

Sağlık Hizmetlerinde Yapay Zekâ Kullanımı: Dönüşüm, Yenilik ve Gelecek Öngörülleri 8

Emre Karasu¹

Lale Karasu²

Özet

Yapay zekâ, sağlık hizmetlerinde hem klinik hem yönetsel süreçleri dönüştüren güçlü bir teknolojik bileşen haline gelmiştir. Bu bölümde, yapay zekânın tanı sistemlerinden tedavi planlamasına, kronik hastalık yönetiminden hastane operasyonlarına kadar geniş bir yelpazede sunduğu katkılar incelenmiştir. Özellikle tıbbi görüntüleme, kişiselleştirilmiş tıp, mobil sağlık uygulamaları ve acil servis yönetimine yönelik örnek olaylar, yapay zekânın sağlık hizmetlerinin hızını, doğruluğunu ve verimliliğini artırdığını göstermektedir.

Bununla birlikte, yapay zekâ kullanımının yaygınlaşması mahremiyet, veri güvenliği, algoritmik yanlılık, kararların açıklanabilirliği ve hukuki sorumluluk gibi çeşitli riskleri beraberinde getirmektedir. Bu nedenle teknolojik ilerlemelerin etik ilkeler ve uygun düzenleyici çerçevelerle desteklenmesi büyük önem taşımaktadır. Sağlık çalışanlarının yapay zekâ okuryazarlığı, sistemlerin şeffaflığı ve güvenli altyapılar, sürdürülebilir bir uygulama için kritik unsurlardır.

Gelecek yıllarda yapay zekânın sağlıkta etkisinin daha da artacağı öngörülmektedir. Tam otomatik görüntüleme raporları, dijital ikiz uygulamaları, biyoteknoloji ile entegre yapay zekâ temelli ilaç keşifleri ve yapay zekâ destekli hastane yönetim sistemleri, sağlık hizmetlerinin yapısını yeniden şekillendirecektir. Bu dönüşümün etkili ve güvenli şekilde yönetilebilmesi için insan merkezli yaklaşımlar, güncel düzenlemeler ve disiplinler arası işbirliği temel gerekliliklerdir.

1 Dr. Öğr. Üyesi, Niğde Ömer Halisdemir Üniversitesi, emrekarasu@ohu.edu.tr, <https://orcid.org/0000-0002-5638-8994>

2 Öğr. Gör., Erciyes Üniversitesi, laleozdemirkarasu@gmail.com, <https://orcid.org/0000-0001-9278-8779>

GİRİŞ

Sağlık hizmetleri, insan yaşamının her döneminde karşılaşılan risklere ve ihtiyaçlara yanıt üretmeye çalışan dinamik bir yapıya sahiptir. Toplumların gelişmişlik düzeyi ne olursa olsun, sağlık sistemleri sürekli bir baskı altındadır: artan nüfus, yaşlanan toplum yapısı, kronik hastalıkların yükselişi, sağlık çalışanı eksikliği ve maliyetlerin giderek yükselmesi... Tüm bu unsurlar, sağlık hizmetlerinin yalnızca mevcut kapasiteyle sürdürülemeyeceğini göstermektedir. Bu nedenle sağlık alanında son yıllarda ortaya çıkan en güçlü dönüşüm araçlarından biri yapay zekâ olmuştur.

Aslında tıpta teknoloji kullanımı yeni bir durum değildir. Radyolojiden laboratuvar otomasyonuna kadar birçok klinik süreç yıllardır bilgisayarlı sistemlerle desteklenmektedir. Ancak yapay zekânın sunduğu yetenekler, önceki teknolojilerden çok daha farklı bir seviyededir. Çünkü yapay zekâ yalnızca bilgiyi depolayan veya hesaplama yapan bir araç değil; örüntüleri tanıyabilen, tahmin üretebilen ve belirli ölçüde karar verebilen bir sistem mantığıyla çalışmaktadır. Bu nedenle sağlık hizmetlerinde yapay zekânın etkisi, diğer dijital teknolojilere kıyasla çok daha geniş bir dönüşüm yaratmaktadır (Topol, 2019).

Günümüzde sağlık kuruluşlarının karşı karşıya kaldığı en büyük sorunlardan biri, veri miktarının hızla artmasıdır. Hastaneler, laboratuvarlar, görüntüleme merkezleri, giyilebilir teknolojiler ve elektronik sağlık kayıtları; her gün milyonlarca veri üretmektedir. Bu verilerin bir kısmı klinik olarak doğrudan kullanılabilirken, önemli bir bölümü ancak işlendikten sonra anlam kazanabilmektedir. Hekimlerin tüm bu veriyi aynı hızda analiz etme kapasitesi doğal olarak sınırlıdır. Bu nedenle yapay zekâ modelleri, büyük veri kümeleri içerisinde anlamlı klinik bilgiyi çekerek sağlık çalışanlarının karar süreçlerini güçlendirmekte ve belirli hataların önüne geçmektedir.

Özellikle tıbbi görüntüleme alanında yapay zekânın etkisi daha erken hissedilmiştir. Derin öğrenme algoritmaları, insan gözüünün ayırt etmekte zorlanabileceği mikroskobik farklılıkları analiz edebilmekte; böylece kanser, damar hastalıkları veya nörolojik bozukluklar gibi kritik durumların daha erken fark edilmesine yardımcı olmaktadır. Ancak yapay zekânın önemi yalnızca tanı ile sınırlı değildir. Tedavi planlaması, ilaç doz ayarı, klinik risk skorlarının belirlenmesi, kronik hastalık yönetimi ve hatta hastanelerdeki operasyonel planlama gibi alanlarda da önemli kazanımlar sağlanmaktadır (Rajpurkar vd., 2022).

Yapay zekânın sağlık hizmetlerinde giderek yaygınlaşması, aynı zamanda bazı tartışmaları da beraberinde getirmiştir. Algoritmaların şeffaflığı,

veri güvenliği, mahremiyet, model yanlılığı ve hukuki sorumluluk gibi konular, sağlık alanında yanlış yönetildiğinde ciddi sonuçlara yol açabilecek başlıklardır. Bu nedenle yapay zekâ uygulamalarının teknik doğruluğu kadar, etik ve yönetim ilkeleri de büyük önem taşımaktadır. Sağlık profesyonelleri açısından bakıldığında yapay zekâ, uzmanlığın yerini alan değil; aksine karmaşık karar süreçlerini destekleyen bir iş ortağı olarak görülmelidir (Vayena vd., 2018).

Bu bölümün amacı, yapay zekânın sağlık hizmetlerinde nasıl bir dönüşüm yarattığını çok boyutlu bir çerçevede ortaya koymaktır. Burada yalnızca teknik uygulamalara değil; klinik etkiler, yönetsel kazanımlar, örnek olaylar, riskler ve geleceğe yönelik öngörülere de yer verilecektir. Böylece okuyucuya hem sağlık sektöründeki mevcut yapay zekâ uygulamalarının kapsamı hem de gelecekte bu alanda ortaya çıkabilecek yenilikler hakkında kapsamlı bir bakış açısı sunulacaktır.

Sonuç olarak yapay zekâ, sağlık sistemlerinin karşı karşıya olduğu sorunları tek başına çözmeyebilir; ancak doğru planlandığında hizmet kalitesini artıran, maliyetleri azaltan ve sağlık çalışanlarının yükünü hafifleten güçlü bir araçtır. Bu nedenle yapay zekâ, günümüz sağlık hizmetlerinin yalnızca teknolojik bir bileşeni değil, aynı zamanda yeni bir yönetim ve bakım anlayışının temel unsurlarından biridir.

1. Yapay Zekânın Sağlıkta Temelleri

Sağlık hizmetlerinde yapay zekâ (YZ) kullanımının temellerini anlamak, bu teknolojinin neden bu kadar hızlı yayıldığını ve klinik süreçlerde nasıl konumlandığını kavramak açısından önemlidir. YZ'nin tıptaki rolü, salt bilgisayar destekli bir teknolojiden öte, karar verme süreçlerini zenginleştiren bilişsel bir araç olarak tanımlanmaktadır. Bu nedenle YZ'nin sağlık alanındaki etkisini değerlendirirken önce, bu teknolojinin ne olduğuna, nasıl çalıştığına ve hangi veri kaynaklarıyla beslendiğine bakmak gerekir.

YZ, en genel anlamıyla, insanın düşünme ve öğrenme biçimlerine benzer süreçleri matematiksel modeller aracılığıyla taklit eden sistemlerdir (Russell & Norvig, 2020). Sağlık alanında kullanılan YZ sistemleri; sınıflandırma, tahmin, örüntü tanıma, optimizasyon ve doğal dil işleme gibi farklı görevleri yerine getirmek üzere tasarlanmıştır. Bu görevlerin çoğu, sağlık profesyonellerinin uzun süredir yürüttüğü işlemleri desteklemekle birlikte, YZ'nin ölçeklenebilirliği ve veri işleme kapasitesi bu süreçleri daha verimli hâle getirebilmektedir.

YZ'nin sağlıkta gelişimini hızlandıran en önemli unsur, veri bolluğu ve veri akış hızındaki artıştır. Elektronik sağlık kayıtları, biyometrik sensörler,

genom dizileme teknolojileri, tıbbi görüntüleme cihazları ve mobil sağlık uygulamaları, klinik kararların desteklenmesi için büyük bir veri havuzu oluşturmuştur. Bu veriler, tek tek ele alındığında sınırlı bilgi taşıyabilir; ancak YZ modelleri tarafından bir araya getirildiğinde, hastalık risklerinden tedavi yanıtlarına kadar pek çok konuda anlamlı sonuçlar ortaya koyabilmektedir.

Örneğin derin öğrenme modelleri, tıbbi görüntülerdeki karmaşık yapıları analiz ederek insan gözüyle fark edilmesi güç mikroskobik farklılıkları tespit edebilir. Bu tür uygulamaların amacı hekimleri devre dışı bırakmak değil, aksine karar süreçlerini zenginleştirerek bilimsel öngörüğü güçlendirmektir (Topol, 2019). Aynı şekilde, makine öğrenmesi tabanlı tahmin modelleri, kronik hastalıkların ilerleyişini öngörmekte veya yoğun bakım hastalarında kritik durumları erken işaretleyebilmekte kullanılmaktadır.

YZ'nin sağlıkta temellerinden biri de veri kalitesi ve model güvenilirliği konularıdır. Tıbbi veriler çoğu zaman kusurlu, eksik veya gürültülü olabilir. Ayrıca farklı hastanelerden elde edilen veriler arasında standardizasyon sorunları bulunabilir. Bu nedenle YZ modellerinin eğitimi sırasında veri temizliği, doğrulama ve klinik uzman görüşü büyük önem taşır. Aksi hâlde yanlış kalıplara dayanan modeller, klinik süreçlerde risk oluşturabilir. Bu durum, YZ'nin sağlık alanında sorunsuz işlemesi için insan-makine işbirliğinin zorunlu olduğunu göstermektedir.

YZ'nin sağlıkta temellerinin anlaşılması için bir diğer önemli başlık da etik sorumluluk ve algoritmik tarafsızlık konularıdır. Bir modelin eğitildiği veri seti, toplumun bir kesimini temsil etmiyor veya belirli gruplar hakkında yanlı örüntüler içeriyorsa, bu durum tedavi kararlarında da yanlı sonuçlara yol açabilir. Bu nedenle YZ modellerinin sağlık alanında kullanılabilmesi için şeffaflık, izlenebilirlik ve denetlenebilirlik ilkeleri titizlikle uygulanmalıdır (Vayena vd., 2018). Günümüzde birçok kurum, YZ sistemlerinin denetlenmesi için yeni yönetmelikler geliştirmektedir.

Sağlıkta YZ'nin temelleri yalnızca teknik detaylardan ibaret değildir; aynı zamanda örgütsel yapı, iş akışları ve sağlık profesyonellerinin rolü de bu temel içinde yer almaktadır. Klinik personelin YZ sistemlerini etkin kullanabilmesi için eğitim, adaptasyon ve güven mekanizmalarının kurulması gerekmektedir. Çünkü YZ sisteminin başarısı sadece algoritmanın doğruluğuna değil, aynı zamanda kullanıcıların sisteme duyduğu güvene ve günlük iş akışına entegrasyonuna bağlıdır.

Sonuç olarak, YZ'nin sağlıkta temelleri; veri bilimi, klinik bilgi, etik ilkeler ve yönetim modellerinin birlikte değerlendirilmesiyle anlaşılabilir. Bu temel yapı, bölümlerin ilerleyen kısımlarında ele alınacak olan teşhis,

tedavi, yönetim ve izleme uygulamalarının zeminini oluşturmaktadır. Şimdi bu temelin üzerine inşa edilen spesifik alt bileşenleri incelemek amacıyla bir sonraki alt bölüme geçilecektir.

1.1. Yapay Zekânın Tanımı ve Temel Bileşenleri

Yapay zekâ (YZ) kavramı, sağlık alanındaki güncel tartışmaların merkezinde yer almasına rağmen, çoğu zaman tek bir teknolojiymiş gibi değerlendirilir. Oysa YZ, farklı amaçlar için geliştirilmiş çok sayıda alt bileşenden oluşan geniş bir yöntem ve yaklaşım ailesidir. Bu nedenle sağlıktaki uygulamaları anlamak için önce YZ'nin temel yapısının açıklanması gerekir.

En geniş anlamıyla yapay zekâ, bir bilgisayar sisteminin “öğrenme”, “çıkarım yapma”, “örüntü tanıma”, “problem çözme” ve “karar verme” gibi insan zekâsını çağrıştıran işlevleri yerine getirebilme kapasitesi olarak tanımlanır (Russell & Norvig, 2020). Bu tanım, YZ'yi yalnızca bir yazılım aracı olmaktan çıkarıp belirli bilişsel yeteneklere sahip bir sistem hâline getirir. Bu nedenle YZ modelleri, özellikle sağlık verisi gibi karmaşık ve çok katmanlı bilgiler üzerinde etkili sonuçlar üretme potansiyeline sahiptir.

YZ'nin temel bileşenleri incelendiğinde, bu teknolojinin birkaç ana yapı taşı üzerinden geliştiği görülür. Bunlar arasında makine öğrenmesi, derin öğrenme, doğal dil işleme (NLP), öngörüselsel analitik, uzman sistemler ve robotik gibi alt alanlar bulunmaktadır. Her alt alan, sağlık hizmetlerinde farklı kullanım amaçlarına sahiptir ve çoğu zaman birbirini tamamlayıcı niteliktedir.

Makine öğrenmesi, YZ'nin en yaygın kullanılan bileşenlerinden biridir. Bu yaklaşımda algoritmalar, geçmiş verilere dayanarak örüntüler öğrenir ve geleceğe yönelik tahminlerde bulunur. Örneğin bir hastanın kalp yetmezliği riskini tahmin eden modeller, makine öğrenmesi yöntemleriyle geliştirilmiştir. Algoritmanın başarısı, büyük ölçüde eğitildiği verinin kalitesine ve çeşitliliğine bağlıdır. Makine öğrenmesi, klinik karar destek sistemlerinden epidemiyolojik öngörülere kadar pek çok alanda kullanılmaktadır (Obermeyer & Emanuel, 2016).

Derin öğrenme, makine öğrenmesinin daha ileri bir biçimi olarak düşünülebilir. Beyindeki nöron ağlarına benzer çok katmanlı yapılar kullanan bu yöntem, özellikle tıbbi görüntüleme alanında çarpıcı başarılar elde etmiştir. Manyetik Rezonans, Bilgisayarlı Tomografi ve Mamografi görüntülerinin analizinde derin öğrenme modellerinin insan uzmanlara yakın, hatta bazı durumlarda daha iyi performans gösterdiği çeşitli çalışmalarla ortaya konmuştur. Derin öğrenmenin en güçlü yönü, görüntüdeki karmaşık

yapıları otomatik olarak ayırt edebilmesi ve çok büyük veri setlerinde bile yüksek doğruluk sağlayabilmesidir.

Sağlık alanında giderek daha fazla önem kazanan bir diğer bileşen ise doğal dil işleme (NLP) teknolojileridir. Klinik notlar, hasta öyküleri, laboratuvar raporları ve diğer çoğu tıbbi kayıt, yapılandırılmamış serbest metinlerden oluşur. Bu veriler manuel olarak incelendiğinde zaman alıcı olabilir; ancak NLP teknikleri, metin içerisindeki anahtar bilgileri ayıklayarak klinik bakım süreçlerinin hızlanmasına katkı sağlar (Shickel vd., 2018). Örneğin acil servislerde triyaj notlarının NLP ile analiz edilmesi, riskli hastaların daha erken tanınmasına yardımcı olabilir.

YZ'nin bir başka önemli bileşeni olan öngörüsöl analitik, geçmiş verilere dayalı olarak gelecekteki klinik sonuçları öngörmeye çalışır. Yoğun bakım ünitelerinde ölüm riski tahmini, hastanelerde yatış süresi projeksiyonu veya bulaşıcı hastalıkların yayılımının modellenmesi gibi konular, bu analitik yöntemlerle desteklenmektedir. Bu modeller, hangi hastaların daha yakın izlemi gerektiği konusunda klinisyenlere önemli bilgiler sağlayabilir.

Uzman sistemler, YZ'nin daha kural tabanlı ve deneyimden beslenen yapısını oluşturur. Bu sistemler, belirli bir bilgi alanına ilişkin uzman görüşlerini formel kurallara dönüştürerek karar önerileri sunar. Günümüzde daha az popüler olsalar da, erken dönem tıbbi bilişim uygulamalarının temelini oluşturmuş ve birçok modern YZ sistemine zemin hazırlamıştır.

Son olarak robotik, YZ'nin fiziksel dünyayla etkileşim kurabilen bileşenidir. Akıllı robotik cerrahi sistemleri, rehabilitasyon robotları ve otomasyon cihazları, YZ modelleri ile entegre çalışarak operasyonların daha hassas bir şekilde yürütülmesini sağlar. Bu teknolojiler, insan yeteneklerini sınırlayan fiziksel kısıtların aşılmasına da yardımcı olmaktadır.

Bu bileşenlerin tümü, YZ'nin sağlık hizmetlerinde neden geniş bir etki alanı yarattığını açıklar. Her bileşen farklı bir işleve sahip olsa da, sağlık ekosisteminde hepsi ortak bir amaca hizmet eder: daha doğru, daha hızlı ve daha güvenli sağlık hizmeti sunmak. Bir sonraki alt bölümde, bu bileşenlerin sağlık özelinde nasıl şekillendiği ve klinik sistemlere nasıl uyarlandığı daha ayrıntılı biçimde ele alınacaktır.

1.1.1. Makine Öğrenmesi ve Derin Öğrenmenin Sağlıktaki Yeri

Makine öğrenmesi (ML-Machine Learning) ve derin öğrenme (DL-Deep Learning), yapay zekânın sağlık alanındaki en etkili ve en hızlı gelişen bileşenleri olarak görülmektedir. Bu iki yaklaşım, büyük veri kümeleri içerisindeki örüntüleri bulma ve bunlardan anlamlı sonuçlar çıkarma

konusunda oldukça başarılıdır. Sağlık hizmetlerinin doğası gereği yoğun veri üretmesi, ML ve DL modellerinin sağlık alanında kullanılmasını hem mümkün hem de gerekli hâle getirmiştir.

Makine öğrenmesi, temel olarak geçmiş verilerden öğrenen ve bu öğrenme sonucunda tahmin veya sınıflandırma yapan algoritmalarla oluşur. Sağlık sektöründe ML'nin en sık kullanıldığı alanlardan biri risk belirleme modelleridir. Örneğin hastaneye tekrar yatış ihtimalinin tahmin edilmesi, diyabet komplikasyonlarının erken tespiti veya yoğun bakımda ölüm riskinin belirlenmesi gibi çalışmalar ML modelleri sayesinde daha güvenilir biçimde yapılabilmektedir (Obermeyer & Emanuel, 2016). Bu tür risk modelleri, hem klinisyenlerin iş yükünü azaltmakta hem de hastaların daha erken müdahaleyle tedavi edilmesine imkân vermektedir.

Derin öğrenme ise ML'nin daha ileri bir formu olup, özellikle çok katmanlı yapay sinir ağları sayesinde yüksek karmaşıklıkta verileri analiz edebilir. Tıbbi görüntüleme bu teknolojinin en çok öne çıktığı alanlardan biridir. MRI, BT, PET (Pozitron Emisyon Tomografisi) ve mamografi gibi görüntüleme yöntemleri, yalnızca hekimlerin gözlemine bırakıldığında bazı ayrıntılar gözden kaçabilir. Derin öğrenme modelleri ise milyonlarca görüntüyü inceleyerek kendi öğrenme sürecini oluşturur ve bu sayede tümör, nodül, damar daralması veya doku bozuklukları gibi patolojik durumları yüksek doğrulukla ayırt edebilir (Rajpurkar vd., 2022).

Örneğin Google Health tarafından geliştirilen bir modelin mamografi görüntülerinde meme kanseri tespitinde insan uzmanlardan daha düşük yanlış pozitif oranına ulaştığı bildirilmiştir (McKinney vd., 2020). Benzer şekilde, akciğer nodüllerinin tespitinde kullanılan derin öğrenme tabanlı bilgisayar destekli sistemler, özellikle erken evre kanserlerde tanıyı hızlandırarak tedavi başarısını artırmaktadır. Bu gelişmeler, derin öğrenmenin yalnızca görüntü analizinde değil, aynı zamanda erken tanı açısından da kritik bir rol oynadığını göstermektedir.

Makine öğrenmesi ve derin öğrenmenin etkili olduğu bir diğer alan da metin ve ses analizidir. Klinik notlar, epikrizler, laboratuvar raporları ve hasta-hekim diyalogları, çoğu zaman yapılandırılmamış veri niteliği taşır. Bu verilerin manuel olarak incelenmesi hem zaman alıcı hem de yoruma açıktır. Doğal dil işleme (NLP) teknikleriyle entegre edilen ML modelleri, bu tür verilerden klinik açıdan anlamlı bilgiler çıkararak hekimlerin iş yükünü azaltmaktadır. Örneğin acil servise başvuran hastaların semptom açıklamalarından risk seviyesi çıkarabilen modeller, triyaj süreçlerinin daha etkin yürütülmesini sağlayabilir.

Bununla birlikte ML ve DL'nin sağlık alanında etkin olabilmesi için bazı koşulların sağlanması gerekmektedir. İlk olarak, modellerin eğitildiği verinin temiz, standart ve temsil edici olması önemlidir. Veri seti belirli bir demografik gruba fazla ağırlık veriyorsa, model bu gruplar dışındaki hastalarda hatalı sonuçlar üretebilir. Bu durum literatürde “algoritmik yanlılık” olarak tanımlanmakta ve sağlık alanında ciddi etik sorunlara yol açabilmektedir (Vayena vd., 2018).

İkinci olarak, ML ve DL modellerinin çıktılarının uzmanlar tarafından yorumlanabilir ve sorgulanabilir olması gerekir. Klinik karar süreçlerinde, modelin neden belirli bir tahmine ulaştığının anlaşılması önemlidir. “Açıklanabilir yapay zekâ (Explainable AI-XAI)” çalışmalarının yoğunlaşmasının nedeni de budur. Hekimler bir modelin karar mantığını görebildiğinde sisteme daha fazla güven duyar ve modelin klinik süreçlere entegrasyonu kolaylaşır.

Son olarak ML ve DL modellerinin sağlık alanında kullanımında göz ardı edilmemesi gereken bir konu da klinik doğrulama süreçleridir. Laboratuvar ortamında geliştirilen bir modelin gerçek hasta verilerinde aynı başarıyı göstermesi her zaman mümkün değildir. Bu nedenle modellerin sahada test edilmesi, kapsamlı denemelerden geçirilmesi ve sürekli izlenmesi gerekmektedir. Sağlık alanında yapay zekânın başarısı, yalnızca doğru teknik modellemeye değil, aynı zamanda bu modellerin gerçek yaşam koşullarında güvenilir biçimde çalışmasına bağlıdır.

Genel olarak değerlendirildiğinde makine öğrenmesi ve derin öğrenme, sağlık hizmetlerinde hem klinik hem de yönetsel süreçleri dönüştüren en etkili YZ yaklaşımlarıdır. Bir sonraki bölümde, bu alt teknolojilerin sağlık alanındaki özel uygulamalarına daha ayrıntılı örneklerle değinilecektir.

1.1.1.1. Sağlıkta Makine Öğrenmesi Uygulamalarının Sınıflandırılması

Makine öğrenmesinin sağlık alanındaki uygulamaları oldukça geniş bir yelpazeye yayılmakla birlikte, bu uygulamaları daha iyi anlamak için belirli sınıflandırmalar yapmak gereklidir. Sağlıkta kullanılan ML modelleri, amaçları, kullandıkları veri türü, karar yapıları ve çıktılarının niteliğine göre farklı kategorilere ayrılabilir. Bu sınıflandırma, hem geliştiricilerin doğru model seçimini yapmasını kolaylaştırmakta hem de klinisyenlerin algoritmaların çalışma mantığını daha iyi kavramasını sağlamaktadır.

Genel olarak sağlıkta makine öğrenmesi uygulamaları denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana başlık altında incelenir.

a) Denetimli Öğrenme Uygulamaları

Denetimli öğrenme (supervised learning), modelin giriş verileriyle birlikte doğru çıktıları da kullanarak eğitildiği bir öğrenme türüdür. Sağlık alanında en yaygın kullanılan ML (Machine Learning) yaklaşımıdır. Çünkü çoğu klinik veri, önceden etiketlenmiş ve sonuçları bilinen kayıtlardan oluşur.

Bu kategorideki uygulamalar genellikle sınıflandırma veya regresyon görevleri biçiminde karşımıza çıkar.

Sınıflandırma modelleri

Sınıflandırma, bir hastanın veya klinik örneğin belirli bir kategoriye atanmasını hedefler. Örneğin:

- Bir akciğer nodülünün malign veya benign sınıfında olup olmadığının tahmini,
- Bir hastanın yüksek, orta veya düşük risk grubuna atanması,
- Laboratuvar bulgularının normal veya anormal olarak sınıflandırılması.

Bu tür modeller, özellikle görüntüleme alanında geniş uygulama bulmaktadır. Derin öğrenme tabanlı sınıflandırıcılar, tıbbi görüntülerdeki patolojik alanları tespit ederek klinik tanıya katkı sağlar (Rajpurkar vd., 2022).

Regresyon modelleri

Regresyon ise belirli bir sayısal çıktının tahmin edilmesini amaçlar. Sağlık alanındaki örnekler:

- Hastanın hastanede kalış süresinin tahmini,
- Kan şekeri düzeyinin bir sonraki 24 saat içerisindeki seyrinin öngörülmesi,
- Yoğun bakımda mortalite riskinin yüzde olarak hesaplanması.

Bu modeller, sağlık yönetimi ve kronik hastalık izleminde önemli katkılar sağlar.

Denetimli öğrenmenin sağlıkta bu kadar yaygın kullanılmasının nedeni, birçok tıbbi sonucun net şekilde tanımlanmış olmasıdır. Doktorların koyduğu tanıları, patoloji sonuçları, laboratuvar raporları ve ölüm oranları model eğitimi için hazır etiket görevi görür.

b) Denetimsiz Öğrenme Uygulamaları

Denetimsiz öğrenme (unsupervised learning), modelin yalnızca giriş verilerini kullanarak kendi içinde örüntüler bulmasını amaçlayan bir

yaklaşımıdır. Sağlık verileri çoğu zaman heterojendir ve bilinmeyen ilişkiler içerir. Bu nedenle denetimsiz öğrenme, yeni tıbbi keşifler yapılmasını sağlayan güçlü bir araçtır.

Bu kategoriye giren başlıca yöntemler:

Kümeleme (Clustering)

Kümeleme, benzer özelliklere sahip hastaları veya verileri bir araya getirir. Örneğin:

- Diyabet hastalarının klinik profillerine göre alt gruplara ayrılması,
- Kanseri hastalarının genetik mutasyonlarına göre yeni alt tiplerin belirlenmesi,
- Yoğun bakım hastalarının fizyolojik veriler üzerinden risk kümelerine ayrılması.

Bu yöntem, kişiselleştirilmiş tıp için kritik bilgiler sağlar (Esteva vd., 2019).

Boyut indirgeme (Dimensionality Reduction)

Genom, metabolom ve proteom gibi çok yüksek boyutlu biyolojik veri setlerinde ilişkilerin anlamlandırılması zor olabilir. Boyut indirgeme yöntemleri:

- Klinik verilerdeki önemli değişkenleri öne çıkarır,
- Gürültüyü azaltır,
- Daha etkili tahmin modelleri geliştirilmesini sağlar.

Bu yöntemler, özellikle genomik tıpta yaygın olarak kullanılmaktadır.

Anomali Tespiti

Denetimsiz öğrenmenin önemli bir uygulaması da anormal durumların tespiti. Örneğin:

- Hastanın kalp ritmindeki ani değişiklikler,
- Laboratuvar sonuçlarında olağandışı değerler,
- Epidemiyolojik verilerde beklenmedik artışlar.

Bu tür tespitler, erken müdahale için kritik öneme sahiptir.

c) Pekiştirmeli Öğrenme Uygulamaları

Pekiştirmeli öğrenme (reinforcement learning), bir ajanın belirli bir ortamda ödül ve ceza mekanizmasıyla karar almayı öğrenmesi prensibine

dayanır. Sağlık alanına uygulandığında, özellikle tedavi optimizasyonu ve ilaç doz ayarı gibi sürekli geri bildirim gerektiren süreçlerde etkili olmaktadır.

Örneğin:

- Yoğun bakım hastalarının ventilatör ayarlarının optimize edilmesi,
- Kanser tedavisinde doz ayarının kişiselleştirilmesi,
- Diyabet hastalarında insülin dozunun gerçek zamanlı düzenlenmesi.

Bu modeller, kontrollü geri bildirim sayesinde zaman içinde daha iyi kararlar üretebilir (Yu vd., 2021).

d) Sağlıkta Makine Öğrenmesi Sınıflandırmasının Önemi

Bu sınıflandırmanın en önemli avantajı, doğru model türünün seçilmesini sağlamasıdır. Hastalığın türü, veri setinin yapısı, klinik hedef ve modelin yorumlanabilirliği gibi kriterler, hangi ML yaklaşımının kullanılacağını doğrudan etkiler. Ayrıca algoritmaların neden farklı yöntemlerle çalıştığını anlamak, sağlık profesyonellerinin modele duyduğu güveni artırmakta ve klinik entegrasyonu kolaylaştırmaktadır.

Sonuç olarak makine öğrenmesi uygulamalarının bu şekilde sınıflandırılması, sağlık alanındaki yapay zekâ projelerinin bilimsel temeller üzerine inşa edilmesine yardımcı olur. Bu bölümle birlikte, bir sonraki ana başlık olan teşhis, tedavi ve sağlık yönetimi uygulamalarının anlaşılması için gerekli metodolojik çerçeve tamamlanmış olmaktadır.

2. Yapay Zekânın Sağlıkta Kullanım Alanları

Sağlık alanında yapay zekâ (YZ) teknolojilerinin yaygınlaşması, özellikle tanı, tedavi ve yönetim süreçlerinin önemli ölçüde yeniden şekillenmesine neden olmuştur. Klinik verilerin çeşitliliği ve hacmi arttıkça, bu verilerin işlenmesi için gelişmiş analitik yöntemlere duyulan ihtiyaç da artmaktadır. YZ bu noktada hem karar destek sistemi hem de klinik doğrulama aracı olarak kritik bir rol üstlenmektedir (Topol, 2019).

2.1. Teşhis ve Tanı Sistemleri

Yapay zekânın (YZ) tıpta en yoğun kullanıldığı alanlardan biri teşhistir. Makine öğrenmesi ve derin öğrenme tabanlı modeller, özellikle kanser taramaları, diyabetik retinopati, kardiyovasküler rahatsızlıklar ve nörolojik hastalıkların tanısında başarılı sonuçlar vermektedir. Yapılan birçok araştırma, bazı YZ modellerinin insan uzmanlarla karşılaştırılabilir düzeyde performans gösterdiğini ortaya koymuştur (Rajpurkar vd., 2022).

Meme Kanseri Tanısında Yapay Zekâ

Google Health tarafından geliştirilen bir model, mamografi taramalarında insan radyologlara kıyasla daha düşük yanlış pozitif oranı ve daha yüksek doğruluk sunmuştur (McKinney vd., 2020). Derin öğrenme tabanlı bu sistem, meme dokusu yoğunluğundaki küçük farklılıkları yüksek hassasiyetle analiz edebilmektedir.

Dermatolojide Yapay Zekâ Kullanımı

Esteva ve çalışma arkadaşları (2017), cilt lezyonlarını sınıflandırmak için geliştirdikleri görüntü analiz modelinin malign melanom tespitinde uzman dermatologlarla benzer doğrulukta sonuç ürettiğini göstermiştir. Bu bulgu, yapay zekânın görsel tanı alanında ciddi bir potansiyeli olduğunu göstermektedir.

2.2. Tedavi Planlaması ve Kişiselleştirilmiş Tıp

Tedavi süreçleri hastadan hastaya farklılık gösterdiği için kişiselleştirme modern tıbbın temel hedeflerinden biri hâline gelmiştir. Yapay zekâ uygulamaları, genetik verilerden laboratuvar sonuçlarına, yaşam biçimi verilerinden tıbbi görüntülere kadar birçok değişkeni analiz ederek bireye özel tedavi planlarının oluşturulmasına yardımcı olur.

Yapay zekânın tedavi planlamasında öne çıkan uygulama alanları özellikle onkoloji ve farmakogenomik çalışmalarıdır.

2.2.1. Onkolojik Tedavi Planlamasında Yapay Zekâ

Onkoloji, tedavi kararlarının oldukça karmaşık olduğu bir tıp dalıdır. Tümörün biyolojik özellikleri, evresi, metastaz durumu ve hastanın genel sağlık profili tedavi sürecini doğrudan etkiler. Bu nedenle IBM Watson for Oncology gibi sistemler, dünya genelindeki kanser vakalarından elde edilen klinik verileri analiz ederek uygun tedavi protokollerini önerir (Sun & Medaglia, 2019).

Bu tür sistemler, hekimlere mevcut verinin ışığında yol gösterirken, özellikle tedavi seçeneklerinin çok olduğu durumlarda karar vermeyi kolaylaştırır.

2.2.2. Farmakogenomik

Farmakogenomik alanında kullanılan yapay zekâ modelleri, genetik değişkenliklerin ilaç metabolizması üzerindeki etkilerini inceleyerek kişiye özel doz ayarlamalarının yapılmasını mümkün kılar. Bu sayede ilaç yan etkileri

azalırken tedavi etkinliği artmaktadır. Kronik hastalıklarda ilaç tedavilerinin daha güvenilir hâle gelmesinde bu tür modeller önemli bir rol oynamaktadır.

2.3. Klinik Karar Destek Sistemleri (CDSS-Clinical Decision Support Systems)

Klinik karar destek sistemleri, sağlık profesyonellerine hasta özelinde öneriler sunarak hata olasılığını azaltan ve bakım kalitesini yükselten araçlardır. Yapay zekâ tabanlı Klinik Karar Destek Sistemleri, laboratuvar sonuçlarını, tıbbi geçmişi, görüntüleme verilerini ve vital parametreleri analiz ederek hekime önerilerde bulunur (Shortliffe & Sepúlveda, 2018).

Sepsis Tahmin Modelleri

Sepsis, yoğun bakım ünitelerinde hızlı müdahale gerektiren kritik bir durumdur. Makine öğrenmesi ile geliştirilen erken uyarı sistemleri, sepsisi 24–48 saat önceden öngörebilmektedir. Bu modeller mortaliteyi azaltmakta ve tedaviye erken başlanmasını sağlamaktadır.

Klinik Karar Destek Sistemleri'nin en önemli avantajlarından biri, klinik kararlardaki standartlaşmayı artırması ve farklı hekimler arasında bilgi farklılıklarının etkisini azaltmasıdır.

2.4. Robotik Cerrahi

Robotik cerrahi sistemleri, cerrahların daha hassas ve kontrollü operasyonlar gerçekleştirmesine yardımcı olur. Yapay zekâ destekli robotik platformlar, kamera görüntülerini analiz ederek cerrahın hareketlerini optimize edebilir ve operasyon sırasında titreme gibi istenmeyen etkileri en aza indirebilir.

Da Vinci Cerrahi Sistemi, dünya genelinde en yaygın kullanılan robotik platformlardan biridir. Prostat kanseri, jinekolojik cerrahiler ve kalp ameliyatlarında yüksek doğruluk sağlamaktadır. Robotik cerrahinin en önemli faydalarından biri, hasta iyileşme süresinin kısalması ve komplikasyon riskinin azalmasıdır.

2.5. Kronik Hastalık İzleme ve Giyilebilir Teknolojiler

Kronik hastalıkların düzenli takibi, komplikasyonların önlenmesi açısından kritik öneme sahiptir. Giyilebilir teknolojiler ve mobil sağlık uygulamaları, sürekli veri toplayarak hastaların sağlık durumunu anlık olarak izlemeyi mümkün hâle getirmiştir.

Apple Watch, Fitbit ve Samsung Health gibi cihazlarda yer alan yapay zekâ tabanlı analiz sistemleri:

- Aritmi tespiti,
- Uyku apnesi değerlendirmesi,
- Aktivite ve kalori analizleri,
- Diyabet yönetimi gibi sağlık verilerini anlamlandırarak erken uyarı sağlar.

Örneğin Apple'ın atriyal fibrilasyon (AF) algoritması, düzensiz kalp ritmini erken fark ederek kardiyologlara yönlendirme yapılmasını sağlayabilmektedir.

2.6. Sağlık Hizmeti Yönetiminde Yapay Zekâ

Sağlık kuruluşlarının operasyonel süreçlerinde de yapay zekâönemli bir araç hâline gelmiştir. Randevu planlaması, yatak doluluk oranlarının yönetimi, envanter tahmini, hasta akış modellemesi ve acil servis yoğunluk tahminleri yapay zekâ tabanlı analizlerle daha verimli hâle getirilmektedir.

Örneğin hasta yoğunluğu tahmin modelleri, acil servislerde bekleme süresini azaltarak hasta memnuniyetini artırmaktadır. Ayrıca yapay zekâ, hastanelerin maliyet yönetimi ve kaynak planlamasında da stratejik avantajlar sunmaktadır.

3. Örnek Olay Çalışmaları

Yapay zekâ (YZ) uygulamalarının sağlık alanındaki gerçek etkisini göstermek için örnek olay analizleri önemli bir araçtır. Türkiye'de ve dünyada, sağlık hizmetlerinde YZ kullanımına ilişkin çok sayıda çalışma yapılmış, özellikle tanı, tedavi, uzaktan izlem ve sağlık yönetimi alanlarında dikkat çekici sonuçlar bildirilmiştir (Kaplan vd., 2024; Yorgancıoğlu Tarcan vd., 2024).

Burada sunulan üç örnek olay:

- Mevcut literatürde bildirilen uygulamalardan esinlenen,
- Eğitim ve açıklama amacıyla kurgulanmış senaryolardır.

Dolayısıyla aşağıdaki vaka anlatımları, gerçek bir çalışmanın aynen özetlenmesi değil, literatürdeki bulgularla uyumlu, temsil gücü yüksek örneklerdir.

3.1. Örnek Olay 1: Türkiye'de COVID-19 Tahmin Modelleri

COVID-19 pandemisi sürecinde Türkiye'de farklı üniversite ve araştırma grupları, vaka sayılarının kısa vadeli tahmini için zaman serisi modelleri ve

yapay zekâ yöntemlerini kullanmıştır. LSTM- Long Short-Term Memory (Uzun Kısa Süreli Bellek ağı), GRU- Gated Recurrent Unit (Kapılı Tekrarlayan Birim) ve yapay sinir ağı tabanlı modellerle günlük vaka sayısını ve ölüm sayısını tahmin eden çalışmalar bulunmaktadır.

Büyük bir üniversite hastanesi ile iş birliği yapan bir araştırma ekibinin, il bazında günlük COVID-19 vaka sayısını öngörmek için LSTM tabanlı bir model geliştirdiğini düşünelim. Modelde:

- Son 30 güne ait vaka sayıları,
- Test sayıları ve pozitiflik oranı,
- Hareketlilik endeksleri,
- Basit meteorolojik değişkenler (sıcaklık vb.) girdi olarak kullanılmış olsun.

Modelin çıktıları, il düzeyinde 7 günlük ileri tahmin üretmekte ve bu tahminler haftalık olarak İl Sağlık Müdürlüğü ile paylaşılmaktadır. Böyle bir sistem:

- Beklenen pik dönemleri birkaç gün öncesinden görmeye,
- Yatak ve yoğun bakım kapasitesini planlamaya,
- Test ve filyasyon ekiplerini öncelikli bölgelere yönlendirmeye yardımcı olabilir.

Benzer yaklaşım ve amaçlara sahip gerçek çalışmaların, Türkiye ve diğer ülkeler için yapıldığı literatürde rapor edilmektedir (Kaplan vd., 2024).

3.2. Örnek Olay 2: Diyabet Yönetiminde Yapay Zekâ Destekli Mobil Uygulama

Tip 2 diyabet, uzun dönemli takip gerektiren kronik bir hastalıktır ve dijital sağlık uygulamalarının bu alanda giderek daha fazla kullanıldığı bilinmektedir. Türkiye’de geliştirilen “Mobil Diyabetim” adlı bulut tabanlı uygulama, diyabet hastalarının günlük ölçümlerini kaydedip izlemesine imkân tanıyan erken örneklerden biridir (Yıldırım vd., 2017). Bu çalışma, Türkiye’de m-sağlık (mobile health) uygulamalarının gelişimi açısından önemli bir adım olarak görülmektedir.

Bu tür uygulamalar, günümüzde makine öğrenmesi modelleri ile entegre edilerek daha gelişmiş özellikler sunmaktadır. Örneğin glikoz seyri tahmini, insülin doz önerisi veya olası hipoglisemi riskinin erken işaretlenmesi gibi fonksiyonlar, yapay zekâ algoritmalarının kullanımıyla mümkün hale gelmiştir (Rajpurkar vd., 2022).

Mobil Diyabetim benzeri bir uygulamanın daha ileri bir sürümünde:

- Hastanın kan şekeri ölçümleri,
- Öğün kayıtları,
- Günlük aktivite düzeyi,
- İlaç kullanımı ve uyku düzeni

makine öğrenmesiyle analiz edilerek ertesi gün için glikoz seviyesi tahmini yapılmış olsun. Böyle bir model, kullanıcılara “yüksek riskli gün” uyarıları göndererek davranışsal düzenlemeler önerebilir. Bu tür özellikler uluslararası literatürde yapay zekâ destekli diyabet yönetimi uygulamalarında rapor edilmektedir (Esteve vd., 2019).

Bu vaka örneği, Türkiye’de geliştirilen gerçek bir uygulama olan Mobil Diyabetim ile yapay zekâ destekli modern m-sağlık uygulamalarının nasıl entegre edilebileceğini göstermektedir.

3.3. Örnek Olay 3: Acil Servis Yoğunluk Tahmini ve Yönetimi

Sağlık hizmetleri ve yönetiminde yapay zekâ uygulamalarına ilişkin Türkçe derlemeler, yapay zekânın özellikle:

- Yatak yönetimi,
- Randevu ve sıra planlama,
- Kaynak tahsisi,
- Maliyet ve süreç iyileştirme

alanlarında kullanılabileceğini vurgulamaktadır (Kaplan vd., 2024; Yorgancıoğlu Tarcan vd., 2024).

Büyük bir şehir hastanesinin acil servisinde, bir yıl boyunca toplanan veriler kullanılarak acil başvuru sayısını saatlik bazda tahmin eden bir makine öğrenmesi modeli geliştirildiğini varsayalım. Model girişleri:

- Günün saati ve haftanın günü,
- Mevsim bilgisi,
- Son 48 saatin başvuru sayıları,
- Yakın çevredeki büyük etkinlikler / tatiller gibi takvim değişkenleri olsun.

Böyle bir model, özellikle:

- Yoğun saatlerde ek hekim / hemşire görevlendirilmesi,

- Gözlem yataklarının sayısının bu saatlere göre ayarlanması,
- Poliklinik–acil etkileşiminin planlanması

için yönetime destek verebilir. Yapay zekânın sağlık hizmetleri ve yönetiminde maliyetleri azaltma ve süreçleri iyileştirme potansiyeli, Türkçe derleme ve incelemelerde ayrıntılı biçimde tartışılmaktadır.

4. Etik, Güvenlik ve Hukuki Boyutlar

Yapay zekâ (YZ) teknolojilerinin sağlık hizmetlerinde hızla yer edinmesi, önemli etik, güvenlik ve hukuki sorumlulukları beraberinde getirmektedir. YZ destekli tanı, tedavi ve karar mekanizmaları klinik fayda sağlarken; bu sistemlerin adalet, mahremiyet, güvenlik ve hesap verebilirlik ilkeleriyle uyumlu olması zorunludur (Floridi vd., 2020; Özdemir&Bilgin, 2021). Yüksek riskli sağlık alanında YZ'nin sorumlu bir şekilde uygulanabilmesi, yalnızca teknik değil, aynı zamanda yasal ve etik temelli çerçevelerin oluşturulmasına bağlıdır (Corfmat vd., 2025).

4.1. Veri Gizliliği ve Mahremiyet

Yapay zekâ (YZ) uygulamaları büyük miktarda sağlık verisine ihtiyaç duyar. Elektronik sağlık kayıtları, tıbbi görüntüler, biyometrik sinyaller ve giyilebilir cihaz verileri hastaya ait en hassas bilgileri içerir. Türkiye’de bu veriler, Kişisel Verilerin Korunması Kanunu’nun 6. maddesi kapsamında “özel nitelikli kişisel veri” olarak sınıflandırılmakta ve sıkı koruma önlemleri gerektirmektedir (KVKK, 2016).

Uluslararası literatürde yapılan çalışmalar, YZ modellerinin eğitiminde kullanılan sağlık verilerinin yeterince anonimleştirilmemesi durumunda kimlik tespitinin yeniden yapılabildiğini göstermektedir (Rocher vd., 2019). Ayrıca YZ sistemlerinde dış saldırılarla verilerin değiştirilmesi, sızdırılması veya model davranışının manipüle edilmesi gibi riskler de mevcuttur (Morley vd., 2021).

Türkiye’de de veri paylaşımı, bulut tabanlı sistemler ve uzaktan sağlık hizmetleri bağlamında mahremiyetin korunması kritik bir tartışma alanıdır. Özdemir ve Bilgin (2021), sağlıkta YZ uygulamalarında etik rızanın kapsamı, veri saklama süreleri ve üçüncü taraf platformların şeffaflığı konularında daha net standartlara ihtiyaç olduğunu vurgulamaktadır. Veri güvenliği, YZ tabanlı sağlık sistemlerinin en temel etik sütunlarından biridir ve hastanın mahremiyet hakkının korunması teknoloji tasarımının ayrılmaz bir parçası olmalıdır.

4.2. Algoritmik Yanlılık (Bias) ve Eşitlik İlkesi

Yapay zekâ (YZ) sistemleri, eğitildiği verilerdeki örüntüleri öğrenir; dolayısıyla verideki her türlü toplumsal yanlılık modele de yansır. Klinik yapay zekâ modellerinde:

- Cinsiyet,
- Etnisite,
- Yaş,
- Sosyoekonomik durum

gibi değişkenlere bağlı doğruluk farkları olduğu dünyanın farklı bölgelerinde gösterilmiştir (Rajpurkar vd., 2022). Bu durum sağlık hizmetlerinde eşitsizlikleri artırma potansiyeli taşır.

Tarcan ve arkadaşları (2024), Türkiye’de YZ’nin sağlık hizmetlerine entegrasyonuna dair yaptıkları derlemede, veri setlerinin adalet açısından sistematik olarak test edilmemesinin en önemli risklerden biri olduğunu belirtmiştir. Benzer şekilde Floridi ve arkadaşları (2020), adil YZ uygulamalarının yalnız teknik değil aynı zamanda toplumsal bir gereklilik olduğunu savunmaktadır.

Klinik pratikte örnek sorunlar:

- Cilt kanseri modelleri açık tenli hastalarda daha yüksek doğruluk verebilir.
- Kardiyoloji algoritmaları genç yaş grubunda daha iyi performans gösterebilir.

Bu nedenle, YZ modellerinin eğitim süreçlerinde çeşitliliğin artırılması, performansın farklı demografik gruplarda test edilmesi ve yanlılık azaltma tekniklerinin uygulanması zorunludur.

4.3. Açıklanabilirlik (Explainable AI) ve Klinik Karar Sorumluluğu

Sağlık alanında kullanılan derin öğrenme modelleri çoğu zaman “kara kutu” özellik taşır; yani hekimler modelin neden belirli bir tanı veya öneri ürettiğini göremez. Hekim–Yapay Zekâ işbirliğinin güvenli şekilde kurulabilmesi için açıklanabilir yapay zekâ (XAI) yaklaşımlarının klinik sistemlere entegre edilmesi gerekmektedir (Alpkoçak, 2024).

Açıklanabilir yapay zekâ (XAI)’nın sağlıkta önemi:

- Modelin karar mantığını göstermek,
- Hekimin sistem önerisini değerlendirmesini kolaylaştırmak,

- Hatalı kararların erken fark edilmesini sağlamak,
- Klinik sorumluluk zincirinin belirginleşmesine katkı sunmak.

Corfinat ve arkadaşları (2025), yapay zekânın “yüksek risk–yüksek ödül teknolojileri” arasında olduğunu söyleyerek, açıklanabilirliğin hukuki sorumlulukla doğrudan ilişkili olduğunu vurgulamaktadır. Eğer bir yapay zekâ sistemi hatalı karar verirse:

- Hekim mi sorumludur?
- Hastane mi?
- Yazılım geliştiricisi mi?
- Modeli eğiten üçüncü taraf firma mı?

Bu soruların mevcut hukuk sistemlerinde net bir yanıtı yoktur. Bu nedenle açıklanabilirlik sadece teknik bir gereklilik değil, hukuki bir zorunluluk hâline gelmektedir.

4.4. Güvenlik Riskleri ve Siber Tehditler

Sağlık sektöründe kullanılan yapay zekâ sistemleri, hem yazılım hem donanım seviyesinde çeşitli siber tehditlere açıktır. Scott ve çalışma arkadaşları (2022), YZ tabanlı sağlık sistemlerinin özellikle şu saldırılara duyarlı olduğunu belirtmiştir:

- Data poisoning: Modeli eğitmek için kullanılan verilerin kötü amaçlı değiştirilmesi.
- Model evasion: Modelin yanlış tahmin vermesi için özel girişlerin oluşturulması.
- Ransomware: Hastanelerin kritik sistemlerinin kilitlenmesi.
- Adversarial saldırılar: Görüntülemeye dayalı sistemlerin manipüle edilmesi.

Türkiye özelinde, son yıllarda kamu hastanelerine yapılan siber saldırılar YZ tabanlı sistemlerde güvenlik açıklarının daha kritik hâle geldiğini göstermektedir. Bu nedenle YZ kullanımının siber güvenlikle uyumlu bir “kurumsal risk yönetimi” anlayışıyla ele alınması gereklidir.

4.5. Yapay Zekâ İçin Hukuki Çerçeve ve Düzenleme İhtiyacı

Avrupa Birliği’nin AI Act düzenlemesi, sağlık alanındaki yapay zekâ uygulamalarını “yüksek riskli” sınıfa sokarak çok katı bir denetim ve sertifikasyon süreci öngörmektedir (European Commission, 2024). Buna göre sağlıkta kullanılan YZ sistemleri:

- Güvenlik testlerinden geçmeli,
- Şeffaflık kriterlerini sağlamalı,
- İnsan gözetimi altında çalışmalı,
- Sürekli performans izlemeye tabi tutulmalıdır.

Türkiye’de ise henüz sağlıkta YZ için bağımsız bir yasa bulunmamaktadır. Yasal dayanaklar:

- KVKK (Kişisel Verilerin Korunması Kanunu),
- Tıbbi Cihaz Yönetmeliği (CE sınıflandırmaları),
- Sağlık Bakanlığı dijital sağlık stratejileri,
- Etik kurul süreçleri

üzerinden parçalı biçimde yürümektedir. Bu nedenle hem klinisyenler hem yöneticiler için daha kapsamlı bir yapay zeka hukuku ihtiyacı açıktır (Özdemir&Bilgin, 2021; Yorgancıoğlu Tarcın vd., 2024).

5. Gelecek Öngörülleri

Yapay zekâ (YZ), sağlık hizmetlerinin dönüşümünde önümüzdeki on yılda belirleyici faktörlerden biri olmaya adaydır. Klinik karar destek sistemlerinden görüntüleme analizlerine, genomik verilerden sağlık yönetimine kadar geniş bir alanda etkisini artıran YZ, gelecekte hem bireysel hem toplumsal sağlık süreçlerini yeniden şekillendirecek potansiyele sahiptir (Topol, 2019; Rajpurkar vd., 2022). Aynı zamanda biyoteknoloji, veri bilimi ve tıbbi cihaz teknolojilerindeki ilerlemeler, YZ’nin etkisini katlanarak büyütecek yeni bir sağlık ekosisteminin ortaya çıkacağını göstermektedir.

5.1. Tam Otomatik Görüntüleme ve Raporlama Sistemleri

Tıbbi görüntülemede yapay zekâ kullanımının gelecekte daha da derinleşmesi beklenmektedir. Derin öğrenme modelleri, radyoloji, dermatoloji ve patoloji gibi alanlarda giderek artan doğruluk seviyeleriyle klinik rutinde daha fazla yer edinecektir (McKinney vd., 2020). Önümüzdeki dönemde:

- Tam otomatik ön rapor hazırlayan radyoloji sistemleri,
- Patoloji lamı analizinde otomatik kanser odakları işaretleyen platformlar,
- Gerçek zamanlı ultrason rehberlik sistemleri

yaygınlaşacaktır. Avrupa Birliği'nin yüksek riskli sistemler için getirdiği standartlar (European Commission, 2024), bu sistemlerin hem güvenli hem de denetlenebilir biçimde uygulanmasını sağlayacaktır.

5.2. Kişisel Sağlık Asistanları ve Hasta Merkezli Yaklaşımlar

Giyilebilir cihazlar, sensör teknolojileri ve ev tipi tıbbi izleme araçları yapay zekâ (YZ) ile birleştiğinde, kişisel sağlık asistanları geleceğin standardı hâline gelecektir. Sürekli veri akışı sayesinde YZ tabanlı sistemler:

- Kronik hastalık alevlenmelerini erken tahmin edebilecek,
- Uyku, beslenme ve aktivite davranışlarına yönelik kişiselleştirilmiş öneriler oluşturabilecek,
- Anlık uyarılarla risk yönetimi yapabilecektir (Morley vd., 2021).

Ayrıca “kişisel dijital sağlık koçları” psikiyatri, diyabet yönetimi ve kalp yetmezliği gibi alanlarda karar destek sağlayarak hastaların özyönetim becerilerini artıracaktır (Yıldırım vd., 2017).

Türkiye’de Sağlık Bakanlığı’nın dijital sağlık stratejileri incelendiğinde, YZ destekli tele-sağlık platformlarının gelecekte daha sistematik ve yaygın hâle getirileceği görülmektedir.

5.3. Biyoteknoloji–Yapay Zekâ Entegrasyonu ve Yeni İlaç Keşifleri

Yeni ilaç geliştirme süreçleri geleneksel olarak uzun ve maliyetlidir. Ancak yapay zekâ destekli (YZ) moleküler modelleme, hedef belirleme, toksisite tahmini ve klinik aday seçimi gibi aşamalar, bu süreci dramatik biçimde hızlandırmaktadır. 2023–2025 arasında yayımlanan çalışmalar, YZ’nin ilaç keşfi süresini %40’a kadar kısaltabildiğini göstermektedir (Corfmat vd., 2025).

Gelecekte:

- Yapay zekâ ile tasarlanan ilk tam biyolojik ilaçların,
- Gen düzenleme (CRISPR) çalışmalarında YZ tabanlı hedef belirleme araçlarının,
- Nadir hastalıklar için hızlı ilaç aday tarama platformlarının

günlük klinik araştırma süreçlerine entegre olması öngörülmektedir. Özellikle kanser ve nörolojik hastalıklarda YZ’nin biyobelirteç keşfi için kullanımı önemli bir sıçrama yaratacaktır.

5.4. Dijital İkiz (Digital Twin) Uygulamaları

Dijital ikiz teknolojisi, bir bireyin biyolojik, fizyolojik ve davranışsal özelliklerinin dijital bir modelini oluşturarak tedavi yanıtlarının simülasyonuna imkân verir. Avrupa Birliği sağlık inovasyonu programları, dijital ikizlerin önümüzdeki on yılda kardiyoloji, metabolizma hastalıkları ve cerrahi planlamada standart hâle gelebileceğini göstermektedir (European Commission, 2024).

Dijital ikizlerin sağlayacağı yenilikler:

- Tedavi senaryolarının simülasyonu,
- İlaç doz optimizasyonu,
- Cerrahi sonuç tahmini,
- Kronik hastalık yönetiminde bireyselleştirilmiş risk analizi.

Bu teknoloji, yapay zekâ destekli kişisel tıp yaklaşımının en kapsamlı örneklerinden biri olacaktır.

5.5. Yapay Zekâ Destekli Hastaneler ve Tam Entegrasyon

Geleceğin hastaneleri sadece dijital kayıtlarla değil, tamamen yapay zekâ destekli süreçlerle yönetilecektir. Bu dönüşümün temel bileşenleri:

- Akıllı triyaj sistemleri,
- Otomatik yatak ve kaynak yönetimi,
- Acil servis yoğunluk tahmini (Scott vd., 2022),
- Yapay zekâ tabanlı kalite ve güvenlik kontrolü,
- Robotik süreç otomasyonu (RPA) ile idari işlerin azaltılması.

Türkiye’de özellikle şehir hastanelerinin dijital altyapısı yapay zekâ entegrasyonu için uygun olduğundan, önümüzdeki yıllarda bu dönüşümün hızlanacağı öngörülmektedir.

5.6. Etik, Hukuk ve Güven Yönetimi Açısından Gelecek

Yapay zekânın (YZ) sağlıkta yaygınlaşması, etik ve hukuki düzenlemelerin de eş zamanlı gelişmesini zorunlu kılacaktır. Corfmatt vd. (2025), YZ’nin “yüksek risk–yüksek ödül” kategorisinde olduğunu ve bu nedenle güçlü güvenlik denetimleri gerektirdiğini vurgulamaktadır.

Gelecek 10 yılda;

- Ulusal YZ etik kurulları,

- Zorunlu model şeffaflık kriterleri,
- Klinik YZ sistemleri için sertifikasyon süreçleri,
- Sağlık çalışanlarına yönelik YZ etik eğitimi

gibi uygulamalar yaygınlaşacaktır. Ayrıca YZ–hekim işbirliğinde sorumluluk paylaşımı, ülkelerin mevzuatlarında açık şekilde tanımlanacaktır.

6. Sonuç

Yapay zekâ (YZ), sağlık hizmetlerinde son yirmi yılda ortaya çıkan en güçlü dönüşüm dinamiklerinden biri hâline gelmiştir. Tam süreçlerinin hızlanması, tedavinin kişiselleştirilmesi, kronik hastalık yönetiminin dijitalleşmesi ve sağlık kurumlarının daha verimli yönetilmesi, YZ'nin sunduğu faydalar arasında yer almaktadır. Bu çalışma kapsamında ele alınan örnek olaylar, literatürdeki bulgularla birlikte değerlendirildiğinde, YZ'nin hem klinik hem yönetsel düzeyde sağlık sistemlerinde derin bir etki yarattığı görülmektedir (Topol, 2019; Rajpurkar vd., 2022).

Bununla birlikte, sağlık sektöründe YZ uygulamalarının yaygınlaşması bir dizi kritik sorunu da gündeme getirmektedir. Verilerin güvenliği ve mahremiyeti, algoritmik yanlılık, sorumluluk zincirinin belirsizliği ve açıklanabilirlik ihtiyacı bu sorunların başında gelir (Floridi vd., 2020; Özdemir&Bilgin, 2021). YZ'nin sağlıkta kullanımının etik bir zemin üzerinde şekillenebilmesi, yalnızca teknoloji üreticilerinin değil; aynı zamanda hekimlerin, sağlık yöneticilerinin, hukukçuların, düzenleyici otoritelerin ve hastaların ortak sorumluluğu altındadır.

Gelecek on yıl içinde, YZ'nin sağlık alanındaki etkisinin daha da artacağı öngörülmektedir. Özellikle dijital ikiz teknolojileri, otomatik görüntüleme raporları, kişisel sağlık asistanları ve YZ destekli hastane yönetim sistemlerinin yaygınlaşması beklenmektedir (European Commission, 2024; McKinney vd., 2020). Biyoteknoloji ve veri bilimiyle bütünleşen YZ modelleri, ilaç geliştirme süreçlerini hızlandıracak ve nadir hastalıklar gibi karmaşık klinik problemlerin çözümünde önemli katkılar sağlayacaktır (Corfmat vd., 2025).

Türkiye özelinde değerlendirildiğinde, güçlü dijital sağlık altyapısı ve büyük ölçekli şehir hastaneleri YZ uygulamalarının hayata geçirilmesi için önemli fırsatlar sunmaktadır (Yorgancıoğlu Tarcan vd., 2024). Bununla birlikte, YZ'ye yönelik ulusal etik rehberlerin, hukuki düzenlemelerin ve denetim mekanizmalarının güçlendirilmesi gerekmektedir (Özdemir&Bilgin, 2021; KVKK, 2016). Ayrıca sağlık profesyonellerinin YZ okuryazarlığının artırılması, sistemlerin güvenli ve etkili bir şekilde kullanılabilmesi açısından kritik bir gerekliliktir (Şahin, 2025; Floridi vd., 2020).

Sonuç olarak, YZ sağlık sektörüne büyük bir yenilik potansiyeli getirirken, bu potansiyelin güvenli, adil ve sürdürülebilir bir çerçevede yönetilmesi zorunludur. Teknolojik gelişmeler hızla devam ederken, insan merkezli sağlık hizmeti anlayışını korumak geleceğin sağlık sistemlerinin temel hedefi olmalıdır. YZ'nin sunduğu güçlü araçlar, doğru etik ve yasal temellerle kullanıldığında sağlık hizmetlerinin kalitesini artıracak ve toplum sağlığına önemli katkılar sağlayacaktır.

Kaynakça

- Alpkoçak, A. (2024). Sağlıkta açıklanabilir yapay zekâ. *TOTBİD Dergisi*, 23, 18–23. <https://doi.org/10.5578/totbid.dergisi.2024.04>
- Corfmat, M., Martineau, J. T., & Régis, C. (2025). High-reward, high-risk technologies? An ethical and legal account of AI development in healthcare. *BMC Medical Ethics*, 26, Article 4. <https://doi.org/10.1186/s12910-024-01158-1>
- Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., Liu, Y., & Hajishirzi, H. (2019). Deep learning-enabled medical computer vision. *Digital Medicine*, 2(1), 1–9.
- Esteva, A., Kuprel, B., Novoa, R. A., et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115–118.
- European Union. (2024). Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act) and amending Regulation (EU) 2022/2065. *Official Journal of the European Union*, L 1689, 1–129. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32024R1689>
- Kaplan, M., Çakar, F., & Bingöl, H. (2024). Sağlık alanında yapay zekanın kullanımı: Derleme. *Muş Alparslan Üniversitesi Sağlık Bilimleri Dergisi*, 4(3), 75–85.
- KVKK. (2016). 6698 Sayılı Kişisel Verilerin Korunması Kanunu. T.C. Resmi Gazete, 7 Nisan 2016.
- McKinney, S. M., Sieniek, M., Godbole, V., et al. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577, 89–94.
- Morley, J., Floridi, L., Kinsey, L., & Elhalal, A. (2020). From what to how: An initial review of publicly available AI ethics tools, methods and research to translate principles into practices. *Science and Engineering Ethics*, 26, 2141–2168. <https://doi.org/10.1007/s11948-019-00165-5>
- Morley, J., Machado, C. C. V., Burr, C., et al. (2021). The ethics of AI in healthcare. *Nature Medicine*, 27, 424–428.
- Obermeyer, Z., & Emanuel, E. J. (2016). Predicting the future—Big data, machine learning, and clinical medicine. *The New England Journal of Medicine*, 375(13), 1216–1219.
- Özdemir, L., & Bilgin, A. (2021). Sağlıkta yapay zekânın kullanımı ve etik sorunlar. *Sağlık ve Hemşirelik Yönetimi Dergisi*, 8(3), 439–445.
- Rajpurkar, P., Chen, E., Banerjee, O., & Topol, E. (2022). AI in health and medicine. *Nature Medicine*, 28, 31–38.

- Rocher, L., Hendrickx, J. M., & de Montjoye, Y. A. (2019). Estimating the success of re-identifications in incomplete datasets. *Nature Communications*, 10, 3069.
- Russell, S. J., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Scott, I., Taylor, N., & Pearson, S. (2022). Cybersecurity risks for healthcare AI. *Health Management Review*, 8(4), 212–225.
- Shickel, B., Tighe, P. J., Bihorac, A., & Rashidi, P. (2018). Deep EHR: A survey of recent advances in deep learning techniques for electronic health record (EHR) analysis. *IEEE Journal of Biomedical and Health Informatics*, 22(5), 1589–1604.
- Shortliffe, E. H., & Sepúlveda, M. (2018). Clinical decision support in the era of artificial intelligence. *JAMA*, 320(21), 2199–2200.
- Sun, T., & Medaglia, J. D. (2019). Artificial intelligence in oncology: Current applications and future directions. *The Lancet Oncology*, 20, e146–e156.
- Şahin, D. (2025). Sağlık hizmetlerinde hasta güvenliği ve yapay zekâ: Bibliyometrik bir analiz. *Elektronik Sosyal Bilimler Dergisi*, 24(2), 764–782.
- T.C. Sağlık Bakanlığı. (2021). COVID-19 günlük durum raporları. Sağlık Bilgi Sistemleri Genel Müdürlüğü.
- Topol, E. (2019). *Deep medicine: How artificial intelligence can make healthcare human again*. Basic Books.
- Vayena, E., Blasimme, A., & Cohen, I. G. (2018). Machine learning in medicine: Addressing ethical challenges. *PLoS Medicine*, 15(11), e1002689.
- Yıldırım, P., Bozyiğit, F., Özcanhan, M. H., & Utku, S. (2017). Bulut tabanlı mobil diyabet kontrol uygulaması: Mobil Diyabetim. *Bilişim Teknolojileri Dergisi*, 10(2), 153–159. <https://doi.org/10.17671/gazibtd.309295>
- Yu, C., Liu, J., Nemati, S., & Clifford, G. D. (2021). Reinforcement learning in healthcare: A survey. *ACM Computing Surveys*, 55(1), 1–36.
- Yorgancıoğlu Tarcan, G., Yalçın Balçık, P., & Sebik, N. B. (2024). Türkiye ve dünyada sağlık hizmetlerinde yapay zekâ. *Mersin Üniversitesi Tıp Fakültesi Lokman Hekim Tıp Tarihi ve Folklorik Tıp Dergisi*, 14(1), 50–60. <https://doi.org/10.31020/mutfd.1278529>