle etik sorunlara yol açabilir. Bu durum, sonuçların adil ve eşitlikçi olmasını tehlikeye atmaktadır. Araştırmacılar, çok modlu verilerdeki önyargıları tespit etmek ve azaltmak için sağlam yöntemler geliştirerek, veri toplama süreçlerini eleştirel biçimde değerlendirmelidir. Ayrıca analiz süreçlerinde şeffaflık sağlanmalı, veri kaynakları, ön işleme

yöntemleri ve modelleme tercihleri açıkça belgelenmeli; algoritma çıktıları için anlaşılır açıklamalar sunulmalıdır. Bu etik yaklaşımlar, tarafsız ve güvenilir YZ sistemlerinin geliştirilmesine katkı sağlayarak, tüm paydaşlar için adil sağlık hizmeti sunumunu destekleyecektir (35).

YZ'nin sağlık alanında kullanımına dair yapılan sistematik bir derleme çalışmasında, etik engellerin uygulamayı sınırlayan önemli faktörler arasında yer aldığı belirtilmiştir. İncelenen 39 çalışmada en çok öne çıkan etik kaygılar; mahremiyet, güven, bilgilendirilmiş onam ve çıkar çatışmaları olmuştur (78).

SONUÇ

Yapay zekâ (YZ) ve derin öğrenme (DÖ) teknolojileri, sağlık bilişimi alanında köklü bir dönüşüm başlatmıştır. Bu çalışma, literatür temelli bir inceleme ile bu teknolojilerin sağlık hizmetlerinin sunumu, yönetimi ve karar destek süreçlerine etkisini sistematik biçimde değerlendirmiştir. Bulgular, YZ ve DÖ'nün klinik teşhis doğruluğunu artırma, hasta bakımını kişiselleştirme, operasyonel verimliliği iyileştirme ve maliyet etkinliğini artırma gibi temel katkılar

sağladığını göstermektedir. Özellikle elektronik sağlık kayıtları (ESK), büyük veri analitiği ve klinik karar destek sistemleri (KKDS) gibi uygulamalar, hasta odaklı ve önleyici sağlık yaklaşımlarını desteklemektedir.

DÖ modellerinin tıbbi görüntülemelerde (örneğin meme kanseri taramalarında %17,6 daha yüksek tespit oranı) gösterdiği başarı, klinisyenlerin iş yükünü azaltırken teşhis doğruluğunu artırdığını ortaya koymaktadır. Makine öğrenmesi algoritmaları da kronik hastalık riski tahmini ve kişiselleştirilmiş tedavi planlamasında etkin biçimde kullanılmaktadır. Mayo Clinic ve Cleveland Clinic gibi kuruluşlarda YZ temelli uygulamaların başarıyla hayata geçirilmesi, bu teknolojilerin pratik faydasını somutlaştırmaktadır. Ancak, bu teknolojilerin yaygın kullanımı bazı engellerle karşı karşıyadır. Veri gizliliği, algoritmik önyargı, etik ikilemler ve düzenleyici belirsizlikler, YZ'nin sağlık sistemlerine entegrasyonunu zorlaştırmaktadır. Özellikle heterojen veri setlerinden kaynaklanan önyargılar, adaletli sonuçların önünde engel teşkil etmektedir. Ayrıca klinisyenlerin sistemlere duyduğu güven eksikliği ve algoritmaların yetersiz şeffaflığı,

benimsenme hızını yavaşlatmaktadır. Hastaların veri mahremiyeti konusundaki endişeleri ise dikkate alınması gereken önemli bir başka unsurdur. Bu zorlukların aşılabilmesi için disiplinler arası iş birliğine ihtiyaç vardır. Algoritmaların açıklanabilirliğini artırmaya yönelik yöntemlerin geliştirilmesi, temsili ve dengeli veri setlerinin kullanılması ve etik çerçevelerin standartlaştırılması, sorumlu YZ uygulamaları için kritik adımlardır. Ayrıca sağlık profesyonellerinin YZ konusunda eğitilmesi, insan-YZ iş birliğinin güçlendirilmesi ve politika yapıcıların sürece dahil edilerek küresel düzenlemelerin oluşturulması önem arz etmektedir. Sonuç olarak, YZ ve DÖ sağlık bilişimini dönüştürme potansiyeline sahip güçlü araçlardır. Ancak bu potansiyelin tam anlamıyla hayata geçirilebilmesi için teknik gelişmelerin etik ve toplumsal boyutlarla dengelenmesi gereklidir. Bilim insanları, klinisyenler ve karar vericiler arasında kurulacak ortaklıklar; adil, şeffaf ve insan merkezli bir YZ ekosisteminin inşasında belirleyici rol oynayacaktır. Bu süreçte teknolojik ilerlemenin insani değerlerle uyumlu hale getirilmesi, sağlık

bilişiminin geleceği açısından temel bir gerekliliktir.

KAYNAKLAR

1. Collen MF, Shortliffe EH. The creation of a new discipline. The History of Medical Informatics in the United States. 2015;75-120.
2. Hersh W. Health Informatics. 2022.
3. Demirhan A, Güler İ. Bilişim ve sağlık. Bilişim Teknolojileri Dergisi. 2011;4(3):13-20.
4. Coiera E. Guide to health informatics: CRC press; 2015.
5. Yang H-L, Hsiao S-L. Mechanisms of developing innovative IT-enabled services: A case study of Taiwanese healthcare service. Technovation. 2009;29(5):327-37.
6. Fang R, Pouyanfar S, Yang Y, Chen S-C, Iyengar S. Computational health informatics in the big data age: a survey. ACM Computing Surveys (CSUR). 2016;49(1):1-36.
7. Gartner I. Glossary: big data. Gartner Inc Available (accessed on 137 2017): <https://research.gartner.com/definition-what-is-bigdata>. 2014;1-8163325102.
8. Sukumar SR, Natarajan R, Ferrell RK. Quality of Big Data in health care. International journal of health care quality assurance. 2015;28(6):621-34.
9. Ahmad HF, Rafique W, Rasool RU, Alhumam A, Anwar Z, Qadir J. Leveraging 6G, extended reality, and IoT big data analytics for healthcare: A review. Computer Science Review. 2023;48:100558.
10. Ahmed A, Xi R, Hou M, Shah SA, Hameed S. Harnessing big data analytics for healthcare: A comprehensive review of frameworks, implications, applications, and impacts. IEEE Access. 2023.
11. Adhiya J, Barghi B, Azadeh-Fard N. Predicting the risk of hospital readmissions using a machine learning approach: a case study on patients undergoing skin procedures. Frontiers in Artificial Intelligence. 2024;6:1213378.
12. Johnson AE, Pollard TJ, Shen L, Lehman L-wH, Feng M, Ghassemi M, et al. MIMIC-III, a freely accessible critical care database. Scientific data. 2016;3(1):1-9.
13. Nuthakki S, Neela S, Gichoya JW, Purkayastha S. Natural language processing of MIMIC-III clinical notes for identifying diagnosis and procedures with neural networks. arXiv preprint arXiv:191212397. 2019.
14. Küçük F, Çelik Ö. Sağlık kurumlarında bilgi sistemleri ve e-hizmetler. : Nobel Yayıncılık.; 2023. 107-30 p.
15. Abdelaziz T, Rosa E. Electronic health records with decision support systems for sharper diagnoses: bibliometric analysis. International Journal of Advances in Applied Sciences. 2024;13.
16. Işık O, Akbolat M. Bilgi teknolojileri ve hastane bilgi sistemleri kullanımı: Sağlık çalışanları üzerine bir araştırma. Bilgi Dünyası. 2010;11(2):365-89.
17. Arnott D, Pervan G, Dodson G. Decision Support Systems Research 1990 to 2003: A Descriptive Analysis. 2004.
18. Cresswell K, Rigby M, Magrabi F, Scott P, Brender J, Craven CK, et al. The need to strengthen the evaluation of the impact of Artificial Intelligence-based decision support systems on healthcare provision. Health policy. 2023;136:104889.

19. Scott PJ, Brown AW, Adedeji T, Wyatt JC, Georgiou A, Eisenstein EL, Friedman CP. A review of measurement practice in studies of clinical decision support systems 1998–2017. *Journal of the American Medical Informatics Association*. 2019;26(10):1120-8.
20. Shahid N, Rappon T, Berta W. Applications of artificial neural networks in health care organizational decision-making: A scoping review. *PloS one*. 2019;14(2):e0212356.
21. Montani S, Striani M. Artificial intelligence in clinical decision support: a focused literature survey. *Yearbook of medical informatics*. 2019;28(01):120-7.
22. Osheroff JA, Teich J, Levick D, Saldana L, Velasco F, Sittig D, et al. Improving outcomes with clinical decision support: an implementer's guide: Himss Publishing; 2012.
23. Kim JT. Application of machine and deep learning algorithms in intelligent clinical decision support systems in healthcare. *J Health Med Inform*. 2018;9:321.
24. Alowais SA, Alghamdi SS, Alsuehaby N, Alqahtani T, Alshaya AI, Almohareb SN, et al. Revolutionizing healthcare: the role of artificial intelligence in clinical practice. *BMC medical education*. 2023;23(1):689.
25. McCorduck P, Cfe C. *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*: AK Peters/CRC Press; 2004.
26. Jiang F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. *Stroke and vascular neurology*. 2017;2(4).
27. Lau AY, Staccini P. Artificial intelligence in health: new opportunities, challenges, and practical implications. *Yearbook of medical informatics*. 2019;28(01):174-8.
28. Shaban-Nejad A, Michalowski M, Buckeridge DL. Health intelligence: how artificial intelligence transforms population and personalized health. *NPJ digital medicine*. 2018;1(1):53.
29. Ventola CL. Social media and health care professionals: benefits, risks, and best practices. *Pharmacy and therapeutics*. 2014;39(7):491.
30. Najjar R. Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*. 2023;13(17):2760.
31. Eisemann N, Bunk S, Mukama T, Baltus H, Elsner SA, Gomille T, et al. Nationwide real-world implementation of AI for cancer detection in population-based mammography screening. *Nature Medicine*. 2025:1-8.
32. Olawade DB, David-Olawade AC, Wada OZ, Asaolu AJ, Adereni T, Ling J. Artificial intelligence in healthcare delivery: Prospects and pitfalls. *Journal of Medicine, Surgery, and Public Health*. 2024;100108.
33. Dicuonzo G, Donofrio F, Fusco A, Shini M. Healthcare system: Moving forward with artificial intelligence. *Technovation*. 2023;120:102510.
34. Hayat Y, Tariq M, Hussain A, Tariq A, Rasool S. A Review of Biosensors and Artificial Intelligence in Healthcare and Their Clinical Significance. *International Research Journal of Economics and Management Studies IRJEMS*. 2024;3(1).
35. Al Kuwaiti A, Nazer K, Al-Reedy A, Al-Shehri S, Al-Muhanna A, Subbarayalu AV, et al. A review of the role of artificial intelligence in healthcare. *Journal of personalized medicine*. 2023;13(6):951.
36. Helaly HA, Badawy M, Haikal AY. A review of deep learning approaches in clinical and healthcare systems based on medical image analysis. *Multimedia Tools and Applications*. 2024;83(12):36039-80.
37. Panch T, Szolovits P, Atun R. Artificial intelligence, machine learning and health systems. *Journal of global health*. 2018;8(2).
38. Makond B, Wang K-J, Wang K-M. Benchmarking prognosis methods for survivability—A case study for patients with contingent primary cancers. *Computers in Biology and Medicine*. 2021;138:104888.
39. Deo RC. Machine learning in medicine. *Circulation*. 2015;132(20):1920-30.
40. Elhanashi A, Dini P, Saponara S, Zheng Q. TeleStroke: real-time stroke detection with federated learning and YOLOv8 on edge devices. *Journal of Real-Time Image Processing*. 2024;21(4):121.
41. Goodfellow I, Bengio Y, Courville A, Bengio Y. *Deep learning*: MIT press Cambridge; 2016.
42. LeCun Y, Bengio Y, Hinton G. Deep learning. *nature*. 2015;521(7553):436-44.
43. Nielsen MA. *Neural networks and deep learning*: Determination press San Francisco, CA, USA; 2015.
44. Schmidhuber J. Deep learning in neural networks: An overview. *Neural networks*. 2015;61:85-117.
45. Russell SJ, Norvig P. *Artificial intelligence: a modern approach*: pearson; 2016.
46. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, Thrun S. Dermatologist-level classification of skin cancer with deep neural networks. *nature*. 2017;542(7639):115-8.
47. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Medical image analysis*. 2017;42:60-88.
48. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. *Briefings in bioinformatics*. 2018;19(6):1236-46.
49. Rajkomar A, Oren E, Chen K, Dai AM, Hajaj N, Hardt M, et al. Scalable and accurate deep learning with electronic health records. *NPJ digital medicine*. 2018;1(1):18.
50. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nature medicine*. 2019;25(1):44-56.
51. Solares JRA, Raimondi FED, Zhu Y, Rahimian F, Canoy D, Tran J, et al. Deep learning for electronic health records: A comparative review of multiple deep neural architectures. *Journal of biomedical informatics*. 2020;101:103337.
52. Giordano C, Brennan M, Mohamed B, Rashidi P, Modave F, Tighe P. Accessing artificial intelligence for clinical decision-making. *Frontiers in digital health*. 2021;3:645232.
53. Secinaro S, Calandra D, Secinaro A, Muthurangu V, Biancone P. The role of artificial intelligence in healthcare: a structured literature review. *BMC medical informatics and decision making*. 2021;21:1-23.
54. Chen M, Wang Y, Wang Q, Shi J, Wang H, Ye Z, et al. Impact of human and artificial intelligence collaboration on workload reduction in medical image interpretation. *NPJ Digital Medicine*. 2024;7(1):349.
55. Khalifa M, Albadawy M. AI in diagnostic imaging: Revolutionising accuracy and efficiency. *Computer Methods and Programs in Biomedicine Update*. 2024;100146.
56. Sarvamangala D, Kulkarni RV. Convolutional neural networks in medical image understanding: a survey. *Evolutionary intelligence*. 2022;15(1):1-22.
57. Upreti M, Pandey C, Bist AS, Rawat B, Hardini M. Convolutional neural networks in medical image understanding. *Aptisi Transactions on Technopreneurship*. 2021;3(2):120-6.
58. Wang Y, Gao R, Wei T, Johnston L, Yuan X, Zhang Y, et al. Predicting long-term progression of Alzheimer's disease using a multimodal deep learning model incorporating interaction effects. *Journal of Translational Medicine*. 2024;22(1):265.
59. Montagnon E, Cerny M, Cadrin-Chênevert A, Hamilton V, Derennes T, Ilinca A, et al. Deep learning workflow in radiology: a primer. *Insights into imaging*. 2020;11:1-15.

60. Grout R, Gupta R, Bryant R, Elmahgoub MA, Li Y, Irfanullah K, et al. Predicting disease onset from electronic health records for population health management: a scalable and explainable Deep Learning approach. *Frontiers in Artificial Intelligence*. 2024;6:1287541.
61. Wang J, Zhu H, Wang S-H, Zhang Y-D. A review of deep learning on medical image analysis. *Mobile Networks and Applications*. 2021;26(1):351-80.
62. Taherdoost H, Ghofrani A. AI and the Evolution of Personalized Medicine in Pharmacogenomics. *Intelligent Pharmacy*. 2024.
63. Unger M, Kather JN. Deep learning in cancer genomics and histopathology. *Genome medicine*. 2024;16(1):44.
64. Humby C. Data is the New Oil. ANA Senior marketer's summit. Kellogg School. 2006.
65. Kastrop N, Holst-Kristensen AW, Valentin JB. Landscape and challenges in economic evaluations of artificial intelligence in healthcare: A systematic review of methodology. *BMC Digital Health*. 2024;2(1):1-12.
66. Elhaddad M, Hamam S. AI-driven clinical decision support systems: an ongoing pursuit of potential. *Cureus*. 2024;16(4).
67. Ghebrehiwet I, Zaki N, Damseh R, Mohamad MS. Revolutionizing personalized medicine with generative AI: a systematic review. *Artificial Intelligence Review*. 2024;57(5):128.
68. Raza MM, Venkatesh KP, Kvedar JC. Generative AI and large language models in health care: pathways to implementation. *npj Digital Medicine*. 2024;7(1):62.
69. Wornow M, Xu Y, Thapa R, Patel B, Steinberg E, Fleming S, et al. The shaky foundations of large language models and foundation models for electronic health records. *npj digital medicine*. 2023;6(1):135.
70. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future healthcare journal*. 2019;6(2):94-8.
71. Faiyazuddin M, Rahman SJQ, Anand G, Siddiqui RK, Mehta R, Khatib MN, et al. The Impact of Artificial Intelligence on Healthcare: A Comprehensive Review of Advancements in Diagnostics, Treatment, and Operational Efficiency. *Health Science Reports*. 2025;8(1):e70312.
72. Ngiam KY, Khor W. Big data and machine learning algorithms for health-care delivery. *The Lancet Oncology*. 2019;20(5):e262-e73.
73. Wainberg M, Merico D, DeLong A, Frey BJ. Deep learning in biomedicine. *Nature biotechnology*. 2018;36(9):829-38.
74. Amal S, Safarnejad L, Omiye JA, Ghanzouri I, Cabot JH, Ross EG. Use of multi-modal data and machine learning to improve cardiovascular disease care. *Frontiers in cardiovascular medicine*. 2022;9:840262.
75. Chen M, Hao Y, Hwang K, Wang L, Wang L. Disease prediction by machine learning over big data from healthcare communities. *Ieee Access*. 2017;5:8869-79.
76. Morley J, Murphy L, Mishra A, Joshi I, Karpathakis K. Governing data and artificial intelligence for health care: developing an international understanding. *JMIR formative research*. 2022;6(1):e31623.
77. Richardson JP, Smith C, Curtis S, Watson S, Zhu X, Barry B, Sharp RR. Patient apprehensions about the use of artificial intelligence in healthcare. *NPJ digital medicine*. 2021;4(1):140.
78. Ahmed MI, Spooner B, Isherwood J, Lane M, Orrock E, Dennison A. A systematic review of the barriers to the implementation of artificial intelligence in healthcare. *Cureus*. 2023;15(10).