



Yapay Zekâ: Alt Dalları ve Uygulama Alanları¹

Artificial Intelligence: Subfields and Applications

Hüseyin İŞCAN², Ayşe DURGUN KAYGISIZ³

¹Makale "Yapay Zekâ ve Uygulama Alanları: Türkiye'de Makroekonomik Değişkenlerin Hibrit Yapay Sinir Ağları ve Geleneksel Ekonometrik Test Yöntemleri Performanslarının Karşılaştırılması" adlı yazımı devam eden tezden türetilerek yazılmıştır.

²Doktora Öğrencisi, Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İktisat Bölümü, huiscan@ziraatbank.com.tr, Orcid Id: <https://orcid.org/0000-0002-3121-4000>.

³Doç. Dr., Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İktisat Bölümü, aysedurgun@sdu.edu.tr, Orcid Id: <https://orcid.org/0002-8062-7473>.

MAKALE BİLGİSİ

Anahtar Kelimeler

Yapay zekâ,
Makine öğrenmesi,
Derin öğrenme

Makale Geçmişi:

Geliş Tarihi: 26 Ekim 2024
Kabul Tarihi: 16 Aralık 2024

ARTICLE INFO

Keywords

Artificial intelligence,
Machine learning,
Deep learning

Article History:

Received: 26 October 2024
Accepted: 16 December 2024

ÖZET

Yapay zekâ, makinelerin insan benzeri düşünme, öğrenme ve problem çözme yetenekleri kazanmasını sağlayan bir teknoloji alanıdır. Makine öğrenimi ve derin öğrenme ve bu verilerden öğrenerek kararlar alabilen bir alan olarak karşımıza çıkan yapay zekâ son yıllarda, çeşitli uygulamalarla, sağlıktan güvenliğe, eğitimden hukuka, ekonomi ve finans alanından her alana dokunan geniş bir yelpazeye yayılmıştır. Günümüzde yapay zekânın dokunmadığı alan neredeyse kalmamıştır. Bu teknoloji, endüstriyel süreçlerden günlük yaşamın basit rutinlerine kadar pek çok alanda devrim yaratmakta ve insanların iş yapma biçimlerini köklü bir şekilde değiştirmektedir. Hem bireysel hem de toplumsal düzeyde sunduğu yeniliklerle, yaşam kalitesini artırmanın yanı sıra verimliliği de önemli ölçüde yükseltmektedir. Bu makalenin amacı yapay zekâyı teorik bir çerçevede inceleyerek alt dalları, tarihesi ve çeşitli uygulama alanları üzerinde durmaktır.

ABSTRACT

Artificial intelligence (AI) is a field of technology that enables machines to acquire human-like abilities such as thinking, learning, and problem-solving. Emerging as a domain that can make decisions by learning from data through methods like machine learning and deep learning, AI has, in recent years, expanded its reach across a wide range of applications, including healthcare, security, education, law, economics, and finance. This technology is revolutionizing various areas, from industrial processes to the simple routines of daily life, fundamentally transforming the way people work. With the innovations it brings at both individual and societal levels, it not only improves quality of life but also significantly enhances productivity. This article examines artificial intelligence within a theoretical framework, focusing on its subfields, history, and diverse application areas.

Sayısal bilgisayarlar, ilk ortaya çıktıkları dönemden itibaren insan hayatında devrim niteliğinde değişikliklere yol açmıştır. Başlangıçta ağırlıklı olarak matematiksel hesaplamalar için kullanılmalarına karşın zamanla gelişerek veri işleme, metin analizi, ses ve görüntü işleme gibi çok çeşitli alanlarda yetenek kazanmıştır. Bu bilgisayarların çoğu, modern bilgisayarların temelini oluşturan Von Neumann mimarisi üzerine inşa edilmiştir. Program ve verinin aynı hafıza alanında saklanması sağlayan bu mimari, bilgisayarlara çok yönlü bir kullanım alanı sunmuş ve onları daha esnek hale getirmiştir. Bu

sayede, sayısal bilgisayarlar günümüzde yapay zekâ, bilimsel arařtırmalar, tıp, mühendislik ve sosyal bilimler gibi geniş bir yelpazede kullanılmaktadır. Ařağıdaki řekilde sayısal bilgisayarların iřlevi görölmektedir (Elmas, 2018, s. 27).



Şekil 1. Von-Neuman Makinesi

Kaynak: (Elmas, 2018, s. 27).

Sayısal bilgisayarlar, girdi bilgilerine önceden belirlenmiş kurallar uygulayarak sonuç üreten tümdengelimci bir yapıya sahiptir. Bu sistemde veriler ve algoritmalar kesin olarak tanımlanmış ve düzenlenmiştir. Bilgisayarlar, bilgileri 0 ve 1'ler řeklinde temsil etmekte ve işlem elemanları arasındaki bağlantıların ağırlıkları, bu işlemler sırasında deęişken olarak iřlev görmektedir. Ancak bu ağırlıklar, saklanan bilginin ne olduęuna dair bir anlam taşımamaktadır. Öte yandan, yapay zekâ tümevarımsal bir yaklaşım benimsemektedir. Bu sistemler, girdiler ve çıktılar arasındaki ilişkileri tanımlamak için önceden belirlenmiş kurallar yerine, verilerden öğrenerek kendilięinden gelişen bir yapıya sahiptir. Bu sayede, geçmişteki örneklerden hareketle daha iyi sonuçlar elde etmek için sürekli olarak kendilerini güncelleyebilmekte ve optimize edilebilmektedir. Yine yapay zekâda veriler, ağırlık içindeki bağlantılarda ve birçok ağırlık aracılıęıyla dağıtılmaktadır. Dolayısıyla, yapay zekâda bilgi merkezi bir noktada deęil, dağıtık bir sistemde bulunmaktadır. Bu durum, yapay zekânın öğrenme yeteneęini ve karmaşıklığını artırmaktadır (Elmas, 2018, s. 28-29).

Yapay zekâ teknolojilerinin hızlı gelişimi hem akademik dünyada hem de toplum genelinde büyük bir ilgi odağı haline gelmiştir. Ekonomik, sosyal ve teknolojik alanlarda yarattığı etkiler, bu teknolojinin gelecekteki potansiyelini anlamayı ve tartışmayı zorunlu kılmaktadır. Yapay zekâya ilişkin mevcut tartışmalar, insanların eleştirel düşünme ve yaratıcılık gibi yetkinliklerdeki üstünlüğünü vurgulamakla birlikte (Gil ve Selman, 2019), bu yetkinliklerin giderek yapay zekâ tarafından da başarılı bir řekilde gerçekleştirilebileceğini gösteren çalışmaların artması, bu tartışmaları daha da derinleştirmiştir. Örneęin, OpenAI tarafından geliştirilen modellerin eleştirel düşünme ve akıl yürütme testlerinde gösterdiği başarı (OpenAI, 2023; Bubeck vd., 2023), yapay zekâdaki hızlı ilerlemeyi açıkça ortaya koymaktadır. Benzer řekilde, ChatGPT ve DALL-E gibi araçların karmaşık problem çözme ve özgün içerik oluşturma konularında sergilediğı performanslar (Roose, 2022; Martinengo vd., 2022), yapay zekânın insanlar tarafından "özgünlük" ve "duygusal algı" gerektiren görevlerde bile etkili olabileceğini göstermektedir.

Ancak, yapay zekânın gelişimi her alanda eşit hızda ilerlememektedir. Özellikle fiziksel ve motor becerilere yönelik uygulamalar, bilişsel alanlardaki başarıların gerisinde kalmıştır. Örneęin, otonom araçlar çevresel deęişkenleri doğru algılama ve karar verme süreçlerinde hala zorluklar yaşarken (Jolly, 2023), depo robotları farklı řekil ve boyutlardaki nesnelere kavrama konusunda eksiklikler sergilemektedir (OECD, 2021; Young, 2023). Bu durum, yapay zekâ teknolojilerinin uygulama alanlarının, teknolojik sınırlamalara ve veri kalitesine baęlı olarak farklılık gösterdiğini ortaya koymaktadır. Bunun yanı sıra, yapay zekâ uygulamalarının küresel ölçekte uygulanabilirlięi, veri çeşitlilięi ve genelleştirme kabiliyeti gibi temel sorunlarla karşı karşıyadır. Bölgesel ve sektörel sınırlamalar, bu teknolojilerin potansiyelinin tam anlamıyla kullanılmasının önünde bir engel oluşturmaktadır.

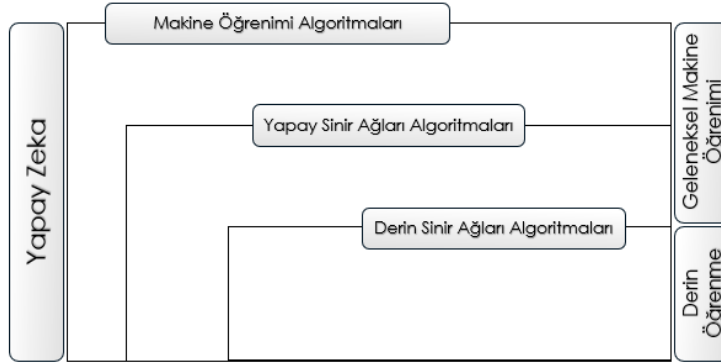
Makale, yapay zekânın teorik temellerinden uygulama alanlarına uzanan geniş bir çerçevede, bu teknolojinin mevcut durumunu ve gelecekteki yönelimlerini ele almayı amaçlamaktadır. Yapay zekânın etkileri, yalnızca teknolojik deęil, aynı zamanda sosyal, ekonomik ve etik bağlamlarda da deęerlendirilmelidir. Bu doęrultuda, makalenin ilk bölümünde yapay zekânın teorik çerçevesi ve alt dalları ele alınacak, ikinci bölümde tarihsel gelişimi ve bu alandaki dönüm noktaları tartışılacaktır. Son bölümde ise saęlık, eğitim, savunma, güvenlik, hukuk ve ekonomi gibi çeşitli alanlardaki uygulamaları analiz edilecek ve gelecekteki olası yenilikler üzerinde durulacaktır.

1. YAPAY ZEKÂ KAVRAMSAL ÇERÇEVE VE ALT DALLARI

Yapay zekâ, makinelerin insan zihnini model olarak düşünme, öğrenme ve karar verme gibi karmaşık süreçleri yerine getirmesine olanak tanıyan disiplinler arası bir bilim ve teknoloji alanıdır (Chakır vd., 2024). Geçmişten günümüze, yapay zekâyâ dair pek çok farklı tanım geliştirilmiştir. McCarthy (1956)'e göre yapay zekâ, zeki olarak nitelendirilen insan davranışlarının makinelere yaptırılmasıdır (Ravid, 2017, s. 673). Axe'ye göre komplike problemleri çözebilen, öğrenerek uzmanlaşan, eski bilgilerle yeni bilgileri uyumlu bir biçimde kullanarak bilgi tabanını genişletebilen, yeni bir durum karşısında tepki gösterebilen akıllı programlar olarak tanımlamıştır (Nabiyev, 2016, s. 26). Slage ise “*Sezgisel programlama yaklaşımı*” olarak ele almıştır (Nabiyev ve Erümit, 2020, s. 2). Nilsson (1990)'a göre yapay zekâ insan zekâsının bir taklidini oluşturmayı amaçlayan bir ifadedir. Cahit Arf, 1959 yılında yazdığı “*Makine düşünebilir mi ve nasıl düşünebilir?*” başlıklı makalesinde, yapay zekâ kavramına felsefi bir perspektifle yaklaşmış ve makinelerin düşünme kapasitesini insan zihniyle karşılaştırarak analiz etmiştir. Arf'in tanımlamasına göre, makineler belirli zihinsel yetilerle tasarlanabilir ve bu tasarımlar, insan beyninin işleyiş tarzıyla makinelerin işleyiş arasında paralellikler kurabilir (Arf, 1959). Yukarıdaki tanımlamalardan yola çıkarak yapay zekâ hakkında temelde yer alan ortak düşünce yapay zekânın, “*insan zekâsını taklit etme*”, “*akıllı programlama*” “*öğrendikçe uzmanlaşma*” gibi kavramlar üzerine oturtulabilmektedir.

Yapay zekâ, karmaşık problemlere çözüm üretmek için farklı disiplinlerden beslenen ve hızla gelişen bir bilim dalıdır. Bu geniş kapsamlı alan, günümüzde teknolojik dönüşümün en önemli itici güçlerinden biri haline gelmiştir. Yapay zekâ, teorik çerçevesi itibarıyla makine öğrenimi algoritmaları, yapay sinir ağları ve derin öğrenme gibi alt dallara ayrılarak hem geleneksel hem de modern yaklaşımları bünyesinde barındırmaktadır. Makine öğrenimi, temelinde veri odaklı tahmin ve modelleme süreçlerini içeren bir yöntemken, yapay sinir ağlarının geliştirilmesiyle daha sofistike bir boyuta taşınmış ve insan beynindeki nöronların işleyişine benzer bir mekanizma ile çalışmaya başlamıştır. Bu ilerlemelerin bir sonucu olarak ortaya çıkan derin öğrenme algoritmaları, çok katmanlı sinir ağlarının kullanımıyla görüntü işleme, doğal dil işleme ve otonom sistemler gibi pek çok alanda çığır açıcı yeniliklere olanak sağlamıştır. Bu hiyerarşik yapı, yapay zekânın teorik temelini şekillendirirken, aynı zamanda bu alanın uygulama zenginliğini ve dönüşüm potansiyelini açıkça göstermektedir. (Nilsson, 2010; Goodfellow vd., 2016; Russell ve Norvig, 2020) Günümüzde, yapay zekâ hem akademik hem de endüstriyel sahada kazandığı önem, insanlık için yeni fırsatlar sunarken beraberinde toplumsal boyutta pek çok tartışmayı da getirmektedir.

Yapay zekâ, makine öğrenimi ve alt dalları arasındaki hiyerarşik ilişki, Şekil 2'de gösterilmiştir. Bu şema, yapay zekânın genel çerçevesini ve içindeki alt alanların birbirleriyle olan bağlantısını görselleştirmektedir. Şekilde, yapay zekâ en üst düzeyde ele alınmış, bunun altına makine öğrenimi algoritmaları ve yapay sinir ağları yerleştirilmiştir. Derin sinir ağları ise yapay sinir ağlarının bir alt dalı olarak sunulmuştur.



Şekil 2. Yapay zekâ ve alt dallarının hiyerarşik yapısı.

Kaynak: (Goodfellow vd., 2016).

1.1. Makine Öğrenimi (Machine Learning)

Makine Öğrenimi (Machine Learning), verilerden kurallar öğrenebilen, değişimlere uyum sağlayabilen ve deneyimle performansını iyileştirebilen programların tasarımıyla ilgilenen bir bilim dalıdır (Taher vd., 2019). Makine Öğrenimi öğrenmeyi bir hesaplama süreci olarak ele alarak temel ilkelerini anlamayı hedeflemektedir. Bu alan, farklı türdeki görevleri başarıyla öğrenmek için gereken temel bilgi ve yetenekleri matematiksel bir düzeyde anlamayı ve bilgisayarların verilerden


öğrenmesini, geri bildirimle performanslarını iyileştirmesini sağlayan temel algoritmik prensipleri incelemeyi amaçlamaktadır. (Jordan ve Mitchell, 2015). Makine öğrenimi literatürde ilk kez resmi olarak 1959 yılında Arthur Samuel tarafından ortaya atılmıştır ve şu şekilde tanımlanmıştır: “*Makine öğrenimi, bilgisayarlara açıkça programlanmadan öğrenme yeteneği kazandıran bir çalışma alanıdır.*” Samuel’in çalışmaları, özellikle dama oynayan bir program geliştirilmesiyle ön plana çıkmıştır. Bu program, kendi performansını geçmiş oyunlardan öğrenerek geliştirebilmiştir. Bu, makine öğreniminin ilk uygulamalı örneklerinden biri olarak kabul edilmektedir (Alzubi vd., 2018).

Makine öğrenimi, analitik model oluşturma sürecini otomatikleştirerek, nesne algılama ve doğal dil çevirisi gibi bilişsel görevleri yerine getirmeyi hedeflemektedir. Bu süreç, algoritmaların problemle ilgili eğitim verilerinden iteratif olarak öğrenmesi sayesinde gerçekleşmektedir. Böylece, bilgisayarlar açıkça programlanmaya gerek kalmadan, gizli kalmış içgörülerini ve karmaşık desenleri keşfetme yeteneği kazanmaktadır (Bishop, 2006). Özellikle sınıflandırma, regresyon ve kümeleme gibi yüksek boyutlu verilerle çalışmayı gerektiren görevlerde güçlü bir uygulama alanı sunarken önceki hesaplamalardan öğrenme ve büyük veri tabanlarından düzenlilikler çıkarma yeteneği sayesinde, güvenilir ve tekrarlanabilir kararlar alınmasını kolaylaştırmaktadır. Bu nedenle, makine öğrenimi algoritmaları dolandırıcılık tespiti, kredi puanlama, en uygun teklif analizi, konuşma ve görüntü tanıma, ayrıca doğal dil işleme (NLP) gibi birçok farklı alanda başarıyla kullanılmaktadır (Goodfellow, 2016).

Verilen problem ve mevcut verilere bağlı olarak, makine öğrenimi üç temel türe ayrılmaktadır: denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning). Bu türler, ağın veriyi nasıl işlediğine, geri bildirimini nasıl değerlendirdiğine ve hedef fonksiyonunu optimize etme sürecine göre farklılık göstermektedir. Her bir öğrenme türü, belirli veri yapıları ve problem alanlarına uyacak şekilde tasarlanmıştır. Öğrenme algoritmaları, ağırlıkların güncellenmesi ve hata minimizasyonu için belirli matematiksel yöntemleri uygulamakta; bu süreç, öğrenme modelinin doğruluğunu artırmayı hedeflemektedir (Sutton ve Barto, 2018). Bu yaklaşımlar, makine öğrenimi modellerinin, veri türüne ve problem özelliklerine bağlı olarak esneklik göstermesini sağlamak ve farklı uygulama alanlarında etkili sonuçlar üretmektedir.

1.1.1. Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme modelinde çalışma kümesi, verinin özellikleri ve gözlemlenebilir çıktılar hakkında bilgiler içermektedir. Model, girdiler ile çıktılar öğrenerek oluşturulmaktadır (Gupta ve Smith, 2002). Bu öğrenme modelinde girdi ve çıktı çiftlerinden oluşan eğitim bilgileri vardır. Ağ girdi bilgisine göre yarattığı çıktı bilgisini, istenilen değerle karşılaştırmak suretiyle ağırlıkların değiştirilmesinde kullanılacak bilgiyi elde etmektedir. Girilen değer ile istenen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük çıkıncaya kadar eğitilmektedir. Bulunan hata değeri istenilen değer altına düştüğünde ağırlıkların tümü sabitlenerek eğitim işlemi sonlandırılmaktadır. Denetimli öğrenmede verilen girişler karşılığında hedeflenen çıktı üretilmiyorsa ağın çıkış değerindeki hatayı en küçük yapacak şekilde ağırlıkların değiştirilmesi sağlanmalıdır (Elmas, 2016, s. 88-89). Örneğin elektronik pazarlardaki birçok uygulama (Brynjolfsson ve McAfee, 2017), hisse senedi piyasalarını tahmin edilmesi (Jayanth Balaji vd., 2018), müşteri algılarını anlamak (Ramaswamy ve DeClerck, 2018), müşteri ihtiyaçlarını analiz etmek (Kühl vd., 2020) veya ürün araması yapmak (Bastan vd., 2020) gibi görevler bu tür uygulamalara örnek gösterilebilmektedir. Aşağıdaki şekilde denetimli öğrenme, temel hatlarıyla gösterilmektedir.



Şekil 3. Denetimli Öğrenme

Kaynak: (Elmas, 2016, s. 89).

Literatürde denetimli öğrenmede regresyon ve sınıflandırma yöntemleri kullanılmaktadır. Bu yöntemler, genellikle veri tipine, problemin yapısına ve çözülmek istenen sorunun doğasına bağlı olarak seçilmektedir. Ancak bu çalışma kapsamında, en yaygın kullanılan yöntemlerden birkaç tanesi ele alınacaktır. Aşağıda, Destek Vektör Makineleri, Karar Ağaçları, Rastgele Orman Yaklaşımı, Naive Bayes, K-En Yakın Komşu gibi algoritmalar açıklanacaktır.

1.1.1.1. Destek Vektör Makineleri (Support Vector Machines- SVM)

Destek Vektör Makineleri (SVM), temelleri Vapnik (1995), tarafından geliştirilmiş olup, son on yılda Makine Öğrenimi alanında en çok dikkat çeken ve geliştirilen yöntemlerden biri olmuştur. Bu başarının temel nedenlerinden biri, SVM'lerin genelleme ve yakınsama konusundaki güçlü teorik özellikleridir (Cristianini ve Shawe-Taylor, 2000). Ayrıca, zorlu problemler üzerindeki üstün performansı da SVM'lerin başarısında önemli bir rol oynamaktadır (Osuna vd., 1997; Dumais vd., 1998). Her ne kadar SVM'ler genellikle sınıflandırma problemleri için kullanılsa da, fonksiyon tahmini (SVM regresyonu) gibi farklı uygulama alanlarına da sahiptir (Martin, 2002). Bu yöntemde, mümkün olduğunca çok eğitim verisini doğru sınıflandırırken, maksimum marjlini ayırıcı hiper düzlem bulunmaktadır. SVM, bu hiper düzlemi destek vektörleri adı verilen ve eğitim verisinin bir alt kümesini oluşturan örneklerle temsil etmektedir. SVM optimizasyon problemini yeniden formüle ederek sürekli değerli fonksiyonu en iyi şekilde tahmin etmeyi hedeflemektedir (Awad ve Khanna, 2015). Destek Vektör Makineleri, spam filtrelemeleri, metin sınıflandırma (Joachims, 1998), hastalık tespiti (Furey vd., 2000), finansal zaman serisi analizleri (Kim, 2003) gibi alanlarda kullanılmaktadır.

1.1.1.2. Karar Ağaçları (Decision Trees-DT)

Karar ağaçları, örnek uzayını tekrarlı olarak bölerek sınıflandırma yapan bir modeldir (Rokach, 2008). Kök düğümden başlayan yapı, test düğümleriyle veriyi alt gruplara ayırmakta ve ardından ilgili karar ağacını adım adım geliştirerek çalışmaktadır. Sonuç olarak, karar düğümleri ve yaprak düğümleri içeren bir ağaç elde edilmektedir. Ağacın tepesinde, en iyi tahmin ediciye karşılık gelen kök düğüm bulunmaktadır (Kotsiantis, 2011). Sayısal özelliklerde karar ağaçları, veri uzayını eksenlere dik düzlemlerle bölen bir yapı olarak düşünülebilir. Daha basit ve anlaşılır oldukları için, karar vericiler genellikle daha az karmaşık ağaçları tercih etmektedir (Nasteski, 2017). Karar ağaçları genellikle potansiyel müşteri tepkilerini tahmin etmek ve davranışsal analizler yapmak için kullanılmaktadır (Tan vd., 2013).

1.1.1.3. Rastgele Orman Yaklaşımı (Random Forest -RF)

Rastgele Orman Yaklaşımı torbalama yöntemine rastgelelik ekleyen bir yaklaşımdır. Standart karar ağaçlarından farklı olarak, her düğümden rastgele seçilen bir alt öznitelik kümesinden en iyi bölme yapılmaktadır. Bu özellik, modeli çeşitlendirerek performansını artırmaktadır. Algoritmanın basit ve az sayıda parametreye dayanması, uygulamasını kolaylaştırmaktadır (Liaw ve Wiener, 2002). Coulston ve arkadaşları 2016 yılında yazdıkları makalede Monte Carlo yöntemi kullanılarak Random Forest regresyon modellerinin tahmin belirsizliği incelenmiş, simüle edilmiş veri kümeleriyle test edilerek tahmin hatalarının güvenilir bir şekilde değerlendirilebileceği gösterilmiştir.

1.1.1.4. Naive Bayes

Naive Bayes, Bayes Teoremi'ne dayalı olasılıksal bir sınıflandırma yöntemidir. Bu yöntem, verilerin olasılık dağılımlarını değerlendirilerek bir örneğin en yüksek olasılıkla ait olduğu sınıfa atamaktadır. Naive Bayes Sınıflayıcı, test verilerinden hareketle öğrenme sürecini gerçekleştirir ve en yüksek olasılıkla uygun sınıfı belirlemektedir (Chandra vd. 2007). Naive Bayes genellikle rekabetçi sınıflandırma doğruluğu sunmaktadır. Ayrıca, hesaplama açısından verimli olması ve diğer birçok avantajlı özelliği sayesinde, pratik uygulamalarda yaygın bir şekilde tercih edilmektedir (Webb, 2017).

1.1.1.5. K-En Yakın Komşu (K-Nearest Neighbors-KNN)


K-En Yakın Komşu algoritması, makine öğreniminde hem sınıflandırma hem de regresyon problemlerinde yaygın olarak kullanılan, sezgisel ve basit bir yöntemdir. Bu algoritma T. M. Cover ve P. E. Hart (1967) tarafından önerilmiş olup, bir veri noktasının sınıfını, bulunduğu bölgedeki en yakın komşularına ve belirlenen k değerine göre tanımlayan bir sınıflandırma yöntemidir. Bu algoritma, makine öğrenimi alanında en iyi bilinen, eski, basit ve etkili örüntü sınıflandırma yöntemlerinden biri olarak popülerliğini korumaktadır (Bhatia ve Vandana, 2020; Qiu vd., 2008; Batista ve Silva, 2009). Bu algoritma büyük eğitim setleriyle çalışırken oldukça etkili sonuçlar elde edebilen bir sınıflandırma yöntemidir. Bunun yanı sıra, ilgisiz veya

gereksiz özneliklerin bulunduğu durumlarda dahi sınıflandırma modeli oluşturabilir. Ancak, böyle durumlarda eğitim süresi önemli ölçüde uzayabilmektedir (Aha, 1991).

KNN algoritması, metin sınıflandırma alanında oldukça geniş bir uygulama alanına sahiptir. Örneğin, vatandaşların şehir gelişim süreçlerine katılımını artırmak amacıyla, vatandaşların şikâyetlerini sınıflandıran bir sistem önerilmiştir. Bu sistemin, iyi yönetim ve demokratik süreçleri destekleme açısından etkili olduğu gösterilmiştir (Tjandra vd., 2015). Bir diğer dikkat çekici kullanım alanı ise, ekonomik olayların tahmin edilmesidir. KNN algoritması, borsa hareketleri, döviz kurları, banka iflasları, finansal risk analizleri, vadeli işlem ticareti, kredi derecelendirmesi, kredi yönetimi ve banka müşteri profillemesi gibi çeşitli finansal tahmin modellerinde başarıyla uygulanmıştır (Imandoust ve Bolandraftar 2013). Bu örnekler, KNN algoritmasının esnekliği ve farklı alanlara kolayca uyarlanabilirliğini göstermektedir.

1.1.2. Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenmede, ağ yalnızca giriş verileriyle çalışmakta ve bu verilere dayanarak kendi kendine örüntüler ve gruplamalar oluşturmaktadır. Denetimsiz öğrenme algoritmalarında, istenen bir çıkış değeri olmaksızın, giriş verilerinin özelliklerine göre ağırlık değerleri ayarlanmaktadır. Bu nedenle, bu yöntem istenilen sonuçların önceden bilinmesini gerektirmemektedir. Ağ, giriş vektörleri arasındaki benzerlikleri analiz ederek, en yakın olanları gruplandırma yoluyla öğrenme sürecini gerçekleştirmektedir (Kosko, 1988, s. 142). Aşağıdaki şekilde denetimsiz öğrenme temel hatlarıyla gösterilmektedir.



Şekil 4. Denetimsiz Öğrenme

Kaynak: (Elmas, 2016, s. 137).

Denetimsiz öğrenmeye en uygun örneklerden biri de Kohonen ağıdır. Bu ağda giriş katmanına ilave olarak birbirine benzer sinirlerden oluşan bir ağ vardır. Her bir girdi, çıktı katmanında bir sinire bağlanmıştır (Elmas, 2016, s. 137). Denetimsiz öğrenme müşteri segmentasyonunda, müşterilerin demografik özellikleri veya alışveriş alışkanlıkları gibi kriterlere göre gruplandırmada kullanılmaktadır. Bu yaklaşım, hedeflenmiş pazarlama stratejileri geliştirmeye olanak tanımaktadır (ASKWEB, 2023). Müşteri yorumlarını kullanarak denetimsiz pazar segmentasyonu (Ahani vd., 2019), perakende sektöründe, müşterilerin birlikte satın aldığı ürünleri belirleyerek çapraz satış stratejileri geliştirmede kullanılmaktadır.

Denetimsiz öğrenme yaklaşımları, insan yapay zekâ sistemlerinin oluşturulmasında kritik öneme sahiptir. Bunun nedeni, akıllı makinelerin büyük miktarda etiketlenmemiş veri temelinde bağımsız çıkarımlar yapabilmesi gerektiğidir. Bu algoritmalar karmaşık görevleri çözmeye denetimli öğrenme algoritmalarından daha başarılıdır. Ancak, denetimli öğrenme modelleri, programcının sisteme açıkça hangi veriyi araması gerektiğini öğretmesi nedeniyle daha doğru sonuçlar üretmektedir (Naeem vd. 2023). Etiketlenmemiş verilerin büyük miktarda artışıyla birlikte, bu tür verilerde ilginç ve faydalı desenleri otomatik olarak keşfedebilen denetimsiz öğrenme algoritmaları, araştırmacılar ve uygulayıcılar arasında popülerlik kazanmıştır. Bu algoritmalar, desen tanıma, pazar sepeti analizi, web madenciliği, sosyal ağ analizi, bilgi erişimi, tavsiye sistemleri, pazar araştırması, saldırı tespiti ve dolandırıcılık tespiti gibi birçok uygulama alanında kullanılmaktadır (Çelebi ve Aydın, 2016).

Literatürde denetimsiz öğrenme yöntemleri, genellikle sınıflandırılmamış veri gruplarını analiz ederek veri içerisindeki gizli desenleri ve yapıları keşfetmek amacıyla kullanılmaktadır. Bu yöntemler, verilerdeki ilişkileri anlamlandırmak ve grupları ortaya çıkarmak için önemli bir araçtır. Bu çalışma kapsamında ise, bu alanda en çok kullanılan yöntemlerden bazılarına odaklanılacaktır. Aşağıda, K-Means Kümeleme, Ana Bileşen Analizi (PCA), Otomatik Kodlayıcılar (Autoencoders) gibi algoritmalar ele alınacaktır.

1.1.2.1. K Means Kümeleme (K- Means Clustering)

K-Means, etiketlenmemiş veri noktalarını gruplara ayırmak için kullanılan ve denetimsiz öğrenme algoritmaları arasında en popüler yöntemlerden biridir. Bu algoritma, verileri kümeler halinde organize ederken, her bir veri noktasının bir küme

merkezine olan mesafesini temel almaktadır. Bir kümenin merkezi, genellikle o kümedeki tüm noktaların ortalaması (veya medyanı) olarak hesaplanmaktadır. Böylece, K-Means, karmaşık veri yapılarının hızlı ve kolay bir şekilde anlamlandırılmasını mümkün kılmaktadır. K-Means algoritması, özellikle verilerin önceden belirlenmiş bir sınıfa ait olmadığı durumlarda etkili bir şekilde çalışmaktadır. Bu özelliği, Piyasa Segmentasyonu, Belge Kümeleme, Görüntü Segmentasyonu ve Sıkıştırma, Biyoinformatik gibi çeşitli uygulama alanlarında oldukça değerli kılmaktadır (IBM, 2024). Yingqiu ve arkadaşlarının 2017 yılında gerçekleştirdiği çalışmada, K-Means algoritması trafik sınıflandırma ve ağ güvenliği uygulamalarında test edilmiş ve %90'ın üzerinde doğruluk oranıyla oldukça başarılı sonuçlar elde edilmiştir. Çalışma, özellikle ağ trafiğini sınıflandırarak ve anormallikleri tespit ederek K-Means'in ağ güvenliğinde ne kadar etkili olabileceğini göstermektedir. Benzer şekilde, Jianliang ve arkadaşlarının 2009 yılında yaptığı çalışmada, K-Means algoritması saldırı tespiti amacıyla kullanılmıştır. Bu çalışmada, KDD-99 veri seti üzerinde yapılan deneylerde, %96'nın üzerinde tespit oranı ve %4'ün altında yanlış alarm oranı elde edilmiştir. Bu sonuçlar, K-Means algoritmasının yalnızca sınıflandırma değil, aynı zamanda güvenlik ve saldırı tespiti gibi kritik uygulamalarda da güçlü bir araç olduğunu ortaya koymaktadır.

K-Means'in bu geniş uygulama yelpazesi, hem basit yapısı hem de çok boyutlu veri kümelerini anlamlandırmadaki esnekliği sayesinde, akademik araştırmalardan endüstriyel çözümlere kadar çok çeşitli alanlarda kullanılmasını sağlamaktadır. Bununla birlikte, K-Means'in, veri noktalarının kümeler arasında yakın mesafelerde olduğu durumlarda performansını artırmak için ön işleme ve özellik mühendisliği ile desteklenmesi önerilmektedir.

1.1.2.2. Otomatik Kodlayıcılar (Autoencoders)

Otomatik Kodlayıcılar, etiketlenmemiş verilerden otomatik olarak özellikler öğrenebilen temsili öğrenme yöntemlerinin bir parçası olan bir ağıdır (Lopez Pinaya vd., 2020). Autoencoderlar, girdileri en az bozulmayla çıktılara dönüştürmeyi hedefleyen basit öğrenme devreleridir. Basit yapıları olmasına rağmen makine öğreniminde kritik bir rol oynamıştır. Hebbian öğrenme kurallarıyla (Hebb, 1949; Oja, 1982) birlikte autoencoderlar, denetimsiz öğrenmenin temel paradigması olarak kabul edilmektedir. Ayrıca, yerel biyokimyasal olayların sinaptik değişiklikleri nasıl düzenleyip global öğrenmeyi ve zekâ davranışlarını ortaya çıkarabileceği konusunda önemli bir başlangıç noktası sunmaktadır (Baldi, 2012).

Yakın zamandaki gizli değişken modellerindeki ilerlemeler, autoencoderları üretici modelleme alanında ön plana çıkarmıştır. Bu gelişmeler, autoencoderların şu alanlarda kullanılmasını sağlamıştır: Görüntülerdeki gürültüyü gidermek (Creswell ve Bharath, 2018), görüntülerin kaybolan veya bozulmuş bölümlerini yeniden yapılandırma (Yeh vd., 2017), görüntülerin çözünürlüğünü artırmak (Zeng vd., 2017) şeklindedir. Literatürdeki diğer çalışmalarda, Wang ve arkadaşları, Android kötü amaçlı yazılım tespit sisteminin doğruluğunu artırmak amacıyla, derin autoencoderlar ve evrimsel sinir ağlarına dayanan hibrit bir model geliştirmiştir. Bu model, sistemin daha karmaşık örüntüleri tanıma ve doğru sınıflandırma yeteneğini güçlendirmeyi hedeflemektedir (Wang vd., 2018). Yine başka bir çalışmada, oto-kodlayıcı sinir ağı (OKSA) kullanılarak Hepatit veri seti üzerinde sınıflandırma yapılmış ve yüksek doğruluk, duyarlılık ve özgüllük değerleri elde edilmiştir. Sonuçlar, önceki çalışmalara kıyasla daha iyi performans göstermiştir ve OKSA'nın Hepatit teşhisinde hızlı, verimli ve etkili bir yöntem olduğu görülmüştür (Deperlioglu, 2019).


1.1.2.3. Ana Bileşen Analizi (PCA)

Ana Bileşen Analizi, yüksek boyutlu bir uzaydaki veri noktalarını, doğrusal yapısını bozmadan daha düşük boyutlu bir uzaya indirgemeyi amaçlayan bir tekniktir. Bu yöntem, denetimsiz bir boyut indirgeme tekniğidir ve yalnızca veri noktalarının koordinatları ile hedeflenen boyut sayısını girdi olarak almaktadır. Matematiksel olarak güçlü bir temele dayanan PCA, veriyi düşük boyutlu bir uzaya yansıtarken optimal bir sonuç elde etmeyi garanti etmektedir (Boutsidis, 2008). PCA, keşifsel veri analizi için birincil bir teknik olarak, n boyutlu bir veri bulutunu döndürerek, veri içerisindeki maksimum değişkenliği görünür hale getirmektedir. Bu yaklaşım, veri setindeki güçlü desenleri daha net ve anlaşılır hale getirmekte ve böylece verinin analizi ve görselleştirilmesi hem daha kolay hem de daha etkili bir şekilde yapılabilmektedir (Usama vd., 2019). PCA, boyut indirgeme, desen keşfi ve veri görselleştirme gibi birçok alanda etkili bir yöntem olarak kullanılmaktadır (Jolliffe ve Cadima, 2016).

1.1.3. Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli (takviyeli) öğrenme, bir ajan ile çevre arasında sürekli bir etkileşim sürecine dayanan bir öğrenme paradigmasıdır. Ajan, çevredeki durumları gözlemleyerek aksiyonlar almakta ve bu aksiyonların sonucunda bir ödül ya da ceza almaktadır.

Amaç, ajan için bir politika geliştirmek ve bu politikayı optimize ederek toplam ödülü maksimize etmektir (Kaelbling vd., 1996).



Şekil 5. Pekiştirmeli Öğrenme Yapısı

Kaynak: (Ankan Kargı, 2015, s. 68).

Pekiştirmeli öğrenme yöntemlerinden yararlanılarak “Genetik Algoritmalar” ve “Learning Vector Quantization (LVQ)” modelleri geliştirilmiştir. Bu modeller, eğiticiden gelen sinyaller doğrultusunda ağırlıkları dinamik olarak değiştirerek öğrenme sürecini gerçekleştirmektedir (Güven, 2020, s. 50). Bu yöntem, öneri sistemlerinde kullanıcı etkileşimlerine dayalı olarak bireysel önerileri özelleştirmek amacıyla etkin bir şekilde kullanılmaktadır. Aynı zamanda, kişiselleştirilmiş deneyimler sunarak ürün satışlarını optimize etmeyi hedeflemektedir. Örneğin, bir uygulama, kullanıcıların demografik bilgilerine dayanarak reklamlar gösterir ve her reklam etkileşiminde, hangi reklamların daha etkili olduğunu öğrenerek önerilerini sürekli olarak iyileştirmektedir (Amazon Web Services, 2023).

Aşağıdaki tablo, makine öğreniminin alt dallarını, bu dalların temel özelliklerini, veri kullanım biçimlerini ve çeşitli uygulama alanlarını özetlemektedir. Denetimli, denetimsiz ve pekiştirmeli öğrenme gibi temel kategorilerin tanımları, girdileri nasıl kullandıkları, hangi durumlarda tercih edildikleri ve sağladıkları sonuçlarla birlikte, her bir dalın temsilci algoritmaları ve gerçek dünya uygulama alanları detaylı bir şekilde sunulmaktadır.

Tablo 1. Makine Öğrenimi Türlerinin Özellikleri ve Kullanım Alanları

Özellikler	Denetimsiz Öğrenme	Denetimli Öğrenme	Pekiştirmeli Öğrenme
Tanım	İnsan müdahalesi olmadan verilerdeki örüntüleri ve yapıları keşfetmeye çalışan makine öğrenimi türüdür.	Etiketlenmiş veriler kullanılarak girdilerle çıktılar arasında bir ilişki öğrenen makine öğrenimi türüdür.	Bir ajanın, çevresinden aldığı ödüllere veya cezalara göre optimal bir politika öğrenmesine dayalı öğrenme türüdür.
Girdi Verisi ¹	Etiketlenmemiş	Etiketlenmiş	Çevreden gelen geri bildirimler (ödül/ceza)
Veri Kullanımı	Model, yalnızca girdileri analiz eder ve çıktıya gerek duymaz.	Model, girdiler ve çıktılar arasındaki ilişkiyi öğrenir.	Ajan, bir politika geliştirmek için eylemleri ve sonuçlarını kullanır.
Ne Zaman Kullanılır	Ne aradığınızı bilmediğiniz durumlarda	Ne aradığınızı bildiğiniz ve etiketli verilerin bulunduğu durumlarda	Çevreden öğrenme yoluyla adım adım karar almanın gerekli olduğu durumlarda
Sonuçların Doğruluğu	Daha az kesin sonuçlar sağlayabilir.	Daha kesin sonuçlar sağlar.	Doğruluk, ajanın çevreyi öğrenme sürecine ve uzun vadeli ödül optimizasyonuna bağlıdır.
Algoritmalar	Kümelendirme Algoritmaları, Boyut İndirgeme Algoritmaları, Bağlılık Analizi, Anomali Tespiti Algoritmaları	Karar Ağaçları, Destek Vektör Makineleri, Naive Bayes, K-En Yakın Komşu, Rastgele Orman Yaklaşımı	Q-Öğrenme, Derin Pekiştirmeli Öğrenme, Monte Carlo Yöntemleri, Asenkron Avantajlı Aktör-Eylem

¹ Girdi verisi, denetimsiz öğrenme algoritmalarında, genellikle etiketlenmemiş veriler ile çalışır. Yani, verilerde "doğru" cevaplar veya sınıflandırma etiketleri yoktur. Denetimli öğrenme algoritmalarında, etiketlenmiş veriler vardır. Bu, verilerin hem girdileri (örneğin, bir görüntü) hem de doğru çıktıları (örneğin, bu görüntünün bir "kedi" olduğu) içerdiği anlamına gelir. Pekiştirmeli öğrenme algoritmaları, girdileri veya etiketlenmiş çıktıları kullanmak yerine, çevre ile etkileşim kurmaktadır. Amaç en yüksek toplam ödülü elde edecek şekilde eğitmektir.


Uygulanma Alanları	Müşteri segmentasyonu, pazar analizi, anomali tespiti, veri sıkıştırma, dijital sinyal işleme, saldırı tespiti ve dolandırıcılık	Spam filtreleme, talep tahmini, fiyat tahmini, yüz tanıma, Hastalık teşhisi, Finansal risk analizi	Otonom araçlar, robotik sistemler, oyun oynama, dinamik fiyatlandırma, fabrika otomasyonu, trafik ışıklarının optimizasyonu.
--------------------	--	--	--

Kaynak: (Altexsoft 2021; Sutton ve Barto, 2018).

1.2. Yapay Sinir Ağları (Artificial Neural Networks- ANN)

Yapay sinir ağları, insan beynindeki nöronların çalışma prensiplerinden esinlenerek geliştirilen güçlü bir hesaplama modelidir. Bu ağlar, öğrenme, problem çözme ve karar verme gibi karmaşık süreçleri taklit etmektedir. Canlılardaki biyolojik sinir hücrelerinin işlevine benzer şekilde, yapay zekâ alanında “*yapay sinir hücreleri*” veya “*proses elemanları*” olarak adlandırılan yapılar kullanılmaktadır. Bu yapay sinir hücreleri, her biri beş temel bileşenden oluşan, bilgiyi işleyen ve aktarabilen birimlerdir (Öztemel, 2012, s. 48). Bu birimler:

- Girdiler (inputs)
- Girdi ağırlıkları (input weights)
- Toplama fonksiyonu (summing function)
- Aktivasyon fonksiyonu (activation function)
- Çıktı (output)



Şekil 6. Yapay Sinir Ağı Mimarisi

Kaynak: (Öztemel, 2012, s. 32).

Girdi, yapay sinir hücresine çevreden verilen bilgilerdir. Girdi ağırlıkları, hücreye ulaşan verilerin üzerindeki etkisini belirleyen değerlerdir. Veriler, bağlantılar üzerinden ağırlıklarla birlikte hücreye iletilir ve bu ağırlıklar, yapay sinirde kullanılacak girdilerin matematiksel katsayılarını oluşturmaktadır (Arıkan Kargı, 2015, s. 39). Toplama fonksiyonu, yapay sinir hücresine gelen net girdileri hesaplayarak sonucu aktivasyon fonksiyonuna iletmektedir. Burada gelen her girdi değeri kendi ağırlığı ile çarpılarak toplanmaktadır. Aktivasyon fonksiyonu, toplama fonksiyonundan gelen bilgileri işleyerek hücrenin çıkışını belirlemektedir. Bu fonksiyon bir yapay sinir ağındaki nöronun çıkış genişliğini (0,1) veya (-1,1) değerleri arasında sınırlandırmaktadır (Sağiroğlu vd., 2003). Bir sonucun hesaplanabilmesi için toplama fonksiyonlarında olduğu gibi aktivasyon fonksiyonlarında da çeşitli formüller kullanılmaktadır. Tasarımcı çeşitli denemeler yaparak farklı varyasyonları deneyerek uygun aktivasyon fonksiyonunu belirlemektedir (Yurtoğlu, 2005, s. 17). Aktivasyon fonksiyonunun sonucunda elde edilen değer, sistemin çıktısını oluşturmaktadır. Bu çıktı değeri, yapay sinir hücresinin diğer katmanlarına girdi olarak veya dış dünyaya iletilebilmektedir. Her ne kadar bir hücre, yalnızca bir çıktı üretse de ağ yapısında gösterildiğinde birden fazla çıktısı varmış gibi görünebilmektedir. Bu, ağın karmaşık bağlantı yapısının bir sonucu olarak ortaya çıkmaktadır (Öztemel, 2012, s. 51).

Literatürde Yapay Sinir Ağları, algoritmaya ve uygulanan ağ modeline göre değişmektedir. Genel özellikleri aşağıdaki gibi sıralanabilmektedir.

- Doğrusal olmama: Yapay sinir ağlarının temel işlem elemanı doğrusal bir yapıda olmadığından dolayı bu hücrelerin birleşmesiyle oluşan yapay sinir ağları doğrusal bir yapıda değildir. Ayrıca aynı katmanlar arasında zaman bağımlılığı da yoktur. Bu sayede sistem eşzamanlı çalışabilmekte ve hızı artmaktadır (Arıkan Kargı, 2015, s. 25). Bunların bir sonucu olarak yapay sinir ağları ile lineer olmayan komplekse problemler kolaylıkla çözülebilmektedir (Simpson, 1989, s. 5).

- Paralel çalışma: Bu özellik, özellikle büyük ve karmaşık veri setleriyle çalışırken önem kazanmaktadır. İşlem elemanlarının paralel bir şekilde çalışması, ağı aynı anda birden fazla işlemi yürütebilmesini sağlamaktadır, bu da öğrenme sürecini hızlandırmakta ve verimliliği artırmaktadır. Özellikle büyük ölçekli entegre devre teknolojisi (VLSI) sayesinde, donanım tabanlı hızlandırma mümkün hale gelmiş ve bu da yapay sinir ağlarının gerçek zamanlı uygulamalarda kullanılabilirliğini artırmıştır (Aytekin, 2006, s. 51).
- Genelleme Yeteneği: Yapay sinir ağları, bir problemi öğrendikten sonra daha önce karşılaşmadıkları test örneklerine de yanıt verebilmektedir. Eğitilen bir ağa, girdi katmanına bir kısım eksik, bozuk bir bilgi verilse bile ağ bunu tamamlayıp buna uygun çıktı üretebilmektedir (Tebelkıs, 1995).
- Örneklerden öğrenme: Yapay sinir ağları olay ile ilgili örneklerin verilmesi ile öğrenmektedir. Örnekleri kullanarak olay hakkında genelleme yapabilecek bir yeteneğe kavuşturulmaktadır (Öztemel, 2012, s. 31). Yapay sinir ağlarının yapısı karmaşık olduğu için ağırlıklar ve bağlantılar önceden ayarlanmış bir şekilde verilememektedir. Bu nedenle istenilen davranış gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmektedir.
- Hata toleransı: Hata toleransı bir ya da daha fazla değişkenin eksilmesi durumunda yapay sinir ağının düzgün çalışmasına izin veren bir özelliktir (Su vd., 2016). Yapay sinir ağları dağıtık sistemlerden oluşmasından dolayı doğası gereği hataya toleranslıdır (Minohara, 2006). Bundan dolayı yapay sinir ağları klasik yöntemlere göre hatayı tolere etme konusunda son derece başarılıdır.
- Uyarlanabilir olma: Yapay sinir ağları, problemde meydana gelen değişimlere göre yeniden eğitilebilmekte, çeşitli koşullara uyarlanabilmektedir. Bu özellik sayesinde örnekleri tanıma, sinyal işleyebilme, sistemi tanımlama ve denetim gibi alanlarda etkin bir şekilde kullanılmasını sağlamaktadır (Simpson, 1989).
- Kendi ilişkilerini oluşturma: Yapay sinir ağları katı kurallara dayalı, sabit bir denkleme bağlı kalmamakta, Aksine, girdiler ve çıktılar arasındaki bağıntıları öğrenerek, sürekli olarak ağırlıklarını optimize etmekte ve yeni örüntüler keşfetmektedir. Bu sayede, sinir ağları her türlü problem için özel çözümler üretebilmekte ve verilerdeki karmaşık ilişkileri tanıyabilmektedir.
- Belirsiz Bilgileri İşleyebilme: Yapay sinir ağları, olayları öğrendikten sonra belirsizlik içeren durumlarda bu olaylar arasındaki ilişkileri kurarak uygun kararlar alabilmektedir (Öztemel, 2012, s. 33).

Yapay sinir ağları, farklı uygulama alanlarına uyum sağlayabilmek farklı veri türlerini işlemek ve çeşitli sorunlara çözüm üretmek için özel olarak tasarlanmıştır (Russell ve Norvig, 2020). Yapay Sinir Ağları yapısındaki katmanlara, mimari yapısına, öğrenme kuralına göre üçe ayrılmaktadır. Her bir algoritma türü, farklı çalışma prensiplerine ve uygulama alanlarına sahiptir.

Tablo 2. Yapay Sinir Ağları Sınıflandırması

Yapısındaki Katmanlara Göre Yapay Sinir Ağları	Mimari Yapısına Göre Yapay Sinir Ağları	Öğrenme Kuralına Göre Yapay Sinir Ağları
Tek Katmanlı Yapay Sinir Ağları	İleri Beslemeli Yapay Sinir Ağları	Hebb Öğrenme Kuralı
Çok Katmanlı Yapay Sinir Ağları	Geri Beslemeli Yapay Sinir Ağları	Hopfield Öğrenme Kuralı
		Delta Öğrenme Kuralı
		Gradyan Öğrenme Kuralı
		Kohonen Öğrenme Kuralı

Kaynak: Haykırı, 1994; Çelik, 2011; Karaman, 2017; Elmas, 2018'den türetilerek yazar tarafından oluşturulmuştur.

1.2.1. Yapısındaki Katmanlara Göre Yapay Sinir Ağları

Yapay sinir ağları, yapılarındaki katman sayısı ve bu katmanların işlevlerine göre sınıflandırılarak, farklı veri türlerine ve problemlere uygun çözümler sunmaktadır. Bu sınıflandırma, sinir ağlarının öğrenme kapasitesini, karmaşıklığını ve uygulama alanlarını belirlemektedir (Haykırı, 1994). Yapısındaki katmanlara göre yapay sinir ağları, tek katmanlı, çok katmanlı sinir ağı olmak üzere ikiye ayrılmaktadır.

1.2.1.1. Tek Katmanlı Yapay Sinir Ağları (One Layer Neural Network)

Tek katmanlı yapay sinir ağları, yalnızca bir giriş ve bir çıkış katmanı içermektedir. Bu tür ağlar, genellikle doğrusal problemleri çözmek için yeterlidir. Ara katman bulunmadığından, veri işleme kapasitesi sınırlıdır. Tek katmanlı yapılar genellikle algılayıcı (perceptron) olarak bilinen basit modellerle temsil edilmektedir (Rosenblatt, 1958). Tek katmanlı bir algılayıcının hesaplanması, her bir ağırlıklarına karşılık gelen vektör elemanı ile çarpılan değer ile giriş vektörünün toplamının hesaplanması üzerinden gerçekleştirilmektedir. 1940'lı yıllarda Warren McCulloch ve Walter Pitts çalışmalarında tek katmanlı yapay sinir ağları kullanılmışlardır (McCulloch ve Pitts, 1943). Sonraki yıllarda tek katmanlı algılayıcıların sadece doğrusal olayları çözebilmesi, doğrusal olmayan olaylarda tıkanması ve XOR problemini çözmemesi nedeniyle gözden düşmüştür.

1.2.1.2. Çok Katmanlı Yapay Sinir Ağları (Multi-Layer Neural Network)

Çok katmanlı yapay sinir ağı ileri doğru bağlantılı üç katmandan oluşan bir sinir ağıdır. Çok katmanlı ağda bilgiler bir katmandan ağa sunulmakta ve gizli katmanlardan geçerek çıkış katmanına gitmekte ve ağa sunulan girdiler karşılığında ağın cevabı dış dünyaya iletilmektedir. Bu sinir ağı danışmanlı öğrenme stratejisine göre çalışmaktadır. Bu ağa eğitimde hem girdi hem de çıktı verileri gösterilmektedir. Burada ağın görevi her girdiye karşılık gelen çıktıyı üretmektir. Bu ağ Delta öğrenme kuralının genelleştirilmiş şeklidir (Öztemel, 2012, s. 76-77).

1.2.2. Mimari Yapısına Göre Yapay Sinir Ağları

Yapay sinir ağları katmanları arasındaki nöron durumuna ve bağlantı şekillerine göre sınıflandırılmaktadır. Bu sınıflandırma, ağın bağlantı düzeni, veri işleme yöntemi ve katmanlar arası bilgi akışını temel almaktadır (Bishop, 2006). Mimari Yapısına Göre Yapay Sinir Ağları İleri Beslemeli ve Geri Beslemeli Yapay Sinir Ağı olmak üzere ikiye ayrılmaktadır.

1.2.2.1. İleri Beslemeli Yapay Sinir Ağları (Feedforward Neural Networks- FNN)

İleri beslemeli yapay sinir ağları 1970'li yıllarda geliştirilmiştir. Bu yapının ilerlemesinde birçok araştırmacının katkıları olmuştur (Rumelhart vd., 1986; Parker, 1987). İleri beslemeli yapay sinir ağları tasarlanan ilk ve en basit yapay sinir ağlarıdır (Schmidhuber, 2015, s. 89). Bu ağda bilgi, giriş düğümlerinden, gizli düğümlerden (varsa) ve çıkış düğümlerine yalnızca bir yönde ileri doğru hareket etmektedir (Zell, 1994, s. 73). İleri beslemeli yapay sinir ağlarında nöronlar birbirleriyle bağlantı kurarken bilgiyi kendi içlerine aktarmadıkları için çıktı hızlı bir şekilde sağlanmaktadır (Mammadova, 2020, s. 7). Bu ağlar genellikle tahmin, fonksiyon kestirme ve örüntü tanıma gibi alanlarda kullanılmaktadır (Cura, 2008, s. 19).

1.2.2.2. Geri Beslemeli Yapay Sinir Ağları (Recurrent Neural Networks- RNN)

Geri beslemeli yapay sinir ağları, çıktıdan girdiye doğru döngüsel bağlantılar bulunmaktadır. Bu ağlar, bir önceki çıktı bilgisini yeniden işleme dâhil ederek, daha karmaşık ve dinamik veri yapılarını öğrenebilmektedir (Elman, 1990). Bu ağda en az bir işlemci ya kendisine ya da diğer elemanlara girdi olarak verilmektedir. Ağdaki geri besleme bir geciktirme elemanı üzerinden gerçekleşmektedir. Buradaki geri besleme süreci katmandaki işlemci elemanları arasında olduğu gibi işlemci elemanlar arasında da olabilmektedir. Geri beslemeli Yapay Sinir Ağlarının dinamik yapıya sahip olması sayesinde bilgi akışı bir döngüye sahip olmakta ve tahmin uygulamalarında başarılı sonuçlar vermektedir (Arıkan Kargı, 2015, s. 64).

1.2.3. Öğrenme Kuralına Göre Yapay Sinir Ağları

Öğrenme Kuralına Göre Yapay Sinir Ağları, öğrenme sürecinde kullanılan kurallara ve bu kuralların bilgi güncelleme mekanizmalarına göre sınıflandırılmaktadır. Bu sınıflandırma, ağın nasıl eğitileceğini ve öğrenme stratejilerini tanımlamaktadır (Mitchell, 1997). Öğrenme Kuralına Göre Yapay Sinir Ağları, Hebb Öğrenme Kuralı, Hopfield Öğrenme Kuralı, Delta öğrenme kuralı, Gradyan Öğrenme Kuralı, Kohonen Öğrenme Kuralı olmak üzere beş başlık altında sıralanmaktadır.

1.2.3.1. Hebb Öğrenme Kuralı

Hebb, 1949 yılında "*Organization of Behavior*" kitabında sinapsların duruma göre uyum sağlama yeteneklerini incelemiş ve Hebbian Öğrenme Kuralını ortaya koymuştur. Bu kurala göre sinir ağlarındaki nöronların arasındaki bağlantı aktif olduğunda bağlantı güçlenmektedir. Buna göre sinir ağlarındaki bağlantı sayısıyla öğrenebilme ve uyum sağlayabilmenin ilişkili olduğunu savunmuştur. Hebb öğrenme kuralına göre, bir sinir hücresi başka bir sinir hücresini tekrar tekrar ateşlediğinde, bu iki hücre arasındaki bağlantı güçlenmektedir. Matematiksel olarak iki nöron arasındaki sinaptik ağırlığın, giriş ve çıkış sinyallerinin çarpımıyla ifade edilmektedir (Hebb, 1949).

1.2.3.2. Hopfield Öğrenme Kuralı

Hopfield Ağları, 1982 yılında John Hopfield tarafından geliştirilen model biyolojik sinir sistemlerinden esinlenmiştir ve içerdiği nöronlar arasındaki geri beslemeli bağlantılar sayesinde öğrenme ve hafıza süreçlerini simüle etmektedir. Hopfield Ağları, özellikle asosiyatif hafıza ve optimizasyon problemleri için kullanılmaktadır. Bu kural temelde Hebb kuralı ile benzer özellikler taşımaktadır. Hopfield kuralında bağlantılardaki ağırlığın ne kadar artırılıp azaltılacağı öğrenme katsayısı ile saptanmaktadır. Bağlantıların (sinaptik ağırlıkların) nasıl güncelleneceğini tanımlayarak ağın belirli bir enerji fonksiyonunu minimize etmesini ve dengeli bir durum (sabit bir çıktı) bulmasını sağlamaktadır (Hopfield, 1982). Hopfield Öğrenme ağı gürültüye dayanıklı bir şekilde örüntüleri öğrenebilmekte, ağın enerji fonksiyonunu minimize ederek kararlı bir çıktı

üretebilmekte ve basit bir mekanizmayla örüntülerin hafızada depolanmasını sağlamaktadır. Ancak fazla yükleme durumunda yanlış örüntü hatırlamaları olabilmektedir (Amit, 1989).

1.2.3.3. Delta öğrenme kuralı

Delta öğrenme kuralı, Hebb kuralının geliştirilmiş versiyonudur. Bu kural istenilen çıktı değeri ile yapay sinir ağının sunduğu çıktı değerlerini karşılaştırarak aralarındaki farkı azaltmak amacıyla geri besleme yapan bir öğrenme ağıdır. Buna göre ağ hatasının karesini minimuma indirebilmek için bağlantının boyutlarını değiştirmektedir. Bulunan hata önceki katmanlara tek seferde geriye doğru yayılmakta ve bu işlem birbiri ardına ilk katmana ulaşılan kadar devam etmektedir. Delta kuralı aynı zamanda En Küçük Ortalama Kare Kuralı ve Widrow-Hoff Öğrenme Kuralı olarak adlandırılmaktadır (Piramuthu vd., 1994).

1.2.3.4. Gradyan Öğrenme Kuralı

Gradyan öğrenme kuralı Delta kuralının geliştirilmesiyle oluşturulmuştur. Gradyan öğrenme kuralı, yapay sinir ağlarının eğitiminde kullanılan temel bir optimizasyon algoritmasıdır. Bu kural, modelin hata fonksiyonunu minimize etmek için ağırlıkları sistematik bir şekilde güncellemektedir. Gradyan inişi, özellikle çok katmanlı sinir ağlarında ve geri yayılım algoritması ile birlikte yaygın olarak kullanılmaktadır Gradyan öğrenme kuralı, hata fonksiyonunun türevini kullanarak ağırlıkların hatayı azaltacak şekilde güncellenmesini sağlamaktadır (Goodfellow vd., 2016).

1.2.3.5. Kohonen Öğrenme Kuralı

Kohonen (1982), bu kuralı geliştirirken canlıların biyolojik sistemlerinden esinlenmiştir. Bu kuralda, yapay sinir hücreleri ağıdaki ağırlıkları ayarlamak için birbirleriyle yarışmaktadır. Buna göre en iyi çıktıyı veren diğerlerine göre daha baskın hale gelmekte ve sadece bu ağı çıktığı sağlaması söz konusu olmaktadır. Ancak yarışta kazanan sinir hücresi kendisine komşu olan sinir hücrelerinin ağırlıklarını artırabilmektedir Kohonen kuralı dağılımlara yönelik çalışmalarda tercih edilse de teorik altyapısının iyi geliştirilememesinden dolayı uygulamada yaygın hale gelememiştir (Haykin, 1999).

1.3. Derin Öğrenme (Deep Learning)

Derin öğrenme, verilerin çok katmanlı bir hiyerarşik yapıda temsil edilmesine dayanan bir yöntemdir. Bu yaklaşımda, verilerin farklı özellik seviyeleri ya da temsilleri öğrenilmekte ve daha üst düzeydeki soyut özellikler, alt düzey özelliklerden türetilmektedir. Böylece, veri hiyerarşik bir biçimde farklı soyutlama seviyelerinde temsil edilmiş olmaktadır. Bu yapı, verilerin karmaşıklığını daha iyi anlamayı ve işlemsel açıdan verimli bir şekilde öğrenmeyi sağlamaktadır (Bengio, 2009).

Bir görüntü üzerinde çalışıldığında, temsil seviyeleri piksellerin yoğunluk değerleri, kenar kümeleri ya da belirli geometrik şekiller gibi farklı özellik gruplarını içerebilmektedir. Her bir özellik seviyesi, bir önceki seviyeden gelen bilgilerle daha karmaşık ve soyut temsiller oluşturmaktadır. Derin öğrenme, bu temsillerin hangi özelliklerinin veriyi daha iyi yansıttığını otomatik olarak öğrenme yeteneğine sahiptir. Bu yöntemlerin en büyük avantajlarından biri, geleneksel yöntemlerde kullanılan “elle çıkarılan özellikler (handcrafted features)” yerine, veriyi doğrudan en iyi temsil eden özelliklerin algoritmalar aracılığıyla öğrenilmesidir (Song ve Lee, 2013). Örneğin, görüntü işleme, ses tanıma veya doğal dil işleme gibi alanlarda, elle çıkarılan özellikler genellikle sınırlı ve insan uzmanlığına bağlıdır. Ancak derin öğrenme yöntemleri, büyük veri kümeleri üzerinde otomatik olarak çalışarak, çok daha geniş bir özellik yelpazesi oluşturabilir ve bu sayede daha yüksek doğruluk oranlarına ulaşabilir. Ek olarak, derin öğrenme algoritmalarının başarısı, genellikle büyük veri kümelerine erişim ve güçlü donanımların kullanılabilmesine bağlıdır. Bu süreçte, konvolüsyonel sinir ağları (CNN), tekrarlayan sinir ağları (RNN) ve generative adversarial networks (GANs) gibi derin öğrenme mimarileri, belirli veri türleri üzerinde etkili temsiller oluşturmak için kullanılmaktadır. Bu yöntemler, verilerin içindeki gizli kalıpları ve ilişkileri anlamada önemli rol oynamaktadır.

Derin sinir ağları konuşma tanıma, görüntü sınıflandırma ve doğal dil işleme gibi pek çok makine öğrenimi görevinde dikkate değer başarılar elde etmiştir (Hinton ve Salakhutdinov, 2006; Krizhevsky vd., 2012; Ciresan vd., 2012; Weston vd., 2012). Derin öğrenme ağlarının başarısında derinlik kavramının önemli bir rol oynadığı yaygın bir şekilde kabul görmektedir (Srivastava vd., 2015; 2015; Szegedy vd., 2014). Derin öğrenmenin etkili bir şekilde uygulanmasını sağlayan bu kavram, farklı ihtiyaçlara ve veri türlerine uygun olarak geliştirilmiş olmasıdır. Her biri belirli bir veri türü veya problem için optimize edilmiş olan bu mimariler, derin öğrenmenin farklı uygulama alanlarında başarıya ulaşmasında kritik bir rol oynamaktadır. Örneğin, Konvolüsyonel Sinir Ağları genellikle görüntü işleme alanında kullanılırken, Tekrarlayan Sinir Ağları ve Uzun Kısa Vadeli Bellek Ağları sıralı verilerle çalışan problemlerde tercih edilmektedir. Ayrıca, Sınırlı Boltzmann Makineleri ve Derin İnanç

Ağları gibi yapılar, veri temsilinde yüksek doğruluk ve soyutlama sağlayarak, derin öğrenme modellerinin geniş bir uygulama yelpazesinde etkili bir şekilde kullanılmasına olanak tanımaktadır. Aşağıdaki bölümlerde, bu sinir ağı türlerinin temel özellikleri, işlevleri ve hangi alanlarda ön plana çıktıkları ele alınacaktır.

1.3.1. Konvolüsyonel Sinir Ağları (Convolutional Neural Networks- CNN)

Konvolüsyonel Sinir Ağları çok katmanlı algılayıcıların özel bir türüdür. Bu yapı, hayvanların görsel sisteminden ilham alınarak geliştirilmiştir. Görme merkezindeki hücrelerin alt bölgelere ayrıldığı ve her bir bölgenin belirli özellikleri algıladığı düşünülmektedir. Basit hücreler kenar benzeri temel özelliklere odaklanırken, karmaşık hücreler daha geniş alıcı alanlarıyla tüm görsel sahneye tepki vermektedir. CNN algoritması da, bu biyolojik süreçleri taklit ederek görsel verileri işlemek için tasarlanmıştır. CNN’de kullanılan matematiksel konvolüsyon işlemi, bir nöronun kendi algı alanındaki uyarılara verdiği tepkiyle ilişkilendirilmektedir (Hubel ve Wiesel, 1968; Fukushima, 1980; LeCun vd., 1998). Bu ağ yapısı, bir veya daha fazla konvolüsyonel katman, altörnekleme katmanı ve ardından standart çok katmanlı bir sinir ağı gibi tamamen bağlı katmanlardan oluşmaktadır. Bu özellikleri sayesinde CNN’ler, görüntü işleme ve nesne tanıma gibi birçok alanda etkili sonuçlar elde etmektedir (LeCun vd., 2015).

2014 yılında düzenlenen ImageNet Yarışması’nda, milyonlarca görüntüden ve yüzlerce nesne sınıfından oluşan geniş bir veri kümesiyle gerçekleştirilen nesne sınıflandırma ve algılama yarışmalarında, en yüksek başarıyı elde eden ekiplerin tamamı, CNN algoritmalarının farklı versiyonlarını ve modifikasyonlarını kullanmıştır (Girshick vd., (2014). Bu yarışma, CNN’nin görüntü işleme alanındaki üstünlüğünü ve esnekliğini kanıtlayan önemli bir dönüm noktası olmuştur. 2015 yılında yapılan başka bir çalışmada, CNN algoritması, ters çevrilmiş yüzler ve geniş açılardaki farklı pozisyonlarda bulunan yüzleri tanımlama konusunda da büyük bir başarı göstermiştir. Bu model, hem çeşitli açılardaki yüz görüntülerini içeren 200.000 görsel hem de yüz barındırmayan 20 milyon ek görsel içeren devasa bir veri kümesi üzerinde eğitilmiştir. Bu kapsamlı eğitim süreci, CNN’nin yalnızca statik görüntüler üzerinde değil, karmaşık görsel varyasyonlar üzerinde de etkili bir şekilde çalışabileceğini ortaya koymuştur (Farfadi vd., 2015). Bu çalışmalar, CNN’nin sadece nesne sınıflandırma ve algılama gibi temel görevlerde değil, aynı zamanda karmaşık yüz tanıma gibi daha zorlayıcı problemlerde de ön plana çıktığını göstermektedir. Ayrıca, CNN’nin farklı veri türlerini işlemedeki esnekliği, onu birçok farklı uygulama alanında vazgeçilmez bir araç haline getirmiştir.

1.3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Networks- RNN)

Tekrarlayan Sinir Ağları birimler arasında döngüsel bağlantılara sahip olan ve bu sayede zamanla değişen veriler üzerinde dinamik bir şekilde işlem yapabilen yapay sinir ağı modelidir. RNN’ler, ileri beslemeli sinir ağlarından farklı olarak, girdilerin sıralı yapısını dikkate almakta ve belleğini kullanarak rastgele dizileri işleyebilmektedir (Mikolov, 2010). RNN’lerin temel amacı, sıralı ve bağlam bağımlı bilgileri analiz edebilmektir. Görüntü tabanlı verilerde genellikle girdilerin veya çıktılarının birbirinden bağımsız olduğu varsayılmaktadır. Ancak, doğal dil işleme (NLP) gibi zaman boyutunun kritik olduğu alanlarda bu varsayım geçerli değildir. Örneğin, bir cümlede bir sonraki kelimeyi doğru bir şekilde tahmin edebilmek için, önceki kelimelerin sırası ve bağlamı hakkında bilgi sahibi olmak gereklidir. RNN’lerin “tekrarlayan” olarak adlandırılmasının nedeni, dizideki her bir öğeyi (örneğin bir cümledeki kelimeleri) önceki çıktılara dayalı olarak işlemesidir. Bu yapı, sıralı verilere anlam kazandırmada ve bağlam ilişkilerini analiz etmede RNN’lere büyük bir avantaj sağlamaktadır. Bu özellik, özellikle dil modeli oluşturma, konuşma tanıma ve zaman serisi analizi gibi alanlarda RNN’lerin etkili bir şekilde kullanılmasına olanak tanımaktadır. 2015 yılında yapılan bir çalışmada, derin tekrarlayan sinir ağı (RNN) mimarisi ile bilgisayarla görme ve doğal dil işleme alanlarını birleştiren yenilikçi bir model geliştirilmiştir. Model, görüntülerin içeriğini analiz ederek doğal cümlelerle açıklamalar üretebilmekte ve bu süreçte makine çevirisi yöntemlerinden de faydalanmaktadır. Eğitim sırasında, görüntü açıklamalarının hedef cümleleri ile uyumunu maksimize etmeye odaklanan model, Pascal, Flickr30k, SBU ve COCO gibi farklı veri kümelerinde yapılan deneylerde, insan performansına yakın doğruluk ve akıcılık sonuçları elde etmiştir. Bu başarı, modelin hem dil üretimi hem de görsel içerik anlama konularında etkili olduğunu göstermektedir (Vinyals vd., 2015).

1.3.3. Uzun Kısa Vadeli Bellek Ağları (Long Short-Term Memory- LSTM)

Uzun Kısa Vadeli Bellek Ağları (LSTM), 1997 yılında Hochreiter ve Schmidhuber tarafından, uzun vadeli bağımlılıkları etkili bir şekilde öğrenebilmek amacıyla geliştirilmiştir (Hochreiter ve Schmidhuber, 1997). Bu model, özellikle Tekrarlayan Sinir Ağları’nın (RNN) uzun süreli bağlam bilgisini korumakta zorlandığı durumlarda önemli bir çözüm sunarak, zamanla değişen

ve sıralı yapıya sahip verilerin işlenmesinde devrim yaratmıştır. LSTM mimarisi, giriş, unutma² ve çıkış olmak üzere üç kapı, blok girişi, sabit hata döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme bağlantılarından oluşan karmaşık ve esnek bir yapıya sahiptir (Greff vd., 2015). Bu kapılar, bilginin hangi kısmının korunacağını, hangi kısmının unutulacağını ve hangi kısmının bir sonraki adımda kullanılacağını belirleyerek, öğrenme sürecini optimize etmektedir. Bloklardan elde edilen çıktılar, tekrar girişe ve tüm kapılara bağlanarak ağız döngüsel yapısını oluşturmaktadır. Bu yapı, verinin sıralı bir şekilde işlenmesini sağlamakta ve geçmiş bilgilerle mevcut veriler arasında anlamlı bir bağ kurmaktadır. LSTM'nin ilk versiyonunda unutma kapısı ve gözetleme bağlantıları bulunmamaktaydı. Ancak, unutma kapısı daha sonra modelin kendi durumunu sıfırlayabilmesini sağlamak amacıyla eklenmiş (Gers vd., 2000), gözetleme bağlantıları ise zamanlama bilgilerini daha etkili bir şekilde öğrenebilmesi için mimariye dahil edilmiştir (Gers ve Schmidhuber, 2000). Gözetleme bağlantıları, hücre durumunun her bir kapı üzerindeki etkisini artırarak, öğrenme sürecine daha fazla esneklik kazandırmıştır. Bu yenilikler, LSTM'nin RNN'lere kıyasla çok daha karmaşık ve uzun vadeli bağımlılıkları öğrenebilmesini mümkün kılmıştır. Özellikle doğal dil işleme (NLP), konuşma tanıma, görüntü açıklama ve zaman serisi analizi gibi alanlarda LSTM'ler, sıralı verilerle çalışmayı gerektiren birçok karmaşık problemi çözmek için kritik bir araç haline gelmiştir. Örneğin, bir dil modeli oluştururken LSTM, cümlenin başındaki kelimeleri hafızada tutarak daha anlamlı ve bağlama uygun tahminler yapabilir. Benzer şekilde, konuşma tanıma uygulamalarında, ses dalgalarının zamanla değişen özelliklerini işleyerek yüksek doğruluk oranları sağlayabilmektedir.

1.3.4. Sınırlı (Kısıtlı) Boltzmann Makineleri (Restricted Boltzmann Machines- RBM)

Sınırlı Boltzmann Makinesi, Smolensky'nin 1986'da yayımladığı çalışmasında, Harmonium adı verilen model ile tanıtılmıştır. (Smolensky, 1986). Bu nedenle, Harmonium, RBM'lerin ilk teorik atası olarak kabul edilmektedir. Geoffrey Hinton ve ekibi, 2006 yılında yayımladıkları çalışmasında, Sınırlı Boltzmann Makineleri (RBM) için verimli bir öğrenme algoritması geliştirerek bu yapıyı yeniden ön plana çıkarmışlardır. Hinton ve ekibi, RBM'leri derin öğrenmenin temel yapı taşlarından biri olarak kullanarak, bu modellerin özellik öğrenimi, boyut indirgeme ve işbirlikçi filtreleme gibi alanlarda etkili bir şekilde uygulanabileceğini göstermiştir. Bu bağlamda, RBM'ler daha karmaşık modellerin (örneğin Derin İnanç Ağları - DBN) geliştirilmesinde önemli bir rol oynamıştır (Hinton vd., 2006).

RBM, bir girdi setindeki olasılık dağılımlarını öğrenebilen üretken bir rastgele yapay sinir ağıdır. Boltzmann Makinelerinin özel bir versiyonu olan RBM, görünür ve gizli birimlerden oluşan iki katmanlı bir yapıya sahiptir. Bu iki katman, simetrik bağlantılarla birbirine bağlanmıştır, ancak aynı katman içerisindeki birimler arasında doğrudan bir bağlantı bulunmamaktadır (Salakhutdinov ve Hinton, 2009). Bu özellik, RBM'yi hem basit hem de verimli bir öğrenme süreci için ideal bir hale getirmektedir.

Geleneksel Boltzmann Makinelerinden farklı olarak, RBM'nin mimarisinde gizli birimler arasında bağlantılar bulunmamaktadır. Bu önemli kısıtlama, modelin hesaplama maliyetini azaltarak, daha hızlı ve etkili öğrenme algoritmalarının geliştirilmesine olanak tanımaktadır. Bu yapı sayesinde, RBM'ler büyük veri kümeleri üzerinde daha pratik bir şekilde çalışabilir ve daha karmaşık problemlere uygun hale getirilebilmektedir. Özellikle boyut indirgeme, özellik öğrenimi ve işbirlikçi filtreleme gibi uygulamalarda, bu mimari sadeleştirme, RBM'nin gücünü ve etkinliğini artırmaktadır (Carreira-Perpiñán ve Hinton, 2005). RBM'ler, çok çeşitli uygulama alanlarında etkili bir şekilde kullanılmaktadır. Örneğin tıbbi görüntülerde, MRI veya CT taramalarındaki yüksek boyutlu veriler, RBM'ler ile boyut indirgenerek daha hızlı analiz edilmektedir. Bu yöntem, özellikle büyük veri setleriyle çalışan tıbbi görüntüleme sistemlerinde zaman ve kaynak tasarrufu sağlamaktadır. Yine başka bir çalışmada RBM'ler, el yazısı karakter tanıma gibi sınıflandırma görevlerinde etkili bir şekilde kullanılmaktadır. MNIST veri kümesi üzerinde yapılan bir çalışmada, RBM'lerin, doğrudan sınıflandırıcı olarak kullanıldığında doğruluğu artırabildiği ve aynı zamanda yarı denetimli öğrenme ortamlarında da başarılı bir performans sergilediği gösterilmiştir (Larochelle ve Bengio, 2008). Sonuç olarak, RBM'ler, öğrenme sürecini hızlandıran yapısıyla hem akademik araştırmalarda hem de endüstriyel uygulamalarda sıkça tercih edilmektedir. Özellikle, yüksek boyutlu veri setlerinde

² Unutma kapısı, İngilizce literatürde "*Forget Gate*" olarak adlandırılmaktadır. LSTM mimarisinde bu kapı, hücrenin önceki durumunu belirli bir dereceye kadar "*unutmasını*" ve yeni bilgilerle güncellenmesini sağlamaktadır. Unutma kapısı, hücre durumunun ne kadarının bir sonraki adıma taşınacağını kontrol etmektedir. Bu durum, modelin daha esnek ve etkili bir şekilde uzun vadeli bağımlılıkları öğrenmesini sağlamaktadır.

etkili boyut indirgeme ve özellik öğrenimi yetenekleri, onu güçlü bir araç haline getirmiştir. Sonuç olarak, RBM'ler, hızlı ve verimli öğrenme süreçleri sunan yapısıyla hem akademik çalışmalar hem de endüstriyel uygulamalar için önemli bir tercih haline gelmiştir. Özellikle yüksek boyutlu veri kümelerinde boyut indirgeme ve özellik öğrenimi konusundaki başarısı, RBM'leri güçlü ve esnek bir araç olarak ön plana çıkarmaktadır.

1.3.5. Derin İnanç Ağları (Deep Belief Networks- DBN)

Derin İnanç Ağları, Geoffrey Hinton tarafından geliştirilmiş ve temelinde, birden fazla Sınırlı Boltzmann Makinesi (RBM) katmanının üst üste yığılmasıyla oluşturulmuş bir mimari olarak tanımlanmıştır. DBN'nin her bir RBM katmanı, bir önceki ve bir sonraki katmanla bağlantılıdır, ancak aynı katman içerisindeki düğümler arasında doğrudan bir etkileşim bulunmamaktadır. Bu yapı, modelin hesaplama karmaşıklığını azaltırken öğrenme sürecinin daha etkili bir şekilde gerçekleşmesine olanak tanımaktadır. Ek olarak, DBN'nin son katmanına entegre edilen softmax katmanı, ağı hem sınıflandırma görevleri için kullanıma uygun hale getirmekte hem de denetimsiz öğrenme kapsamında kümeleme işlemlerini gerçekleştirme yeteneği kazandırmaktadır (Hinton ve Salakhutdinov, 2006). Derin İnanç Ağlarını kullanan bir çalışmada insan hareketlerini tanımlamak için çeşitli hareket dizilerini sentezlemiş ve hareket yakalama sırasında eksik kalan verilerin çevrimiçi olarak tamamlanmasını mümkün kılmıştır (Taylor vd., 2006). Bu yaklaşım, insan hareketlerinin analizi ve animasyon gibi uygulamalarda yeni bir standart oluşturmuştur. DBN'ler, çok katmanlı yapısıyla yüksek boyutlu verilerdeki karmaşık özellikleri öğrenebilme kapasitesine sahiptir. Bu özelliği, onları yalnızca görüntü tanıma değil, aynı zamanda doğal dil işleme ve tıbbi veri analizi gibi birçok alanda da değerli bir araç haline getirmiştir.

2. YAPAY ZEKÂ TARİHÇE

Yapay zekâ alanındaki ilk çalışmalar 20. yy'ın ortalarına dayanmaktadır. İlk olarak 1943 yılında McCulloch ve Pitts tarafından "*A Logical Calculus of Ideas Immanent in Nervous Activity*" adlı çalışmada bir nöronun basit bir matematiksel modelini tanımlayan bir makale yayımlanmıştır. Bu çalışma, yapay zekânın temelini oluşturan teorik çerçevelerden biri olarak kabul edilmektedir (McCulloch ve Pitts, 1943). Daha sonraki yıllarda Shannon (1948), "*A Mathematical Theory of Communication*" makalesinde bilgisayarların belli algoritmalarla komplike matematik problemleri ispatlamak ve satranç oynamak için kullanılabilirliğini öne sürmüştür. 1949 yılında Donald Hebb "*Hebbian öğrenme*" ile ilgili temel teoriyi ele almıştır (Hebb, 1949). Hebbian öğrenme, sinir hücrelerinin etkinliklerinin birbirleriyle nasıl etkileşimde bulunduğunu ve bu etkileşimlerin sinirsel bağlantıları nasıl güçlendirdiğini ortaya koymaktadır. 1950 yılında Alan Turing'in, "*Computing Machinery And Intelligence*" makalesinde düşünen makineler yaratma olasılığı hakkında düşüncelerini paylaşmıştır. Turing, makinelerin düşünme yeteneğini değerlendirmek için bir test önermiştir. Bu teste göre, bir bilgisayar insanlardan ayırt edilemeyecek kadar başarılı yanıtlar verebildiğinde, onun "*düşündüğü*" kabul edilebileceğini ileri sürmüştür (Turing, 1950). 1951 yılında Minsky ve Edmonds tarafından ilk yapay sinir ağı temelli bilgisayar olan SNARC geliştirilmiştir (Russell ve Norvig, 2020). Bu erken dönem yapay sinir ağı çalışmaları, daha sonra yapay zekânın gelişimine önemli katkılarda bulunmuştur.

1956 yılında, Princeton Üniversitesi'nde çalışmalarını sürdüren John McCarthy, Marvin Minsky, Claude Shannon ve Rochester tarafından başlatılmıştır. Bu öncü bilim insanları, Dartmouth Koleji'nde düzenlenen ve iki ay süren bir çalışma programında bir araya gelmiştir. Yapay zekâ üzerine gerçekleştirilen bu ilk konferans, alanın temel taşlarını oluşturmuş ve yeni bir bilim dalının doğuşuna zemin hazırlamıştır. Bu toplantıda, John McCarthy "*yapay zekâ*" kavramını ilk kez ortaya atarak, insan zekâsını makinelerle taklit etme fikrini resmi olarak tanımlamıştır. Bu tarihi olay, modern yapay zekâ araştırmalarının başlangıcı olarak kabul edilmektedir (Allahverdi, 2002, s. 13). Bu dönemde, sembolik yapay zekâ çalışmaları ağırlık kazanmış ve makinelerin problem çözüme yeteneklerini geliştirmek amacıyla mantık ve matematik temelli algoritmalar üzerinde yoğunlaşmıştır. Alan Newell ve Herbert Simon tarafından geliştirilen "*Mantık Teorisyonu (Logic Theorist)*" programı, matematiksel teoremleri ispat edebilen bir yapay zekâ sistemi olarak dikkat çekmiştir. Bu çalışma, yapay zekânın problem çözüme kabiliyetlerini sergileyen ilk önemli örneklerden biri olmuştur (Newell ve Simon, 1976).

1960'lı yılların sonlarına doğru dönemin ünlü bilim adamlarından olan Minsky ve Pappert (1969) tarafından yazılan "*Algılayıcılar (Perceptron)*" isimli kitap ile birlikte yapay zekâ duraklama devrine girmiştir. Kitapta, yapay zekânın bilimsel açıdan bir değerinin olmadığını ve doğrusal olmayan problemlere yönelik bir çözüm üretmediği öne sürülmüştür. Kitapta öne sürülen bu eleştiriler, özellikle algılayıcıların sınırlı yeteneklerine vurgu yapmıştır. Doğrusal sınıflandırma yapabilen temel yapay sinir ağı modellerinden algılayıcılar, ancak XOR gibi doğrusal olmayan problemlerin çözümünde yetersiz kalmaktaydı. Minsky ve Papert, bu tür doğrusal olmayan problemleri çözebilmek için daha karmaşık yapılar gerektiğini savunmuşlardır. Bu

da o dönemde yapay zekâ arařtırmalarında bir hayal kırıklığı yaratmış ve çalışmalarında bir “duraklama” dönemine sebep olmuřtur (Misnky ve Pappert, 1969).

1970 yılların başlarında çok sayıda uzman sistem geliştirilmiştir. Her sorunu çözebilecek genel amaçlı bir program yerine artık belli bir uzmanlık dalındaki bilgiyle donatılmış programlar kullanma fikri yapay zekâ alanında yeniden bir canlanma sağlamıştır (Allahverdi, 2002, s. 15). 1970’li yılların ortalarına gelindiğinde Feigenbaum, Buchanan ve Dr. Edward Shortliffe, kan enfeksiyonlarını teşhis etmek için MYCIN programını geliřtirmiştir (Russell ve Norving, 2020). MYCIN, zamanın teknolojik kısıtlamaları nedeniyle pratik uygulamada yaygın kullanılmamış, yine de yapay zekâ ve uzman sistemlerin geliřiminde önemli bir adım olmuřtur. Bu dönem, yapay zekânın pratik uygulama alanlarında önemli ilerlemeler kaydetmiş ve bu sistemlerin sađlık, mühendislik ve finans gibi çeřitli alanlarda kullanılmıştır. Ancak, bu sistemlerin sınırlamaları ve yüksek maliyetleri, yapay zekâ arařtırmalarındaki optimizmin hızla azalmasına yol açmış ve bu durum, ikinci kez yapay zekânın duraklamasına neden olmuřtur (Clancey, 1985).

1980 yılında Stanford’da Amerikan Yapay Zekâ Derneđi tarafından Ulusal Konferans düzenlenmiştir (turkiye.ai). Yine bu yıllarda “lisp” tabanlı bilgisayarlar piyasaya sürülmüş ve ilk ticari yapay zekâ uygulamaları ortaya çıkmıştır. Kazanılan ticari başarılar yapay zekâ üzerine olan ilginin ve arařtırmaların artmasını sağlamıştır (Okutan, 2006, s. 27). Yine bu dönemde, Japon hükümeti Beřinci Nesil Bilgisayar Projesi gibi büyük ölçekli yapay zekâ projelerine yatırım yapmaya başlamıştır. Aynı zamanda, David Rumelhart, Geoffrey Hinton ve Ronald J. Williams tarafından geliřtirilen “geri yayılım (backpropagation)” algoritması, sinir ađlarının yeniden popülerlik kazanmasını sađlamış ve bu yöntem, yapay sinir ađlarının öğrenme kapasitelerini önemli ölçüde artırarak, derin öğrenmenin temellerini atmıştır (Rumelhart vd., 1986).

1990’lı yıllardan itibaren yapay zekâ arařtırmaları makine öğrenimi ve veri madenciliđi alanlarına odaklanmaya başlamıştır. Özellikle 1997’de IBM’in Deep Blue isimli bilgisayarı, dünya satranç şampiyonu Garry Kasparov’u yenerek Yapay zekânın pratik uygulamalarının gücünü göstermiştir. Bu yıllarda bilgisayarların işlem gücündeki artış, büyük veri setlerinin erişilebilirliđi ve yeni makine öğrenimi yöntemlerinin geliřtirilmesi, yapay zekânın yeniden canlanmasına yol açmıştır. 2000’li yılların başında, makine öğrenimi ve destek vektör makineleri (SVM) gibi algoritmalar büyük veri ile birleřerek daha etkili hale gelmiştir (Goodfellow vd., 2016).

2010’lu yıllarda yapay zekâ, sadece akademik bir arařtırma konusu olmaktan çıkıp, ticari uygulamalarda da kendine yer bulmaya başlamıştır. Arama motorları, öneri sistemleri ve görüntü tanıma gibi birçok alanda yapay zekâ teknolojileri kullanılmıştır. Google, Facebook ve Amazon gibi teknoloji devleri, yapay zekâ teknolojilerini iş süreçlerine entegre etmeye başlamışlardır. 2011 yılında Apple, İOS işletim sistemlerinde sanal bir asistan olan “Siri”yi ve 2016 yılında Google tarafından geliřtirilen “Google Asistan”, gibi yapay zekâ destekli araçlar yaygın olarak kullanılmaya başlanmıştır. 2016’da AlphaGo, Go oyununda dünya şampiyonunu yenerek yapay zekânın strateji oyunlarındaki üstün başarısını göstermiştir. Dođal dil işleme alanında ise, 2020 yılında OpenAI tarafından geliřtirilen üretken yapay zekâ sistemi GPT-3 ve günümüzdeki versiyonu GPT4, insan benzeri dil üretme yetenekleri ile dikkat çekmiştir (Brown vd., 2020). 2019 yılında COVID-19 pandemisi nedeniyle yapay zekânın sađlık alanındaki uygulamaları hız kazanmıştır. Yapay zekâ tabanlı sistemler, virüsün yayılmasını tahmin etme, teşhis koyma ve tedavi yöntemleri geliřtirme konularında etkili olmuřtur (Budd vd., 2020). Ayrıca, uzaktan çalışma ve dijitalleşmenin artmasıyla birlikte, yapay zekâ destekli otomasyon çözümleri, işletmelerin verimliliđini artırmak için yaygın olarak kullanılmaya başlanmıştır.

Son yıllarda yapay zekâ alanında robot teknolojisi ve otonom sistemler önemli geliřmelere sahne olmuřtur. Otonom araçlar, taşımacılık ve lojistik sektörlerinde etkili bir şekilde kullanılmaya başlanırken, insansız hava araçları tarım, güvenlik ve keşif gibi birçok alanda kendine yer bulmuřtur (Geiger vd., 2020). Bunun yanı sıra, yapay zekâ destekli sistemler enerji verimliliđi ve sürdürülebilirlik projelerinde kritik bir rol üstlenerek geleceđe yönelik çözümler sunmaktadır. Bu teknolojiler, yalnızca verimliliđi artırmakla kalmayıp, aynı zamanda insan hayatını daha güvenli, kolay ve konforlu hale getirmeyi de hedeflemektedir. Tüm bu ilerlemeler, yapay zekânın yalnızca teknolojik bir yenilik deđil, aynı zamanda toplumsal ve küresel dönüşümün önemli bir itici gücü olduğunu göstermektedir.

3. YAPAY ZEKÂ UYGULAMA ALANLARI

Günümüzde hızla gelişen bir teknoloji olan yapay zekâ, pek çok alanda köklü değişikliklere yol açarak yenilikçi çözümler sunmakta ve insanların yaşam kalitesini önemli ölçüde iyileştirmektedir. Yapay zekânın kullanım alanları gün geçtikçe genişlemekte ve çeşitlenmektedir. İş dünyasından, sağlık sektörüne, ekonomi ve finans alanından hukuka, savunma ve güvenlikten, kişiselleştirilmiş asistanlara kadar hemen her alanda yapay zekâ uygulamaları kullanılmaktadır. Bu durum, gelecekte yapay zekânın günlük yaşamın her alanında derinlemesine entegre olacağını göstermektedir.

Aşağıdaki bölümlerde, yapay zekânın sağlık, savunma ve güvenlik, eğitim, hukuk, ekonomi ve finans gibi farklı sektörlerdeki kullanım alanları detaylı bir şekilde ele alınacaktır.

3.1. Sağlık Alanında Yapay Zekâ

Sağlık alanında yapay zekâ son 50 yılda çarpıcı bir ilerleme kaydetmiştir. Makine öğrenmesi ve derin öğrenmenin ortaya çıkışından bu yana yapay zekâ uygulamaları genişleyip çeşitlenmiştir. Özellikle son yıllarda yalnızca algoritmaya dayalı tıptan ziyade kişiselleştirilmiş sağlık hizmetleri tıp alanı için fırsatlar yaratmıştır. Tahmine dayalı modeller hastalıkların teşhisi, tedavi yanıtı öngörüsü ve gelecekte potansiyel olarak koruyucu sağlık için kullanılabilir (Ruffle vd., 2019).

Sağlık hizmetlerinde bilgi teknolojisi gelişimi, ürünlerden hizmetlere ve çözümlere doğru hızla ilerlemektedir (Frost ve Sullivan, 2016). 21. yüzyılın başlarında, tıp alanında yaşanan inovasyonlar, tarihe ve kanıta dayalı bakım sağlayan medikal ürünlerin geliştirilmesine odaklanmış, bu da tıbbi uygulamalarda önemli bir dönüşümü beraberinde getirmiştir (Niessen vd., 2000). Özellikle teknolojinin sağlık alanında kullanılabilir hale gelmesiyle hem hastalar hem de sağlık profesyonelleri için süreçler daha verimli ve etkili hale gelmiştir. İçinde bulunduğumuz on yıl, gerçek zamanlı ve sonuç odaklı bakım sunmayı hedefleyen yeni nesil tıbbi platformların yükselişiyle dikkat çekmektedir. Bu platformlar, bireysel hasta ihtiyaçlarını anlamaya odaklanan yenilikçi yaklaşımlarla, sağlık hizmetlerini kişiselleştirilmiş bir seviyeye taşımayı amaçlamaktadır. Sağlık sektörü, bu doğrultuda daha akıllı ve verimli çözümler geliştirmek için yapay zekâ, robot teknolojisi, büyük veri analitiği ve bulut bilişim gibi teknolojilerden yoğun şekilde faydalanmaktadır. Önümüzdeki on yıl ise, yalnızca mevcut sistemlerin geliştirilmesiyle sınırlı kalmayıp, kanıta ve sonuca dayalı sağlık hizmetleri sunumunda devrim yaratacak yeni teknolojilerin ön planda olacağı bir dönem olarak öngörülmektedir. Bu dönemde, yapay zekâ destekli robotik sistemlerin daha geniş ölçekte kullanılmasının yanı sıra, sanal ve artırılmış gerçeklik teknolojilerinin de tıbbi teşhis, tedavi ve eğitim süreçlerinde etkin bir şekilde uygulanması beklenmektedir. Bu teknolojiler, özellikle cerrahi operasyonlardan rehabilitasyona, uzaktan hasta takibinden tıbbi eğitim simülasyonlarına kadar birçok alanda çığır açıcı çözümler sunacaktır (thinktech.stm.com).

Teknoloji tabanlı ürünlerin, platformların ve çözümlerin birleşimi, bireysel ve toplumsal düzeyde hayal bile edilemeyecek yenilikçi sağlık uygulamalarını ortaya çıkarmıştır. Bu gelişmeler, yapay zekâ ve robot biliminin “Yeni Sağlık” anlayışını şekillendirdiği çeşitli trendlerin temelini oluşturmaktadır. Sağlık sektöründe dijitalleşmenin hız kazanmasıyla birlikte veri üretiminde kayda değer bir artış yaşanmış, sağlıkla ilgili veri hacmi benzersiz seviyelere ulaşmıştır. Ancak, bu kadar büyük bir veri miktarını analiz etmek ve yönetmek, ne kadar yetenekli olursa olsun bireysel insan kapasitesini aşmaktadır. İşte bu noktada yapay zekâ devreye girerek verilerin işlenmesi ve anlamlandırılmasında kritik bir rol üstlenmektedir. Ayrıca, teknolojik gelişmelerin hızlanması sağlık hizmetlerine erişimi daha demokratik hale getirmiştir. Bu yenilikler, bireylerin kendi sağlıklarını ve yaşam tarzlarını daha bilinçli bir şekilde yönetmelerine olanak tanırken, sağlık hizmeti sağlayıcılarıyla daha etkili bir iş birliği kurmalarını da sağlamaktadır (Bresnick, 2017).

Sağlık hizmetleri ekosistemi, yeni nesil sağlık teknolojisinde yapay zekâ destekli araçların önemini farkına varmaktadır. Yapay zekânın sağlık hizmeti operasyonları ve sunumu kapsamındaki tüm süreçlere iyileştirmeler getirebileceğine inanılmaktadır. Yapay zekânın sağlık sistemine sağlayabileceği maliyet avantajları, bu teknolojinin uygulama sürecinde kritik bir rol oynamaktadır. 2017 yılında Accenture dergisinin analizine göre, klinikte yapay zekâ uygulamaları sayesinde, 2026 yılına kadar ABD'nin sağlık ekonomisi için potansiyel olarak yıllık 150 milyar dolar tasarruf sağlayabileceği tahmin edilmektedir. Bu maliyet düşüşlerinin büyük bir kısmı, sağlık hizmeti modelinin reaktif bir yaklaşımdan proaktif bir yaklaşıma, hastalık tedavisinden ziyade sağlık yönetimine odaklanan bir yaklaşıma dönüştürülmesinden kaynaklanmaktadır. Bu dönüşümün, daha az hastaneye ziyaret, daha az doktor ziyareti ve hastalıkların erken önlenmesi sayesinde daha kısa ve basit tedavi süreçleriyle sonuçlanması beklenmektedir. Yapay zekâ tabanlı teknoloji, sürekli izleme ve rehberlik yoluyla insanların sağlıklı kalmalarına yardımcı olmada önemli bir role sahip olacak ve teşhislerin daha erken gerçekleşmesi, kişiye özel tedaviler ve daha etkili takipler sağlayacaktır (Bohr ve Memarzadeh, 2020, s. 26).

Sağlık sektörü, önemli bir dönüşüm sürecinden geçmektedir. Bu dönüşümün başlıca nedenleri arasında artan sağlık hizmeti maliyetleri ve sağlık uzmanlarının sayısındaki giderek büyüyen eksiklik bulunmaktadır. Bu durumun bir sonucu olarak, sağlık sektörü, maliyetleri düşürmeye ve artan bu zorluklara çözüm sunmaya yönelik yeni bilgi teknolojisi tabanlı çözümleri ve süreçleri hayata geçirmeyi hedeflemektedir. Dünya genelindeki sağlık sistemleri, erişim eksikliği, yüksek maliyetler, israf ve yaşanan nüfus gibi büyük sorunlarla karşı karşıyadır. COVID-19 pandemisi gibi krizler, sağlık sistemleri üzerinde koruyucu ekipman yetersizliği, yanlış veya eksik teşhis testleri, aşırı çalışan hekimler ve bilgi paylaşımındaki eksiklikler gibi ciddi bir baskı yaratmıştır (Greenberg vd., 2020; Pavli vd., 2021). Daha da önemlisi, COVID-19 gibi sağlık krizleri veya 1980'lerde ortaya çıkan HIV gibi durumlar, sağlık sistemlerindeki eksiklikleri açıkça ortaya koymaktadır. Bu sağlık krizleri mevcut sorunları artırmakla birlikte, sağlık hizmetlerini ve arka ofis sistemlerini yeniden tasarlama ve geliştirme fırsatını da sunmaktadır. Burada yapay zekâ, sağlık hizmetlerini sadeleştirme ve akıllı bakım sistemleri geliştirme yolunda kritik bir rol oynamaktadır. COVID-19 krizi, yapay zekânın teşhis ve tedavi kararı desteği, temas takibi ve yapay zekâ destekli teknolojilerin kullanımı gibi birçok amaç için nasıl kullanılabileceğini göstermiştir (Shaheen, 2021). Yine bu gibi krizlerin yaşattığı olumsuz durumlar beraberinde daha derin araştırmalara ve devletlerin bu alandaki desteklerini artırmalarına neden olmuştur. Google DeepMind tarafından geliştirilen AlphaFold modeli (Hey vd., 2020), SARS-CoV-2 proteininin 3 boyutlu yapısını tahmin ederek, bilim insanlarının virüsü daha iyi anlamalarına yardımcı olmuştur (Kryshafovich vd., 2021). Pfizer-BioNTech COVID-19 aşısının tasarımını, SARS-CoV-2'nin spike proteini hedef alınarak geliştirilmiştir. Bu tasarım süreci, AlphaFold'un spike proteininin yapısına dair sağladığı tahminlerle daha da optimize edilmiştir (Higgins, 2021).

Sağlık alanında çeşitli hastalıkların risklerini hesaplamada ve tanı aşamasında yapay zekâ sistemlerinden yararlanılmaktadır (Şahin, 2020). Yapay zekâ, sağlık ekiplerinin hastanın verilerini dijital olarak depolayarak dokümantasyon süresini kısaltmakta ve teşhis, tedavi ve düzenli tıbbi hizmetler için kullanılabilecek dijital bir veri tabanı oluşturmasına yardımcı olmaktadır. Yapay zekâ donanımı ile geliştirilen yazılımlar veri toplamak için platform geliştirilmekte ve bu yazılımlar belirli uygulamalar için özelleştirilmektedir. Buna göre hastanın ihtiyaçlarına göre özel teşhis tedavi protokolleri ve tedavi sonrası bakım modülleri geliştirilmektedir. Bununla birlikte toplanan verilerin analizi, yapay zekâ sisteminin performansı için hayati önem taşımaktadır (Haleem vd., 2019, s. 1-2).

Yapay zekâ, sağlık alanında veri görselleştirme konusunda da önemli bir rol oynamaktadır. Tıbbi görüntüleme teknikleriyle elde edilen veri ve videoların yorumlanması, karmaşıklığı ve detay seviyesi nedeniyle oldukça zorlu bir süreç olabilmektedir. Bu alandaki uzmanlar, tıbbi anomalileri ve olayları doğru bir şekilde tespit edebilmek için yıllar süren yoğun bir eğitimden geçmek zorundadır. Ayrıca, tıp dünyasında sürekli olarak yeni araştırmalar ve bilgiler ortaya çıktıkça, bu profesyonellerin kendilerini güncel tutmaları ve yeni gelişmeleri yakından takip etmeleri gerekmektedir. Bununla birlikte, sağlık sektöründe tıbbi görüntüleme ve veri analizine duyulan ihtiyaç her geçen gün artmaktadır. Bu artan talep, nitelikli uzman eksikliği nedeniyle karşılanmakta zorlanmaktadır ve bu durum sağlık hizmetlerinde aksamalara yol açabilmektedir. Geleneksel yöntemlerle bu açığın kapatılması mümkün görünmediğinden, sektörde yenilikçi ve etkili çözümlere ihtiyaç duyulmaktadır. İşte bu noktada, yapay zekâ teknolojileri devreye girerek önemli bir çözüm sunmaktadır. Yapay zekâ destekli sistemler, büyük ölçekli tıbbi verileri hızlı ve hassas bir şekilde işleyerek uzmanların yükünü hafifletmektedir. Özellikle derin öğrenme algoritmaları, tıbbi görüntülerin analizinde yüksek doğruluk oranlarıyla doktorlara yakın performans sergileyebilmektedir. Bu teknolojiler, teşhis süreçlerini hızlandırarak hasta bakım kalitesini artırmakta ve sağlık hizmetlerine erişimi kolaylaştırmaktadır. Ayrıca, yapay zekâ sistemleri sürekli öğrenme kapasitesine sahip oldukları için, yeni tıbbi bilgiler ve araştırmalar ışığında kendilerini güncelleyebilmektedirler. Bu da onları dinamik bir araç haline getirmekte ve sağlık sektöründeki hızlı değişimlere uyum sağlamalarını kolaylaştırmaktadır. Sonuç olarak, yapay zekâ, sağlık alanındaki uzman açığını kapatmada ve hizmet kalitesini yükseltmede önemli bir potansiyele sahiptir (Bohr ve Memarzadeh, 2020, s. 34). Bu gelişmeler, sağlık profesyonellerinin daha karmaşık ve insani yönü ağır basan görevlere odaklanmasına olanak tanırken, yapay zekâ rutin ve zaman alıcı görevleri üstlenmektedir. Böylece, sağlık hizmetlerinde verimlilik ve etkinlik artmakta, hastalar ise daha hızlı ve doğru teşhis ve tedavi imkânlarına kavuşmaktadır. Özellikle teşhis süreçlerini hızlandırmak, kişiselleştirilmiş tedaviler geliştirmek, ilaç ve aşı keşiflerini hızlandırmak gibi hayati öneme sahip konularda önemli faydalar sunmaktadır. Aşağıdaki tablo, yapay zekâ modellerinin sağlık sektöründeki farklı kullanım alanlarını ve bu modellerin sağladığı yararları kategorilere ayrılmış şekilde sunmaktadır.

Tablo 3. Yapay Zekâ Modellerinin Sağlık Alanındaki Yararları ve Kullanım Alanları

Yapay Zeka Modelleri	Sağlıkta Yararı	Kullanım Alanları	Kategori
Zebra Medical Vision, Enlitic, Aidoc, Qure.ai, Viz.ai	Erken teşhis, doğru tanı, hayati risk taşıyan durumların tespiti	Radyoloji, kanser teşhisi, göğüs hastalıkları, inme	Görüntüleme ve Teşhis
PathAI, Proscia	Kanser teşhisinde destek, patoloji verilerinin analizi	Patoloji, kanser teşhisi	Görüntüleme ve Teşhis
Google Health AI, EyeArt	Körlüğün önlenmesi, diyabetik retinopati taraması	Oftalmoloji	Görüntüleme ve Teşhis
SkinVision, Derma.AI	Cilt kanserini erken teşhis, dermatolojik hastalıkların analizi	Dermatoloji, cilt kanseri	Cilt Hastalıkları ve Dermatoloji
BioXcel Therapeutics AI, Insilico Medicine, Atomwise	İlaç keşfi ve geliştirme süreçlerini hızlandırmak	Farmakoloji, biyoteknoloji	Aşı ve İlaç Geliştirme
Moderna AI, LinearDesign	mRNA dizaynı ve stabilite optimizasyonu	Aşı geliştirme, mRNA stabilitesi	Aşı ve İlaç Geliştirme
DeepMind (AlphaFold), Google DeepMind RNA Structurizer	RNA yapılarının tahmini, protein yapısının modellenmesi	Aşı geliştirme, biyoinformatik	Aşı ve İlaç Geliştirme
Exscientia, BenevolentAI	Yeni ilaç adaylarının belirlenmesi	Farmakoloji, ilaç geliştirme	Aşı ve İlaç Geliştirme
IBM Watson Health, Tempus, Flatiron Health	Kişiselleştirilmiş tedavi önerileri	Onkoloji, genetik analiz, klinik karar destek	Kişiselleştirilmiş Tedavi
23andMe AI, Helix, Deep Genomics	Genetik yatkınlık ve hastalık risklerinin analizi	Genetik testler, kalıtsal hastalıklar	Kişiselleştirilmiş Tedavi
Bay Labs, Arterys, Caption Health	Kalp hastalıklarının erken teşhisini sağlamak, doğru tanı	Kardiyoloji, pulmonoloji	Kardiyoloji ve Kalp Sağlığı
Ultromics	Kardiyak görüntüleme analizi ile daha doğru teşhis	Kardiyoloji	Kardiyoloji ve Kalp Sağlığı
Aidoc, Viz.ai, RapidAI	Kritik durumların hızlı tespiti, inme kaynaklı sakatlıkların azaltılması	Acil tıp, yoğun bakım	Yoğun Bakım ve Acil Tıp
DeepMind Health, CLEW Medical	Erken uyarı sistemleri ile organ yetmezliğini önlemek	Yoğun bakım	Yoğun Bakım ve Acil Tıp
Olive, Health Catalyst, Qventus	Operasyonel süreçleri otomatikleştirmek, verimlilik artırmak	Sağlık yönetimi, hasta kayıt sistemleri	Sağlık Yönetimi ve Operasyonel Süreçler
Babylon Health, Ada Health	Hastalık riskini analiz etmek, ön tanı koymak	Tele-tıp, birinci basamak sağlık hizmetleri	Sağlık Yönetimi ve Operasyonel Süreçler
SkinVision, Derma.AI	Cilt kanserini erken teşhis, egzama gibi hastalıkların analizi	Dermatoloji, cilt hastalıkları	Cilt Hastalıkları ve Dermatoloji

Kaynak: Her bir yapay zekâ modeli, ilgili resmî web siteleri incelenerek yazar tarafından derlenmiştir.

Yapay zekânın sağlık sektöründeki uygulamaları ve etkileri üzerine yapılan çalışmalar, bu teknolojinin teşhis, tedavi, ilaç geliştirme ve operasyonel süreçlerin optimize edilmesi gibi alanlarda önemli katkılar sağladığını göstermektedir. Ayrıca, yapay zekâ algoritmaları, her türlü süreci hızlandırmakta iken bu gelişmeler, sağlık hizmetlerinin verimliliğini artırmakta, hasta sonuçlarının iyileştirilmesine ve maliyetlerin düşürülmesine katkı sağlamaktadır. Gelecekte, yapay zekânın sağlık sektöründe daha karmaşık sorunları çözmek ve inovasyonu hızlandırmak için daha geniş bir rol üstleneceği öngörülmektedir (Nasr vd., 2021).

3.2. Savunma ve Güvenlik Alanında Yapay Zekâ

Savunma ve güvenlikte yapay zekânın kullanımı, çok çeşitli ve ileri düzey teknolojilerin geliştirilmesine yol açmaktadır. Bu teknolojiler, stratejik planlama, istihbarat toplama, gözetleme ve hedefleme operasyonları gibi kritik alanlarda kullanılmaktadır. Yapay zekâ, tehdit tespiti, otonom sistemler, siber güvenlik, istihbarat analizi ve kriz yönetimi gibi alanlarda insanın karar verme hızını ve doğruluğunu artırarak, geleceğin savaş ve güvenlik senaryolarını yeniden şekillendirmektedir. Bu teknolojiler hem ulusal güvenliği sağlamada hem de siber tehditlere karşı daha etkin çözümler geliştirmede kritik bir rol üstlenmektedir (Davis, 2019; Raska, 2021).

Yapay zekâ, büyük veri setlerini hızla işleyerek, derinlemesine analizler yapma ve karmaşık veri kalıplarını tanıma kapasitesi ile savunma istihbaratına büyük katkılar sağlamaktadır. Örneğin, görüntü tanıma teknolojileri, uydu ve hava fotoğraflarından elde edilen verilerin analizinde kullanılarak, düşman hareketlerinin belirlenmesi ve stratejik noktaların tespiti gibi görevlerde etkin bir şekilde rol oynamaktadır. Yapay zekâ, gerçekçi ve dinamik savaş simülasyonları yaratma kapasitesi ile askeri eğitimi dönüştürmüştür. Bu simülasyonlar, askerlere çeşitli senaryolar altında eğitim alma imkânı sunmakta ve onların karşılaşılabilecekleri gerçek dünya durumlarına karşı hazırlıklı olmalarını sağlamaktadır. Ayrıca, yapay zekâ destekli sanal

gerçeklik (VR) uygulamaları, askeri eğitimde fiziksel ve psikolojik hazırlığı artırmak için kullanılmaktadır. Yapay zekânın kullanım alanlarına bakıldığında;

- Yapay Zekâ ve Siber Savunma, yapay zekânın önemli bir uygulama alanıdır. AI destekli siber savunma sistemleri, ağ trafiğini sürekli izleyerek anormal aktiviteleri tespit etmekte ve siber saldırıları gerçek zamanlı olarak önlemek için hızlı kararlar alabilmektedir. Bu sistemler, karmaşık siber tehditlere karşı savunma yeteneğini büyük ölçüde artırmıştır (aiseclab.org).
- Otonom Savunma Sistemleri, insan müdahalesi olmadan hedefleri tespit edebilmekte, izleyebilmekte ve hatta angaje olabilmektedir. Otonom Sistemler sayesinde keşif, gözetleme ve lojistik gibi görevler için otonom araçların, dronların ve robotların geliştirilmesine olanak tanımakta ve tehlikeli ortamlarda insan müdahalesi ihtiyacını azaltmaktadır. Örneğin, İsrail'in Iron Dome hava savunma sistemi, gelen tehditleri otomatik olarak tespit edip, onlara karşı müdahale edebilmektedir (Scharre, 2018).
- Gözetleme ve Keşif: Yapay zekâ destekli sistemler, potansiyel tehditleri tespit ve takip edebilmekte, sınırları izleyebilmekte ve şüpheli etkinlikleri belirlemek için uydular, dronlar ve kameralar gibi çeşitli sensörlerden gelen büyük miktarda veriyi analiz edebilmektedir (Karve International, 2024).
- Tahmine Dayalı Analitik: Yapay zekâ algoritmaları, potansiyel güvenlik tehditlerini tahmin etmek veya suç faaliyetini gösteren kalıpları belirlemek için geçmiş verileri analiz etmekte ve proaktif önlemlerin alınmasına yardımcı olabilmektedir (Emerj, 2024).
- Eğitim ve Simülasyon: Yapay zekâ destekli simülasyonlar, askeri personel ve güvenlik güçleri için gerçekçi eğitim senaryoları sunarak, gerçek riskler olmadan çeşitli senaryolarda karar verme ve müdahale stratejileri uygulamalarına olanak tanıyabilmektedir.
- Doğal Dil İşleme teknikleri sayesinde sosyal medya, haber makaleleri ve ele geçirilen iletişimler de dahil olmak üzere büyük hacimli metin verilerini analiz edip anlamasını, değerli istihbarat elde etmesini ve potansiyel tehditleri belirlemesini sağlayabilmektedir (lingvanex.com).
- Biyometrik Tanımlama: Yapay zekâ algoritmaları, kimlikleri doğrulamak ve ilgilenilen kişileri takip etmek için yüz tanıma, parmak izleri ve ses izleri gibi biyometrik verileri analiz edebilmektedir (Karve International, 2024).
- Terörle Mücadele: Yapay zekâ algoritmaları, terörist faaliyetlere katılan bireyleri veya grupları tespit etmek ve takip etmek için iletişim, finansal işlemler ve sosyal medyadaki kalıpları analiz edebilmektedir (Total Military Insight, 2023).
- Dinamik Kaynak Tahsisi: Yapay zekâ algoritmaları, değişen operasyonel gereksinimlere ve gerçek zamanlı istihbarata dayalı olarak birlikler, araçlar ve ekipman gibi kaynakları dinamik olarak tahsis ederek verimliliği ve etkinliği en üst düzeye çıkarabilmektedir (AI in Defense – Advancing Border Security ve Surveillance, 2023).
- Uydu Görüntüsü Analizi: Yapay zekâ, arazi, altyapı ve askeri faaliyetlerdeki değişiklikleri tespit etmek için uydu görüntülerini analiz edebilmekte ve stratejik planlama ve durumsal farkındalık için değerli istihbarat bilgileri sağlayabilmektedir (Frontex AI research study, 2020).
- Sınır Güvenliği: Yapay zekâ, sensör verilerini analiz ederek, izinsiz geçişleri tespit ederek ve kaçakçılık faaliyetlerini belirleyerek sınırların izlenmesine ve güvenliğinin sağlanmasına yardımcı olabilmektedir (AI in Defense – Advancing Border Security and Surveillance, 2023).
- Uzak Güvenliği: Yapay zekâ, uzay varlıklarını korumak ve kritik uzay altyapısının güvenliğini sağlamak için durumsal farkındalığı, uydu takibi ve uydu savunmasında çok önemli bir rol oynamaktadır (Frontex AI research study, 2020).
- Biyolojik Tehdit Tespiti: Sağlık kayıtları, çevresel veriler gibi çeşitli veri kaynaklarını analiz ederek, pandemiler, biyoterörizm ve ortaya çıkan bulaşıcı hastalıklar dahil olmak üzere biyolojik tehditleri erken tespit ve hızlı yanıt alabilmesine olanak tanımaktadır (Center for Security and Emerging Technology, 2024).
- İnsani Yardım ve Afet Yardımı (HADR): Yapay zekâ teknolojilerinden, tahmine dayalı modelleme, kaynak tahsisi ve kriz durumlarında insani yardımın koordinasyonu da dahil olmak üzere afete hazırlık, müdahale ve kurtarma çabaları için yararlanılmaktadır (Frontex AI research study, 2020).

Teknolojinin getirdiği yenilikler çatışma riskini artırabilmektedir. Silahlanmış robotik sistemler ve yapay zekâ alanında yeni bir silahlanma yarışı gelişmektedir. Siber uzay artık bir çatışma alanı haline gelmiş olup, Arktik bölgesi ve derin okyanuslar uzaktan erişim araçlarıyla kullanılabilir hale gelmektedir; bu durumlarda meydana gelecekleri denetleyecek yerleşik bir sistem de günümüzde bulunmamaktadır. Araştırma ve geliştirme süreçlerinin büyük ölçüde özel sektörde gerçekleşmesi nedeniyle, bu teknolojiler daha geniş bir yelpazede devlet ve devlet dışı aktörler tarafından silah haline getirilebilmektedir. Örneğin, Orta Doğuda bazı aykırı gruplar, Suriye'de bomba taşımak için ticari dronları kullanmış ve açık kaynaklı teknolojilerin potansiyel olarak yıkıcı biyolojik silahlar yaratabildiği görülmüştür. Mevcut bu durum karşısı yöntemler ve kurumlar, dijital dünyadaki var olan teknolojilerin yayılmasını engelleyememektedir (Rickli, 2019).

Makine öğrenimi sistemleri askeri düzeyde güvenlik ve güvene ulaşmanın önümüzdeki yıllarda çok fazla yatırım gerektireceği unutulmamalıdır. Örneğin, büyük miktarda veriyi işleme yeteneği, görünüşte belirli bir ordunun durumsal farkındalığını artırabilmekte, ancak aldatma, dezenformasyon, makine öğrenimi ve derin öğrenmenin etkileşimi ve birleşik kullanımı muhtemelen durumun netliğinden ziyade belirsizlik ve karmaşıklık yaratabilecektir. Başka bir deyişle yapay zekânın askeri alanda uygulanmasının etkileri tek yönlü olmayacak; yapay zekânın potansiyel avantajlarını ortadan kaldıracak veya dengeleyecek karşıt uygulamaların ortaya çıkması çok muhtemel olacaktır. Akıllı sistemlere olan güven düşük kalırsa, askeri

uygulamalar da muhtemelen sınırlı kalacaktır. Yapay zekânın erken uyarı sistemlerinde kullanımı ve hızlı hedeflemeye yardımcı olma yeteneği, aynı zamanda kriz istikrarını ve nükleer silahları da etkileyebilecektir (Horowitz, 2018, s. 55).

Yapay zekâ alanındaki çok sayıda çalışmanın beraberinde getirdiği hızlı teknolojik gelişmeler göz önüne alındığında, savunma ve güvenlik alanı geleceğin savaşlarına hazırlıklı olmak için bu teknolojilerden yararlanmanın önemini vurgulamıştır. Ülkeler arasındaki savunma ve güvenlik rekabeti yoğunlaştıkça, yeni teknolojilerden yararlanma ve bunları ordularına ve ulusal savunma sistemlerine entegre etme yarışı da hızlanmaktadır. Genişleyen dijital bağlantı ve akıllı makinelerin yükselişiyle karakterize edilen bilgi devrimi çağında, sadece caydırıcı gücün bileşenleri temelden değişmekle kalmayacak, aynı zamanda yapay zekâ, büyük veri analitiği, robotik ve kuantum bilgi biliminin askeri uygulamaları ve diğer son teknolojiler nedeniyle savaşın karakteri de değişebilecektir (Scharre, 2018). Sürekli değişen küresel teknolojik ortam, uzun vadeli stratejik rekabet içinde olan askeri örgütlerden daha fazla değişim talep etmektedir. Başka bir deyişle, bir yandan kısa vadeli zorluklarla başa çıkarken diğer yandan gelecekteki güvenlik ortamına uyum sağlamaya hazırlanmak giderek daha da zorlaşmaktadır.

Yapay zekâ, askeri bağlamda birçok avantaj sağlayabilse de, aynı zamanda kendine özgü zorluklar da sunmaktadır. Yapay zekâ teknolojisi, otonom operasyonları kolaylaştırabilmekte daha bilinçli askeri kararlar alınmasına yol açabilmekte ve muhtemelen askeri eylemlerin hızını ve ölçeğini artırabilmektedir. Ancak bu teknoloji aynı zamanda öngörülemezdir, benzersiz manipülasyon biçimlerine karşı savunmasızdır ve insan-makine etkileşimi açısından zorluklar sunmaktadır. Analistler, yapay zekânın gelecekteki muharebe operasyonlarındaki etkisi konusunda farklı görüşlere sahiptir. Küçük bir grup analist teknolojinin sınırlı bir etkiye sahip olacağını düşünürken, daha geniş bir uzman topluluğu, yapay zekânın devrim niteliğinde bir etkiye sahip olacağına inanmaktadır (Hoadley ve Lucas, 2018).

Yapay zekânın silah sistemlerine entegre edilmesi, savaşların doğasında köklü bir paradigma değişikliğine yol açacak ve uluslararası güvenlik ve istikrar üzerinde ciddi sonuçlar doğurabilecektir. 2014 yılında, Birleşmiş Milletler Konvansiyonel Silahlar Sözleşmesi kapsamında bu tür ölümcül otonom silah sistemleri tartışılmaya başlanmış olsa da, devletler bu teknolojilerin geliştirilmesi ve kullanımı konusunda net bir yol haritası belirlemede hâlâ zorluk çekmektedir. Otonom silah sistemlerinin yasaklanması çağrısında bulunanların en büyük endişesi, insan faktörünün bu süreçten tamamen çıkarılması ve ölümcül güç kullanımı kararlarının makineler tarafından alınmasıdır. Bu durum, etik ve hukuki açıdan derin tartışmaları beraberinde getirmektedir. Üstelik yapay zekânın askeri olmayan uygulamalarından alınabilecek dersler de bu tartışmalara ışık tutabilmektedir. Örneğin, yapay zekânın karar alma süreçlerinde insan mantığına uymayan yöntemler benimseyebileceği görülmüştür. Eğer "*sadece kazanmanın önemli olduğu ve zaferin boyutunun önemsiz olduğu*" bir yaklaşım otonom silah sistemlerine entegre edilirse, bu durum orantılılık ilkesinin ciddi şekilde ihlal edilmesine yol açabilir. Böyle bir algoritma, bir düşmanı öldürerek kazanmak ile 1.000 kişiyi öldürerek kazanmak arasında hiçbir fark görmeyecektir (Rickli, 2019). Bu tür bir yaklaşım yalnızca savaş hukukunun temel prensiplerini değil, aynı zamanda insanlığın etik değerlerini de tehdit etmektedir. Yapay zekâ teknolojilerinin geliştirilmesinde, yalnızca teknik üstünlük değil, aynı zamanda etik sorumluluk ilkesi de gözletilmelidir. Eğer bu sorumluluk ihmal edilirse, yalnızca savaşlar değil, uluslararası düzenin temeli de ciddi şekilde sarsılabilecektir.

3.3. Eğitim Alanında Yapay Zekâ

Globalleşen dünyada çağın gerekleri sürekli bir değişim içindedir. Burada en büyük rolün hızla gelişen teknolojinin ihtiyaçları ve istekleri yeni duruma devşirmesinden kaynaklanmaktadır. Bu değişim ve dönüşümün temelinde eğitim yatmaktadır. Farklı öğelerden etkilenen ve etkileyen dinamik bir sistem olarak karşımıza çıkan eğitimi etkileyen birçok içsel ve dışsal öğe bulunmaktadır. Bu öğeler öğretmen ve öğrenci ile ilgili değişkenlere, okulların fiziki yapılarına, sosyal ve kültürel çevreye, aileye, teknolojik gelişmelere ve benzeri birçok faktöre bağlı olarak değişmektedir. Bu öğeler eğitimde girdi olarak ele alınırsa, bu girdiler sürecin sonundaki çıktıları olumlu ve olumsuz yönde etkileyebilmektedir (Ertmer ve Ottenbreit-Leftwich, 2010; Roblyer ve Doering, 2010). Günümüzde bu girdilerin içindeki en önemli öğe belki de teknolojidir. Teknoloji sayesinde bilgi artık hemen her kişiye ve istenilen her anda ulaşabilmektedir.

Yapay zekâ alanındaki gelişmeler, toplumda kapsamlı ve hızlı dönüşümlerin temelini oluşturmaktadır. Politika yapıcılarının, devam eden ve yaklaşan değişimlere uyum sağlayabilmesi için yapay zekânın yetenekleri ile insan becerileri arasındaki ilişkiyi anlaması kritik önem taşımaktadır. OECD, Uluslararası Öğrenci Değerlendirme Programı'nın (PISA) okuma, matematik ve fen bilimleri gibi temel alanlarındaki görevlerde yapay zekâ sistemlerinin ne kadar başarılı olduğunu takip etmiştir. Bu süreçte, 2022'nin sonlarında kamuoyuna sunulduktan sonra büyük bir etki yaratan ChatGPT'nin arkasındaki Generative Pre-Trained Transformer (GPT) ailesinden büyük dil modelleri (LLM'ler) kullanılmıştır. Sonuçlar, GPT modellerinin okuma ve fen bilimlerinde ortalama öğrenci performansını aştığını göstermiş, ayrıca, matematikte hızlı ilerlemeler kaydedildiği, yapay zekâ

yeteneklerinin öğrenci becerilerine hızla yaklaştığı gözlemlenmiştir. GPT-3.5 PISA matematik sorularının %35'ini doğru yanıtlarken, öğrenciler bu soruların ortalama %51'ini doğru yanıtlamaktaydı. Ancak, Mart 2023'e gelindiğinde, GPT-4 soruların %40'ını doğru yanıtlayarak kayda değer bir gelişim göstermiştir (OECD, 2023).

Yapay zekâ veri, bilgi ve mantık tabanlı yaklaşımları içermektedir (Sleeman ve Brown, 1982). Milenyum çağına kadar, yapay zekânın eğitimdeki kullanımları genellikle bilgi tabanlı yöntemlere dayanmaktayken, bu dönemdeki araştırma alanları daha çok pedagojik, konu ve öğrenci modelleri etrafında şekillenmiştir (Woolf, 2009). Günümüzde ise artık sadece bilgi tabanlı olmayıp, veri, mantık ve kişiselleştirilmiş modeller üzerine bir yapı inşa edilmiştir (Arslan, 2020, s. 81). Yapay zekâ bireyselleştirilmiş öğrenme, otomasyon ve eşitlik fırsatları sunarak geleneksel eğitim anlayışını dönüştürmüş, öğrencilerin bireysel öğrenme yollarını optimize eden sistemlerden sanal gerçeklik ile zenginleştirilmiş ders materyallerine kadar geniş bir yelpazede eğitim süreçlerini desteklemiştir. Özellikle pandemi döneminde uzaktan eğitim çözümleri hızla devreye alınmış, yapay zekânın eğitimdeki potansiyeli daha görünür hale gelmiştir. Örneğin, Google Classroom gibi araçlar, öğrencilerin ve öğretmenlerin ders materyallerine erişimini kolaylaştırırken, yapay zekâ tabanlı değerlendirme sistemleri, öğretmenlerin öğrenci performansını etkili bir şekilde izlemesini sağlamıştır. (edu.google.com). Bu teknolojiler, eğitimde kaliteyi artırmak ve öğrenci başarısını desteklemek adına büyük bir fırsat sunmaktadır.

Eğitimde kullanılan birçok yapay zekâ uygulaması bulunmaktadır. Bu uygulamaların yapay zekâ içeren özellikleri, eğitimdeki rolleri ve bu uygulamaların geliştirilmesinde kullanılabilecek teknikler aşağıdaki tabloda gösterilmiştir.

Tablo 4. Yapay zekâ uygulamalarının eğitimdeki rolleri ve kullanılan teknikler

Yazılım/Uygulama İsimleri	Uygulama Özellikleri	Eğitimdeki Rolü	Kullanılabilecek Yapay Zekâ Teknikleri
Aleks, Mathia Dreambox Learning, IBM Watson Education, Smart Sparrow	Öğrenme Gelişim Takibi Gelişim Değerlendirme Performans İyileştirme Önerileri	Otomasyon Açıklama	Makine Öğrenmesi Veri Madenciliği
Udemy, Edx Coursera, Edmodo Grammarly Virtualwritingtutor	Ödev ve sınavları otomatik puanlama İlgiye yönelik içerik önerme Yapay zekâ dâhil her alandaki eğitim içeriğine ulaşabilme Dilbilgisi ve yazım kurallarını dikkate alarak düzeltmeler önerme	Tanımlama Evrensel Erişim Fırsat Eşitliği Yaşam Boyu Öğrenme Entegrasyon Evrensel erişim Fırsat eşitliği	Makine Öğrenmesi Veri Madenciliği Doğal dil işleme Makine öğrenmesi
Google Translate Yandex Translate Amazon Translate Cambridge Translate	Dil algılama Görüntüyü yazıya çevirme Sesi yazıya çevirme El yazıdaki karakterleri algılama	Entegrasyon Fırsat eşitliği	Derin öğrenme Yapay sinir ağları Doğal dil işleme Görüntü işleme
İthenticate, Turnitin	Belgelerin içeriklerindeki benzerlik oranlarını geçmiş belgelerle karşılaştırma	Entegrasyon	Derin öğrenme Yapay sinir ağları Doğal dil işleme
Presentation Translator	Canlı sunum anında farklı dil çevirisi yapma	Entegrasyon Fırsat eşitliği	Makine öğrenmesi Yapay sinir ağları Doğal dil işleme
Evernote Google Keep Microsoft One Note	Sesi yazıya çevirme El yazısındaki karakterleri algılama	Entegrasyon	Yapay sinir ağları Doğal dil işleme Görüntü işleme
Elementsofai.com Ocw.mit.edu	Yapay zekâ programlama ve otonom sistemler ile ilgili öğrenme ortamı sunma	Evrensel erişim Fırsat eşitliği Yaşam boyu öğrenme	Karar Ağaçları Derin Öğrenme Simulasyon ve Modelleme
Nao, Keepon, Kaspar, Romibo, Tito, Troy, Robonova, Probo, Pleo, Lego Nxt, İrobiq	Davranışları taklit edebilme, Dans edebilme Şarkı söyleyebilme, Eşleştirme yapma Sıralama yapma, Sorulara cevap verme Duyguları algılama	Fırsat eşitliği	Makine öğrenmesi Robotik

Kaynak: (Nabiyev ve Erümit, 2020, s. 53).

Eğitimde yapay zekâ uygulamaları, öğretim süreçlerini daha verimli hale getirirken, öğrencilere daha fazla özelleştirilmiş ve etkileşimli bir öğrenme deneyimi sunmaktadır. Kişiselleştirilmiş Öğrenme ile çeşitli öğrenme teknikleri kullanarak öğrencilerin performansını analiz eden sistemler, öğrencilerin hangi konularda zorluk yaşadıklarını belirleyebilmektedir. Bu veriler, öğretmenlerin öğrencilerine daha iyi destek sunmasını sağlarken, öğrencilere de kendi öğrenme yollarını belirleme imkânı tanınmaktadır (Zawacki-Richter vd., 2019). Örneğin, DreamBox Learning ve Knewton gibi platformlar, öğrencilerin öğrenme

stillerine ve hızlarına göre özelleştirilmiş ders içerikleri sunmaktadır. Yine Akıllı öğrenme sistemleri ile öğrenme süreçlerini optimize edilebilmekte ve öğrenci başarılarını artmaktadır. Bu sistemler, öğrencilere anlık geri bildirimler vererek, hangi alanlarda geliştirme yapmaları gerektiğini belirleyebilmektedir. Örneğin, Carnegie Learning, matematik eğitimi için akıllı bir sistem geliştirmiştir. Bu sistem, öğrencilerin cevaplarına dayanarak öğretim yöntemini ayarlayarak, öğrenme sürecini daha etkili hale getirmektedir (Koedinger vd., 2015).

Yapay zekâ destekli sanal öğretmenler ve asistanlar, öğrencilere rehberlik etme, soruları yanıtlama ve ders içeriklerini açıklama gibi görevleri üstlenebilmektedir. Bu asistanlar, öğrencilere 7/24 destek sağlayarak, eğitimde erişilebilirliğini artırmaktadır. Örneğin, IBM Watson, eğitim alanında öğretmenlere destek olmak için kullanılmaktadır. Öğrencilerin sorularını yanıtlayabilen bu sistem, öğretmenlerin iş yükünü azaltarak, öğretim süreçlerini iyileştirmektedir (Kumar vd., 2019).

Dünyada Eğitim 4.0 ile birlikte yapay zekâ eğitim ve öğretimin biçimi değiştirmiştir (Alkayış, 2021, s. 231). Bu değişen yönler şu şekilde sıralanabilmektedir:

- Yapay zekâ ve e-öğrenme yöntemiyle öğretmenin bilgisi desteklenip dersin içeriği daha da zenginleşmiştir (Türkel ve Yeşilkuş, 2020, s. 340).
- Öğrencilerin öğrenmelerinde rehber öğretmenlerle birlikte eğitim programlarının içeriği güncellenerek uygulanabilirliğinin sınırları genişlemiştir.
- Eğitim kurumlarının erişime açık eğitim materyallerini kişisel uyarlanabilir öğrenme yöntemiyle birleştirilen yapay zekâ merkezli çevrimiçi eğitim platformları artmıştır.

Eğitim 4.0'ın hedefi, öğrencilerin çağın gereksinimlerine uyum sağlayabilecekleri ve yaşamları boyunca sürekli olarak öğrenmeye devam edebilecekleri becerilerle donatılmasını sağlamaktır. Bu, teknolojinin eğitim sürecindeki rolünü önemli ölçüde artırmakta ve öğrenme deneyimini daha etkili, erişilebilir ve ilgi çekici hale getirmektedir.

Eğitimin geleceğinde yapay zekâ daha fazla ileri düzey yenilikler sunarak öğrenme ve öğretim süreçlerinde çok farklı dönüşümlere yol açabilecektir. “*Holografik eğitim sistemleri*”, fiziksel sınıf ortamına ihtiyaç duymadan öğrencilerin sanal öğretmenlerle etkileşime geçmesini sağlayarak coğrafi engelleri ortadan kaldıracaktır. Örneğin, Microsoft’un HoloLens teknolojisi, biyoloji derslerinde hücrelerin iç yapısını üç boyutlu olarak görüntülemeye olanak tanımakta, öğrencilerin öğrenme sürecini görselleştirme yoluyla derinleştirmektedir (Microsoft, 2023). Bu tür teknolojiler, hem ders içeriklerini daha ilgi çekici hale getirirken hem de eğitimde fırsat eşitliğini desteklemektedir. Hologramlar, öğrencilerin derse katılımını artırarak öğrenme süreçlerini daha etkileşimli ve verimli hale getirmektedir. Yine öğrencilerin tüm öğrenim yolculuğunu kapsayan ve bireysel veri analizine dayalı öneriler sunan platformlardan “*tam entegre sistemler*”, hem öğrenim süreçlerini hem de kariyer planlamasını desteklemede önemli bir rol oynayabilecektir. Bu teknolojilerin ortak amacı, her öğrencinin öğrenme ihtiyaçlarına özel olarak uyarlanmış içerik ve öneriler sunmaktır. Ayrıca, öğretmenlere öğrencilerin ilerlemesini detaylı bir şekilde izleme ve buna dayalı kararlar alma imkânı sağlamaktadır (IBM, 2021; Knewton, 2023; Dreambox, 2023). Bunun yanı sıra, özellikle gelişmekte olan bölgelerde bu tür teknolojiler, eğitimde eşitsizlikleri azaltma potansiyeline sahiptir.

3.4. Hukuk Alanında Yapay Zekâ

Tarih boyunca hukuki kararların öngörülebilirlik, akılcılık, tutarlılık ve homojenlik gibi temel niteliklere sahip olduğu ileri sürülmektedir. Bir hukukçunun karar verme sürecinde doğal olarak sağduyu kullandığı varsayılsa bile, sağduyunun bu süreçteki tek belirleyici faktör olduğu düşüncesi doğru değildir (Doğan, 2018, s. 314). Çünkü bir hâkimin karar verme sürecinde çeşitli faktörler bulunmakta ve bu faktörler arasında karmaşık ilişkiler mevcuttur (Sümer, 2021, s. 1552).

Hukuk alanında beklenen, dava sonuçlarının en doğru ve hızlı bir şekilde sonuçlanmasıdır. Yapay zekânın en büyük avantajlarından biri olan hız, hukukta davaların erken sonuçlanmasına yardımcı olabilecektir. Ancak hukukta normlar ve bu normların içinde birbiriyle bağlantılı olmayan normlar da bulunabilmektedir. Burada yapay zekâ normlar içinde bağlantıları doğru bir şekilde yönetip karar alabilirse hukuk alanında başarısını artırabilecektir (Özbilgin, 2023, s. 105-106). Özetle yapay zekâ ne kadar çok veriyle beslenebilirse hukuk alanındaki başarısı da o kadar artabilecektir.

Teknolojik yenilikleri yakından takip eden hukuk sistemi, insanların ihtiyaçları doğrultusunda çeşitlenmektedir. Hukuk sisteminde teknolojinin ve yapay zekânın yardımıyla çeşitli robotik sistemler geliştirilmiştir. Örneğin, İngiltere’de geliştirilen algoritmik bir yazılım kullanarak faaliyet gösteren bir robot hâkim, doğal dil işleme ve makine öğrenmesi tekniklerini

uygulayarak konular ve metinlerdeki benzerliklerden hareketle veri tabanındaki kararları analiz etmiş ve Avrupa İnsan Mahkemesi kararlarını %79 oranında başarıyla tahmin edebilmiştir (Sümer, 2021, s. 1562).

Yapay zekâ, büyük veri organizasyonunda önemli kolaylıklar sunmaktadır. Elde edilen verilerin sisteme aktarılması sürecinde bürokratik yükü azaltabilmektedir. Özellikle birçok bürokratik süreç, öngörülebilir sonuçlar doğuran otonom süreçler kapsamında değerlendirilmektedir. Bu nedenle, sonuçların ne kadar tahmin edilebilir olduğu, verilerin kısmen veya belirli koşullar altında otomatik olarak işlenebilmesini mümkün kılmaktadır. Bu sayede, akıllı bir dosyalama portalının oluşturulması, tarafların mahkemeye taşınan uyumsuzluklarını en etkin şekilde yönetmelerini sağlamaktadır (Reiling, 2020, s. 3). Dünyada ve ülkemizde buna benzer çeşitli uygulamalar vardır. Bunlardan bazıları, “eDiscovery”, “Uyap”, “Turklex”, “Arya”, “Hukuk Work”, “Perfect DNA” gibi verilerin otomatik işlenmesi ile hızlıca belge oluşturularak zamandan tasarruf sağlamaktadır.

Hukuk alanında yapay zekâ destekli tahmin sistemleri, çeşitli hukuki sonuçları tahmin etmek veya belirli olayların olasılığını değerlendirmek için kullanılmaktadır. Bu sistemler genellikle büyük veri kümelerini analiz etmekte, bunları benzer durumlarla ilişkilendirmekte ve gelecekteki sonuçları öngörmeye çalışmaktadır. Bu tür tahmin sistemleri, Hukuki Karar Tahmini, Hukuki Risk Değerlendirmesi, Ceza Tahmin, Hukuki Trendlerin Tahmini, Hukuki Talep Tahmini örnek olarak verilebilmektedir.

- Hukuki Karar Tahmini: Yapay zekâ, geçmiş mahkeme kararlarını ve hukuki davaların detaylarını analiz ederek benzer davalardaki sonuçları tahmin edebilmektedir. ABD’de bir grup bilim adamı tarafından geliştirilen “SCOTUS” isimli bir uygulama ABD Yüksek Mahkemesi’nin belirli bir davada vereceği kararı tahmin etmeye odaklanmaktadır. SCOTUS Yüksek Mahkeme kararlarını incelemekte ve belirli bir davada Yüksek Mahkeme’nin kararını tahmin etmek için istatistiksel modelleri kullanmaktadır. Uygulama, mahkemede davanın sonucunu %70,2, hakimlerin oy kullanma davranışlarını da %71,9 başarı ile tahmin edebilmiştir (Reiling, 2020, s. 5).
- Hukuki Risk Değerlendirmesi: Yapay zekâ tabanlı tahmin sistemleri, belirli bir işlemin veya anlaşmanın hukuki riskini değerlendirebilmektedir. Bununla ilgili olarak, Hollanda hükümeti tarafından geliştirilen bir veri analizi aracı olan “Sistem Risk Göstergesi (SyRI)”, farklı kamu kurumları tarafından toplanan verileri bir araya getirerek ve analiz ederek sosyal yardım alıcılarının potansiyel risklerini tespit etmeyi amaçlamaktadır. SyRI’nin amacı, kamu kaynaklarının etkin bir şekilde kullanılmasını sağlamak ve hükümetin sosyal yardım programlarının daha adil ve verimli olmasını sağlamaktır (Osborne, 2020).
- Ceza Tahmini: Yapay zekâ, bir suçun cezasını tahmin etmek için mahkeme kararlarını ve yargısal önyargıları analiz edebilmektedir. Bununla ilgili olarak ABD’de geliştirilen “COMPAS (Correctional Offender Management Profiling for Alternative Sanctions)”, isimli bir yazılım, suçluların tekrar suç işleme olasılığını tahmin etmek için kullanılmaktadır. Başka bir yazılım olarak, “PredPol”, polis departmanları için suç tahmini yazılımıdır. Makine öğrenimi ve istatistiksel analizleri kullanarak belirli bölgelerde gelecekteki suçları tahmin etmeye çalışmaktadır. Bu tahminler, polis kaynaklarının daha etkili bir şekilde dağıtılmasına ve suç önleme çabalarının optimize edilmesine yardımcı olmaktadır (Themakup, t.y.).
- Hukuki Trendlerin Tahmini: Yapay zekâ, hukuki trendleri ve değişiklikleri analiz ederek gelecekteki hukuki gelişmeleri tahmin edebilmektedir. Bu, hukuk firmalarının veya şirketlerin geleceğe yönelik stratejilerini belirlemelerine yardımcı olabilmektedir. “Lex Machina”, hukuk firmalarına ve avukatlara gelecekteki hukuki trendleri tahmin etmelerine yardımcı olmak için veri analizi sağlayan bir platformdur (Lex Machina). Yine “Legal Analytics” Platformları, hukuk firmalarının veya şirketlerin hukuki riskleri ve fırsatları daha iyi anlamalarına yardımcı olmak için hukuki trend tahmini sağlamaktadır. Bu platformlar, belirli hukuki konular veya endüstrilerdeki değişiklikleri ve eğilimleri izlemekte ve tahminlerde bulunmaktadır (Legalmasterai). Yine başka bir uygulama “ROSS Intelligence”, yapay zekâ tabanlı bir hukuk arama motoru ve analitik platformudur. Bu platform, hukuki trendleri ve dava sonuçlarını analiz etmekte, avukatlara hukuki araştırma yapmak ve gelecekteki hukuki talepleri tahmin etmek için yardımcı olmaktadır (Rossintelligence, t.y.).

Yapay zekâ ve teknolojiadaki gelişmelerle hukuk alanında doğru ve hızlı sonuçlara ulaşmak önemli bir gereksinim ve adaletin gerekliliği olarak karşımıza çıkmaktadır. Yapay zekânın hızlı ve doğru sonuca ulaşma konusunda kullanılan algoritmaların katkısı her geçen gün artmaktadır. Ancak hızın pozitif etkisinin yanında, bazı negatif etkileri olabileceği de kabul edilmelidir, zira hukuki işlemler bakımından sonuca hızlı ulaşmak kadar ulaşılan sonuç da önem taşımaktadır. Bu sebeple, hukuk sistemlerinin gerek analiz gerek karar süreçlerindeki yapay zekânın entegrasyonunun etik, sosyolojik, psikolojik açılarından da değerlendirilmesi ve güvenlik bakımından da kontrolünün gerektiği, verimli bir teknolojik ilerlemenin ve sağlıklı entegrasyonunun ancak bu şekilde gerçekleşebileceği düşünülmektedir (Özbilgin, 2023, s. 15).

Aşağıdaki tabloda, hukuk alanında kullanılan yapay zekâ uygulamaları, bu uygulamalarda yer alan yapay zekâ özellikleri, hukuk içindeki rolleri ve geliştirilmesinde kullanılabilecek teknikler özetlenmiştir.

Tablo 5. Yapay zekâ uygulamalarının hukuk alanındaki rolleri ve kullanılan teknikler

Yazılım/Platform İsmi	Uygulama Özellikleri	Etkilendiği Bölümler	Kullanılabilecek Yapay Zekâ Teknikleri
ROSS Intelligence	Hukuki araştırmalar, yasal doküman analizleri	Hukuki Araştırmalar, Karar Destek Sistemleri	Doğal Dil İşleme (NLP), Makine Öğrenimi
Lex Machina	Davaların sonuçlarını tahmin etme, karar analitiği	Mahkeme Stratejileri, Hukuki Karar Tahminleri	Veri Madenciliği, Tahmine Dayalı Modelleme
CaseMine	Benzer davaların analizini yapma, bağlamsal analizler	Hukuki Doküman Yönetimi, İlgili Davaları Bulma	Makine Öğrenimi, Kümeleme Algoritmaları
Legal Robot	Sözleşme analizi, dil karmaşıklığını azaltma	Sözleşme Analizleri, Hukuki Belgeler	Derin Öğrenme, Doğal Dil İşleme
DoNotPay	Hukuki şikayetler, küçük taleplerin yönetimi	Tüketici Hakları, Küçük Hukuki Talepler	Chatbotlar, Pekiştirmeli Öğrenme
Judicata	Mahkeme kararlarının analizi ve hukuki mantığın doğruluğunu değerlendirme	Hukuki Argüman Analizi	Doğal Dil İşleme, Veri Görselleştirme
Kira Systems	Sözleşme incelemesi, hukuki belgelerdeki önemli maddeleri bulma	Sözleşme İncelemesi, Belgelerin Hızlı Analizi	Metin Madenciliği, Kümeleme Algoritmaları
eDiscovery Software	Elektronik belgelerin taranması ve delil analizi	Elektronik Delil Analizi, Belgelerin Keşfi	Makine Öğrenimi, Anomali Tespiti
Courtroom Analytics (Premonition)	Avukatların performans analizleri, dava başarı oranları	Dava Stratejileri, Performans Analizleri	Tahmine Dayalı Analitik, Makine Öğrenimi
JurisPredict	Mahkeme kararlarının sonuçlarını öngörme	Karar Tahmin Sistemleri	Veri Madenciliği, Regresyon Modelleri
Luminance	Karmaşık sözleşme verilerini analiz etme	Hukuki Due Diligence, Sözleşme Analizleri	Derin Öğrenme, Makine Öğrenimi

Kaynak: Her bir yapay zekâ modeli, ilgili resmî web siteleri incelenerek yazar tarafından derlenmiştir.

Hukuk alanında yapay zekâ, son yıllarda hem verimlilik artırıcı çözümler sunmak hem de karmaşık hukuki süreçleri basitleştirmek için yoğun bir şekilde kullanılmaktadır. Bu uygulamalar, sözleşme hazırlama ve inceleme, hukuki araştırmalar, dava sonuçlarının tahmini, müşteri iletişim süreçleri gibi geniş bir yelpazede yer almaktadır. Yapay zekâ, bu alanlarda yalnızca iş yükünü azaltmakla kalmamakta, aynı zamanda hata oranını minimize ederek daha doğru ve hızlı sonuçlar elde edilmesini sağlamaktadır. Yapay zekâ ile güçlendirilmiş bu uygulamalar, genellikle doğal dil işleme (NLP), makine öğrenimi ve öngörücü analiz gibi ileri teknikleri kullanarak hukuk dünyasına değer katmaktadır. Örneğin, tahminci analiz sistemleri dava sonuçlarının büyük bir doğrulukla tahmin edilmesine olanak tanırken, adli yardım chatbotları vatandaşların hukuki süreçlerde daha hızlı bilgiye ulaşmasını sağlamaktadır. Bununla birlikte, bu uygulamalar dolandırıcılık tespiti, risk analizi ve küçük ölçekli anlaşmazlıkların çözümünde de önemli bir rol üstlenmektedir.

Gelecekte, yapay zekâ daha geniş bir kapsamda kullanılmasıyla hukuk alanındaki teknolojilerin daha özerk, etik ve şeffaf hale getirilmesi beklenmektedir. Bu sistemlerin algoritmik şeffaflık ilkesine uygun olarak geliştirilmesi, adaletin sağlanması açısından büyük önem taşımaktadır. Yapay zekânın sağladığı avantajlar, özellikle rutin hukuki işlerde zaman tasarrufu ve erişim kolaylığı sağlaması, insan avukatlara karmaşık dava ve strateji geliştirme gibi daha yaratıcı görevlerde odaklanma imkânı sunabilecektir. Hukukta Yapay zekânın etkili kullanımı, adaletin daha geniş kitlelere ulaşmasını ve hukuki süreçlerin daha verimli hale gelmesini mümkün kılacaktır.

3.5. Ekonomi ve Finans Alanında Yapay Zekâ

Ekonomi ve finans alanında yapay zekânın kullanımı, çeşitli görevlerin otomatikleştirilmesi, süreçlerin daha verimli hale getirilmesi ve daha doğru öngörüler sunulmasıyla bu sektörlerde büyük bir dönüşüm yaratmaktadır. Dijital çağın en önemli yeniliklerinden biri olan yapay zekâ teknolojisi, özellikle ekonomi ve finans gibi veri yoğun alanlarda hızlı bir şekilde kendine yer bulmuş ve etkisini giderek artırmıştır. Son yıllarda, yapay zekâ teknolojilerinin geniş bir finansal uygulama yelpazesinde benimsenmesi, yalnızca sektördeki işletmelerin değil, akademisyenlerin ve bilim insanlarının da dikkatini çekmiştir. Özellikle algoritmik ticaret, risk yönetimi, müşteri davranışlarının analizi ve dolandırıcılık tespiti gibi kritik alanlarda yapay zekâ, karar alma süreçlerini daha hızlı ve güvenilir hale getirmiştir. Bu alanlardaki ilk başarılar, yapay zekânın finans kurumlarındaki verimliliği ve karar alma süreçlerini iyileştirme potansiyelini ortaya koymuştur (Pau ve Yong, 1994, s. 407).

Yapay zekâ ve makine öğrenimi finansal sistemlerdeki kullanımlarıyla endüstrileri ve toplumları dönüştürmektedir. Geleneksel fon yönetim firmalarından yatırım ve perakende bankalarına, günümüz finansal teknoloji (Fintek) hizmet sağlayıcılarına kadar birçok finansal kuruluş, veri bilimi ve makine öğrenimi uzmanlığı edinimine yoğun yatırımlar yapmaktadır. Finansal sistem genelinde veri üretimi, hesaplama gücü ve depolama kapasitesindeki sürekli artışla desteklenerek finans endüstrisi üzerinde büyük etkiler yaratmıştır. Bu veri arayışı ile birlikte, düzenleyici sistemlerin yeniden ele alınması ihtiyacı sürekli bir gereklilik haline gelmiştir. 2007-2008 küresel finansal krizi, finansal endüstrinin düzenlenmesinde yapısal değişikliklere yol açarak veri odaklı düzenlemeye odaklanılmasını sağlamıştır (Davies, 2012, s. 2).

Finansal sektör profesyonelleri, standart şirket temellerinin, menkul kıymet fiyatlarının ve makroekonomik göstergelerin ötesinde, sosyal medya gönderileri, haber makaleleri, ses kayıtları ve uydu görüntüleri gibi alternatif verilerle giderek daha fazla ilgilenmektedir. Bu tür büyük veri kaynakları, ticaret kararları üzerinde önemli etkilere sahiptir. Bu tür veri kümelerinin özelliklerini keşfeden Prado (2019), bu tür büyük veri kaynaklarının geleneksel yaklaşımlar için karakteristik olarak zor olduğunu ve çoğunlukla sayısal olmadığını, eksik değerlere sahip olduğunu ve kategorik olmadığını gözlemlemiştir. Genellikle yüksek boyutlu olan bu tür veriler ve değişkenlerin sayısı genellikle gözlem sayısını aşmaktadır. Bu anomaliler göz önüne alındığında, klasik ekonometrik modeller, alternatif veriler kullanarak öngörücü ve belirleyici modeller üretmekte daha az yarar sağlamaktadır (Coulombe vd., 2020).

Yapay zekâ ve makine öğreniminin finans ve ekonomi alanındaki uygulamaları geniş bir yelpazeyi kapsamaktadır. Yapay zekânın ekonomi ve Finans Alanında uygulama alanları olarak Ekonomik ve Finansal Tahminler, Risk Yönetimi, Portföy Optimizasyonu, Alım Satım Stratejileri, Müşteri Davranış Analizi, Piyasa Trendlerinin Belirlenmesi, Piyasa Duyarlılığı Analizleri gibi alanlarda kullanılmaktadır (frontiersin.org).

- Ekonomik ve Finansal Tahminler: Yapay zekâ, ekonomik göstergeler, hisse senedi fiyatları, döviz kurları, talep yönetimi, kripto para tahmini, çeşitli değerlendirme tahminleri, çeşitli politika analizleri ve diğer finansal araçların tahmin edilmesinde önemli bir rol oynamaktadır. Gelişmiş algoritmalar, geçmiş verilere dayanarak daha doğru tahminler yapabilmektedir. Sonuç olarak, yapay zekâ ve makine öğreniminin ekonomik ve finansal tahminlerdeki rolü, daha iyi analiz, daha etkili stratejiler ve daha bilinçli kararlar alınmasına katkıda bulunmaktadır. Bu süreçler hem bireysel yatırımcılar hem de büyük finansal kurumlar için stratejik bir avantaj sağlamaktadır. Yapay zekânın gelişimi ile birlikte, gelecekte daha da karmaşık ve kesin tahminlerin yapılması beklenmektedir, bu da ekonominin dinamik yapısının daha iyi anlaşılmasına yardımcı olacaktır (Kahyaoglu, 2021).
- Risk Yönetimi: Finansal risklerin değerlendirilmesi ve yönetimi için gelişmiş modelleme ve simülasyon teknikleri ile özellikle kredi verenlerin daha iyi kararlar almasına yardımcı olabilmektedir. Risk yönetiminde yapay zekânın kullanımı, finansal kurumların ve işletmelerin riskleri daha etkili bir şekilde tanımlayıp yönetmelerine yardımcı olmaktadır. Bunun için anomali tespitleri, kredi risk değerlendirmesi, senaryo analizleri ve simülasyonlar, davranışsal risk analizleri ve erken uyarı gibi çeşitli teknikler uygulanmaktadır. Böylece yapay zekâ, risk yönetimi süreçlerini daha verimli ve etkili hale getirerek, finansal kurumların ve işletmelerin riskleri daha iyi tanımlayıp yönetmesine olanak tanımakta ve bu uygulamalar, işletmelerin daha bilinçli kararlar almasını sağlamakta ve potansiyel kayıpları azaltmaktadır (Mashrur vd., 2020).
- Portföy Optimizasyonu: Yatırım portföylerinin optimize edilmesi ve performanslarının artırılması için yapay zekâ teknikleri uygulanmaktadır. Farklı varlık sınıflarının risk ve getirilerini analiz ederek, yatırımcıların portföylerini daha iyi yönetmelerine yardımcı olmaktadır. Yine yapay zekâ algoritmaları, risk toleransına göre en iyi varlık dağılımını belirleyebilmektedir. Bu süreç hem varlık seçiminde hem de varlıkların ağırlıklarının belirlenmesinde daha etkili kararlar alınmasına olanak tanımaktadır (Kazeem, 2023). Yapay zekâ, portföy optimizasyonu alanında yatırımcıların daha iyi kararlar almasına ve riskleri yönetmesine yardımcı olmaktadır. Varlık seçimi, risk yönetimi, dinamik portföy yönetimi ve tahmin gücü gibi alanlarda Yapay zekâ uygulamaları, daha etkili ve verimli bir yatırım stratejisi geliştirilmesine olanak tanımaktadır. Gelecekte, yapay zekânın bu alandaki etkisinin daha da artması ve yatırımcıların karar alma süreçlerini köklü bir şekilde değiştirmesi beklenmektedir.
- Alım Satım Stratejileri: Yapay zekâ alım satım stratejilerinin geliştirilmesi ve uygulanmasında önemli bir rol oynamaktadır. Yatırımcılar ve finansal kurumlar, piyasa dinamiklerini anlamak ve daha etkili kararlar almak için yapay zekâ teknolojilerinden faydalanmaktadır. Bu stratejiler, belirli kurallar ve koşullara dayalı olarak otomatik alım satım işlemleri gerçekleştirmekte ve veri analizi yaparak alım satım sinyalleri üretebilmekte ve bu sinyallere dayanarak işlemler yapabilmektedir (Wang ve Yang, 2020). Yine sosyal medya, haber akışları ve diğer veri kaynakları üzerinden duyarlılığı ölçerek, yatırımcıların hangi varlıkların alım satımına odaklanması gerektiği konusunda bilgi sağlayabilmektedir (Churi vd., 2020).
- Müşteri Davranış Analizi: Müşteri davranışını anlamak ve tahmin etmek, işletmelerin müşteri memnuniyetini artırmalarına, satışlarını ve pazarlama etkinliklerini optimize etmelerine yardımcı olmaktadır. Yapay zekâ, büyük veri analizi yaparak müşterileri farklı gruplara ayırma konusunda yardımcı olmaktadır. Makine öğrenimi algoritmaları, demografik bilgiler, alışveriş geçmişi ve çevrimiçi etkileşimler gibi verileri kullanarak benzer özelliklere sahip müşteri gruplarını belirlemekte ve bu segmentasyon, hedeflenmiş pazarlama stratejilerinin geliştirilmesini sağlamaktadır (Gupta vd., 2023). Yine yapay zekâ, müşteri sadakatini artırmak ve müşteri kaybını azaltmak için de

kullanılmaktadır. Müşteri davranış verilerini analiz ederek, hangi müşterilerin sadık olduğu ve hangilerinin terk etme riski taşıdığı belirlenebilmektedir. Bu analizler, müşteri ilişkileri yönetimi stratejilerinin optimize edilmesine yardımcı olmaktadır (Bharambe vd., 2023).

- Piyasa Trendlerinin Belirlenmesi: Yapay zekâ, piyasa trendlerinin belirlenmesinde önemli bir araç olarak kullanılmaktadır. Piyasa trendlerini analiz etmek, yatırımcıların karar verme süreçlerini optimize etmelerine ve daha iyi stratejiler geliştirmelerine yardımcı olmaktadır. Özellikle zaman serileri analizleriyle geçmiş piyasa verilerini kullanarak trendleri belirleyebilmektedir. Makine öğrenimi algoritmaları, fiyat hareketlerini analiz ederek gelecekteki piyasa yönünü tahmin edebilmektedir. Bu sayede yatırımcılar, alım satım stratejilerini daha bilinçli bir şekilde oluşturabilmektedir (Abbas vd., 2024; Adrian, 2024). Yapay zekâ, teknik analiz araçları ile birleştirildiğinde piyasa trendlerinin belirlenmesinde etkili olabilmektedir. Farklı teknik göstergeler (örneğin, hareketli ortalamalar, RSI) algoritmalar tarafından analiz edilerek piyasa trendleri hakkında daha derinlemesine içgörüler sağlayabilmektedir. Sonuç olarak Yapay zekâ, piyasa trendlerinin belirlenmesinde güçlü bir araçtır. Zaman serisi analizi, teknik analiz, duygusal analiz ve piyasa anomali analizi gibi uygulamalar, yatırımcıların piyasa hareketlerini daha iyi anlamalarına ve daha etkili stratejiler geliştirmelerine olanak tanımaktadır (McCarthy ve Gita Alagband, 2023). Gelecekte, yapay zekanın piyasa analizindeki rolünün daha da artması ve daha karmaşık analizlerin gerçekleştirilmesi beklenmektedir.

Yapay zekâ ekonomi ve finans alanında devrim niteliğinde değişikliklerle veri analizi ve tahmin süreçlerini hızlandırarak yatırımcıların, finansal analistlerin ve yöneticilerin daha bilinçli kararlar almasına olanak tanımaktadır. Müşteri davranış analizi, piyasa trendlerinin belirlenmesi, risk yönetimi, alım satım stratejileri, portföy optimizasyonu ve ekonomik tahminler gibi çeşitli alanlarda yapay zekâ kullanımı, işletmelerin verimliliğini artırmakta ve rekabet avantajı sağlamaktadır. Özellikle büyük veri analitiği ve makine öğrenimi teknikleri, finansal verilerin işlenmesi ve anlamlandırılmasında kritik bir rol oynamaktadır. Sonuç olarak, yapay zekâ, ekonomi ve finans alanında önemli bir dönüşüm yaratmakta ve bu dönüşüm, gelecekteki ekonomik dinamikleri şekillendirecek potansiyele sahiptir.

4. SONUÇ

Yapay zekâ, günümüz dünyasında önemli bir dönüşüm aracı olarak ön plana çıkmaktadır. Makine öğrenimi ve derin öğrenme gibi teknikler sayesinde karar alma yeteneğine sahip yapay zekâ, son yıllarda çeşitli sektörlerde devrim niteliğinde uygulamalara öncülük etmektedir. Sağlık hizmetlerinden güvenlik sistemlerine, eğitim alanından hukuka, ekonomi ve finans sektörü ve diğer birçok alanda yenilikçi çözümler sunarak insanların yaşam kalitesini artırmakta ve iş süreçlerinde önemli değişim ve dönüşümlere zemin hazırlamaktadır. Özellikle, yapay zekâ destekli sistemler, veri analizi ve öngörü yetenekleri sayesinde daha hızlı ve doğru kararlar alınmasını sağlarken, insan gücünün de daha stratejik görevlere odaklanmasına olanak tanımaktadır. Böylece, yapay zekâ, yalnızca verimliliği artırmakla kalmayıp aynı zamanda kaynakların daha etkin kullanılmasına ve hizmetlerin daha erişilebilir hale gelmesine de katkıda bulunmaktadır.

Özellikle sağlık alanında yapay zekâ, teşhis ve tedavi süreçlerini hızlandırarak bireylerin sağlık hizmetlerine daha hızlı erişmesini sağlamaktadır. Eğitimde, kişiselleştirilmiş öğrenme deneyimleri sunarak öğrenci başarılarını artırmakta, savunma ve güvenlik alanında ise tehditlerin daha erken tespit edilmesiyle ulusal güvenlik seviyesini yükseltmektedir. Ekonomi ve finans sektöründe, büyük veri analitiği sayesinde piyasa trendlerinin öngörülmesi, risklerin azaltılması ve daha iyi karar alma süreçleri sağlanmaktadır. Bu bağlamda, yapay zekânın geniş bir uygulama alanına yayıldığı ve toplumun farklı kesimlerine yenilikçi çözümler sunduğu açıktır. Yapay zekanın sunduğu bu olanaklar, bazı zorlukları da beraberinde getirmektedir. Etik ve güvenlik endişeleri, iş gücü piyasasında oluşabilecek potansiyel değişiklikler ve veri gizliliği gibi konular, yapay zekanın sorumlu bir şekilde geliştirilmesi ve uygulanması gerektiğini ortaya koymaktadır. Örneğin, hukuki süreçlerde kullanılan yapay zekâ uygulamaları karar verme süreçlerini hızlandırır da bu kararların adil ve şeffaf bir şekilde alınması gerekmektedir. Yapay zekâ algoritmalarındaki önyargı riskleri, sosyal eşitsizlikleri artırma potansiyeline sahiptir ve bu durum hem teknolojiyi geliştirenler hem de uygulayanlar için büyük bir sorumluluk doğurmaktadır. Bu bağlamda, politika yapıcılar, iş dünyası ve akademik çevreler arasında iş birliğinin güçlendirilmesi, yapay zekanın potansiyelinden en iyi şekilde yararlanmak için elzem bir konudur.

Sonuç olarak, yapay zekânın geleceği, bu teknolojinin toplumun her kesimi üzerinde nasıl bir etki yaratacağını dikkatle ele almayı gerektirir. Yapay zekâ destekli teknolojilerin yalnızca teknik bir başarıdan ibaret olmadığı, aynı zamanda sosyal ve ekonomik boyutlarıyla da ele alınması gerektiği unutulmamalıdır. Gelecekte yapay zekâ, yalnızca bireylerin yaşam kalitesini artırmakla kalmayacak, aynı zamanda toplumların sürdürülebilir kalkınmasına da katkıda bulunacaktır. Ancak bu potansiyelin tam anlamıyla hayata geçirilmesi için, teknoloji geliştirme süreçlerinin somut çerçevelerle desteklenmesi ve sosyal sorumluluk anlayışıyla ilerlenmesi büyük bir önem taşımaktadır. Bu nedenle, yapay zekâ ile birlikte şekillenen dönüşüm sürecinde, toplumsal faydanın ön planda tutulması, eşitlikçi yaklaşımların benimsenmesi ve olası risklerin etkin bir şekilde yönetilmesi, uzun vadede sürdürülebilir bir teknoloji ekosistemi yaratılması için kritik bir öneme sahiptir.

YAZAR BEYANI

Araştırma ve Yayın Etiği Beyanı: Bu çalışma bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır.

Etik Kurul Onayı: Bu araştırma etik kurul izni gerektiren analizleri kapsamadığından etik kurul onayı gerektirmemektedir.

Yazar Katkıları: Yazar çalışmayı diğer yazar ile birlikte gerçekleştirmiştir.

Çıkar Çatışması: Yazar açısından ya da üçüncü taraflar açısından çalışmadan kaynaklı çıkar çatışması bulunmamaktadır

KAYNAKÇA

- Abbas, N., Cohen, C., Grolleman, D.J., & Mosk, B. (2024). Artificial Intelligence Can Make Markets More Efficient and More Volatile (www.imf.org Erişim Tarihi: 29.09.2024).
- Adrian, T. (2024). Artificial Intelligence and its Impact on Financial Markets and Financial Stability. (www.imf.org Erişim Tarihi: 29.09.2024).
- Aha, D. W., Kibler, D., & Goldstone, R. L. (1991). Instance-based learning algorithms. *Machine Learning*, 6(1), 37–66. doi.org/10.1007/BF00153759.
- AI-Powered Legal Assistance at Your Fingertips, (https://legalmasterai.com. Erişim Tarihi: 08.04.2024).
- Alkayış, S. (2021). Eğitim Felsefesi Perspektifinden Dijitalleşme ve Eğitim 4.0, *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 11(21), 221-237.
- Allahverdi, N., (2002). *Uzman Sistemler Bir Yapay Zekâ Uygulaması*. Atlas Yayın-Dağıtım, İstanbul.
- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine learning from theory to algorithms: An overview. *IOP Conference Series: Journal of Physics: Conference Series*, 1142(1), 012012. doi.org/10.1088/1742-6596/1142/1/012012.
- Amazon Personalize (2023), (https://aws.amazon.com/tr/personalize/ Erişim Tarihi: 25.11.2024).
- Amit, D. J. (1989). Modeling Brain Function: The World of Attractor Neural Networks. *Cambridge University Press*.
- Aranca (2023). AI in Defense – Advancing Border Security and Surveillance. (www.aranca.com. Erişim Tarihi: 29.08.2024).
- Arf, C. (1959). Makine Düşünebilir mi ve Nasıl Düşünebilir? *Atatürk Üniversitesi 1958- 1959 Öğretim Yılı Halk Konferansları*(1), 91-103.
- Arıkan Kargı, V.S. (2015). *Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama*, Ekin Yayınevi, Bursa.
- Arslan, K. (2020). Eğitimde Yapay Zekâ ve Uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Awad, M., & Khanna, R. (2015). Support vector regression. In Efficient learning machines (67–80). *Springer*. doi.org/10.1007/978-1-4302-5990-9_4.
- Aytekin, G. (2006). *İnternet İçerik Madenciliğinde Yapay Sinir Ağları ve Bir Uygulama*. Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmış Yüksek Lisans Tezi, Bursa. http://tez2.yok.gov.tr/ adresinden edinilmiştir.
- Baldi, P. (2012). Autoencoders, unsupervised learning, and deep architectures. In I. Guyon, G. Dror, V. Lemaire, G. Taylor, & D. Silver (Eds.), *Proceedings of the 2012 Conference on Learning Representations (ICLR)*. University of California, Irvine.
- Bastan, M., Ramisa, A., & Tek, M. (2020). Cross-modal fashion product search with transformer-based Embeddings. *CVPR Workshop - 3rd workshop on Computer Vision for Fashion, Art and Design*, Seattle: Washington.
- Batista, G., & Silva, D. F. (2009). How k-nearest neighbor parameters affect its performance. In Simposio Argentino de Inteligencia Artificial (ASAI 2009) (95–106).
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and Trends® in Machine Learning*, 2(1), 1–127. doi: 10.1561/2200000006.
- Bharambe, Y., Deshmukh, P., Karanjawane, P., & Chaudhari, D. (2023). *Churn prediction in telecommunication industry. 2023 International Conference for Advancement in Technology (ICONAT)*. doi.org/10.1109/ICONAT57137.2023.10080425.
- Bhatia, N., & Vandana. (2010). Survey of nearest neighbor techniques. *International Journal of Computer Science and Information Security*, 8(2), 302–305.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Bohr, A., & Memarzadeh, K. (2020). *The Rise of Artificial Intelligence in Healthcare Applications*. doi:10.1016/B978-0-12-818438-7.00002-2.
- Boutsidis, C., Mahoney, M. W., & Drineas, P. (2008). Unsupervised feature selection for principal components analysis. In *Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (61–69). ACM. doi.org/10.1145/1401890.1401903.
- Bresnick J. (2017). Artificial intelligence in healthcare market to see 40% CAGR surge. (https://healthanalytics.com Erişim Tarihi: 25.09.2024).
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., & Amodei, D. (2020). *Language models are few-shot learners*. doi.org/10.48550/arXiv.2005.14165
- Brynjolfsson, E., & McAfee, A. (2017). The business of artificial intelligence. *Harvard Business Review*, 1–20.
- Bubeck, S., Chandrasekaran, V., Eldan, R., Gehrke, J., Horvitz, E., Kamar, E., Lee, P., Lee, Y. T., Li, Y., Lundberg, S., Nori, H., Palangi, H., Ribeiro, M. T., & Zhang, Y. (2023). Sparks of Artificial General Intelligence: Early experiments with GPT-4. *arXiv preprint arXiv:2303.12712*. https://arxiv.org/abs/2303.12712.
- Budd, J., Miller, B. S., Manning, E. M., & Zin, K. (2020). COVID-19 and the Role of Artificial Intelligence in Health Care. *Journal of Healthcare Management*, 65(4), 232-243. doi.org/10.1097/JHM-D-20-00065.
- Carreira-Perpiñán, M. A., & Hinton, G. E. (2005). On contrastive divergence learning. In *Proceedings of the 10th International Conference on Artificial Intelligence and Statistics (AISTATS)* (Vol. 10).
- Center for Security and Emerging Technology (CSET). (2024). *Don't fear AI-driven 'biosurveillance,' experts say*. (CSET. https://cset.georgetown.edu. Erişim Tarihi: 29.08.2024.)
- Chakir, A., Andry, J. F., Ullah, A., Bansal, R., & Ghazouani, M. (Eds.). (2024). Engineering applications of artificial intelligence. *Elsevier*.

- Chandra, B., Gupta, M., & Gupta, M. P. (2007). Robust approach for estimating probabilities in Naive-Bayes classifier. In Proceedings of the 2nd International Conference on Pattern Recognition and Machine Intelligence. Springer. doi.org/10.1007/978-3-540-77046-6_2.
- Churi, A., Chakraborty, D., Khatwani, R., & Pinto, G. (2023). Stock price prediction using deep learning and sentiment analysis. *IEEE 2nd International Conference on Futuristic Technologies*. doi.org/10.1109/INCOFT60753.2023.10425124.
- Ciresan, D., Meier, U., & Schmidhuber, J. (2012). Multicolumn deep neural networks for image classification. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (3642–3649).
- Clancey, W. J. (1985). *Heuristic Classification*. *Artificial Intelligence*, 27(3), 289–350. doi: 10.1016/0004-3702(85)90016-5(DBLP).
- Coulombe, P.G., Leroux, M., Stevanovic, D., & Surprenant, S., (2020). *How is machine learning useful for macroeconomic forecasting?* doi.org/10.48550/arXiv.2008.12477.
- Coulston, J. W., Blinn, C. E., Thomas, V. A., & Wynne, R. H. (2016). Approximating prediction uncertainty for random forest regression models. *Photogrammetric Engineering & Remote Sensing*, 82(3), 189–197. doi.org/10.14358/PERS.82.3.189
- Cover, T. M., & Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. doi.org/10.1109/TIT.1967.1053964.
- Creswell, A., & Bharath, A. A. (2018). Denoising adversarial autoencoders. *IEEE Transactions on Neural Networks and Learning Systems*, 99, 1–17. doi.org/10.1109/TNNLS.2018.2836147.
- Cristianini, N., & Shawe-Taylor, J. (2000). *An introduction to support vector machines*. Cambridge University Press.
- Cura, T. (2008). *Modern Sezgisel Teknikler ve Uygulamaları*. Papatya Yayıncılık, İstanbul.
- Çelebi, M. E., & Aydin, K. (Eds.). (2016). Unsupervised learning algorithms. Springer. doi.org/10.1007/978-3-319-24211-8
- Çelik, E. (2011). *Görüntü İşlemeye Dayalı Aruç İçin Yapay Sinir Ağı ile Tanınması*. Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmış Yüksek Lisans Tezi. http://tez2.yok.gov.tr/ adresinden edinilmiştir.
- Davies, H. (2012). *Regulatory Responses to the Financial Crisis: An Interim Assessment*. The New Palgrave Dictionary of Economics, 1–10. doi:10.1057/978-1-349-95121-5_2932-1.
- Davis, Z.S. (2019). Artificial Intelligence on Battlefield: An Initial Survey of Potential Implications for Deterrence, Stability and Strategic Surprise. *Center for Global Security Research Lawrence Livermore National Laboratory*. Vol. 8, Iss. 2, (Oct 2019): 114-131.
- Deperlioğlu, Ö. (2019). Derin sinir ağları ile Hepatit hastalığı teşhisi. In *ECSAC'19 IVth European Conference on Science, Art, and Culture*.
- Doğan, K. (2018). *Ceza Muhakemesinde Belirsizlik Kuşkusundan Sanık Yararlanr İlkesi "in dubio pro reo"*, 2. Basım, Seçkin Yayıncılık, Ankara.
- Dreambox (2023). Inspire lifelong learning. https://www.dreambox.com/ Erişim tarihi: 05.11.2024.
- Dumais, S., Platt, J., Heckerman, D., & Sahami, M. (1998). Inductive learning algorithms and representations for text categorization. In *Proceedings of the 7th International Conference on Information and Knowledge Management (ACM-CIKM98)* (148–155).
- Elmas, Ç. (2018). *Yapay Zekâ Uygulamaları*. 4. Baskı. Seçkin Yayıncılık. Ankara.
- Emerj Artificial Intelligence Research. *"Predictive Analytics in the Military – Current Applications* (2024), (https://emerj.com/ai-sector-overviews/predictive-analytics-in-the-military-current-applications/ Erişim Tarihi: 02.07.2024).
- Ertmer, P. A., ve Ottenbreit-Leftwich, A. T. (2010). Teacher Technology Change: How Knowledge, Confidence, Beliefs, and Culture Intersect. *Journal of Research on Technology in Education*, 42(3), 255-284.
- Farfadi, S. S., Saberian, M., & Li, L.-J. (2015). Multiview face detection using deep convolutional neural networks. In Proceedings of the 5th ACM on International Conference on Multimedia Retrieval. doi.org/10.48550/arXiv.1502.02766.
- Frontex (2020). *AI Research Study*. Retrieved from (www.frontex.europa.eu, Erişim Tarihi: 29.08.2024).
- Frost & Sullivan. (2016). *Healthcare Information Technology Development*. Erişim Tarihi: 02.07.2024. (https://store.frost.com/global-healthcare-industry-outlook-2016.html. Erişim Tarihi: 02.07.2024).
- Fukushima, K. N. (1980). A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202. doi.org/10.1007/BF00344251.
- Furey, T. S., Cristianini, N., Duffy, N., Bednarski, D. W., Schummer, M., & Haussler, D. (2000). Support vector machine classification and validation of cancer tissue samples using microarray expression data. *Bioinformatics*, 16(10), 906–914. doi.org/10.1093/bioinformatics/16.10.906.
- Geiger, M., Nardi, D., & Aftalion, J. (2020). The Future of Artificial Intelligence and Robotics: Applications in Logistics and Beyond. *AI ve Society*, 35(3), 563-576.
- Gers, F. A., & Schmidhuber, J. (2000). Recurrent nets that time and count. In Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN 2000): Neural Computing: New Challenges and Perspectives for the New Millennium (Vol. 3, 189–194).
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471. doi.org/10.1162/089976600300015015.
- Gil, Y. & B. Selman (2019), A 20-year community roadmap for artificial intelligence research in the US, *Computing Community Consortium* doi.org/10.48550/arXiv.1908.02624.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 580–587. doi.org/10.1109/CVPR.2014.81.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT Press.
- Google Education. (2023). AI in the Classroom: Google's Vision. Erişim Tarihi: 02.09.2024).
- Greenberg, N., Docherty, M., Gnanaprasasam, S., & Wessely, S. (2020). *Managing mental health challenges faced by healthcare workers during covid-19 pandemic*. *Bmj*, 368.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2015). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*. doi.org/10.1109/TNNLS.2015.2482599.
- Gupta, J.N.D., & Smith, K.A. (2002). *Neural Networks in Business: Techniques and Applications*. IRM Press, United Kingdom. doi: 10.4018/978-1-93070-831-0.
- Gupta, S., Jain, T. Sinha, A., & Tanwar, V. (2023). Review on Customer Segmentation Methods Using Machine Learning. *International Conference on IoT, Intelligent Computing and Security*. Conference paper. 397-411.
- Güven, İ. (2020). *Perakende Hazır Giyim Endüstrisinde Yapay Zeka Yöntemleri ile Talep Tahmini*. Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yayınlanmış Yüksek Lisans Tezi. http://tez2.yok.gov.tr/ adresinden edinilmiştir.

- Haleem, A., Javaid, M., & Khan, İ.H. (2019). Current status and applications of Artificial Intelligence (AI) in medical field: An overview. *Current Medicine Research and Practice*, 9(6), 1-16.
- Haykin, S. (1994). *Neural Networks*. Macmillan College Publishing Company, USA.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Fundation*. (2nd ed.), Pearson Education, Inc. Pearson Prentice Hall, ISBN 81-7808-300-0, McMaster University, Hamilton, Ontario, Canada.
- Hebb, D. O. (1949). *The Organization of Behavior: A Neuropsychological Theory*. Wiley.
- Hey, T., Butler, K., Jackson, S. & Thiyagalingam, J. (2020). Machine learning and big scientific data. *Philosophical Transactions of the Royal Society A*, 378(2166), 20190054.
- Higgins, M. K. (2021). Can we AlphaFold our way out of the next pandemic? *Journal of molecular biology*, 433(20), 167093.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507. doi.org/10.1126/science.1127647.
- Hoadley, D. S., & Lucas, N. J. (2018). Artificial intelligence and national security (CRS Report No. R45178). *Congressional Research Service*, (CRS Report No. R45178).
- Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, 195(1), 215–243. doi: 10.1113/jphysiol.1968.sp008455.
- IBM. (2021). Watson for Education: Future-Proofing Careers. <https://www.ibm.com> Erişim tarihi: 05.11.2024).
- IBM. (2024). What is k-means clustering? <https://www.ibm.com> Erişim tarihi: 30.11.2024).
- Imandoust, S. B., & Bolandraftar, M. (2013). Application of K-Nearest Neighbor (KNN) approach for predicting economic events: Theoretical background. *International Journal of Engineering Research and Applications*, 3(5), 605–610.
- Jayanth Balaji, A., Harish Ram, D. S., & Nair, B. B. (2018). Applicability of deep learning models for stock Price forecasting an empirical study on BANKEX data. *Procedia Computer Science*, 143, 947–953. doi.org/10.1016/j.procs.2018.10.340.
- Jianliang, M., Haikun, S., & Ling, B. (2009). The application on intrusion detection based on K-means cluster algorithm. In *Proceedings of the International Forum on Information Technology and Applications (IFITA)* (1), 150–152).
- Joachims, T. (1998). Text categorization with support vector machines: Learning with many relevant features. *Proceedings of the 10th European Conference on Machine Learning (ECML)*, 137-142. doi.org/10.1007/BFb0026683.
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202. doi.org/10.1098/rsta.2015.0202.
- Jolly, J. (2023). It's a long-term journey we're on': taking a ride towards self-driving cars, *The Guardian*, <https://www.theguardian.com/technology/2023/feb/17/taking-ride-self-driving-car-nissan-servcityautonomous-vehicles>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. doi:10.1126/science.aaa8415.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, 4, 237-285.7
- Kahyaoglu, S. B. (Ed.). (2021). The Impact of Artificial Intelligence on Governance, Economics and Finance. Volume:1, *Springer*. doi.org/10.1007/978-3-030-66498-8
- Karaman, H. (2017). *Yapay Zekâ Yaklaşımıyla Jeofizik Kuyu Loglarından Kömür Varlığının Belirlenmesi: Manisa, Soma Havzası*. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmış Yüksek Lisans Tezi. <http://tez2.yok.gov.tr/> adresinden edinilmiştir.
- Karve International. Autonomous Surveillance: A Game Changer for Military Intelligence (2024), (www.karveinternational.com, Erişim Tarihi: 02.07.2024).
- Kazeem, O. (2023). *Portfolio Optimization Using Machine Learning*. University of Stirling.
- Kızılkaya, M., & Oğuzlar, A. (2018). Bazı denetimli öğrenme algoritmalarının R programlama dili ile kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*, 37(37), 90–98. doi.org/10.17498/kdeniz.405746.
- Kim, K.-j. (2003). Financial time series forecasting using support vector machines. *Neurocomputing*, 55(1-2), 307–319. doi.org/10.1016/S0925-2312(03)00372-2.
- Knewton. (2023). Adaptive Learning Technology Overview. <https://www.knewton.com> Erişim tarihi: 05.11.2024).
- Koedinger, K. R., Corbett, A. T., & Perfetti, C. A. (2015). The Knowledge-Learning-Instruction framework: Bridging the science-practice chasm to enhance robust student learning. *Cognitive Science*, 39(8), 1702-1720. doi: 10.1111/j.1551-6709.2012.01245.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43(1), 59–69.
- Kosko, B. (1988). Feedback Stability and Unsupervised Learning. *Proceedings of IEEE, International Conference on Neural Network*, Vol. 1, 141-152. doi: 10.1109/ICNN.1988.23842.
- Kotsiantis, S. (2011). Decision trees: A recent overview. *Artificial Intelligence Review*, 39(4), 261–267. doi.org/10.1007/s10462-011-9228-5
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems* (1097–1105).
- Kryshafovich, A., Moul, J., Billings, W. M., Della Corte, D., Fidelis, K., Kwon, S., Olechnovič, K., Seok, C., Venclovas, Č. & Won, J. (2021). Modeling SARS-CoV-2 proteins in the CASP- commons experiment. *Proteins: Structure, Function, and Bioinformatics*, 89(12), 1987-1996.
- Kühl, N., Mühlthaler, M., & Goutier, M. (2020). Supporting customer-oriented marketing with artificial intelligence: Automatically quantifying customer needs from social media. *Electronic Markets*, 30(2), 351–367. doi.org/10.1007/s12525-019-00351-0.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. doi.org/10.1038/nature14539.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. doi: 10.1109/5.726791.
- Liaw, A., & Wiener, M. (2002). Classification and regression by Random Forest. *R News*, 2(3), 18–22.
- Lopez Pinaya, W. H., Vieira, S., Garcia-Dias, R., & Mechelli, A. (2020). Autoencoders. In *Machine learning: Methods and applications to brain disorders* (pp. 193–208). Elsevier. doi.org/10.1016/B978-0-12-815739-8.00011-0.
- Mammadova, M. (2020). *Pi-Sigma Yapay Sinir Ağları ile Turist Sayısı Tahmini*. Giresun Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmış Yüksek Lisans Tezi. <http://tez2.yok.gov.tr/> adresinden edinilmiştir.

- Martin, M. (2002). On-line support vector machine regression. *In Proceedings of the European Conference on Machine Learning (ECML 2002)* (282–294). Lecture Notes in Computer Science, vol. 2430. Springer. doi.org/10.1007/3-540-36755-1_23.
- Martinengo, L., E. Lum & J. Car (2022), Evaluation of chatbot-delivered interventions for selfmanagement of depression: Content analysis, *Journal of Affective Disorders*, Vol. 319, 598-607, doi.org/10.1016/j.jad.2022.09.028.
- Mashrur, A., Luo, W., Zaidi, N. A., & Robles-Kelly, A. (2020). *Machine Learning for Financial Risk Management: A Survey*. IEEE Access, 9, 20184–20205. doi.org/10.1109/ACCESS.2021.3053094.
- McCarthy (1956). *A Proposal For The Dartmouth Summer Research Project On Artificial Intelligence*. Erişim: <https://raysolomonoff.com/dartmouth/boxa/dart564props.pdf>.
- McCarthy, S., & Alaghaband, G. (2023). Enhancing Financial Market Analysis and Prediction with Emotion Corpora and News Co-Occurrence Network. *Journal of Risk and Financial Management*, 16(4), 226. doi.org/10.3390/jrfm16040226.
- McCulloch, W., & Pitts, W. (1943). A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biology* Vol: 52, No. 1/2., 99–115.
- Microsoft. (2023). HoloLens and Education. <https://www.microsoft.com>. Erişim Tarihi: 08.11.2024).
- Minohara, T. (2006). Fault Tolerant Training of Neural Networks for Learning Vector Quantization. *ICONIP: Neural Information Processing*. 786-795.
- Minsky, M., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry*. MIT Press.
- Nabiyev, V. V. (2016). *Yapay zekâ: Teori ve uygulamaları*. Seçkin Yayıncılık.
- Nabiyev, V.V., & Ertümit, A.K. (2020). *Eğitimde Yapay Zekâ: Kuramdan Uygulamaya*. Pegem Yayınları, 1. Baskı, Ankara.
- Nasr, M., Islam, M. M., Shehata, S., Karray, F., & Quintana, Y. (2021). Smart healthcare in the age of AI: Recent advances, challenges, and future prospects. IEEE Access, 9, 145248-145270. doi.org/10.48550/arXiv.2107.03924.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons*, 4(1), Article P05. doi.org/10.20544/HORIZONS.B.04.1.17.P05
- Newell, A., & Simon, H. A. (1976). Computer Science as Empirical Inquiry: Symbols and Search. *Communications of the ACM*, 19(3), 113-126.
- Niessen, L. W., Grijseels, E. W. and Rutten, F. F. H. (2000). The Evidence Based Approach in Health Policy and Health Care Delivery. *Social Science and Medicine*, 51(6): 859-869.
- Nilsson, N. J. (2010). *The Quest for Artificial Intelligence: A History of Ideas and Achievements*. Cambridge University Press.
- OECD (2021). AI and the Future of Skills, Volume 1: Capabilities and Assessments, Educational Research and Innovation, *OECD Publishing*, doi.org/10.1787/5ee71f34-en.
- OECD (2023). Putting AI to the test: How does the performance of GPT and 15-year-old students in PISA compare?, Volume 6: OECD Education Spotlights, No. 6, OECD Publishing, doi.org/10.1787/2c297e0b-en.
- Oja, E. (1982). Simplified neuron model as a principal component analyzer. *Journal of Mathematical Biology*, 15(3), 267–273. doi.org/10.1007/BF00275687.
- Okutan, O. (2006). *Yapay Zekâ ile Mobil Robot Kontrolü*. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmış Yüksek Lisans Tezi. <http://tez2.yok.gov.tr/> adresinden edinilmiştir.
- OpenAI (2023). GPT-4 Technical Report, <https://cdn.openai.com/papers/gpt-4.pdf>.
- Osborne, C. (2020), *Dutch court rules AI benefits fraud detection system violates EU human rights*, (<https://www.zdnet.com/article/dutch-court-rules-ai-benefits-fraud-detection-system-violates-eu-human-rights/>) Erişim Tarihi: 02.07.2024).
- Osuna, E., Freund, R., & Girosi, F. (1997). Training support vector machines: An application to face detection. *In Proceedings of the International Conference on Computer Vision and Pattern Recognition (CVPR97)* (30–136).
- Özbilgin, (2023). *Uluslararası Hukukun Yapıtırım Problemine Özel Hukuk Perspektifinde Alternatif Çözüm: Yapay Zekâ*. Yeditepe Üniversitesi, SBE, Yayınlanmış Yüksek Lisans Tezi.
- Öztemel, E. (2012). *Yapay Sinir Ağları*, 3. Baskı, Papatya Yayıncılık, İstanbul.
- Parker, D. (1987). Optimal Algorithms for Adaptive Networks: Second order Back Propagation, Second Order Direct Propagation, and Second Order Hebbian Learning. *Proceedings of the IEEE First International Conference on Neural Networks (San Diego, CA)*, II, 593–600.
- Pau, L.F., & Yong, T.P. (1994), *Artificial intelligence in economics and finance: A state of the art — 1994: The real estate price and assets and liability analysis case*, *Handbook of Computational Economics*, 1, 405-439.
- Pavli, A., Theodoridou, M., & Maltezou, H. C. (2021). Post-COVID syndrome: Incidence, clinical spectrum, and challenges for primary healthcare professionals. *Archives of Medical Research*.
- Piramuthu, S., Shaw, M.J. & Gentry, J.A., (1994). A Classification Approach Using Multi-Layered Neural Networks. *Decision Support Systems*, 11(5), 509- 525.
- Qiu, X. Y., Kang, K., & Zhang, H. X. (2008). Selection of kernel parameters for K-NN. *In IEEE International Joint Conference on Neural Networks (IJCNN)* (61–65).
- Ramaswamy, S., & DeClerck, N. (2018). Customer perception analysis using deep learning and NLP. *Procedia Computer Science*, 140, 170–178. doi.org/10.1016/j.procs.2018.10.326.
- Raska, M. (2021). The sixth RMA wave: Disruption in military affairs? *Journal of strategic studies*, 44(4), 456-479.
- Ravid, S.Y. (2017). Generating Rembrandt: Artificial Intelligence, Copyright, and Accountability in the 3A Era--The Human-like Authors are Already Here- A New Model, *Mich. St. L. Rev.* 659, 664-666.
- Reiling, A. D. (2020). Courts and Artificial Intelligence. *International Journal for Court Administration*, 11(2), 2-10. doi.org/10.36745/ijca.343.
- Rickli, J.M. (2019). Artificial Intelligence and the Future of Warfare Chapter, *Global Risk Report, World Economic Forum*. (https://www.researchgate.net/publication/337103254_Artificial_Intelligence_and_the_Future_of_Warfare) Erişim Tarihi: 30.09.2024):
- Roblyer, M. D., & Doering, A. H. (2010). *Integrating Educational Technology into Teaching* (5th ed.). Boston: Allyn ve Bacon.
- Rokach, L., & Maimon, O. Z. (2008). *Data mining with decision trees: Theory and applications*. World Scientific.
- Roose, K. (2022), *A.I.-Generated Art Is Already Transforming Creative Work*, *The New York Times*, <https://www.nytimes.com/2022/10/21/technology/ai-generated-art-jobs-dall-e-2.html>.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. doi.org/10.1037/h0042519.

- Rossintelligence (t.y.), (<https://www.rossintelligence.com/about-us>, Erişim Tarihi: 08.04.2024).
- Ruffle, J. K., Kane, J. A., Hopfner, F., & Shura, R. D. (2019). Predictive models in personalized medicine: Applications, challenges, and ethical considerations. *Journal of Translational Medicine*, 17(1), 42.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. doi.org/10.1038/323533a0.
- Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach*, 4. Baskı. Pearson.
- Sağiroğlu, Ş., Beşdok, E., & Erler, M. (2003). *Mühendislikte Yapay Zeka Uygulamaları- I: Yapay Sinir Ağları*, Ufuk Yayıncılık, Kayseri.
- Şahin, A. (2020). *İleri Zamanlı Kan Glikoz Değeri Tahmini*. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmış Yüksek Lisans Tezi. <http://tez2.yok.gov.tr/> adresinden edinilmiştir.
- Salakhutdinov, R., & Hinton, G. (2009). Deep Boltzmann Machines. In *Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS)* (3–11).
- Samuel A.L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*. 3(3):210-29.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*. 61: 85–117. doi:10.1016/j.neunet.2014.09.003.
- Shaheen, M.Y. (2021). Applications of Artificial Intelligence (AI) in healthcare: A review. *ScienceOpen Preprints*. doi: 10.14293/S2199-1006.1.SOR-PPVRY8K.v1.
- Shannon, C.E. (1948). A Mathematical Theory of Communication. *The Bell System Technical Journal*, Vol:27, 379-423. doi.org/10.1002/j.1538-7305.1948.tb01338.x.
- Simpson, P.K. (1989). *Artificial neural networks*. Pergamon Press, New York.
- Sleeman, D., & Brown, J. S. (1982). *Intelligent tutoring systems*. Academic Press.
- Smolensky, P. (1986). Information processing in dynamical systems: Foundations of harmony theory. In D. E. Rumelhart, J. L. McClelland, & PDP Research Group (Eds.), *Parallel distributed processing: Explorations in the microstructure of cognition*. Volume 1: Foundations (194–281). Cambridge, MA: MIT Press.
- Song, H. A., & Lee, S.-Y. (2013). Hierarchical representation using NMF. In *International Conference on Neural Information Processing* (466–473). doi: 10.1007/978-3-642-42054-2_58.
- Srivastava, R. K., Greff, K., & Schmidhuber, J. (2015). Training very deep networks. In *Proceedings of the 28th International Conference on Neural Information Processing Systems (NIPS'15)*, Vol. 2 (2377–2385).
- Su, F., Yuan, P., Wang, Y., & Zhangcorresponding, C. (2016). *The superior fault tolerance of artificial neural network training with a fault/noise injection-based genetic algorithm*. *Protein Cell*. 2016 Oct; 7(10), 735–748. doi:10.1007/s13238-016-0302-5.
- Sümer, S. Y. (2021). Ceza Yargılamasının Geleceği: Robot Hâkim. *Dokuz Eylül Üniversitesi Hukuk Fakültesi Dergisi*, (23), 1543-1591. doi.org/10.33717/deuhfd.998255.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2nd ed.). MIT Press.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2014). Going deeper with convolutions. arXiv preprint arXiv:1409.4842.
- Taher, K. A., Jisan, B. M. Y., & Rahman, M. M. (2019). Network intrusion detection using supervised machine learning technique with feature selection. *International Conference on Robotics*, DOI: 10.1109/ICREST.2019.8644161.
- Tan, P.-N., Steinbach, M., Karpatne, A., & Kumar, V. (2013). *Introduction to data mining* (2nd ed.). Addison-Wesley.
- Taylor, G. W., Hinton, G. E., & Roweis, S. T. (2006). Modeling human motion using binary latent variables. In *Advances in Neural Information Processing Systems 19*. MIT Press. (1345–1352).
- Tebelkis, J. (1995). *Speech Recognition using Neural Networks*, Thesis (PhD), School of Computer Science Carnegie Mellon University, Pennsylvania.
- Themarkup (t.y.), (<https://www.ebrevia.com/#homepage>, Erişim Tarihi: 12.03.2024).
- Thintech STM (2019). *İleri Sağlık Teknolojileri I: Akıllı Sağlık Uygulamaları ve Veri Analizi İle Sağlık Sorunlarını Tanımlamak*, (<https://thinktech.stm.com.tr/tr/ileri-saglik-teknolojileri-i-akilli-saglik-uygulamaları-ve-veri-analizi-ile-saglik-sorunlarını-tanımlamak> Erişim Tarihi: 29.09.2024).
- Tjandra, S., Alexandra, A., & Warsito, P. (2015). Determining citizen complaints to the appropriate government departments using KNN algorithm. *Proceedings of the International Conference on Information Technology and Electrical Engineering (ICITEE)*, 2–5.
- Total Military Insight. (2023). *Enhancing Security: The Role of AI for Threat Detection*. (www.totalmilitaryinsight.com, Erişim Tarihi: 29.08.2024).
- Turing, A. M. (1950). *Computing machinery and intelligence*. *Mind*, 59 (236), 433-460. doi.org/10.1093/mind/LIX.236.433.
- Türkel, S. ve Yeşilkuş, F. (2020). Dijital Dönüşüm Paradigması: Endüstri 4.0. *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi (ASEAD) Eurasian Journal of Researches in Social and Economics (EJRSE)*, 7(5), 332-346.
- Unsupervised Learning: Algorithms and Examples, (2021), (<https://www.altexsoft.com/blog/unsupervised-machine-learning/> Erişim Tarihi: 25.11.2024).
- Usama, M., Qadir, J., Raza, A., Arif, H., Yau, K.-L. A., Elkhatib, Y., Hussain, A., & Al-Fuqaha, A. (2019). Unsupervised machine learning for networking: Techniques, applications, and research challenges. *IEEE Access*, 7, 65579–65615. doi.org/10.1109/ACCESS.2019.2916648.
- Vapnik, V. (1995). *The nature of statistical learning theory*. Springer-Verlag.
- Wang, W., Zhao, M., & Wang, J. (2018). Effective android malware detection with a hybrid model based on deep autoencoder and convolutional neural network. *Journal of Ambient Intelligence and Humanized Computing*. doi.org/10.1007/s12652-018-0803-6.
- Wang, Y., & Yan, G. (2021). *Survey on the application of deep learning in algorithmic trading*. *Data Science and Financial Economics*, 1(2), 345-361. doi.org/10.3934/DSFE.2021019.
- Webb, G. I. (2017). Naïve Bayes. In C. Sammut & G. I. Webb (Eds.), *Encyclopedia of Machine Learning and Data Mining*. Springer.
- Weston, J., Ratle, F., Mobahi, H., & Collobert, R. (2012). Deep learning via semi-supervised embedding. In *Neural networks: Tricks of the trade* (639–655). Springer.
- Woolf, B. P. (2009). *Building intelligent interactive tutors: Student-centered strategies for revolutionizing e-learning*. Morgan Kaufmann.
- Yeh, R. A., Chen, C., Lim, T.-Y., Schwing, A. G., Hasegawa-Johnson, M., & Do, M. N. (2017). Semantic image inpainting with deep generative models. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (2), 4). doi.org/10.1109/CVPR.2017.4.

- Yingqiu, L., Wei, L., & Yunchun, L. (2007). Network traffic classification using K-means clustering. *In Proceedings of the 2nd International Multi-Symposium on Computer and Computational Sciences (IMSCCS)* (pp. 360–365).
- Young, L. (2023). Companies Are Slow to Adopt Robot-Operated ‘Dark’ Warehouses, *Wall Street Journal*, <https://www.wsj.com/articles/companies-are-slow-to-adopt-robot-operated-dark-warehouses46e1c887>.
- Yurtođlu, H. (2005). *Yapay sinir ađları metodolojisi ile öngörü modellemesi: bazı makroekonomik deđişkenler için Türkiye örneđi*. DPT Uzmanlık Tezi, Ankara.
- Zawacki-Richter, O., Marinsky, A., & Wiatrowski, M. (2019). Systematic review of research on artificial intelligence in higher education: Trends, challenges, and future directions. *International Journal of Educational Technology in Higher Education*, 16(1), 1-20.
- Zell, A. (1994). *Simulation of Neural Networks*. 1st ed. Addison-Wesley. ISBN 3-89319-554-8.
- Zeng, K., Yu, J., Wang, R., Li, C., & Tao, D. (2017). Coupled deep autoencoder for single image super-resolution. *IEEE Transactions on Cybernetics*, 47(1), 27–37. doi.org/10.1109/TCYB.2016.2523960.

