

SAĞLIK BİLİMLERİNDE YAPAY ZEKÂ UYGULAMALARI: DİJİTAL SAĞLIK DÖNÜŞÜMÜNDE YENİ YAKLAŞIMLAR

Doç. Dr. Okan KOÇ¹

ÖZ

Sağlık sistemleri, yaşlanan nüfus, kronik hastalıkların artışı, yükselen sağlık maliyetleri ve artan hasta yükü gibi çok boyutlu sorunlarla karşı karşıyadır. Bu durum, sağlık hizmetlerinin daha verimli, sürdürülebilir ve hasta odaklı biçimde sunulabilmesi için dijital dönüşüm süreçlerini zorunlu hale getirmiştir. Yapay zekâ (YZ) teknolojileri, büyük veri analitiği, makine öğrenmesi ve derin öğrenme gibi yöntemler aracılığıyla sağlık hizmetlerinde önemli bir dönüşüm potansiyeli sunmaktadır. Bu çalışma, sağlık bilimlerinde yapay zekâ teknolojilerinin gelişimini ve sağlık hizmetlerindeki temel uygulama alanlarını incelemeyi amaçlamaktadır. Çalışma, anlatı derlemesi (narrative review) olarak tasarlanmış olup, ilgili literatür ProQuest, Scopus ve Google Scholar veri tabanları üzerinden taranmış; elde edilen bulgular içerik analizi yaklaşımıyla sentezlenmiştir. Çalışmada öncelikle sağlık hizmetlerinde dijital dönüşüm süreci ve akıllı hastane kavramı ele alınmış, ardından yapay zekânın kuramsal çerçevesi, tarihsel gelişimi ve sağlık alanındaki rolü değerlendirilmiştir. Araştırma kapsamında yapay zekânın özellikle tıbbi görüntüleme, klinik karar destek sistemleri, hastalık tahmini ve erken teşhis uygulamaları gibi alanlardaki kullanım örnekleri incelenmiştir. Koios DS, Caption Care, ExoAI, Sonio, Us2.ai, Qure.ai ve Infervision gibi yapay zekâ tabanlı sağlık teknolojileri, tanı doğruluğunu artırma, klinik iş akışlarını hızlandırma ve sağlık hizmetlerinin maliyet etkinliğini güçlendirme açısından önemli katkılar sunmaktadır. Bununla birlikte veri güvenliği, etik sorumluluk, algoritmik önyargı ve regülasyon eksikliği gibi sorunlar yapay zekâ uygulamalarının yaygınlaşmasında önemli tartışma alanları oluşturmaktadır. Sonuç olarak yapay zekâ, sağlık sistemlerinde tanı doğruluğunu artıran, klinik karar süreçlerini destekleyen ve dijital sağlık ekosisteminin gelişimine katkı sağlayan stratejik bir teknoloji olarak değerlendirilmektedir.

Anahtar Kelimeler: Yapay Zekâ, Sağlık Teknolojileri, Klinik Karar Destek Sistemleri, Tıbbi Görüntüleme, Dijital Sağlık

Jel Kodları: I11, O33, O31

¹Doç. Dr., Balıkesir Üniversitesi, okan.koc@balikesir.edu.tr, (ORCID: <https://orcid.org/0000-0002-5356-5940>)

ARTIFICIAL INTELLIGENCE APPLICATIONS IN HEALTH SCIENCES: NEW APPROACHES IN DIGITAL HEALTH TRANSFORMATION

ABSTRACT

Health systems face multifaceted challenges such as aging populations, the increasing prevalence of chronic diseases, rising healthcare costs, and growing patient demand. These pressures have made digital transformation processes essential for delivering healthcare services in a more efficient, sustainable, and patient-centered manner. Artificial intelligence (AI) technologies, through methods such as big data analytics, machine learning, and deep learning, offer significant transformative potential for healthcare services. This study aims to examine the development of artificial intelligence technologies in health sciences and their primary application areas in healthcare services. This study was designed as a narrative review. Relevant literature was searched through the ProQuest, Scopus, and Google Scholar databases, and the retrieved findings were synthesized using a content analysis approach. Within the scope of the study, the digital transformation process in healthcare and the concept of smart hospitals are first discussed. Subsequently, the conceptual framework of artificial intelligence, its historical development, and its role in healthcare are evaluated. The study further explores the use of artificial intelligence in areas such as medical imaging, clinical decision support systems, disease prediction, and early diagnosis applications. AI-based healthcare technologies such as Koios DS, Caption Care, ExoAI, Sonio, Us2.ai, Qure.ai, and Infervision contribute significantly to improving diagnostic accuracy, accelerating clinical workflows, and enhancing the cost-effectiveness of healthcare services. However, issues such as data security, ethical responsibility, algorithmic bias, and regulatory gaps remain important challenges for the widespread adoption of artificial intelligence applications. Consequently, artificial intelligence is considered a strategic technology that enhances diagnostic accuracy in healthcare systems, supports clinical decision-making processes, and contributes to the development of the digital health ecosystem.

Keywords: Artificial Intelligence, Health Technologies, Clinical Decision Support Systems, Medical Imaging, Digital Health

JEL Codes: I11, O33, O31

GİRİŞ

Dünya genelinde sağlık hizmeti sunucularında; yaşlanan nüfus, kronik hastalıkların artan yaygınlığı, yükselen sağlık maliyetleri, artan hasta sayıları ve tedavi seçeneklerinin karmaşıklığı gibi çok boyutlu ve baskılayıcı zorluklarla karşılaşmaktadır. Bu dinamikler, sağlık hizmeti sunumunda verimliliği, kaliteyi ve sürdürülebilirliği artırmak adına köklü bir inovasyon sürecini zorunlu kılmaktadır (Koning vd., 2019; Hussain vd., 2024). Bu bağlamda hastaneler, yalnızca belirli hastalıkların tedavi edildiği merkezler olmaktan çıkarak, hastanın genel sağlığının proaktif bir şekilde yönetildiği yapılar olma yolunda bir evrim geçirmekte; bu dönüşümün temelini ise dijital ve akıllı hastane modelleri oluşturmaktadır.

Sağlıkta dijital dönüşüm, bilgi ve iletişim teknolojilerinin (BİT) kullanımıyla bir organizasyonun yapısının, süreçlerinin ve stratejisinin temelden yeniden şekillendirilmesi olarak tanımlanmaktadır. Bu süreç, analog verilerin dijital formatlara dönüştürülmesini, operasyonel maliyetlerin azaltılmasını ve kurum içi fonksiyonlar arasındaki koordinasyonun güçlendirilmesini

amaçlayan kapsamlı bir dönüşümü ifade etmektedir. (Yao vd., 2011). Dijital dönüşüm, yalnızca yeni teknolojilerin edinilmesini değil, aynı zamanda bu teknolojilerin mevcut klinik ve idari süreçlere etkin bir şekilde entegre edilmesini, kanıta dayalı karar verme mekanizmalarının desteklenmesini ve hasta bakım kalitesinin artırılmasını da kapsamaktadır. Dijitalleşme yolculuğu, kaynaklardaki verilere göre üç temel aşamadan oluşan evrimsel bir çerçevede ele alınmaktadır. İlk aşama olan "Kurumsal Hazırlık Değerlendirmesi", organizasyonun bilişim altyapısının, dijital olgunluk seviyesinin, yönetim politikalarının ve kültürünün analiz edilmesini içermektedir (Agarwal vd., 2010; (Gopal vd., 2019; Klinker vd., 2020). Bu aşamada HIMSS EMRAM gibi modeller kullanılarak mevcut yetkinlikler ölçülmekte ve stratejik yol haritaları belirlenmektedir (Marques ve Ferreira, 2020; Stephanie ve Sharma, 2020). İkinci aşama olan "Dijital Hastane", süreçlerin kağıtsız bir yapıya taşınması, Elektronik Tıbbi Kayıtların (EMR) merkezi bir şekilde entegre edilmesi ve Görüntü Arşivleme ve İletişim Sistemleri (PACS) gibi temel altyapıların kurulması ile karakterize edilmektedir (Uslu vd., 2020; Krasuska vd., 2020). Dijital hastaneler, sağlık verilerinin erişilebilirliğini ve bütünlüğünü artırarak klinik hata oranlarının azaltılmasını, hasta güvenliğinin güçlendirilmesini ve sağlık hizmeti sunum süreçlerinin etkinlik ile verimliliğinin optimize edilmesini hedeflemektedir. Dönüşümün en gelişmiş evresi olan "Akıllı Hastane" ise dijitalleşmenin ötesine geçerek; Nesnelerin İnterneti (IoT), yapay zeka (AI), büyük veri analitiği, sensör teknolojileri ve bulut bilişim gibi ileri teknolojilerin otonom ve entegre bir şekilde kullanıldığı bir ekosistemi ifade etmektedir. Akıllı hastanelerde odak, epizodik tedavilerden sürekli bakıma, önleyici tıp uygulamalarına ve hasta katılımının en üst düzeye çıkarılmasına kaymaktadır. Bu yapılar; gerçek zamanlı hasta izleme, otonom iş akışları, akıllı lokasyon takip sistemleri (RFID/ZigBee) ve otonom karar destek sistemleri (CDSS) aracılığıyla hem operasyonel verimliliği hem de hasta güvenliğini en üst seviyeye taşımayı amaçlamaktadır (European Union Agency for Network and Information Security [ENISA], 2016; Dhariwal ve Mehta, 2017; Hu vd., 2022).

Ancak bu karmaşık dönüşüm süreci, çeşitli engelleri de beraberinde getirmektedir. Kaynaklar; teknoloji adaptasyonu ve sistemler arası birlikte çalışabilirlik sorunları, veri güvenliği ve gizliliğiyle ilgili endişeler, yüksek kurulum maliyetleri ve kurumsal değişim direnci gibi temel zorluklara dikkat çekmektedir (Kwon vd., 2022; Kaldoudi, 2023). Özellikle standart terminolojinin yetersizliği ve sağlık çalışanlarının dijital sağlık okuryazarlığı düzeyleri, akıllı sağlık sistemlerinin etkin bir şekilde uygulanması ve sürdürülebilir başarısının sağlanmasında belirleyici rol oynayan temel faktörler arasında yer almaktadır. Sonuç olarak, dijital ve akıllı hastane modellerine geçiş, modern sağlık hizmetlerinin sürdürülebilirliği için kaçınılmaz bir gereklilik haline gelmiştir. Başarılı bir dönüşüm, yalnızca teknolojik yatırımları değil; aynı zamanda organizasyonel stratejilerin, politikaların ve insan kaynağı yetkinliklerinin bu yeni dijital ekosisteme uyumlu hale getirilmesini gerektiren bütüncül bir yaklaşımı zorunlu kılmaktadır.

1. KAVRAMSAL ÇERÇEVE

1.1. YAPAY ZEKA NEDİR?

İnsanlık tarihi boyunca, belirli görevleri kendi kendine yerine getirebilen akıllı sistemlere ve makinelere yönelik ilgi sürekli varlığını sürdürmüştür. Bu ilginin bilimsel ve teknolojik gelişmeler doğrultusunda somut bir araştırma alanına dönüşmesiyle birlikte ortaya çıkan yapay zekâ (YZ) kavramı, günümüzde yalnızca teknik bir yenilik veya mühendislik uygulaması olarak değil, aynı zamanda kültürel dönüşümü şekillendiren, toplumsal yapıları etkileyen ve bireylerin günlük yaşam pratiklerine yön veren önemli bir olgu olarak değerlendirilmektedir. Bu doğrultuda yapay zekâ, yaşamın birçok alanında karar verme süreçlerini destekleyen, insan-makine etkileşimini yeniden tanımlayan ve dijital dönüşümün temel bileşenlerinden biri olarak kabul edilmektedir. Temelinde insan zekâsını taklit etme ve bu zekâyı ileri seviyelere taşıma hedefi yatan yapay zekâ; insan benzeri davranışlar sergileme, sayısal mantık yürütme, hareket etme, konuşma ve ses tanıma gibi çok boyutlu yeteneklere sahip yazılımsal ve donanımsal sistemler bütünü olarak tanımlanmaktadır (Rigla vd., 2017; Betancourt, 2020; Çilhoroz ve Işık, 2021; Wang vd., 2024). Akademik literatürde yaygın kabul gören bir diğer tanıma göre YZ, "bilgisayarların, insanlar tarafından yapıldığı takdirde zekâ gerektiren işleri yapma bilimi" olarak tanımlanmaktadır (Çilhoroz ve Işık, 2021). İnsan zekâsına özgü üst düzey bilişsel süreçlerin bilgisayar sistemleri tarafından gerçekleştirilmesini ifade etmektedir.

Yapay zekânın tarihsel gelişimi ve kuramsal çerçevesi incelendiğinde, kavramın 1950'lerden 1980'lere kadar güçlü ve zayıf yapay zekâ olmak üzere iki ana paradigma üzerinden tartışıldığı görülmektedir (Çilhoroz ve Işık, 2021). Güçlü yapay zekâ tezi, programlanmış bir bilgisayarın insanın yapabileceği her türlü entelektüel görevi yerine getirebileceğini savunurken; bu alandaki ilerlemenin kısıtlı kalması araştırmacıları zayıf yapay zekâ paradigmasına yönlendirmiştir. Zayıf yapay zekâ, zihnin bilgisayarda kopyalanmasından ziyade simüle edilmesine ve daha dar kapsamlı problemlerin çözümüne odaklanmaktadır. Kavramsal olarak YZ; uzman sistemler, doğal dil işleme, bulanık mantık, yapay sinir ağları, makine öğrenmesi ve derin öğrenme gibi heterojen araç ve algoritmaları bünyesinde barındıran şemsiye bir terimdir (Jarrahi, 2018). Roubal ve Narusevych (2025) ise bu teknolojik sürecin "gelişim" (development) ve "ilerleme" (advancement) kavramları arasındaki farka dikkat çekerek; gelişimin teknik bir süreç olduğunu, ilerlemenin ise bu teknolojinin toplumsal refah ve insani değerler üzerindeki ambivalent (ikircikli) etkileriyle ölçülmesi gerektiğini vurgulamaktadır.

Yapay zekâ ekosistemi içerisinde yer alan makine öğrenmesi ve derin öğrenme kavramları, işlevsel ve yapısal açıdan farklılıklar göstermektedir. 1980'li yıllardan itibaren yapay zekâ alanının en önemli alt disiplinlerinden biri olarak gelişim gösteren makine öğrenmesi, bilgisayar sistemlerine verilerden öğrenme, örüntüleri belirleme ve bu örüntülerden hareketle geleceğe yönelik tahminlerde bulunma yeteneği kazandırmayı amaçlayan hesaplama algoritmaları ve yöntemler bütünüdür ifade etmektedir. Makine öğrenmesi yaklaşımında sistemler, açık biçimde programlanmış kurallara ihtiyaç

duyumsuzun elde edilen veriler üzerinden modeller geliştirebilmekte ve zaman içerisinde performanslarını iyileştirebilmektedir. Makine öğrenmesinin temel özelliği, çevresinden öğrenerek insan zekâsını taklit etmesi ve genellikle veri sınıflandırmasına dayalı problemlerin çözümüne odaklanmasıdır. Yapay sinir ağları ise bu sürecin biyolojik temelini oluşturur; insan beynindeki nöronların işleyişine dayanan bu sistemlerde, her bağlantıya bir ağırlık verilerek gerçek çıktı ile bilinen verinin karşılaştırılması yoluyla sistemin "öğrenmesi" sağlanmaktadır (Çilhoroz ve Işık, 2021).

Derin öğrenme ise 2000'li yılların başlarında makine öğrenmesi ve yapay sinir ağlarındaki evrimin bir sonucu olarak ortaya çıkmıştır. İnsan beynindeki nöron davranışlarına dayanan derin öğrenme, çok sayıda işlem katmanından oluşan modellerin, verileri birden fazla soyutlama düzeyiyle temsil etmesine olanak tanımaktadır. Geri yayılım algoritmalarını kullanarak büyük veri kümelerindeki karmaşık yapıları keşfeden derin öğrenme; görüntü, video, konuşma ve ses işleme alanlarında devrim niteliğinde ilerlemeler sağlamıştır (Çilhoroz ve Işık, 2021). Dolayısıyla, makine öğrenmesi daha genel bir algoritma yapısını ifade ederken, derin öğrenme çok katmanlı sinir ağları üzerinden yüksek düzeyde karmaşıklığa sahip verileri otonom olarak analiz edebilen daha spesifik ve ileri bir tekniği temsil etmektedir.

Bu teknolojilerin sağlık alanında yaygın olarak kullanılmaya başlanması, modern sağlık sistemlerinin karşı karşıya olduğu artan maliyetler, büyük ve karmaşık veri kümelerinin analiz edilmesi gereksinimi, tanı ve tedavi süreçlerinde hata oranlarının azaltılması ihtiyacı ile yakından ilişkilendirilmektedir. (Ramesh vd., 2004). Sağlık hizmetlerinde yapay zekâ; hastalıkların teşhis edilmesi, tedavi sonuçlarının tahmin edilmesi, karar destek mekanizmalarının güçlendirilmesi ve robotik cerrahi gibi alanlarda aktif olarak kullanılmaktadır. Örneğin, radyoloji bölümündeki raporların metinlerinin derin öğrenme modelleriyle yüksek doğrulukla sınıflandırılması (Chen vd., 2017) veya kardiyovasküler tıp alanında yeni hastalık fenotiplerinin tanımlanması (Krittanawong vd., 2017) YZ'nin klinik verimliliği artıran uygulamaları arasında yer almaktadır. Ayrıca makine öğrenmesi yaklaşımları, ekokardiyografi görüntülerindeki devasa verilerin yorumlanmasında klinisyenlerin bilişsel yükünü azaltarak daha kesin sonuçlara ulaşılmasını sağlamaktadır (Tajik, 2016).

Dijital sağlık bağlamında yapay zekâ, "akıllı hastane" ve "sanayi 5.0" vizyonunun temel taşıdır. Sağlık hizmetlerinin finansal sürdürülebilirliği açısından kritik öneme sahip olan YZ uygulamalarının, 2026 yılına kadar ABD sağlık sisteminde yıllık 150 milyar dolara kadar tasarruf sağlayabileceği öngörülmektedir; bu tasarrufun en büyük payının robot destekli cerrahiye ait olduğu bilinmektedir (Kalis vd., 2018). Google DeepMind Health, IBM Watson Health ve Microsoft Project Hanover gibi küresel girişimler, biyomedikal makaleleri otomatik okuyarak kişiselleştirilmiş ilaç kombinasyonları geliştirme veya kronik hastalıkları öngörücü tıp yöntemleriyle yönetme gibi projelerle dijital dönüşümü

hızlandırmaktadır (Çilhoroz ve Işık, 2021). Apple'ın ResearchKit ve CareKit platformları ise dijital sağlık verilerinin toplanması ve paylaşılmasında yeni modeller sunmaktadır (Evans, 2018).

Ancak bu teknolojik entegrasyon süreci, "etik yıkama" (ethics washing) ve "gözetim kapitalizmi" gibi sosyal ve felsefi riskleri de beraberinde getirmektedir (Van Maanen, 2022; Zuboff, 2019; Roubal ve Narusevych, 2025). Roubal ve Narusevych (2025), yapay zekânın teşhis ve tedavide hekimin yeteneklerini aşabilme potansiyeline rağmen, bu teknolojinin bir "yardımcı araç" olarak mı kalacağı yoksa insani değerlerin yerini mi alacağı sorusunun kritik bir tartışma konusu olduğunu belirtmektedir. Sağlıkta dijital dönüşümün başarısı, teknik gelişimin (development) insani refahı artıran bir ilerleme (advancement) ile desteklenmesine ve veri gizliliği ile güvenliği konularındaki yasal düzenlemelerin etkinliğine bağlı olduğu düşünülmektedir (Çilhoroz ve Işık, 2021; Roubal ve Narusevych, 2025).

Sonuç olarak yapay zekâ, sağlık bilimleri perspektifinden bakıldığında; tıbbi hataları azaltan, maliyetleri düşüren ve hasta bakım kalitesini optimize eden analitik bir güç olarak karşımıza çıkmaktadır. Elektronik sağlık kayıtlarının (EHR) ve büyük biyomedikal veri setlerinin yaygınlaşması, YZ tekniklerinin uygulama alanını genişletirken; teşhis ve tedavi süreçlerinde daha kesin, kaliteli ve sürdürülebilir bir sağlık sisteminin inşasını mümkün kılmaktadır. Bu dönüşüm, yalnızca teknolojik bir yenilik değil, aynı zamanda sağlık hizmeti sunumunda paradigmaları değiştiren kuramsal ve işlevsel bir devrim olarak görülmektedir.

1.1.1. Sağlıkta Yapay Zekânın Tarihsel Gelişimi

Sağlık hizmetlerinde yapay zekânın (YZ) tarihsel serüveni, teknolojik inovasyon ile tıbbi ihtiyaçların kesiştiği uzun bir süreci kapsamaktadır. Literatür incelendiğinde, hekimlerin tanı süreçlerini iyileştirmek ve desteklemek amacıyla bilgisayar tabanlı programlardan yararlanma girişimlerinin 1950'li yıllara kadar uzandığı görülmektedir (Kononenko, 2001; Samek ve Mueller, 2019; Thrall vd., 2018; Shah vd., 2024). Bu erken dönem, yapay zekânın tıbbın temel bir bileşeni haline gelmesinin ilk adımlarını oluşturmuştur. Başlangıçta daha kısıtlı bir kapsamda ilerleyen bu süreç, zamanla bilgisayarların hesaplama kapasitesindeki devasa artış ve toplanan dijital veri miktarındaki büyük büyüme ile ivme kazanmıştır (Esmacilzadeh, 2020; Reddy vd., 2019).

Yapay zekânın sağlık alanındaki ilk uygulamaları, temel olarak insan zekâsının belirli yönlerini taklit eden algoritmalar ve kural tabanlı sistemler üzerine odaklanmıştır. Bu dönemde YZ; algılama, etkileşim, adaptasyon ve mantıksal akıl yürütme gibi insan zekâsı gerektiren faaliyetleri gerçekleştirebilen bilgisayar teknolojileri olarak konumlandırılmıştır (Jiang vd., 2017; Khanna vd., 2013). Tarihsel süreçte, özellikle karar destek sistemleri (DSS), tıbbi görüntüleme ve entegre sağlık bilgi sistemleri, YZ tekniklerinin verimli bir şekilde uygulanmasıyla köklü bir değişim geçirmiştir (Shaban-Nejad vd., 2018).

Sağlık bilişimi ile yapay zekâ arasındaki tarihsel ilişki, veri yönetimi ve politika oluşturma süreçlerinde belirginleşmektedir. Sağlık bilgi teknolojileri; veriye dayalı politikaların formüle edilmesi ve uygulanması süreçlerinde kritik bir rol oynamış, bu teknolojilerin YZ ile entegrasyonu ise sağlık ekosisteminin yönetimi için kapsamlı çerçevelerin oluşturulmasını zorunlu kılmıştır. Özellikle 1990'lı yıllardan itibaren akademik ilginin bu alanda yoğunlaşmaya başladığı görülmektedir. Örneğin, Scopus veritabanı üzerindeki bibliyometrik analizler, sağlık hizmetlerinde YZ üzerine yapılan yayınların 1992 yılında tek bir makale ile başladığını, ancak 2021 yılına gelindiğinde bu sayının elliye yükseldiğini ortaya koymaktadır (Shah vd., 2024). Bu istatistiksel veri, teknolojinin sadece klinik bir araç olarak değil, aynı zamanda idari ve stratejik bir yönetim unsuru olarak da gelişim gösterdiğini desteklemektedir.

Tarihsel dönüşümün en dikkat çekici aşaması, geleneksel programlama mantığından güncel makine öğrenmesi ve derin öğrenme yaklaşımlarına doğru yaşanan evrimi ifade etmektedir. Erken dönemdeki kural tabanlı sistemler yerini, verilerden otonom olarak öğrenen ve insan bilişsel işlevlerini taklit eden daha karmaşık yapılara bırakmıştır (Sahu vd., 2021). Günümüzde YZ; derin öğrenme (deep learning), makine öğrenmesi (machine learning) ve duysal algılama gibi insan zekâsı tarafından desteklenen mekanizmaları içerecek şekilde genişlemiştir (Tagliaferri vd., 2020). Bu dönüşüm, hastalıkların erken teşhisi, ilaç keşfi süreçlerinin hızlandırılması ve idari görevlerin otomasyonu gibi alanlarda devrim niteliğinde sonuçlar doğurmuştur.

Son aşamada, sağlık hizmetlerinde YZ'nin güncel rolü; büyük veri analitiği, Nesnelerin İnterneti (IoT) ve sensör tabanlı teknolojilerle bütünleşmiş bir yapıya evrilmiştir. Tarihsel süreç boyunca, başlangıçta doktorların teşhis yeteneklerini artırmaya çalışan basit programlar, günümüzde radyolojik görüntülerin taranması, sonuçların öngörülmesi ve elektronik sağlık bilgileri kullanılarak kişiselleştirilmiş tedavilerin sunulması noktasına gelmiştir. Bu gelişim süreci, YZ'nin sağlık hizmetlerinde sadece bir destek unsuru olmaktan çıkıp, operasyonel verimliliği artıran, maliyetleri düşüren ve hasta güvenliğini optimize eden akıllı bir ekosistemin temel taşı haline geldiğini göstermektedir.

1.1.2 Sağlıkta Yapay Zekâ: Etik İlkeler, Veri Yönetişimi ve Hukuki Sorumluluklar

Yapay zekâ uygulamalarının sağlık alanında yaygınlaşması, hasta verilerinin kullanımı ve korunmasına ilişkin etik ve hukuki sorumlulukları da beraberinde getirmektedir. Yapay zekâ sistemlerinin eğitilmesi ve geliştirilmesi sürecinde büyük hacimli sağlık verilerinden yararlanılması, aydınlatılmış onam, veri mahremiyeti, veri güvenliği ve veri yönetişimi gibi konuları sağlık hizmetlerinin temel etik tartışma alanlarından biri hâline getirmiştir. Özellikle elektronik sağlık kayıtları, tıbbi görüntüler ve genomik veriler gibi hassas sağlık verilerinin işlenmesinde bireylerin verilerinin hangi amaçlarla kullanılacağı konusunda açık şekilde bilgilendirilmesi ve özgür iradeye dayalı

onamlarının alınması gerekmektedir. Bunun yanında verilerin saklanması, paylaşılması ve işlenmesi süreçlerinde şeffaflık, hesap verebilirlik ve izlenebilirlik ilkelerinin gözetilmesi büyük önem taşımaktadır. Yapay zekâ destekli sağlık uygulamalarında hasta verilerinin işlenmesi sürecinde, Avrupa Birliği veri koruma mevzuatı bireylerin mahremiyet haklarının korunmasını ve veri işleme faaliyetlerinin yasal zeminde yürütülmesini zorunlu kılmaktadır (European Commission, 2022).

Amerika Birleşik Devletleri'nde güvenli ve güvenilir yapay zekâ kullanımını destekleyen yürütme emirleri yürürlüğe konulurken, Kanada'da Algoritmik Etki Değerlendirmesi yaklaşımı benimsenmiş, OECD ise yapay zekâ sistemlerinin sınıflandırılmasına yönelik kapsamlı bir çerçeve geliştirmiştir (OECD, 2022). Avrupa Birliği ise yapay zekâ yönetişimine ilişkin küresel ölçekte öncü bir rol üstlenerek etik, hukuki ve toplumsal boyutları kapsayan düzenlemeler geliştirmektedir. Bu çerçevede önerilen Avrupa Birliği Yapay Zekâ Yasası (EU AI Act), özellikle yüksek riskli yapay zekâ uygulamalarına yönelik şeffaflık, hesap verebilirlik ve insan haklarının korunmasına ilişkin yükümlülükler getirmektedir (Neuwirth, 2023). Bununla birlikte, yapay zekâ sistemlerinin güvenilirliğinin yalnızca teknik performansla değil, toplumsal kabul edilebilirlik ve risk yönetimiyle birlikte değerlendirilmesi gerektiği vurgulanmaktadır (Laux vd., 2024). Avrupa politika çerçeveleri incelendiğinde ise yapay zekânın etik, sosyal ve yönetsel etkilerinin teknoloji politikalarının ayrılmaz bir parçası hâline geldiği görülmektedir (Vesnic-Alujevic vd., 2020). Bu gelişmeler, sağlık bilimlerinde kullanılan yapay zekâ uygulamalarının yalnızca teknik doğruluk temelinde değil, aynı zamanda etik ilkeler, veri koruma standartları ve düzenleyici gereklilikler doğrultusunda değerlendirilmesi gerektiğini ortaya koymaktadır.

Yapay zekâ çerçevelerinin ALTAI (Assessment List for Trustworthy AI) gibi sistem teorisi perspektifinden değerlendirilmesi, farklı disiplinlerde etik araçların, mevzuatların ve yaklaşımların bütünlüklü biçimde uygulanabilmesine katkı sağlamaktadır (Stahl ve Leach, 2023). Yapay zekânın veri gizliliği mevzuatı yoluyla düzenlenmesi; kişisel verilerin kontrolü, erişim hakkı, amaçla sınırlılık ilkesi ve algoritmik karar verme süreçlerinin şeffaflığı gibi çeşitli hukuki zorlukları da beraberinde getirmektedir (Chaturvedi, 2023).

2. YÖNTEM

Bu çalışma, sağlık bilimlerinde yapay zekâ uygulamalarının kullanım alanlarını, dijital sağlık dönüşümüne katkılarını ve güncel uygulama örneklerini değerlendirmek amacıyla hazırlanmış bir anlatı derlemesi niteliğindedir. Araştırmada nitel araştırma yaklaşımı benimsenmiş ve doküman incelemesine dayalı literatür taraması yöntemi kullanılmıştır. Literatür taraması ProQuest, Scopus ve Google Scholar veri tabanlarında gerçekleştirilmiştir. Tarama sürecinde yapay zekâ ve sağlık alanına ilişkin çalışmaların belirlenebilmesi amacıyla çeşitli anahtar kelimeler ve Boolean operatörleri kullanılmıştır. ProQuest veri tabanında ("artificial intelligence" OR "AI" OR "machine learning" OR "deep learning") AND ("healthcare" OR "health services" OR "digital health" OR "medical informatics" OR "clinical decision

support”) sorgusu kullanılmıştır. Scopus veri tabanında ise TITLE-ABS-KEY ((“artificial intelligence” OR “AI” OR “machine learning” OR “deep learning”) AND (“healthcare” OR “health services” OR “digital health” OR “medical informatics” OR “clinical decision support”)) sorgusu ile tarama gerçekleştirilmiştir. Google Scholar veri tabanında ise “artificial intelligence in healthcare”, “digital health”, “machine learning in healthcare”, “clinical decision support systems”, “sağlıkta yapay zekâ” ve “dijital sağlık” anahtar kelimeleri kullanılarak tarama yapılmıştır. Tarama sürecinde herhangi bir dil sınırlaması uygulanmamış olup, erişilebilen ve araştırma konusu ile doğrudan ilişkili çalışmalar değerlendirmeye alınmıştır. Çalışmaya sağlık alanında yapay zekâ uygulamalarını ele alan araştırma makaleleri, derleme çalışmaları, uluslararası kuruluş raporları ve akademik kitap bölümleri dâhil edilmiştir. Tam metnine ulaşılamayan çalışmalar, yinelenen kayıtlar ve araştırma konusu ile doğrudan ilişkili olmayan yayınlar ise değerlendirme kapsamı dışında bırakılmıştır.

Elde edilen çalışmalar içerik analizi yaklaşımı doğrultusunda incelenmiş; yapay zekânın sağlık hizmetlerinde kullanım alanları, klinik karar destek sistemleri, makine öğrenmesi uygulamaları, dijital sağlık teknolojileri ve sağlık hizmetlerinin geleceğine yönelik katkıları çerçevesinde değerlendirilmiştir. Bulgular, mevcut literatürde yer alan çalışmaların sonuçları doğrultusunda sentezlenerek sunulmuştur.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle araştırma yalnızca ProQuest, Scopus ve Google Scholar veri tabanlarında erişilebilen yayınlarla sınırlandırılmış olup, konuya ilişkin tüm ulusal ve uluslararası çalışmaları kapsamamaktadır. Ayrıca çalışma, anlatı derlemesi niteliğinde olup sistematik derleme metodolojisini izlememektedir. Bu nedenle literatürün değerlendirilmesinde sistematik derlemelerde kullanılan PRISMA benzeri standart protokoller uygulanmamıştır. Son olarak araştırma herhangi bir deneysel uygulama, saha çalışması veya birincil veri toplama süreci içermemekte; elde edilen bulgular incelenen literatürde yer alan çalışmaların sonuçları ile sınırlı kalmaktadır. Bu çalışmada ele alınan yapay zekâ uygulamaları rastgele seçilmemiştir. Uygulamaların belirlenmesinde sağlık hizmetlerinde yaygın kullanım alanlarını temsil etmesi, farklı klinik disiplinlerde kullanılmaları, yapay zekânın tanı ve karar verme süreçlerindeki çeşitliliğini göstermeleri ve literatürde sıklıkla referans verilen örnekler arasında yer almaları ölçüt olarak dikkate alınmıştır. Bu kapsamda uygulamalar; tıbbi görüntüleme ve görüntü analizi sistemleri, klinik karar destek sistemleri ile patoloji, radyoloji ve hassas tıp platformları olmak üzere üç temel kategoride değerlendirilmiştir. Böylece yapay zekânın sağlık hizmetlerinde üstlendiği farklı rollerin bütüncül bir bakış açısıyla incelenmesi amaçlanmıştır. Seçilen araçlar herhangi bir ticari üstünlük veya ürün tanıtımı amacı taşımamakta; sağlık alanında yapay zekâ kullanımının güncel örneklerini temsil eden uygulamalar olarak ele alınmaktadır.

3. SAĞLIKTA YAPAY ZEKÂ UYGULAMA ALANLARI

Sağlık hizmetlerinde yapay zekâ (YZ) uygulamalarının yükselişi, küresel ölçekte artan demografik ve ekonomik baskıların yanı sıra teknolojik ilerlemelerin bir sonucudur. Yaşlanan nüfus,

kronik hastalıkların yaygınlaşması, yükselen sağlık maliyetleri ve sınırlı bakım erişimi gibi zorluklar, mevcut hizmet sunum modellerinin verimliliğini ve sürdürülebilirliğini tehdit etmektedir (Rabiei vd., 2025). Bu bağlamda yapay zekâ, hem operasyonel süreçleri iyileştirme hem de klinik sonuçları optimize etme potansiyeliyle kritik bir çözüm odağı olarak konumlanmaktadır. Modern bilgisayarların hesaplama kapasitesindeki devasa artış ve toplanan dijital verilerin hacmindeki büyüme, YZ'nin tıp dünyasında etkin bir şekilde kullanılabilmesi için gerekli teknik altyapıyı olgunlaştırmaktadır. Dolayısıyla yapay zekâ, günümüzde yalnızca teknik bir araç olmanın ötesine geçerek, sağlık sistemlerindeki yapısal boşlukları gidermek ve hasta bakım kalitesini proaktif bir düzeye taşımak için zorunlu bir inovasyon alanı olarak karşımıza çıkmaktadır.

Yapay zekâ teknolojileri, sağlık hizmetlerinin klinik karar verme, teşhis, tedavi, rehabilitasyon, cerrahi uygulamalar ve prognostik değerlendirmeler gibi doğrudan hasta bakımına yönelik alanlarının yanı sıra, hastane bilgi yönetim sistemleri, müşteri ilişkileri yönetimi (CRM), hasta deneyimi yönetimi, randevu planlama sistemleri, çağrı merkezi süreçleri, hasta şikâyet ve geri bildirim analitiği ile operasyonel karar destek sistemleri gibi yönetsel ve organizasyonel süreçlerde de yaygın olarak kullanılmaktadır (Milne-Ives vd., 2020; Geoghegan vd., 2021; Shah vd., 2024). Klinik karar destek sistemleri (CDSS) ve gelişmiş tıbbi görüntüleme teknolojileri, YZ'nin en belirgin etkilerinin gözlemlendiği sahalardan biridir; bu sistemler hastalıkların erken teşhisinde, radyolojik görüntülerin taranmasında ve laboratuvar sonuçlarının otonom olarak yorumlanmasında doğruluğu artırarak tıbbi hata payını minimize etmektedir. Tanı süreçlerinin ötesinde, YZ algoritmaları kişiselleştirilmiş tedavi planlarının oluşturulmasında, farmasötik alandaki ilaç keşfi süreçlerinin hızlandırılmasında ve karmaşık cerrahi operasyonlarda robotik asistanlar aracılığıyla kesinlik kontrolü sağlanmasında aktif rol oynamaktadır (Shah vd., 2024; Bizalwan vd., 2025).

Hastane Bilgi Yönetim Sistemleri (HBYS), sağlık kuruluşlarında klinik, idari ve finansal süreçlerin bütünsel biçimde yönetilmesini sağlayan temel dijital altyapılardır (Behnam vd., 2023). Son yıllarda yapay zekâ teknolojilerinin HBYS'lere entegrasyonu, bu sistemleri yalnızca veri depolayan ve yöneten platformlar olmaktan çıkararak karar destek sağlayan akıllı sistemlere dönüştürmüştür (Zhang vd., 2023). Makine öğrenmesi, derin öğrenme, doğal dil işleme (NLP) ve üretken yapay zekâ uygulamaları sayesinde büyük hacimli sağlık verileri gerçek zamanlı olarak analiz edilebilmekte, klinik süreçlerin etkinliği artırılabilir. Özellikle elektronik sağlık kayıtlarının etkin kullanımı için veri birlikte çalışabilirliği kritik bir gereklilik olup, Sağlık Bilgi Değişim Ağları (Health Information Exchange-HIE) farklı sağlık kuruluşları arasında hasta bilgilerinin güvenli şekilde paylaşılmasını sağlayarak bakım koordinasyonunu güçlendirmektedir. Bunun yanında konuşma tanıma, doğal dil işleme ve yapay zekâ teknolojilerini kullanan dijital sekreter sistemleri, klinik dokümantasyon süreçlerini otomatikleştirmektedir (Steering vd., 2023; Tierney vd., 2024; Rashid vd., 2025). Ayrıca, hizmet sunumunun idari ve operasyonel boyutunda randevu yönetimi gibi rutin görevlerin otomasyonu,

veri madenciliği yoluyla kaynak planlaması yapılması ve sağlık çalışanlarının üzerindeki bilişsel yükün azaltılması, sistemin genel işleyiş verimliliğini artıran temel unsurlardır.

Bu uygulama alanlarının bütüncül bir çerçevede ele alınması, sağlık sistemleri açısından epizodik tedavilerden sürekli ve hasta merkezli bir bakım modeline doğru yaşanan tarihsel dönüşümü simgelemektedir (Rabiei vd., 2025). Yapay zekâ teknolojilerinin dijitalleşme ve bütünleşik bilgi yönetimi süreçleriyle sinerjik bir şekilde çalışması, geleneksel hastane yapılarının otonom karar verebilen "akıllı hastanelere" evrilmesini tetiklemektedir. Bu dönüşüm, veriye dayalı politikaların geliştirilmesine, kanıta dayalı klinik müdahalelerin otonomizasyonuna ve hasta güvenliğinin gerçek zamanlı izleme sistemleriyle en üst seviyeye çıkarılmasına imkan tanımaktadır. Özellikle hassas tıp uygulamaları kapsamında bireylerin genetik profilleri ve yaşam tarzı verilerinin analizi, hastalıkların henüz ortaya çıkmadan öngörülmesini sağlayarak sağlık sistemlerinin maliyet etkinliğini güçlendirmektedir (Çilhoroz ve Işık, 2021). Sonuç olarak yapay zekâ, sağlık kuruluşlarının hem operasyonel mükemmeliyet hem de stratejik değer üretme hedeflerine ulaşmasında merkezi bir kaldıraç görevi görerek, geleceğin dijital sağlık ekosistemini yeniden şekillendirmektedir.

3.1. Tıbbi Görüntüleme ve Görüntü Analizi Uygulamaları

Görüntü tanıma ve örüntü analizi, tıbbi görüntüleme süreçlerinde veriden bilgi üretilmesini sağlayan temel teknolojik yaklaşımları temsil etmektedir. Yapay zekâ (YZ) uygulamaları, tıbbi tanıda temel olarak görüntü tanıma algoritmaları üzerine inşa edilmiştir (Bahl, 2024; Yan vd., 2025). Makine öğrenmesi, bir bilgisayarın önceden tanımlanmış görevleri, herhangi bir ön bilgiye sahip olmaksızın deneyimler yoluyla öğrenmesi süreci olarak tanımlanmaktadır (Sanjeevi vd., 2024). Bu sürecin birincil hedefi, algoritmalar aracılığıyla büyük veri kümeleri içindeki kalıpları ve düzenlilikleri keşfetmek, böylece daha önce karşılaşılmamış yeni veriler hakkında isabetli tahminlerde bulunabilmektir. AI destekli görüntü tanı iş akışları genellikle görüntünün ön işlemeden geçirilmesi, gürültünün giderilmesi ve ardından algoritmalar vasıtasıyla özellik çıkarımı ile sınıflandırma yapılması aşamalarından oluşmaktadır.

Derin öğrenme (DL), günümüzde görüntü analizi için kullanılan en yetkin yapay zekâ aracı olarak kabul edilmektedir (Aruleba vd., 2022). Girdilerden el ile özellik çıkarımı (hand-engineered feature extraction) yapılmasını gerektiren geleneksel ML yöntemlerinin aksine, derin öğrenme teknikleri veri sınıflandırması için gerekli olan özellikleri ham veriden otomatik olarak öğrenme kabiliyetine sahiptir (Loppini vd., 2022). Makine öğrenmesinin bir alt kümesi olan bu yaklaşım, verileri hiyerarşik ve doğrusal olmayan bir şekilde işlemek için çok katmanlı yapay sinir ağlarından yararlanmaktadır. Bu metodoloji, örüntü tanımayı kullanarak görüntülerden yüksek düzeyde temsil kabiliyeti olan özellikler çıkarmakta ve bilgi temsillerini sürekli olarak geliştirmektedir. Derin öğrenmenin temel amacı,

hiyerarşik ağlar vasıtasıyla verilerden otonom olarak yüksek düzeyde soyut özellikler keşfetmektir (Gandhi vd., 2018; Xu vd., 2023).

Konvolüsyonel Sinir Ağları (CNN'ler), görüntü analizinde uzamsal modelleme (spatial modeling) için özel olarak tasarlanmış derin ileri beslemeli sinir ağları sınıfını temsil etmektedir. Tıbbi görüntü analizinde CNN'ler, temel olarak anatomik yapıların ve lezyonların semantik segmentasyonu için kritik bir rol oynamaktadır. Tipik bir CNN mimarisi; konvolüsyonel katmanlar, havuzlama katmanları ve tam bağlantılı katmanlardan oluşmaktadır. Bu yapıda konvolüsyonel katmanlar, girdi verilerini tanınabilir kalıplara sıkıştırarak veri boyutunu azaltmakta ve ilgili özellikleri vurgulayan temel yapı taşları olarak işlev görmektedir (Akkuş vd., 2019; Goldenberg, Nir ve Salcudean, 2019; Zegarra ve Ghi, 2023). CNN'lerin temel gücü, birden fazla soyutlama düzeyinde ayırt edici özelliklerin çıkarılmasını kolaylaştıran derin mimarilerinden gelmektedir. Bu hiyerarşik öğrenme yaklaşımı, tıbbi görüntülerdeki karmaşık örüntülerin yakalanmasını sağlayarak tanısal doğruluğu en üst düzeye çıkarmaktadır.

Bu teknolojik çerçeve, sağlık sistemlerinde tanısal doğruluğu ve klinik iş akışlarını kökten değiştirme potansiyeline sahiptir. Tıbbi görüntüleme teknolojilerindeki hızlı ilerleme ve artan veri hacmi, hastalıkların zamanında ve doğru teşhisini çağdaş araştırmaların odak noktası haline getirmiştir. Geleneksel tanı yöntemlerinde hekimin deneyimine ve öznel faktörlere bağlı olarak ortaya çıkabilecek sapmalar, görüntü tanıma sistemlerinin nesnel ve tekrarlanabilir analiz yetenekleriyle giderilebilmektedir. Yapay zekâ destekli çözümler, hassas lezyon tespiti ve otomatik raporlama sunarak hekimlerin iş yükünü azaltırken, hata yakalama kabiliyetleri sayesinde tanı kalitesini artırmaktadır. Bu kuramsal zemin; radyoloji başta olmak üzere, tiroid nodüllerinin değerlendirilmesi, meme lezyonlarının tespiti, karaciğer hastalıklarının sınıflandırılması ve dermatolojik analizler gibi farklı tıbbi uzmanlık alanlarında precizyonel sağlık hizmetlerine geçişi mümkün kılmaktadır.

3. 1. 1. Koios DS Akıllı Ultrason Yazılımı


Koios Medical tarafından geliştirilen Koios DS Akıllı Ultrason Yazılımı, meme ve tiroid kanserinin erken ve doğru teşhisini desteklemek amacıyla tasarlanmış yapay zekâ tabanlı bir klinik karar destek sistemidir.

Koios DS, 2 milyondan fazla ultrason görüntüsünden oluşan özel bir veri kümesiyle eğitilmiş algoritma topluluğu üzerine kurulmuş olup, her bir görüntü için yaklaşık 17.900 farklı özelliği analiz ederek kanser riskini yüksek doğrulukla sınıflandırmakta ve görselleştirmektedir. Klinik kullanımlarda, iyi huylu doku biyopsilerinde %35–40 oranında azalma, takip randevularında ise yaklaşık %40 oranında düşüş sağlandığı raporlanmıştır. Bu kazanımlar sayesinde sağlık sistemlerinde 5 milyon doların üzerinde tedavi maliyeti tasarrufu elde edildiği belirtilmektedir. Koios DS, dünya genelinde 28 ülkede aktif olarak kullanılmakta, 101 farklı kurulumla hizmet vermekte ve haftalık 1–2 yeni sağlık kuruluşunda uygulamaya alınmaktadır (Koios Medical, 2024).

Yapılan araştırmalarda sistemin malign ve benign lezyonların ayırımında yüksek duyarlılık düzeyine sahip olduğu, ancak deneyimli radyologların tanısallık performansının gerisinde kaldığı görülmüştür. Çalışma sonuçlarına göre deneyimli okuyucu %88,8 doğruluk ve 0,888 AUC değeri ile en yüksek performansı gösterirken, Koios DS %78,6 doğruluk ve 0,693 AUC değeri elde etmiştir (Çelebi vd., 2025).

3.1. 2. Caption Care

Caption Health tarafından geliştirilen ve daha sonra GE Healthcare bünyesine katılan Caption Care teknolojisi, kalp hastalıklarının daha erken evrede, yönetiminin daha kolay ve maliyetinin daha düşük olduğu aşamalarda tespit edilmesini amaçlayan yapay zekâ destekli kardiyak ultrason çözümleri sunmaktadır.




Şekil 1. Caption Care

Kaynak: Caption Health. Caption Care.

Ultrasonografi güvenli ve etkili bir tanı yöntemi olmasına karşın, yüksek düzeyde uzmanlık gerektirmesi, öğrenme sürecinin uzunluğu ve görüntü kalitesindeki değişkenlikler nedeniyle klinik potansiyelinden yeterince yararlanılamamaktadır. Caption Health tarafından geliştirilen yapay zekâ destekli kalp ultrasonu yönlendirme ve yorumlama teknolojisi sayesinde, herhangi bir sağlık çalışanı, yapay zekânın gerçek zamanlı rehberliğiyle tanı kalitesinde transtorasik ekokardiyografi (TTE) görüntüleri elde edebilmektedir. Yapay zekâ yazılımı, görüntü kalitesini otomatik olarak değerlendirmekte, ejeksiyon fraksiyonunu hesaplamakta ve tarama sırasında derin öğrenme tabanlı algoritmalar aracılığıyla sonograf uzmanlığını taklit eden anlık yönlendirmeler sunmaktadır. Ticari olarak temin edilebilen uSmart 3200t Plus (Terason) sistemi üzerine kurulan yazılım, görüntü kalitesini sürekli izleyerek yinelemeli ve reçeteli ipuçları aracılığıyla görüntü iyileştirme sürecini eş zamanlı olarak desteklemektedir (Narang vd., 2021; Caption Health, 2024).

3. 1. 3. Exo AI (Exo Iris / SweepAI / Exo AI Platform)

ExoAI, Exo Inc. (Santa Clara, Kaliforniya, ABD) tarafından geliştirilen, bir yazılım aracıdır (sürüm 2.1.0). Yazılım iki farklı işlem hattına (pipeline) sahiptir: biri apikal görüntüler (A2C veya A4C) için, diğeri ise PLAX görüntüsü için tasarlanmıştır. Araştırmalar bir yapay zekâ algoritması olan ExoAI'nin, farklı ekokardiyografik görüntüleme değerlerini doğru biçimde öngörebildiğini göstermektedir (Vega vd., 2024). Exo Iris platformu kullanılarak yapılan çalışmada, deneyimsiz kullanıcıların hastaların %96'sında beş dakikadan kısa sürede sol ventrikül ejeksiyon fraksiyonunun hesaplanmasına olanak sağlayacak kalitede görüntüler elde edebildiği gösterilmiştir (Gallant vd., 2025).



Şekil 2. Exo AI (Exo Iris / SweepAI / Exo AI Platform)

Kaynak: Exo Imaging Inc. Exo AI Platform (Exo Iris, SweepAI ve Exo AI Platform).

Yapay zekâ destekli tıbbi görüntüleme alanında önemli yenilikler geliştiren Exo, gelişmiş görüntü analizi teknolojilerini klinik karar verme süreçleriyle bütünleştirerek akciğer hastalıklarının tanı ve değerlendirilmesinde dikkat çekici ilerlemeler sağlamıştır. Exo Iris platformuna entegre edilen ve plevral efüzyon ile konsolidasyon/atelektazi tespiti için FDA 510(k) onayını alan ilk yapay zekâ özelliği, klinik pratikte cihaz içi ve gerçek zamanlı göstergeler sağlayarak zatürre ve tüberküloz gibi akciğer hastalıklarının saniyeler içerisinde yatak başında tespit edilmesine olanak tanımaktadır (Exo Imaging, 2026).

3.1. 4. Sonio (Sonio Detect)

Sonio, yapay zekâ destekli doğum öncesi ultrason raporlama alanında klinik iş akışlarını optimize etmeyi amaçlayan bulut tabanlı bir yazılım çözümü sunmaktadır. Sistem, Expert ve Detect modülleri dâhil olmak üzere yapay zekâ modellerini eğitmek ve geliştirmek amacıyla, gerçek klinik ortamlardan elde edilmiş, sıralanmamış ve yüksek çeşitlilik içeren geniş bir ultrason görüntü ve video koleksiyonuna dayanmaktadır.




Şekil 3. Sonio Detect

Kaynak: Sonio. Sonio Detect.

Bu kapsamda Sonio, 1.000.000'dan fazla taranmış görüntü, 30.000'in üzerinde ultrason klipi, 35.000'den fazla doğum öncesi muayene ve 150.000'den fazla açıklamalı veri ile derin öğrenme tabanlı algoritmalarını beslemektedir. Klinik performans açısından Sonio Detect, fetal ultrason görüntülerini T1 düzeyinde %94, T2/T3 düzeyinde ise %92 hassasiyetle ayırt edebilmekte; fetal beyin yapılarını %86 duyarlılık ve %96 özgüllükle, kalp yapılarını ise %90 duyarlılık ve %98 özgüllükle tanımlayabilmektedir. Bu özellikleriyle Sonio, doğum öncesi ultrason incelemelerinde hem tanısal kaliteyi hem de iş akışı verimliliğini artıran yenilikçi bir klinik yapay zekâ çözümü olarak öne çıkmaktadır (Sonio, 2026).

3.1. 5. Us2.ai

Yapay zekâ destekli ekokardiyografik analiz çözümleri geliştiren Us2.ai, klinik karar destek sistemleri aracılığıyla kardiyovasküler hastalıkların tanı, izlem ve yönetim süreçlerini daha objektif ve ölçeklenebilir hâle getirmeyi amaçlamaktadır.




Şekil 4. Us2.ai

Kaynak: Us2.ai. Us2.ai – Yapay Zekâ Destekli Ekokardiyografi Analiz Platformu.

Bu kapsamda gerçekleştirilen çalışmalarda, transtiretin kardiyak amiloidoz (ATTR-CM) tanısı bulunan hastalardan elde edilen 750'den fazla ekokardiyografi verisi, zaman içerisindeki yapısal ve fonksiyonel kalp değişikliklerini değerlendirmek amacıyla Us2.ai yazılımı kullanılarak analiz edilmiştir. Elde edilen bulgular, yapay zekâ destekli ekokardiyografik analizlerin hastalık progresyonunu etkili biçimde izleyebildiğini ve tedaviye verilen yanıtın daha erken dönemde saptanmasına katkı sağlayabildiğini göstermektedir (Venneri vd., 2025). Avrupa Kalp Yetmezliği Dergisi'nde yayımlanan çalışmada, el tipi ekokardiyografi görüntülerinde tamamen otomatik yapay zekâ analizi (Us2.ai) kullanılarak sol ventrikül ejeksiyon fraksiyonunun ($LVEF \leq 40\%$) %0,93 tanısal doğrulukla saptanabildiğini, elde edilen ölçümlerin uzman analizleriyle istatistiksel olarak eşdeğer olduğunu ve bu yaklaşımın birinci basamak ve toplum temelli ortamlarda kalp yetmezliği tanısını daha hızlı, erişilebilir ve küresel ölçekte dönüştürücü biçimde mümkün kılabileceğini ortaya koymaktadır (Campbell vd., 2025). Hirata vd., tarafından gerçekleştirilen çalışma bulgularına göre Us2.ai destekli analizler, ölçüm süresini ve rapor oluşturma aşamasını anlamlı düzeyde kısaltmış, toplamda yaklaşık %70 oranında zaman kazancı sağlamıştır. Bu durum, özellikle yoğun hasta yüküne sahip kardiyoloji ve ekokardiyografi birimlerinde iş akışının hızlandırılmasına ve sağlık profesyonellerinin zamanının daha verimli kullanılmasına katkı sunmaktadır (Hirata vd., 2024).

3.1. 6. UltraSight

UltraSight'ın yapay zekâ destekli çözümleri, hastane dışı bakım ortamlarında tedavi sürecine yön vermek amacıyla izlem olanağı sunmaktadır.



Şekil 5. UltraSight


Kaynak: UltraSight. UltraSight – AI Guided Cardiac Ultrasound Platform.

Bu uygulamalar, hastaların evlerine yakın veya toplum temelli bakım noktalarında gerçekleştirilebilmekte; yapay zekâ destekli gerçek zamanlı rehberlik sayesinde daha önce ultrasonografi eğitimi almamış sağlık personelinin de bakım noktasında tanısal nitelikte kardiyak ultrasonografi uygulamalarını etkin biçimde gerçekleştirmesine destek olmaktadır (UltraSight, 2026).

UltraSight'a ilişkin yapılan araştırma, yapay zekâ destekli gerçek zamanlı yönlendirme yazılımı sayesinde sınırlı eğitim alan acemi kullanıcıların, hastaların büyük çoğunluğunda uzman ultrason teknisyenlerinin elde ettiği tanı kalitesine yakın görüntüler üretebildiğini ortaya koymaktadır (Mor-Avi vd., 2023). Anisuzzaman vd., tarafından gerçekleştirilen araştırma UltraSight'ın ekokardiyografi uygulamalarında uzmanlık gereksinimini azaltarak bakım noktası ultrason kullanımını yaygınlaştırma potansiyeline sahip olduğunu ve kardiyak değerlendirmelerin daha erişilebilir hale gelmesine katkıda bulunabileceğini göstermektedir (Anisuzzaman vd., 2026).

3.1. 7. Butterfly Network

Butterfly Network, dünya genelinde 145.000'den fazla sağlık profesyoneli tarafından hasta bakımını iyileştirmek amacıyla kullanılmaktadır. Butterfly'ın tüm vücut ultrason problemleri, yapay zekâ destekli analizler, iş akışı yönetim yazılımı ve kapsamlı eğitim içerikleri ile birlikte çalışarak, kullanıcıların ihtiyaçlarına göre uyarlanabilen eksiksiz ve pratik bir POCUS çözümü sunmaktadır (Butterfly Network, 2026).



Şekil 6. Butterfly Network


Kaynak: Butterfly Network. Butterfly iQ – Yapay Zekâ Destekli Elde Taşınabilir Ultrason Platformu.

Araştırmalar, günlük POCUS uygulamasının hasta sonuçlarını anlamlı biçimde iyileştirdiğini ve sağlık hizmeti maliyetlerini azalttığını; tüm hasta gruplarında hastanede kalış süresinin ortalama 4 günden fazla kısaldığını, daha düşük şiddetli hastalarda yaklaşık %50 maliyet tasarrufu sağlandığını ve daha yüksek bakım gerektiren hastalarda ise yatış süresinin 22,3 gün azaldığını göstermektedir (Maganti vd., 2023).

3.1. 8. SmartAlpha

SmartAlpha, yapay zekâ destekli gerçek zamanlı çözümleriyle ultrason uygulamalarında uzman seviyesinde rehberlik sunmayı hedeflemektedir. Geliştirdiği teknoloji, standart gri tonlamalı ultrason

muayenelerini sezgisel, anatomiye duyarlı ve gerçek zamanlı bir klinik deneyime dönüştürerek sağlık profesyonellerinin tanısal doğruluğunu artırmaktadır.



Şekil 7. SmartAlpha

Kaynak: SmartAlpha. Nerveblox™ – Yapay Zekâ Destekli Ultrason Rehberlik Sistemi.

Ultrason yapay zekâ teknolojileri alanında dünyanın en geniş anatomik kapsamlarından birini sunan SmartAlpha, kullanıcıların 200’den fazla anatomik yapıyı tanıyarak farklı klinik ortamlarda 50’den fazla muayene prosedürünü gerçekleştirmelerine olanak tanımaktadır. Platformun Nerveblox™ modülü ise, gerçek zamanlı yapay zekâ algoritmaları aracılığıyla 50’den fazla anatomik yapıyı otomatik olarak tespit etmekte ve 12 farklı bölgesel anestezi prosedüründe kritik anatomik yapıların güvenilir biçimde görselleştirilmesini destekleyerek klinik uygulamaların güvenliğini ve etkinliğini artırmaktadır (Arnett, 2025; Nerveblox, 2025; SmartAlpha, 2026).

3.1. 9. ContextVision

ContextVision, tıbbi görüntüleme alanında görüntü analizi ve yapay zekâ tabanlı yazılım çözümleri geliştiren bir sağlık teknolojisi şirkettir. Şirket tarafından geliştirilen sistemler; iki boyutlu, üç boyutlu ve dört boyutlu ultrason görüntüleme, radyografi, manyetik rezonans görüntüleme (MR), X-ışını görüntüleme ve veteriner görüntüleme uygulamaları gibi farklı klinik alanlarda kullanılmaktadır.



Şekil 8. ContextVision

Kaynak: ContextVision. ContextVision – Yapay Zekâ Destekli Tıbbi Görüntü Analizi ve Görüntü İyileştirme Teknolojileri.

ContextVision'ın geliştirdiği görüntü işleme teknolojileri, dijital tıbbi görüntülerdeki klinik açıdan önemli bilgilerin daha belirgin hâle getirilmesini ve analiz edilmesini sağlayarak görüntü kalitesinin artırılmasına katkıda bulunmaktadır. Bu sayede hekimler anatomik yapıları ve patolojik bulguları daha net değerlendirebilmekte, tanısal doğruluğun artırılması ve tedavi süreçlerinin desteklenmesi mümkün olmaktadır. ContextVision, 3D/4D ultrason uygulamaları için en son teknolojiye dayalı görüntü iyileştirme çözümleri sunarak tanısal ultrason alanında yenilikçi bir yaklaşım ortaya koymaktadır (ContextVision, 2026). ContextVision'ın geliştirdiği görüntü iyileştirme ve analiz çözümleri, radyoloji ve ultrasonografi uygulamalarında görüntü kalitesini artırarak patolojik bulguların daha etkin şekilde değerlendirilmesine katkı sağlayabilmektedir. Araştırmalar, yapay zekânın acil tıp uygulamalarında hasta sonuçlarını iyileştirme ve klinik süreçleri hızlandırma potansiyeline sahip olduğunu ortaya koyarken, ContextVision gibi gelişmiş görüntü analiz platformlarının da dijital sağlık dönüşümünün önemli bileşenlerinden biri hâline geldiğini göstermektedir. Bununla birlikte, bu sistemlerin klinik etkinliğinin sürdürülebilmesi için farklı hasta gruplarında doğrulanması ve uzman değerlendirmesiyle birlikte kullanılması gerekmektedir (Alimiri Dehbaghi ve Khoshgard, 2025).

3. 2. Yapay Zekâ Destekli Klinik Karar Destek Sistemleri

3.2. 1. IBM Watson Health

IBM Watson Health, sağlık ve yaşam bilimleri alanında büyük ve karmaşık veri kümelerini analiz ederek klinik karar süreçlerini desteklemek amacıyla geliştirilmiş yapay zekâ tabanlı bir platformdur.



Şekil 9. IBM Watson Health

Kaynak: IBM. IBM Watson Health.

Yapılandırılmış veriler (laboratuvar sonuçları, tanı kodları gibi) ile yapılandırılmamış verileri (doktor notları, bilimsel literatür, klinik raporlar gibi) birlikte işleyebilme kapasitesine sahip olan Watson, doğal dil işleme ve gelişmiş analitik yöntemler aracılığıyla klinisyenlere kanıta dayalı ve kişiselleştirilmiş öneriler sunmayı hedefler. Sistem; onkoloji, genomik analiz, hasta yönetimi ve klinik araştırmalar gibi alanlarda kullanılarak daha doğru tanı, daha uygun tedavi seçimi ve maliyet etkin sağlık hizmeti sunumuna katkı sağlamayı amaçlamaktadır (Electrical and Computer Engineering at the U, 2013). IBM Institute for Business Value tarafından yayımlanan *Healthcare in the AI Era* başlıklı rapora göre IBM Watson Health ve ilişkili yapay zekâ çözümleri, sağlık sistemlerinde klinik ve idari süreçleri veri odaklı biçimde dönüştürmeyi amaçlayan entegre dijital platformlardır. Raporda, yapay zekânın özellikle erken uyarı sistemleri, hasta izleme, klinik dokümantasyonun otomasyonu, gelir döngüsü yönetimi ve disiplinler arası ekip koordinasyonu gibi alanlarda sağlık kuruluşlarına ölçülebilir verimlilik ve kalite artışı sağladığı vurgulanmaktadır. Ayrıca, büyük hacimli ve yapılandırılmamış sağlık verilerinin analiz edilerek karar vericilere anlamlı içgörüler sunulmasının, daha hızlı ve kanıta dayalı klinik kararların önünü açtığı belirtilmektedir (IBM Institute for Business Value, 2023).

3.2. 2. Aidoc

Aidoc'un yapay zekâ destekli sağlık platformu, klinik karar destek süreçlerini güçlendirmek ve disiplinler arası bakım koordinasyonunu artırmak amacıyla geliştirilmiş bütünlük bir dijital ekosistem sunmaktadır.

Dünya genelinde 1.600'den fazla hastanede kullanılan aiOS™ kurumsal platformu, hasta popülasyonunun yaklaşık %75'ini kapsayarak gerçek zamanlı veri analizi, otomatik triyaj, risk sınıflandırması ve mobil bildirim mekanizmaları aracılığıyla klinisyenlerin hızlı ve kanıta dayalı kararlar almasına olanak tanımaktadır. Radyoloji alanında 17 FDA onaylı yerleşik algoritma ve sekiz iş ortağı algoritması ile görüntü temelli önceliklendirme ve kantitatif analiz sağlanmakta; bakım koordinasyonu modülü, elektronik sağlık kayıtlarıyla entegre çalışarak departmanlar arası iletişimi kolaylaştırmaktadır.

Ayrıca hasta yönetimi ve klinik araştırmalara otomatik hasta tanımlama sistemleri sayesinde takip gerektiren olguların izlenmesi ve araştırma süreçlerine katılımın artırılması mümkün olmaktadır (Aidoc, 2026). Araştırmalar, Aidoc'un büyük damar tıkanıklıklarının belirlenmesinde yüksek tanısal performans gösterdiğini ve iş listesi önceliklendirmesi sayesinde kritik hastaların daha hızlı değerlendirilmesine olanak sağladığını ortaya koymaktadır. Bu özellikleriyle Aidoc, tanısal güvenliği artıran ve klinik iş akışlarını optimize eden önemli bir yapay zekâ uygulaması olarak değerlendirilmektedir (Mateusz vd., 2025).

3.2. 3. Viz.ai


Viz.ai, hasta bakım süreçlerini dönüştürmek amacıyla geliştirilmiş, yapay zekâ destekli entegre bir bakım koordinasyon platformudur. Sistem, bilgisayarlı tomografi (BT), elektrokardiyografi (EKG), ekokardiyografi ve diğer tıbbi görüntüleme verilerini analiz eden 50'den fazla FDA onaylı algoritma aracılığıyla şüpheli patolojileri gerçek zamanlı olarak otomatik biçimde tespit etmekte ve klinisyenlere hızlandırılmış tanı ve tedavi karar desteği sunmaktadır.

Viz.ai One platformu, teşhis süresini kısaltmayı, iş akışlarını optimize etmeyi ve multidisipliner ekipler arasında iletişimi güçlendirmeyi hedefleyen bütünsel bir dijital altyapı sağlamaktadır. Klinik olarak doğrulanmış ve gerçek dünya performans verileriyle desteklenen bu yapay zekâ tabanlı sistem, yalnızca erken hastalık tespitini kolaylaştırmakla kalmayıp, aynı zamanda hasta sonuçlarının iyileştirilmesine ve sağlık hizmeti maliyetlerinin azaltılmasına katkı sunarak modern sağlık hizmetlerinde veri temelli karar alma süreçlerinin güçlendirilmesine olanak tanımaktadır (Viz.ai, 2026).

Viz.ai üzerine yapılan araştırmalar, sistemin büyük damar tıkanıklıklarının hızlı şekilde belirlenmesine katkı sağladığını ve sağlık ekipleri arasındaki iletişimi hızlandırarak tedavi süreçlerini optimize ettiğini göstermektedir. Özellikle inme hastalarında tedaviye başlama süresinin kritik önem taşıdığı göz önünde bulundurulduğunda, Viz.ai'nin kapıdan girişimsel tedaviye kadar geçen süreyi 11–25 dakika azaltabildiği bildirilmiştir (Mateusz vd., 2025).

3. 2. 4. Caption AI (GE HealthCare)

GE HealthCare Imaging, klinik karar destek süreçlerini güçlendirmek ve görüntüleme temelli tanısal doğruluğu artırmak amacıyla akıllı cihazlar ile derin öğrenme destekli yazılım çözümlerini entegre eden kapsamlı bir medikal görüntüleme ekosistemi sunmaktadır.



Şekil 10. Caption AI (GE HealthCare)

Kaynak: GE HealthCare. Caption AI™ (Vscan Air™ SL).

Manyetik rezonans (MR), bilgisayarlı tomografi (BT), SPECT/CT, PET/CT, X-ışını, mamografi, girişimsel sistemler ve moleküler görüntüleme gibi çoklu modalitelerde geliştirilen yapay zekâ uygulamaları, görüntü elde etme, yeniden yapılandırma ve analiz süreçlerinde otomasyon ve kalite iyileştirmesi sağlamaktadır. Özellikle Effortless Recon gibi derin öğrenme tabanlı yazılım koleksiyonları, daha kısa sürede yüksek görüntü kalitesi elde edilmesine olanak tanıyarak hem hasta konforunu artırmakta hem de klinik iş akışlarının verimliliğini desteklemektedir (GE HealthCare, 2026). Yazılım, gerçek zamanlı görüntüleme rehberliği, otomatik görüntü yakalama ve sol ventrikül ejeksiyon fraksiyonunun otomatik hesaplanması gibi özellikleri sayesinde yüksek kaliteli kardiyak görüntülerin elde edilmesini kolaylaştırmakta ve klinik karar verme süreçlerini hızlandırmaktadır (Stephens, 2024).

3.2. 5. Epic Cognitive Computing (Epic EHR AI Tools)

Epic Health System Community, dünya genelinde hasta bakımını geliştirmek ve sağlık hizmet sunumunda yenilikçi çözümler üretmek amacıyla iş birliği yapan güçlü bir sağlık ekosistemini temsil etmektedir. ABD’de en iyi hastanelerin ve tıp fakültelerinin büyük çoğunluğu Epic sistemlerini kullanmakta; finansal performansı en güçlü sağlık sistemlerinin %90’ı Epic altyapısını tercih etmektedir.



Şekil 11. Epic Cognitive Computing (Epic EHR AI Tools)

Kaynak: Epic Systems Corporation. Artificial Intelligence – Epic EHR AI Tools (Epic Cognitive Computing).

Epic topluluğuna bağlı kurumlarda ameliyat sonrası akut böbrek hasarında %80'e varan azalma, cerrahi enfeksiyon oranlarında %50 düşüş, hastanede kalış sürelerinde belirgin kısalma ve milyonlarca dolarlık maliyet tasarrufu gibi dikkat çekici sonuçlar elde edilmiştir. Bu veriler, Epic'in yalnızca bir bilgi sistemi sağlayıcısı değil, aynı zamanda klinik kalite, finansal performans ve veri temelli karar destek süreçlerinde dönüşüm yaratan stratejik bir sağlık teknolojisi platformu olduğunu göstermektedir (Epic, 2026).

Epic Cognitive Computing altyapısıyla gerçekleştirilen analizde, antihipertansif tedavi başlanan 24.325 hastada tele-sağlık kullanım oranının ilk 12 haftalık sistolik kan basıncı kontrolünü olumsuz etkilemediği gösterilmiştir. Takiplerinin %50–74'ünü tele-sağlık yoluyla sürdüren hastaların kan basıncı değerleri, tamamen yüz yüze izlenen hastalarla büyük ölçüde benzer bulunmuş; gruplar arasındaki farkların küçük ve çoğu zaman istatistiksel olarak anlamsız olduğu saptanmıştır. Bu bulgular, Epic'in gelişmiş veri analitiği ve klinik karar destek kapasitesinin, gerçek dünya verileri üzerinden güvenilir sonuçlar üreterek tele-sağlık temelli hipertansiyon yönetiminin etkinliğini ortaya koyduğunu göstermektedir (American Medical Association, 2021).

Amerika Birleşik Devletleri'nde Epic kullanan hastaneler üzerinde gerçekleştirilen araştırmalar, ambient yapay zekâ destekli dokümantasyon araçlarının hastanelerin yaklaşık üçte ikisi tarafından benimsendiğini göstermiştir. Özellikle yüksek hasta yoğunluğuna sahip, finansal açıdan güçlü ve büyük ölçekli sağlık kuruluşlarında kullanım oranlarının daha yüksek olduğu bildirilmiştir. Bu bulgular, Epic Cognitive Computing çözümlerinin klinik dokümantasyon süreçlerini kolaylaştırma ve sağlık profesyonellerinin idari yükünü azaltma potansiyeline sahip olduğunu göstermektedir. Bununla birlikte, teknolojinin farklı hastane türlerinde eşit düzeyde yaygınlaşmadığı ve klinik sonuçlar, bakım kalitesi ve sağlık hizmetlerinde eşitlik üzerindeki etkilerinin daha kapsamlı araştırmalarla değerlendirilmesi gerektiği vurgulanmaktadır (Yang ve Graetz, 2026).

3. 3. Yapay Zeka Destekli Patoloji, Radyolojik ve Hassas Tıp Platformları

3. 3. 1. Paige.ai

Paige, dijital patoloji ve çok modlu veri analitiğini birleştiren yapay zekâ tabanlı çözümleriyle kanser teşhis ve karakterizasyon süreçlerini dönüştürmeyi amaçlayarak, milyonlarca dijitalleştirilmiş patoloji slaytı, klinik rapor ve genomik veriden oluşan geniş ve çeşitli veri altyapısını kullanıp, doku temelli görüntü analizi ile moleküler profillemeyi entegre ederek kanserin hücresel ve biyolojik karmaşıklığını daha yüksek doğrulukla değerlendirmeye olanak tanımaktadır.

40'tan fazla kanser türünü kapsayan ve 800'den fazla laboratuvar ile tıp kurumundan elde edilen verilerle eğitilen Paige'in yapay zekâ modelleri, 25 milyondan fazla patoloji slaytı ve yüz binlerce hasta verisi üzerinden geliştirilmiş olup, patoloğlara tanı ve sınıflandırma süreçlerinde karar desteği sağlamaktadır (Paige, 2026). Paige.ai, dijital patoloji alanında yapay zekâ destekli görüntü analizleri

sunarak patoloji iş akışlarının daha verimli yürütülmesine katkı sağlamaktadır. Yapılan çalışmalar, sistemin özellikle prostat biyopsileri ve meme dokusu örneklerinin değerlendirilmesinde raporlama süreçlerini hızlandırdığını, çalışma sürelerini azalttığını ve patoloji raporlarının standardizasyonunu desteklediğini göstermektedir (da Silva ve Athanazio, 2026).



Şekil 12. Paige.ai

Kaynak: Paige AI Inc. Paige.ai – Yapay Zekâ Destekli Dijital Patoloji Platformu.

3.3. 2. Tempus

Tempus, yapay zekâ destekli hassas tıp alanında geliştirdiği çok modlu veri analitiği platformuyla kanser başta olmak üzere karmaşık hastalıkların teşhis, tedavi ve klinik araştırma süreçlerini dönüştürmeyi amaçlayan küresel bir sağlık teknolojisi şirkettir.



Şekil 13. Tempus


Kaynak: Tempus AI Inc. Tempus – AI Destekli Hassas Tıp ve Genomik Platformu.

Genomik dizileme, klinik veriler, görüntüleme ve gerçek dünya hasta kayıtlarını entegre eden sistem; tedavi etkinliğini öngörme, potansiyel klinik denemeleri belirleme ve hedefe yönelik terapileri eşleştirme kapasitesi sunmaktadır. ABD'deki akademik tıp merkezlerinin büyük kısmı ve onkologların

önemli bir bölümü Tempus altyapısını kullanmakta; biyofarma ortaklıkları ve geniş anonimleştirilmiş veri havuzu sayesinde bilimsel keşifleri hızlandırmaktadır. Jensen ve arkadaşları (2026) tarafından gerçekleştirilen çalışma, Tempus'un nadir ve agresif kanser türlerinde klinik açıdan anlamlı biyobelirteçlerin tanımlanmasını ve translasyonel araştırmalara aktarılmasını hızlandıran güçlü bir genomik veri ve analiz altyapısı sunduğunu ortaya koymuştur (Jensen vd., 2026). Başka bir çalışmada, Tempus xT platformunun sağladığı ham DNA/RNA dizileme verileri kapsamlı genomik analizle yeniden değerlendirilmiş; bu sayede ilgili varyantın patojenik olmadığı gösterilerek olası yanlış hedefe yönelik tedavi kararlarının önüne geçilmiştir (Kenny, 2026). 17.449 kanser hastasının verileri üzerinde gerçekleştirilen bir çalışmada, tümörlerinde daha fazla genetik değişiklik bulunan hastaların immünoterapi tedavilerine daha iyi yanıt verdiği belirlenmiştir. Özellikle tümör mutasyon yükü çok yüksek olan hastalarda tedaviye yanıt oranlarının daha yüksek olduğu ve yaşam sürelerinin daha uzun olduğu görülmüştür (Johnson vd., 2025).

3.3. 3. Qure.ai

Qure.ai; akciğer hastalıkları, tüberküloz, akciğer kanseri ve inme gibi kritik durumların erken saptanmasına yönelik otomatik görüntü analizi, önceliklendirme (triage) ve raporlama desteği sunarak tanı sürecini hızlandırmayı hedeflemektedir (Qure.ai,2026). 2025 yılında Nijerya'da gerçekleştirilen çalışmada Qure.ai tabanlı yapay zekâ destekli akciğer grafisi yorumlama sistemi, geleneksel semptom taramasına kıyasla daha fazla tüberküloz vakasının saptanmasını sağlamıştır (Garg vd., 2025).



Şekil 14. Qure.ai

Kaynak: Qure.ai. Qure.ai – Yapay Zekâ Destekli Tıbbi Görüntüleme ve Klinik Karar Destek Platformu.

Acil servise başvuran 40 hastaya ait akciğer grafilerinin değerlendirildiği bir çalışmada, Qure.ai'nin tanısal doğruluğunun acil tıp uzmanları ve diğer yapay zekâ modellerine kıyasla daha yüksek olduğu bulunmuştur. Özellikle zatürre (pnömoni), akciğer sönmesi (pnömotoraks) ve akciğer zarında sıvı birikmesi (plevral efüzyon) gibi hayati risk taşıyan durumların belirlenmesinde üstün performans

göstermiştir. Bunun yanında normal akciğer grafilerinin ve tüberküloz bulgularının tanınmasında uzman hekimlerle benzer düzeyde başarı sağlamıştır. Bu sonuçlar, Qure.ai'nin görüntüleme verilerini analiz ederek hekimlere hızlı ve güvenilir karar desteği sunabildiğini ve özellikle acil sağlık hizmetlerinde tanı süreçlerinin iyileştirilmesine katkı sağlayabileceğini göstermektedir (Dogan vd., 2026).

3.3. 4. Infervision – AI Radiology Platform

Infervision, derin öğrenme tabanlı algoritmalar kullanarak bilgisayarlı tomografi (BT) ve dijital radyografi görüntülerini otomatik analiz eden, klinik karar destek sistemleri geliştiren bir tıbbi yapay zekâ platformudur.



Şekil 15. Infervision – AI Radiology Platform

Kaynak: Infervision. Infervision – AI Radiology Platform.

Sistem; akciğer nodülü, pnömoni, inme, koroner arter stenozu ve kemik kırıkları gibi patolojilerin erken saptanmasına yönelik InferRead görüntü analiz modülleri ile tanısal süreçleri desteklerken, InferOperate çözümleri aracılığıyla cerrahi planlama için üç boyutlu anatomik rekonstrüksiyonlar sunmakta, InferCare ile hasta izlem ve görüntüleme yönetimini kolaylaştırmakta ve InferScholar ile araştırma süreçlerinde veri analitiği sağlamaktadır. Klinik iş akışına entegrasyon, hızlı triyaj ve standardize raporlama özellikleri sayesinde radyologların değerlendirme süresini azaltarak tanı doğruluğunu artırmayı amaçlayan sistem, dünya genelinde 30'dan fazla ülkede kullanılmakta; 380'in üzerinde patent başvurusu ve 330'dan fazla hakemli yayın/konferans çıktısı ile bilimsel ve teknolojik gelişimini desteklemektedir. Bu yönüyle Infervision, yapay zekânın sağlık hizmetlerinde yalnızca otomasyon aracı değil, klinisyen performansını güçlendiren bir artırılmış zekâ (augmented intelligence) yaklaşımı olarak konumlandırıldığı uygulamalardan biridir (Infervision, 2025).

Shan vd., tarafından yapılan çalışmada, Aralık 2021 ile Haziran 2023 tarihleri arasında patolojik olarak doğrulanmış karaciğer kanseri olgularına ait BT görüntüleri analiz edilmiş ve yapay zekâ sisteminin performansı deneyimli radyologların değerlendirmeleriyle karşılaştırılmıştır. Bulgular, sistemin karaciğer tümörlerinin yerini ve boyutunu başarılı bir şekilde belirleyebildiğini, böylece

radyologların lezyonları daha hızlı tespit etmesine ve değerlendirmesine yardımcı olabileceğini göstermiştir. Ayrıca platformun, tümörlerin otomatik olarak sınırlandırılması ve ölçülmesinde hızlı ve güvenilir sonuçlar sunarak görüntü analiz süreçlerini desteklediği belirlenmiştir (Shan vd., 2025).

4. SAĞLIKTA YAPAY ZEKÂ UYGULAMALARINA YÖNELİK KAVRAMSAL BİR SINIFLANDIRMA ÖNERİSİ

Bu çalışma yalnızca sağlık alanında kullanılan yapay zekâ uygulamalarının tanıtılmasını amaçlayan betimleyici bir derleme niteliğinde değildir. Aynı zamanda dijital sağlık dönüşümü perspektifinden yapay zekâ uygulamalarının sağlık hizmetleri içerisindeki işlevsel rollerini ortaya koyan kavramsal bir sınıflandırma önerisi sunmaktadır. İncelenen uygulamalar değerlendirildiğinde yapay zekâ teknolojilerinin sağlık hizmetlerinde birbirinden farklı ancak birbiriyle ilişkili üç temel işlev üstlendiği görülmektedir.

Birinci grup, görüntü tanıma ve örüntü analizi odaklı sistemlerden oluşmaktadır. Bu grupta yer alan uygulamalar ultrason, radyoloji ve diğer tıbbi görüntüleme süreçlerinde görüntülerin işlenmesi, anormalliklerin belirlenmesi ve klinisyenlere tanısal destek sağlanması amacıyla kullanılmaktadır. Koios DS, Exo AI, Sonio, Us2.ai ve benzeri uygulamalar bu kategoride değerlendirilebilir.

İkinci grup, klinik karar destek sistemleri olarak tanımlanabilir. Bu sistemler hasta verilerini analiz ederek tanı, tedavi ve bakım süreçlerinde sağlık profesyonellerine öneriler sunmakta ve klinik karar verme süreçlerini desteklemektedir. IBM Watson Health, Aidoc, Viz.ai ve Epic Cognitive Computing bu gruba örnek olarak gösterilebilir.

Üçüncü grup ise hassas tıp, patoloji ve ileri tanısal analiz sistemlerinden oluşmaktadır. Bu uygulamalar büyük veri analitiği, genomik veriler, dijital patoloji ve radyolojik verileri birlikte değerlendirilerek kişiselleştirilmiş sağlık hizmetlerinin geliştirilmesine katkı sağlamaktadır. Paige.ai, Tempus, Qure.ai ve Infervision bu kategoride yer almaktadır.

Bu sınıflandırma, yapay zekâ uygulamalarının yalnızca teknik özelliklerine göre değil, sağlık hizmeti sunum sürecinde üstlendikleri işlevlere göre değerlendirilmesini mümkün kılmaktadır. Böylece yapay zekâ teknolojilerinin dijital sağlık dönüşümündeki rolü; veri üretimi ve analizi, klinik karar verme ve kişiselleştirilmiş sağlık hizmetleri olmak üzere üç temel eksen üzerinden açıklanabilmektedir. Önerilen kavramsal çerçeve, gelecekte geliştirilecek yapay zekâ uygulamalarının değerlendirilmesinde ve sağlık bilişimi araştırmalarında kullanılabilecek bütüncül bir yaklaşım sunmaktadır.

SONUÇ

Yapay zekâ teknolojilerinin sağlık hizmetlerine entegrasyonu, geleneksel reaktif tıp modelinden proaktif, sürekli ve hasta merkezli bir "Akıllı Hastane" ekosistemine geçişi destekleyen önemli bir unsur olarak değerlendirilmektedir. Yapılan incelemeler, YZ'nin sadece teknolojik bir gelişme olmanın ötesinde, sağlık hizmeti sunumunda paradigma değişimine katkı sağlayabilecek yapısal bir dönüşüm

unsuru olarak değerlendirilebileceğini göstermektedir. Özellikle dijitalleşme ve sağlık bilgi yönetimi süreçleriyle sağlanan sinerji, tıbbi verilerin sadece depolanmasını değil, bu verilerin otonom analizler yoluyla yüksek değerli klinik çıktılara dönüştürülmesini mümkün kılmıştır. Bu süreçte tiroid nodüllerinin sınıflandırılmasında %85'i aşan F1 skorları, karaciğer tümörü tespitinde ulaşılan %99,5'lik doğruluk oranları ve meme lezyonlarının değerlendirilmesindeki yüksek AUC değerleri, teknolojinin tanısal kesinlik üzerindeki önemli bir dönüşüm potansiyeli sunmaktadır. Erken teşhis kapasitesindeki bu artış, 2026 yılına kadar sadece ABD sağlık sisteminde yıllık 150 milyar dolarlık tasarruf öngörüsüyle birleştiğinde, YZ'nin maliyet etkinliğinin stratejik bir öncelik olduğu görülmektedir.

Ancak bu dönüşüm, sağlık profesyonellerinin rollerini de kökten yeniden şekillendirmektedir. YZ sistemleri, hekimlerin yerini almaktan ziyade, onların bilişsel yükünü azaltan ve özellikle radyoloji, patoloji gibi görüntü yoğun branşlarda "ikinci bir göz" olarak işlev gören birer asistan niteliğindedir. Araştırmalar, özellikle daha az deneyimli radyologların YZ desteğinden yararlanabildiğini ve bazı çalışmalarda tanısal performanslarının daha deneyimli uzmanların düzeyine yaklaşılabildiğini düşündürmektedir. Bununla birlikte, rutin ve idari görevlerin otomasyonu, sağlık çalışanlarının tükenmişlik sendromunu azaltma fırsatı sunarken, mesleki rollerin teknik yetkinlik ve dijital okuryazarlık temelinde yeniden tanımlanmasını gerektirmektedir.

Bununla birlikte, veri güvenliği, etik sorumluluk ve düzenleyici çerçevelere ilişkin belirsizlikler, yapay zekâ uygulamalarının sağlık hizmetlerine yaygın entegrasyonu açısından önemli zorluklar olarak değerlendirilmektedir. Algoritmaların "kara kutu" niteliği, klinik kararların şeffaflığı ve hesap verebilirliği konusunda ciddi güven endişelerine yol açabilecek bir unsur olarak değerlendirilmektedir. Ayrıca, eğitim setlerindeki eksiklikler nedeniyle ortaya çıkan algoritmik önyargıların, özellikle azınlık gruplar üzerinde yanlış tanı riskini artırması, etik bir kriz potansiyeli taşımaktadır. Avrupa Birliği'nin YZ Yasası ve GDPR gibi düzenlemeler bu riskleri dizginlemeye yönelik adımlar olsa da, tıbbi hata durumunda hukuki sorumluluğun kimde olduğu sorusu hala net bir uluslararası standarttan yoksundur. YZ'nin insani empati ve etik muhakeme kapasitesinin sınırlı olması, yapay zekâ uygulamalarının klinik karar süreçlerinde insan denetimi ve gözetimi altında kullanılmasının önemine işaret etmektedir.

Geleceğe yönelik perspektifte, YZ'nin tıbbi görüntüleme (Qure.ai, Infervision gibi sistemlerle örneklenen süreçler), Nesnelerin İnterneti ve bulut bilişim ile daha derin bir entegrasyon kuracağı öngörülmektedir. Çok modlu görüntüleme sistemlerinin yaygınlaşması, hastaya özel biyobelirteçlerin büyük veri analitiği ile birleştirilmesi ve tele-tıp uygulamalarıyla sağlık hizmetlerinin kırsal bölgelere ulaştırılması, küresel sağlık eşitliği için büyük fırsatlar sunmaktadır. Sınırlılıklar arasında yer alan yüksek kurulum maliyetleri ve sistemler arası birlikte çalışabilirlik sorunları, standart terminolojilerin geliştirilmesi ve kurumsal kültürün dönüşümüyle aşılabilecektir.

Sonuç olarak, mevcut literatür yapay zekânın sağlık bilimlerinde yalnızca bir yardımcı araç olmanın ötesinde, akıllı sağlık yönetiminin gelişimini destekleme potansiyeline sahip stratejik bir

teknoloji olarak değerlendirildiğini göstermektedir. Akademik değerlendirmeler, teknik gelişimin toplumsal bir ilerlemeye dönüşebilmesi için etik kurallar, sağlam yasal çerçeveler ve insan odaklı tasarım stratejilerinin kritik öneme sahip olduğuna işaret etmektedir. Geleceğe yönelik mevcut vizyon, yapay zekânın sağlık profesyonellerinin yerini aldığı bir modelden ziyade, veriye dayalı karar verme süreçlerini destekleyerek sağlık profesyonellerinin kişiselleştirilmiş, güvenli ve erişilebilir sağlık hizmetleri sunmasını destekleyen bütünleşik bir dijital sağlık ekosistemine işaret etmektedir.

KAYNAKÇA

Agarwal, R., Gao, G., DesRoches, C., & Jha, A. K. (2010). Research commentary—The digital transformation of healthcare: Current status and the road ahead. *Information Systems Research*, 21(4), 796–809. <https://doi.org/10.1287/isre.1100.0327>

Aidoc. (2026). *AI-powered medical imaging solutions (EU)*. <https://www.aidoc.com/eu/>

Akkus, Z., Cai, J., Boonrod, A., Zeinoddini, A., Weston, A. D., Philbrick, K. A., ve Erickson, B. J. (2019). A survey of deep-learning applications in ultrasound: Artificial intelligence-powered ultrasound for improving clinical workflow. *Journal of the American College of Radiology*, 16, 1318–1328. <https://doi.org/10.1016/j.jacr.2019.06.004>

Alimiri Dehbaghi, H., ve Khoshgard, K. (2025). Revolutionizing emergency care: An overview of the transformative role of artificial intelligence in diagnosis, triage, and patient management. *International Journal of Emergency Medicine (Online)*, 18(1), 242. doi:<https://doi.org/10.1186/s12245-025-01049-1>

American Medical Association. (2021, July 16). *Clinical case study: Telehealth for hypertension*. Retrieved December 29, 2025, from <https://www.ama-assn.org/public-health/prevention-wellness/clinical-case-study-telehealth-hypertension>

Anisuzzaman, D. M., Malins, J. G., Jackson, J. I., Lee, E., Naser, J. A., Rostami, B., . . . Attia, Z. I. (2026). A view-flexible deep learning framework for automated analysis of 2D echocardiography. *NPJ Cardiovascular Health*, 3(1), 17. doi:<https://doi.org/10.1038/s44325-025-00100-7>

Arnett, A. (2025). FDA clears AI software for ultrasound-guided nerve blocks. Los Angeles: Anthem Media Group. Retrieved from <https://www.proquest.com/other-sources/fda-clears-ai-software-ultrasound-guided-nerve/docview/3241001283/se-2>

Aruleba, R. T., Adekiya, T. A., Ayawei, N., Obaïdo, G., Aruleba, K., Mienye, I. D., *et al.* (2022). COVID-19 diagnosis: A review of rapid antigen, RT-PCR and artificial intelligence methods. *Bioengineering*, 9(4), 153. <https://doi.org/10.3390/bioengineering9040153>

Bahl, M. (2024). Combining AI and radiomics to improve the accuracy of breast US. *Radiology*, 312(3). <https://doi.org/10.1148/radiol.241795>

Behnam, F., Khajouei, R., Nabizadeh, A. H., Saedi, S., ve Ghaemi, M. M. (2023). Usability evaluation of emergency information systems in educational hospitals in Kerman, Iran. *BMC Medical Informatics and Decision Making*, 23(1), 277. <https://doi.org/10.1186/s12911-023-02357-3>

Betancourt, M. (2020). *Force magnifier: The cultural impacts of artificial intelligence*. Wildside Press LLC.

Bizalwan, D. S., Kumar, R., Kumar, A., & Gong, Y. Y. (2025). Enhancing Healthcare with Artificial Intelligence: A Configurational Integration of Complementary Technologies and Stakeholder

Needs. Communications of the Association for Information Systems, 57, 384-417. <https://doi.org/10.17705/1CAIS.05715>

Caption Health. (2024). *AI-guided cardiac ultrasound solutions*. <https://www.caption-care.com/>

Chen, M. C., Ball, R. L., Yang, L., Moradzadeh, N., Chapman, B. E., Larson, D. B., *et al.*, & Lungren, M. P. (2017). Deep learning to classify radiology free-text reports. *Radiology*, 286(3), 845–852. <https://doi.org/10.1148/radiol.2017171115>

Chaturvedi, A. (2023). Defining legal responsibility in the age of AI: Addressing gaps in data privacy regulation. *Indian Journal of Integrated Research in Law*, 3(1).

Chibuzor, U., Voicu-Dorobanțu Roxana, Ogunyemi, A. A., Alex, N., Nata, S., & Craß Stefan. (2025). Leveraging blockchain for ethical AI: Mitigating digital threats and strengthening societal resilience. *Future Internet*, 17(7), 309. doi:<https://doi.org/10.3390/fi17070309>

Çelebi, F., Tuncer, O., Oral, M., Duymaz, T., Orhan, T., & Ertaş, G. (2025). Artificial intelligence in diagnostic breast ultrasound: A comparative analysis of decision support among radiologists with various levels of expertise. *European Journal of Breast Health*, 21(1), 33-39. doi:<https://doi.org/10.4274/ejbh.galenos.2024.2024-9-7>

Çilhoroz, Y., ve Işık, O. (2021). Yapay zekâ: Sağlık hizmetlerinden uygulamalar. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23(2), 573–588.

da Silva, L. M., & Athanazio, D. A. (2026). Real world experience on digital transformation and deployment of artificial intelligence tools across a network of pathology laboratories in brazil. *Surgical and Experimental Pathology*, 9(1), 17. doi:<https://doi.org/10.1186/s42047-026-00229-4>

Dhariwal, K., & Mehta, A. (2017). Architecture and plan of smart hospital based on Internet of Things (IoT). *International Research Journal of Engineering and Technology*, 4(4), 1976–1980.

Dogan, Y., Az, A., Sogut, O., Akdemir, T., Ergenc, H., Umit, T. B., . . . Ozturk, M. F. (2026). Domain-specific and computer-vision-driven versus general-purpose AI models in PA-CXR analysis: A comparative study with emergency-medicine specialists. *Journal of Imaging Informatics in Medicine*, doi:<https://doi.org/10.1007/s10278-025-01806-x>

Epic. (2026). *Epic Health System Community*. 6 Şubat 2026 tarihinde <https://www.epic.com/community/> adresinden erişildi.

Esmailzadeh P (2020) Use of AI-based tools for healthcare purposes: a survey study from consumers' perspectives. *BMC Med Inf Decis Mak* 20(1). <https://doi.org/10.1186/s12911-020-01191-1>

European Commission. (2022). *Legal framework of EU data protection*. 18 Nisan 2026 tarihinde https://commission.europa.eu/law/law-topic/data-protection/legal-framework-eu-data-protection_en adresinden erişildi.

European Union Agency for Network and Information Security. (2016). *Smart hospitals: Security and resilience for smart health service and infrastructures*. 18 Nisan 2026 tarihinde <https://www.enisa.europa.eu/publications/cyber-security-and-resilience-for-smart-hospitals> adresinden erişildi.

Evans, J. (2018, Ağustos). How Apple's AI imaging vision may save lives. *Computerworld*. 18 Nisan 2026 tarihinde <https://www.computerworld.com/article/1699377/how-apple-s-ai-imaging-vision-may-save-lives.html> adresinden erişildi.

Gallant, C., Bernard, L., Cherise, K., Stephanie, W., Noga, M., Kumaradevan, P., . . . Jaremko Jacob L. (2025). AI-augmented point of care ultrasound in intensive care unit patients: Can novices perform a “Basic echo” to estimate left ventricular ejection fraction in this acute-care setting? *Journal of Clinical Medicine*, 14(9), 2899. doi:<https://doi.org/10.3390/jcm14092899>

Gandhi, S., Mosleh, W., Shen, J., & Chow, C. M. (2018). Automation, machine learning, and artificial intelligence in echocardiography: A brave new world. *Echocardiography*, 35, 1402–1418. <https://doi.org/10.1111/echo.14086>

Garg, T., John, S., Abdulkarim, S., Ahmed, A. D., Kirubi, B., Rahman, M. T., Ubochioma, E., & Creswell, J. (2025). Implementation costs and cost-effectiveness of ultraportable chest X-ray with artificial intelligence in active case finding for tuberculosis in Nigeria. *PLOS Digital Health*, 4(6), e0000894. <https://doi.org/10.1371/journal.pdig.0000894>

GE HealthCare. (2026). *Imaging products | GE HealthCare*. 6 Şubat 2026 tarihinde <https://www.gehealthcare.com/products/imaging> adresinden erişildi.

Geoghegan, L., Scarborough, A., Wormald, J. C. R., Harrison, C. J., Collins, D., Gardiner, M., Bruce, J., & Rodrigues, J. N. (2021). Automated conversational agents for post-intervention follow-up: A systematic review. *BJS Open*, 5(4), zrab070. <https://doi.org/10.1093/bjsopen/zrab070> Goldenberg, S., Nir, G., & Salcudean, S. E. (2019). A new era: Artificial intelligence and machine learning in prostate cancer. *Nature Reviews Urology*, 16, 391–403. <https://doi.org/10.1038/s41585-019-0193-3>

Gopal, G., Suter-Crazzolara, C., Toldo, L., & Eberhardt, W. (2019). Digital transformation in healthcare: Architectures of present and future information technologies. *Clinical Chemistry and Laboratory Medicine*, 57(3), 328–335. <https://doi.org/10.1515/cclm-2018-0658>

Hirata, Y., Nomura, Y., Saijo, Y., Sata, M., & Kusunose, K. (2024). Reducing echocardiographic examination time through routine use of fully automated software: A comparative study of measurement and report creation time. *Journal of Echocardiography*, 22(3), 162-170. doi:<https://doi.org/10.1007/s12574-023-00636-6>

Hu, H., Su, J., & Ma, J. (2022). Editorial: Smart hospital innovation: Technology, service, and policy. *Frontiers in Public Health*, 10, 845577. <https://doi.org/10.3389/fpubh.2022.845577>

Hussain, A., Umair, M., Khan, S., Alonazi, W. B., Almutairi, S. S., & Malik, A. (2024). Exploring sustainable healthcare: innovations in health economics, social policy, and management. *Heliyon*, 10(13). <https://doi.org/10.1016/j.heliyon.2024.e33186>.

IBM Institute for Business Value. (2023). *Healthcare in the AI era: Leading through trust, value and transformation*. IBM. 18 Nisan 2026 tarihinde <https://www.ibm.com/downloads/documents/us-en/1379d330685ae497> adresinden erişildi.

Infervision. (2025). *AI medical imaging, empowering the patient journey*. Ocak 2026 tarihinde <https://global.infervision.com/> adresinden erişildi.

Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human–AI symbiosis in organizational decision making. *Business Horizons*, 61(4), 577–586. <https://doi.org/10.1016/j.bushor.2018.03.007>

Jensen, J. L., Peterson, S. K., Sambade, M. J., Alley, J. R., Yu, S., Kinjo, T., et al. (2026). Shared PRAME epitopes are T-cell targets in NUT carcinoma. *Journal for ImmunoTherapy of Cancer*, 14, e013539. <https://doi.org/10.1136/jitc-2025-013539>

Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., et al. (2017). Artificial intelligence in healthcare: Past, present and future. *Stroke and Vascular Neurology*, 2, e000101. <https://doi.org/10.1136/svn-2017-000101>

Johnson, D. B., Binyam, Y., Stamatini, F., Metamia, C., O’Grady Tina, Park, B. H., & Balko, J. M. (2025). 136 Ultrahigh tumor mutational burden (TMB) is associated with improved survival outcomes in patients (pts) treated with immune checkpoint inhibitors (ICIs). *Journal for Immunotherapy of Cancer*, 13, A151-A152. doi:<https://doi.org/10.1136/jitc-2025-SITC2025.0136>

Kaldoudi, E. (2023). Smart hospital: The future of healthcare. *Computational and Structural Biotechnology Journal*, 24, 87–88. <https://doi.org/10.1016/j.csbj.2023.12.011>

Kalis, B., Collier, M., & Fu, R. (2018). *10 promising AI applications in health care*. *Harvard Business Review*, 2–5.

Kenny, P. A. (2026). *Pathogenicity assessment of a TSC2 c.2966+1G>A splice site variant in vaginal adenocarcinoma* [Preprint]. medRxiv. <https://doi.org/10.64898/2025.12.31.25343109>

Khanna, S., Sattar, A., & Hansen, D. (2013). Artificial intelligence in health: The three big challenges. *The Australasian Medical Journal*, 6(5), 315–317. <https://doi.org/10.4066/AMJ.2013.1758>

Kim, S. J., Roh, J. W., Kim, S., Park, J. Y., & Choi, D. (2020). Current State and Strategy for Establishing a Digitally Innovative Hospital: Memorial Review Article for Opening of Yongin Severance Hospital. *Yonsei medical journal*, 61(8), 647–651. <https://doi.org/10.3349/ymj.2020.61.8.647>

Klinker, K., Wiesche, M., & Krcmar, H. (2020). Digital transformation in health care: Augmented reality for hands-free service innovation. *Information Systems Frontiers*, 22, 1419–1431. <https://doi.org/10.1007/s10796-019-09937-7>

Ko, E. Y. (2014). *S-Detect™ in breast ultrasound: Initial experience*. Samsung Medical Center, Sungkyunkwan University School of Medicine. 18 Nisan 2026 tarihinde https://images.samsung.com/is/content/samsung/assets/pl/business/ultrasonograf/wiedza/White_Paper_S-Detect_Breast_1_RS80A_2014.pdf adresinden erişildi.

Koios Medical. (2024). *Koios DS: AI-powered ultrasound decision support*. 5 Mart 2026 tarihinde <https://koiosmedical.com/> adresinden erişildi.

Kononenko, I. (2001). Machine learning for medical diagnosis: History, state of the art and perspective. *Artificial Intelligence in Medicine*, 23(1), 89–109. [https://doi.org/10.1016/S0933-3657\(01\)00077-X](https://doi.org/10.1016/S0933-3657(01)00077-X)

König, M., Sander, A., Demuth, I., Diekmann, D., & Steinhagen-Thiessen, E. (2019). Knowledge-based best of breed approach for automated detection of clinical events based on German free text digital hospital discharge letters. *PloS one*, 14(11), e0224916. <https://doi.org/10.1371/journal.pone.0224916>

Krasuska, M., Williams, R., Sheikh, A., *et al.* (2020). Technological capabilities to assess digital excellence in hospitals in high performing health care systems: International eDelphi exercise. *Journal of Medical Internet Research*, 22(8), e17022. <https://doi.org/10.2196/17022>

Krittanawong, C., Zhang, H., Wang, Z., *et al.* (2017). Artificial intelligence in precision cardiovascular medicine. *Journal of the American College of Cardiology*, 69(21), 2657–2664. <https://doi.org/10.1016/j.jacc.2017.03.571>

Kwon, H., An, S., Lee, H.-Y., *et al.* (2022). Review of smart hospital services in real healthcare environments. *Healthcare Informatics Research*, 28(1), 3–15. <https://doi.org/10.4258/hir.2022.28.1.3>

Laux, J., Wachter, S., & Mittelstadt, B. (2024). Trustworthy artificial intelligence and the European Union AI Act: On the conflation of trustworthiness and acceptability of risk. *Regulatory Governance*, 18, 3–32. <https://doi.org/10.1111/rego.12512>

Li, Y., Li, Q., Fu, K., Zhou, X., & Zhang, K. (2025). Progress in the application of artificial intelligence in ultrasound-assisted medical diagnosis. *Bioengineering*, 12(3), 288. doi:<https://doi.org/10.3390/bioengineering12030288>

Loppini, M., Gambaro, F. M., Chiappetta, K., Grappiolo, G., Bianchi, A. M., & Corino, V. D. A. (2022). Automatic identification of failure in hip replacement: An artificial intelligence approach. *Bioengineering*, 9(7), 288. <https://doi.org/10.3390/bioengineering9070288>

Marques, I. C. P., & Ferreira, J. J. M. (2020). Digital transformation in the area of health: Systematic review of 45 years of evolution. *Health and Technology*, 10, 575–586. <https://doi.org/10.1007/s12553-019-00402-8>

Mateusz, D., Kacała Arkadiusz, Tołkacz Aleksandra, Aleksandra, K., Maja, G., & Guziński Maciej. (2026). Transforming stroke diagnosis with artificial intelligence: A scoping review of brainomix e-stroke, aidoc, RapidAI, and viz.ai. *Medicina*, 62(3), 582. doi:<https://doi.org/10.3390/medicina62030582>

McDougall, R. J. (2019). No we shouldn't be afraid of medical AI; it involves risks and opportunities. *Journal of Medical Ethics*, 45(8), 559. <https://doi.org/10.1136/medethics-2019-105572>

Milne-Ives, M., de Cock, C., Lim, E., Shehadeh, M. H., de Pennington, N., Mole, G., Normando, E., & Meinert, E. (2020). The effectiveness of artificial intelligence conversational agents in health care: Systematic review. *Journal of Medical Internet Research*, 22(10), e20346. <https://doi.org/10.2196/20346>

Muda, N., & Sulaiman, M. H. (2026). Adapting quality function deployment to translate patient feedback into prioritized technical requirements for healthcare artificial intelligence. *Scientific Reports*, 16(1), 5713. <https://doi.org/10.1038/s41598-026-36550-x>

Narang, A., Bae, R., Hong, H., et al. (2021). Utility of a deep-learning algorithm to guide novices to acquire echocardiograms for limited diagnostic use. *JAMA Cardiology*, 6(6), 624–632. <https://doi.org/10.1001/jamacardio.2021.0185>

Nerveblox, the ultrasound AI for regional anaesthesia receives US FDA 510(k) clearance. (2025, 20 Ağustos). *PharmaBiz*. 6 Mart 2026 tarihinde <https://www.proquest.com/magazines/nerveblox-ultrasound-ai-regional-anaesthesia/docview/3241208613/se-2> adresinden erişildi.

Neuwirth, R. J. (2023). Prohibited artificial intelligence practices in the proposed EU Artificial Intelligence Act (AIA). *Computer Law & Security Review*, 51, 105798. <https://doi.org/10.1016/j.clsr.2023.105798>

Paige. (2026). *Request a trial – Paige AI*. Retrieved February 6, 2026, from <https://www.paige.ai/request-a-trial>

OECD. (2022). *OECD framework for the classification of AI systems*. OECD Publishing. 18 Nisan 2026 tarihinde https://www.oecd.org/en/publications/oecd-framework-for-the-classification-of-ai-systems_cb6d9eca-en.html adresinden erişildi.

Qure.ai. (2026). *AI assistance for accelerated healthcare*. 7 Mart 2026 tarihinde <https://www.qure.ai/> adresinden erişildi.

Rabiei, R., Dehghan, S., Hsu, W.-C., Bastani, P., Almasi, S., & Mortezaei, S. (2025). Transition toward smart hospitals: A scoping review of features, technologies, and challenges. *Health Science Reports*, 8, e71601. <https://doi.org/10.1002/hsr2.7160>

Ramesh, A. N., Kambhampati, C., Monson, J. R. ve Drew, P. J. (2004). Artificial intelligence in medicine. *Annals of the Royal College of Surgeons of England*, 86(5), 334-338.

Rashid, Z., Ahmed, H., Nadeem, N., Zafar, S. B., & Yousaf, M. Z. (2025). The paradigm of digital health: AI applications and transformative trends. *Neural Computing & Applications*, 37(17), 11039-11070. doi:<https://doi.org/10.1007/s00521-025-11081-0>

Reddy, S., Fox, J., & Purohit, M. P. (2018). Artificial intelligence-enabled healthcare delivery. *Journal of the Royal Society of Medicine*, 112(1), 22–28. <https://doi.org/10.1177/0141076818815510>

Rigla, M., García-Sáez, G., Pons, B., & Hernando, M. E. (2017). Artificial intelligence methodologies and their application to diabetes. *Journal of Diabetes Science and Technology*, 12(2), 303–310. <https://doi.org/10.1177/1932296817710475>

Roubal, O., & Narusevych, K. (2025). The panorama of artificial intelligence – development or advancement? *Communication Today*, 16(1). <https://doi.org/10.34135/communicationtoday.2025.Vol.16.No.1.4>

Sahu CK, Young C, Rai R (2021) Artificial intelligence (AI) in augmented reality (ar)-assisted manufacturing applications: a review. *Int J Prod Res* 59(16):4903–4959. <https://doi.org/10.1080/00207543.2020.1859636>

Samek, W., & Müller, K. R. (2019). Towards explainable artificial intelligence. In W. Samek, G. Montavon, A. Vedaldi, L. K. Hansen, & K. R. Müller (Eds.), *Explainable AI: Interpreting, explaining and visualizing deep learning* (pp. 5–22). Springer.

Sanjeevi, G., Gopalakrishnan, U., Parthinarupothi, R. K., & Madathil, T. (2024). Deep learning supported echocardiogram analysis: A comprehensive review. *Artificial Intelligence in Medicine*, 151, 102866. <https://doi.org/10.1016/j.artmed.2024.102866>

Shah, W. S., Elkhwesky, Z., Jasim, K. M., Elkhwesky, E. F. Y., & Elkhwesky, F. F. Y. (2024). Artificial intelligence in healthcare services: Past, present and future research directions. *Review of Managerial Science*, 18(3), 941-963. doi:<https://doi.org/10.1007/s11846-023-00699-w>

Shan, R., Pei, C., Fan, Q., Liu, J., Wang, D., Yang, S., & Wang, X. (2025). Artificial intelligence-assisted platform performs high detection ability of hepatocellular carcinoma in CT images: An external clinical validation study. *BMC Cancer*, 25, 1-13. doi:<https://doi.org/10.1186/s12885-025-13529-x>

Stahl, B. C., & Leach, T. (2023). Assessing the ethical and social concerns of artificial intelligence in neuroinformatics research: An empirical test of the European Union Assessment List for Trustworthy AI (ALTAI). *AI and Ethics*, 3, 745–767. <https://doi.org/10.1007/s43681-022-00201-4>

Steerling, E., Siira, E., Nilsen, P., Svedberg, P., & Nygren, J. (2023). *Implementing AI in healthcare—The relevance of trust: A scoping review*. *Frontiers in Health Services*, 3, 1211150. <https://doi.org/10.3389/frhs.2023.1211150>

Stephanie, L., & Sharma, R. S. (2020). Digital health eco-systems: An epochal review of practice-oriented research. *International Journal of Information Management*, 53, 102032. <https://doi.org/10.1016/j.ijinfomgt.2019.10.017>

Stephens, K. (2024). GE HealthCare debuts Caption AI for rapid cardiac assessment. *AXIS Imaging News*. 18 Nisan 2026 tarihinde <https://www.proquest.com/scholarly-journals/ge-healthcare-debuts-caption-ai-rapid-cardiac/docview/3037168498/se-2> adresinden erişildi.

Tagliaferri SD, Angelova M, Zhao X, Owen PJ, Miller CT, Wilkin T, Belavy DL (2020) Artificial intelligence to improve back pain outcomes and lessons learnt from clinical classification approaches: three systematic reviews. *npj Digit Med* 3(1). <https://doi.org/10.1038/s41746-020-0303-x>

Tajik, A. (2016). Machine learning for echocardiographic imaging: Embarking on another incredible journey. *Journal of the American College of Cardiology*, 68(21), 2296–2298. <https://doi.org/10.1016/j.jacc.2016.09.915>

Thrall, J. H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K., & Brink, J. (2018). Artificial intelligence and machine learning in radiology: Opportunities, challenges, pitfalls, and criteria for success. *Journal of the American College of Radiology*, 15(3, Pt B), 504–508. <https://doi.org/10.1016/j.jacr.2017.12.026>

Tierney, A. A., Gayre, G., Hoberman, B., Mattern, B., Ballesca, M., Kipnis, P., Liu, V., & Lee, K. (2024). *Ambient artificial intelligence scribes to alleviate the burden of clinical documentation*. *NEJM Catalyst Innovations in Care Delivery*, 5(3). <https://doi.org/10.1056/CAT.23.0404>

Uslu, B. Ç., Okay, E., & Dursun, E. (2020). Analysis of factors affecting IoT-based smart hospital design. *Journal of Cloud Computing*, 9(1), 67. <https://doi.org/10.1186/s13677-020-00215-5>

Van Maanen, G. (2022). AI ethics, ethics washing, and the need to politicize data ethics. *Digital Society*, 1(2), 1–23. <https://doi.org/10.1007/s44206-022-00013-3>

Vega, R., Kwok, C., Rakkunedeth Hareendranathan, A., Nagdev, A., & Jaremko, J. L. (2024). Assessment of an artificial intelligence tool for estimating left ventricular ejection fraction in echocardiograms from apical and parasternal long-axis views. *Diagnostics*, 14, 1719. <https://doi.org/10.3390/diagnostics14161719>

Vesnic-Alujevic, L., Nascimento, S., & Polvora, A. (2020). Societal and ethical impacts of artificial intelligence: Critical notes on European policy frameworks. *Telecommunications Policy*, 44, 101961. <https://doi.org/10.1016/j.telpol.2020.101961>

Viz.ai. (2026). *Transforming healthcare with AI-powered care coordination* | Viz.ai. 7 Mart 2026 tarihinde <https://www.viz.ai/> adresinden erişildi.

Wang, B., Zheng, H., Qian, K., Zhan, X., & Wang, J. (2024). Edge computing and AI-driven intelligent traffic monitoring and optimization. *Applied and Computational Engineering*, 77, 225–230. <https://doi.org/10.54254/2755-2721/67/2024MA0062>

Xu, W., Jia, X., Mei, Z., Gu, X., Lu, Y., Fu, C.-C., *et al.* (2023). Generalizability and diagnostic performance of AI models for thyroid US. *Radiology*, 307(5). <https://doi.org/10.1148/radiol.221157>

Yang, F., & Graetz, I. (2026). Ambient AI tool adoption in US hospitals and associated factors. *The American Journal of Managed Care*, 32(1), e25-e30. doi:<https://doi.org/10.37765/ajmc.2026.89876>

Yannier, N., Hudson, S. E., & Koedinger, K. R. (2020). Active learning is about more than hands-on: A mixed-reality AI system to support STEM education. *International Journal of Artificial Intelligence in Education*, 30, 74–96. <https://doi.org/10.1007/s40593-020-00194-3>

Yao, W., Chu, C. H., & Li, Z. (2011). Leveraging complex event processing for smart hospitals using RFID. *Journal of Network and Computer Applications*, 34(3), 799-810. <https://doi.org/10.1016/j.jnca.2010.04.020>

Zegarra, R. R., & Ghi, T. (2023). Use of artificial intelligence and deep learning in fetal ultrasound imaging. *Ultrasound in Obstetrics & Gynecology*, 62, 185–194. <https://doi.org/10.1002/uog.26130>

Zhang, L., Wu, J., Yang, J., Chen, S. S., Liu, J. P., Zhang, P., Chu, J., & Luo, C. L. (2023). Development and application evaluation of a nursing simulation teaching information system based on hospital information systems. *International Journal of Clinical Practice*, 2023, 6334967. <https://doi.org/10.1155/2023/6334967>

Zuboff, S. (2019). *The age of surveillance capitalism: The fight for a human future at the new frontier of power*. New York, NY: PublicAffairs. 18 Nisan 2026 tarihinde <https://www.hbs.edu/faculty/Pages/item.aspx?num=56791> adresinden erişildi.