

Eğitimde Dijital Dönüşüm: Makine Öğrenmesi

Şeyma Erbay Mermer¹

Özet

Eğitim sistemi dahil olmak üzere birçok alanda köklü değişikliklere yol açan önemli bir teknolojik gelişme olan makine öğrenmesi, yapay zeka alanının önemli bir alt dalıdır ve bilgisayarların verilere dayalı olarak öğrenme yeteneği kazanmasını sağlar. Makineler tüm işlemleri kodlar aracılığıyla algoritmalar üzerinden gerçekleştirirler. Kodlar ve algoritmalar, büyük veri kümelerini analiz ederek örüntüyü tanıır ve bu örüntüyü kullanarak tahminlerde bulunur. Bu teknoloji, öğrencilere bireyselleştirilmiş öğrenme fırsatları sunma, öğretmenlere öğrenci ilerlemesini izleme, öğrencilerin güçlü ve zayıf yönlerini belirleme ve daha iyi öğretme stratejileri ve materyalleri geliştirme konularında büyük bir potansiyele sahiptir. Ayrıca, otomatik değerlendirme ve geri bildirim verme yetenekleri, öğrencilerin hızla ilerlemelerini destekler ve öğretmenlere öğrencileri daha iyi anlama ve gerektiğinde yardımcı olma konusunda rehberlik eder. Makine öğrenmesi eğitim alanında büyük bir potansiyele sahip olsa da, etik ve güvenlik konularına odaklanmak oldukça önemlidir. Bu bölüm, makine öğrenmesinin eğitim alanında sağladığı ve gelecekte sunabileceği olası katkılara odaklanmayı amaçlamaktadır. Bunun için öncelikle, “Makine öğrenmesi nedir?”, “Makine öğrenmesinin işleyişi nasıldır?”, “Makine öğrenmesinin eğitim alanındaki uygulamaları nelerdir” gibi sorular ile konunun terminolojik boyutu tartışılacaktır. Devam eden bölümlerde ise makine öğrenmesinin avantajları ve dezavantajlarının neler olduğuna dair bir analiz yapılacaktır. Bu bölümün, makine öğrenmesinin eğitim bilimleri alanına genel bir çerçeve sunması ve ayrıca eğitim-öğretim süreçlerinde kullanım alanlarını ortaya koymasıyla alana katkı sağlayacağı düşünülmektedir.

1. Giriş

Eğitim, insanlığın bilgiye erişme ve bilgiyi aktarma şeklini temelden değiştiren evrimsel bir süreçtir. Son yıllarda, teknolojiye meydana gelen

1 Öğr. Gör. Dr., Bilecik Şeyh Edebalı Üniversitesi, seyma.erbay@bilecik.edu.tr, 0000-0002-7747-9545

hızlı gelişim, eğitim alanında da köklü değişikliklere yol açmış, öğrenme süreçleri artık geleneksel sınıf ortamlarının sınırlarını aşmış, dijital dünyanın derinliklerine doğru genişlemiştir (Atabay, Güllüoğlu ve Şimşek, 2023). Bu gelişimin merkezinde, yapay zeka ve onun alt dalı olan makine öğrenmesi yer almaktadır.

Her bireyin zihinsel işlem kapasitesi birbirinden farklı olduğu için öğrenme bireyseldir ve öğrenciler aynı konuda birbirinden farklı öğrenmeler yaşarlar (Temizkan, 2010). Yapay zeka ve makine öğrenmesi, öğrencilerin bireysel öğrenme ihtiyaçlarını daha erişilebilir ve kişiselleştirilebilir hale getirmiştir. Öğrenciler, dünyanın herhangi bir yerinden çevrimiçi kurslara erişebilir ve kendi hızlarında öğrenebilir imkanına sahiptir (Turhan, 2002). Eğitim materyalleri artık sadece basılı kitaplardan ibaret değil; zengin dijital içerikler, interaktif öğrenme platformları ve sanal sınıf ortamları öğrencilere daha etkili öğrenme deneyimleri sunmaktadır. Makine öğrenmesi, bu yeni eğitim paradigmasını desteklemekte önemli bir rol oynamakta, bu sayede eğitim daha etkili ve verimli hale gelmektedir. Tüm bu gelişmelere bakıldığında makine öğrenmesinin eğitimde büyük potansiyeli olduğu görülmekte, ancak her sorunun tek bir çözümü olmadığı da kabul edilmesi gerekmektedir. Bu bölüm ile, makine öğrenmesinin eğitime yaptığı ve yapabileceği katkıyı bir denge içerisinde sunulacaktır. Bunun için öncelikle, “Makine öğrenmesi nedir?”, “Makine öğrenmesinin eğitim alanındaki uygulamaları nelerdir” gibi sorular ile konunun terminolojik boyutu tartışılacaktır. Devam eden bölümlerde ise makine öğrenmesinin avantajları ve dezavantajlarının neler olduğuna dair bir analiz yapılacaktır.

2. Makine Öğrenmesi

Makine öğrenmesi, karmaşık örüntüyü algılayarak veriye dayalı karar verebilme özellikleriyle ele alınan problemin çözümünü kendi kendine öğrenebilen bilgisayar algoritmalarının genel adıdır (Gültepe, 2019). Bu algoritmalar, büyük miktarda veriyi işleyerek örüntü ve ilişkiler keşfetme yetenekleri sayesinde öğrenme süreçlerini geliştirme potansiyeli taşırlar.

Makine öğrenmesi, insanların öğrenme şekillerini taklit etmek için veri ve algoritmaların kullanımını sağlayan ve doğruluğunu kademeli olarak artıran bir yapay zekâ (AI) ve bilgisayar bilimi dalıdır (IBM SPSS, 2021). Yapay zeka; “insan gibi düşünen, insan gibi davranan, akılcı (rasyonel) düşünen ve akılcı davranan” (Balaban ve Kartal, 2015: 16), canlıların zekice kabul edilebilecek davranışlarına sahip bilgisayar sistemleridir ve makine öğrenmesi bu anlamda yapay zekanın son evresi olarak kabul edilmektedir (Atalay ve Çelik, 2017). Yapay zeka, insan zekasının bir bilgisayar programı

tarafından simülasyonunu ifade ederken makine öğrenmesi, bir bilgisayar programının yeni bilgileri, kalıpları ve eğilimleri bulan algoritmaların sürekli geliştirilmesini içerir (Nykon, 2023). Makine öğrenmesi veri biliminde oldukça önemli bir yere sahiptir ve istatistiksel yöntemler kullanılarak, algoritmalar; sınıflama ve tahminler yapmak üzere eğitilir ve optik karakter algılama, e-posta filtrelemesi, yüz tanıma, konuşma dili anlama, tıbbî teşhis, sahtekârlık tespiti ve hava durumu tahmini gibi birçok farklı problemin çözümünde kullanılmaktadır (Schapire, 2008). Makine öğrenmesinin en iyi bilinen örnekleri arasında Google Asistan, Facebook, Alexa ve Siri tarafından kullanılan yüz ve ses tanıma yer alır (Nykon, 2023). Makine öğrenmesinin sunduğu bu olanaklar giderek artacak, gelecekte daha fazla yenilik ve uygulama fırsatları sunacaktır.

2.1. Makine Öğrenmesinin Tarihçesi

Makine öğrenmesi, tarih boyunca çeşitli dönemlerde gelişen bilimsel ve teknolojik ilerlemelere dayanmaktadır. İlk temeller, 1940'lı yıllarda geliştirilen dijital bilgisayarlarla atıldı. Walter Pitts ve Warren McCulloch tarafından hazırlanan “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap (A Logical Calculus of Ideas Immanent in Nervous Activity)” isimli çalışma, insanın düşünsel sürecini taklit etmeyi amaçlayan matematiksel algoritmaları sunmuştur (Akbiğiç, 2011). İngiliz matematikçi Alan Turing matematiğe ve bilime olan katkıları da, makine öğrenmesinin temelini oluşturan kavramların geliştirilmesi sağlamıştır (Arslan, 2017).

1950'ler ve 1960'lar, makine öğrenmesinin kuramsal temellerinin atıldığı dönemlerdi. Arthur Samuel 1952'de makine öğrenimi icat etmiş ve “makine öğrenimi” ifadesini ilk defa kullanmıştır (İnal, 2021). Bu dönemin önemli olaylarından biri de, Arthur Samuel'in “oyun oynayan” bir programı eğitime çabasıydı (Çömlekçi, 2020). Bu, bilgisayarların oyunlarda insanlara karşı rekabet edebileceğini gösteren ilk adımdı. Ayrıca bu dönemde, örüntü tanıma ve sınıflandırma problemleriyle ilgili çalışmalar da başlamıştır.

1970'lerde Japonya'da makine öğrenmesi üzerine yapılan çalışmaların ardından ilk insansı robot olan Wabot-1 üretilmiştir (İnal, 2021). 1980'lerde istatistiksel yöntemlerin ve veri madenciliğinin gelişimi, makine öğrenmesinin temelini güçlendirmiş, uzman sistemler ve karar destek sistemleri gibi yapay zeka uygulamaları da popüler olmuştur (Foote, 2021).

1980'lerden itibaren hız kazanmaya başlayan makine öğrenmesi alanı, 1990'larda veriye dayalı yaklaşıma odaklanmıştır. Bu tarihlere gerçekleşen en heyecan verici olay ise 1997 yılında gerçekleşmiş, IBM'in geliştirdiği ‘Deep


Blue' isimli oyun programı, Satranç Dünya Şampiyonu Garry Kasparov'ü yenerek dikkatleri çekmeyi başarmıştır (Campbell, Hoane & Hsu, 2002).

1990'lar ve 2000'ler, makine öğrenmesinin büyük bir ivme kazandığı dönemlerdir. Büyük veri kavramının ortaya çıkması, daha fazla veriye erişim sağlamış, bu da makine öğrenmesi algoritmalarının daha etkili hale gelmesine yardımcı olmuştur (Foote, 2021). Ayrıca, bu dönemde destek vektör makineleri, rastgele ormanlar ve derin öğrenme gibi önemli makine öğrenmesi teknikleri geliştirilmiştir.

2010'larda işlem gücünü arttıran donanımların geliştirilmesi, veri akışının çok büyümesi ve derin öğrenme modellerinin geliştirilmesiyle büyük değişimler kaydedilmiştir. Son yıllarda ise, derin öğrenme ve sinir ağı tabanlı yaklaşımlar, özellikle görüntü ve metin tanıma gibi alanlarda büyük başarılar elde etmiş, endüstride, sağlık sektöründe, otomasyonda, eğitimde ve daha birçok alanda büyük etkiler yaratmıştır (Koch, 2022).

2.2. Makine Öğrenmesi Algoritmalarının İşleyişi

Öğretmen-öğrenci ilişkisinde olduğu gibi makine öğrenmesinde de görevin yerine getirilebilmesi için gereken bilgiye sahip olan eğitmen (teacher) ve verilen görevin yerine getirilebilmesi için bilgiyi öğrenen (learner) vardır (Camastra ve Vinciarelli, 2008).



Şekil 1. Makine öğrenmesinin işleyişi (Yazan, 2023)

Makine öğrenmesinde temel olan, veri setine uygun model seçimidir. Uygun model oluşturmadaki temel amaç, verinin dağılımı ve verinin büyüklüğü gibi etkenler ile doğru sonuç üretmeye çalışmaktır. Bu süreçte karşılaşılan en büyük problemlerden biri karar sınıfına ait veri setinin dengeli dağılıma sahip olmamasıdır (Alan ve Karabatak, 2020). Makine öğrenmesinde veriler, eğitim verileri (train) ve test verileri olmak üzere iki alt kümeye ayrılır. Eğitim verisi (Training Set), modelin eğitilmesinde kullanmak için rastgele seçilen durumlardır. Test verisi (Testing Set) ise, modelin tahmin edilebilirliğinin belirlemek için kullanılan durumlardır. Eğitim veri setinin

gerçek dünyayı kapsayıcılığı ne kadar yüksek ise, geliştirilen modelin test verisinin gerçek kategorisini tespit etme durumu da o kadar artmaktadır.

Makine öğrenmesinde model, eğitim verilerinden elde edilen örüntülere göre oluşturulur. Bu işlem sonucunda modelin aşırı öğrenmesi ya da eksik öğrenmesi gibi iki sorunla karşılaşılabilir. Bu durumda model yeterli öngörüde bulunamayacak ve tahminlerde hata oranı yüksek olacaktır (Jabbar & Khan, 2014). Aşırı öğrenme (Overfitting), modelin eğitim veri seti üzerinde ezber yapıp test veri setinde bu örüntüye ulaşmaya çalışma durumudur. Bu modellerin yeni ve daha önceden karşılaşılmamış gözlemlerde başarılı bir tahmin yapma olasılığı çok düşüktür (Arlot & Celisse, 2010). Eksik öğrenme (Underfitting), Modelin eğitim setindeki örüntüyü yeterli öğrenememesinden kaynaklanmaktadır. Eksik öğrenme sorunu olan modellerde hem eğitim hem de test veri setinde hata oranı oldukça yüksektir (Zhang, Zhang & Jiang, 2019).

Makine öğrenmesi süreci problemin tespiti, verinin toplanması, verinin düzenlenmesi, programlama dilinin seçimi, modelin inşası, eğitim aşaması ve test aşaması olarak gerçekleşmektedir. Makine öğrenme temel olarak programlama dilinin seçimi ile başlar. Python, Javascript, R ve C++ programlama dilleri sıklıkla tercih edilir (Hillier, 2023). Bu diller, veri işleme, analiz ve model oluşturma için gelişmiş kütüphanelere sahiptir. Problem belirlendikten ve veriler toplandıktan sonra, uygun model seçimine geçilir. Bu, regresyon, sınıflandırma, derin öğrenme veya başka bir teknik olabilir. Doğru modelin seçimi, problemi etkili bir şekilde çözebilenin en önemli anahtarıdır (Weedmark, 2021). Model seçildikten sonra, eğitim süreci başlar. Bu aşamada, model, veriye dayalı olarak belirli bir örüntüyü öğrenmeye başlar. Öğrenme, veriler üzerinde tekrarlanan işlemlerle gerçekleşir ve modeli iyileştirir. Model eğitildikten sonra, modelin performansını değerlendirmek için gerçek verilerle test edilir. Modelin doğruluğu, hassasiyeti ve diğer performans metrikleri bu aşamada değerlendirilir. Eğer model başarılı bir şekilde çalışıyorsa, gerçek uygulamaya geçilebilir.

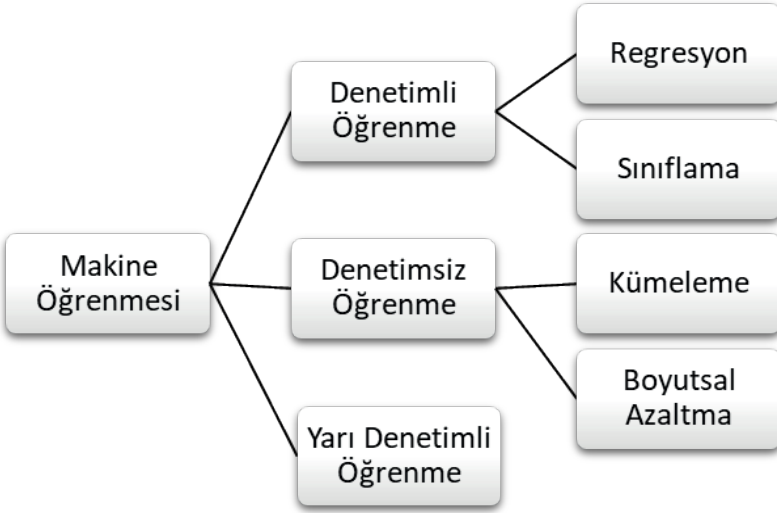
Şekil 1'de makine öğrenmesindeki işleyiş sürecini genel hatlarıyla anlatmaktadır. Makineler gerçekleştirdikleri tüm işlemleri kodlar aracılığıyla algoritmalar üzerinden gerçekleştirirler. Makine öğrenmesi algoritmaları, çeşitli kaynaklardan gelen verileri birleştirip, büyük miktarda veriyi yönetebilme kabiliyeti sayesinde tahmin gücünü arttırmaktadır (Özlüer Başer, Yangın ve Sarıdaş, 2021). Öğrenmeyi gerçekleştirecek eğitim verileri büyüdükçe, algoritma daha gerçekçi sonuçlarla tahminler yapar. Makine öğrenmesinde genel olarak Denetimli, Denetimsiz ve Destekleyici olmak üzere 3 algoritma çeşidi vardır (Brownlee, 2016).

2.2.1. Algoritma Çeşitleri

2.2.1.1. Denetimli Öğrenme: Her bir verinin hangi sınıfa ait olduğu bilindiği durumlarda kullanılan algoritma çeşididir. Temel amaç sonuçları bilinen veri setinden yapılan sınıflandırmadan, sonuçları bilinmeyen veri setiyle ilgili tahminler yapabilmektir (Aydın ve Özkul, 2015). Denetimli öğrenme; sınıflama ve regresyon olarak iki gruba ayrılır (Brownlee, 2016). Sınıflandırmada çıktılar kategorik durumda iken, regresyonda ise çıktı değeri reel bir sayıdır.

2.2.1.2. Denetimsiz Öğrenme: Sadece girdi verilerinin bilindiği çıktı verilerinin bilinmediği durumlarda kullanılan algoritma çeşididir. Bu algoritmadaki temel amaç, verinin altında yatan yapının ve dağılımının modellenmesidir. Sistem otomatik olarak keşifler yapar, ilişki ağını ortaya koymaya çalışır (Alpaydın, 2010).

2.2.1.3. Yarı Denetimli Öğrenme: Girdi verileriyle çıktı verilerinin sadece bir kısmının etiketinin bilindiği öğrenme algoritmasıdır. Denetimli ve denetimsiz öğrenmenin her ikisini de kapsamaktadır (Kızılkaya ve Oğuzlar, 2018).



Şekil 2. Makine öğrenmesi algoritmaları hiyerarşisi

Yukarıda makine öğrenmesi algoritmalarının stiline göre hiyerarşisi gösterilmektedir. Makine öğrenmesinde veri analizleri için girdi yapısının inceleneceği durumlarda Denetimsiz Öğrenme, verilerle ilgili tahmin yapılacağı durumlarda ise Denetimli Öğrenme algoritmalarının kullanılması

daha doğru olacaktır (Brownlee, 2016). Destekleyici öğrenme ise girdi değerlerine karşılık gelecek en uygun çıktı edilmesi sırasında katsayıların en uygun değerlerinin bulunması ile sağlanır (Ülker ve Civalek, 2002). Makine öğrenmesi algoritmaları temel olarak olayları sınıflandırmak, örnekler bulmak, sonuçları tahmin etmek ve bilinçli kararlar vermek için tasarlanmıştır. Algoritmalar karmaşık ve daha öngörülemeyen veriler söz konusu olduğunda mümkün olan en iyi doğruluğu elde etmek için tek seferde bir veya bir arada kullanılabilir.

Makine öğrenmesinde kullanılacak çok fazla algoritma vardır ve veriyi işleyebilecek en uygun algoritmayı seçmek önemlidir. Bu sebeple algoritmaları kullanım amaçları açısından gruplandırmak yol gösterici olacaktır.

Tablo 1. Makine öğrenmesi algoritmaları (machinelearningmastery, 2020)

Algoritma	Algoritma Çeşitleri	Kullanım Amacı
Regresyon Algoritmaları	Sıradan En Küçük Kareler Regresyonu (OLSR) Doğrusal Regresyon (Goodfellow vd., 2016) Lojistik regresyon (Goodfellow vd., 2016) Kademeli Regresyon Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS) Yerel Tahmini Dağılım Çizgisi Pürüzsüzleştirme (LOESS)	Model tarafından yapılan tahminlerde bir hata ölçüsü kullanılarak yinelemeli olarak rafine edilmiş değişkenler arasındaki ilişkinin modellenmesi ile ilgilidir (Jason, 2013).
Örnek Tabanlı Algoritmalar	K - En Yakın Komşu (kNN) (Ansari vd., 2018) Vektör Ölçümü Öğrenmesi (LVQ) Kendi Kendini Düzenleyen Harita (SOM) Yerel Ağırlıklı Öğrenme (LWL)	Tipik olarak örnek veri tabanı oluşturur ve en iyi eşleşmeyi bulmak ve bir tahmin yapmak için benzerlik ölçüsü kullanarak yeni verileri veri tabanı ile karşılaştırır (Jason, 2013).
Düzenleme Algoritmaları	Ridge Regresyonu En Küçük Mutlak Çekme ve Seçme Operatörü (LASSO) Elastik Ağ En Küçük Açık Regresyonu (LARS)	Karmaşık modellerin genellemesinde öğrenmeye basit modelleri tercih ederek devam eder.

Karar Ağacı Algoritmaları	Sınıflandırma ve Regresyon Ağacı (CART) Tekrarlı İkिलikçi Ağacı (ID3) C4.5 ve C5.0 Ki-kare Otomatik Etkileşim Tespiti (CHAID) Karar Kökü M5 Koşullu Karar Ağaçları	Büyük veri setlerini daha küçük sınıflara ayırmak için kullanılan ve veri setinde çok nadir görülen sınıfların tahmininde daha iyi sonuçlar veren bir yapıya sahiptir (Luckert & Schaefer-Kehnert, 2015).
Bayes Algoritmaları	Naive Bayes Gauss Saf Bayes Çok terimli Naif Bayes Ortalamalı Tek Bağımlılık Tahmincileri (AODE) Bayes İnanç Ağı (BBN) Bayes Ağı (BN)	Belirli bir özellik kapsamına dayanarak verinin ait olduğu sınıfın tahmin edilmesini sağlar.
Kümeleme Algoritmaları	K- Ortalama K- Medyanlar Beklenti Maksimizasyonu (EM) Hiyerarşik Kümeleme	Verileri en iyi ortaklığa sahip gruplar halinde en iyi şekilde düzenlemek için verilerdeki doğal yapıların kullanılmasıyla ilgilidir (Jason, 2013; Wu vd., 2008).
İlişkilendirme Kuralı Öğrenmesi Algoritmaları	Apriori algoritması Eclat algoritması	İlişkilendirme kuralı öğrenme yöntemleri, verilerdeki değişkenler arasındaki gözlenen ilişkileri en iyi açıklayan kuralları gösterir (Jason, 2013).
Yapay Sinir Ağı Algoritmaları	Perceptron Geri Yayılım Hopfield Ağı Radyal Temel Fonksiyon Ağı (RBFN) (Sobie vd., 2018)	Her türlü problem tipi için yüzlerce algoritma ve varyasyondan oluşan muazzam bir alt alandır (Jason, 2013).
Derin Öğrenme Algoritmaları	Derin Boltzmann Makinesi (Zhao vd., 2019) Derin İnanç Ağları (DBN) (Zhao vd., 2019) Dönüşümlü Sinir Ağı (CNN) Yığılmış Otomatik Kodlayıcılar	Çok daha büyük ve daha karmaşık sinir ağları oluşturmakla ilgilidir.

Boyut İndirgeme Algoritmaları	Temel Bileşen Analizi (PCA) Temel Bileşen Regresyonu (PCR) Kısmi En Küçük Kareler Regresyonu (PLSR) Sammon Haritalama Çok Boyutlu Ölçeklendirme (YTH) Projeksiyon Takip Lineer Ayırt Edici Analiz (LDA) Karışım Ayırma Analizi (MDA) Karesel Ayırt Edici Analiz (QDA) Esnek Ayırt Edici Analiz (FDA) t-Dağılımlı Stokastik Komşu Yerleştirme(t-SNE)	Boyutsallığın azaltılmasında verilerdeki doğal yapıyı araştırır ancak bu durumda denetimsiz bir şekilde veya sırayla daha az bilgi kullanarak verileri özetlemek veya açıklamak için kullanır (Jason, 2013).
Topluluk Algoritmaları	Yükseltme Bootstrapped Toplama (Torbalama) AdaBoost Yığılmış Genelleme (harmanlama) Gradyan Artırma Makinaları (GBM) Gradyan Arttırılmış Regresyon Ağaçları (GBRT) Rastgele Orman (Sobie vd., 2018)	Bağımsız bir şekilde eğitilmiş ve öngörülere bir şekilde genel tahminde bulunmak için bir araya getirilmiş olan daha zayıf modellerden oluşan modellerdir (Jason, 2013).
Diğer Algoritmalar	Özellik seçim algoritmaları Algoritma doğruluk değerlendirme Performans ölçüleri Optimizasyon algoritmaları Hesaplamalı zeka (evrimsel algoritmalar, vb.) Bilgisayarla Görme (CV) Doğal Dil İşleme (NLP) Tavsiye Sistemleri Destekleyici Öğrenme Grafik Modeller	Gerek konu genişliği gerekse bilim dünyasında bu algoritmaların sınıflandırılmasında henüz tam anlamı ile fikir birliğine varılmamış olması bu konuda çalışmaya yapmayı güçleştirmektedir.

Yukarıdaki tabloda işlevlerine göre algoritmalar yer almaktadır. Bu algoritmalar, veri bilimi ve makine öğrenimi uygulamalarında geniş bir yelpazede kullanılır ve problemin türüne, veri setine ve amaçlarına göre seçilirler. Ayrıca, bu algoritmaların birçoğu çeşitli varyasyonlara sahiptir ve belirli bir görevi daha iyi ele almak için uyarlanabilirler. En yaygın makine öğrenmesi algoritmaları k-en yakın komşu, Bayes sınıflandırıcısı, karar ağaçları, lojistik regresyon, destek vektör makineleri ve yapay

sinir ağlarıdır (Tosunoğlu, Yılmaz, Özeren ve Sağlam, 2021). Makine öğrenimi algoritmaları, işlevlerine göre farklı alanlarda yaygın bir şekilde kullanılır. Hastalık teşhisi, kanser sınıflandırması, ilaç etkisi tahminleri gibi sağlık uygulamalarında (Karakoyun ve Hacıbeyoğlu, 2014), kredi riski değerlendirmesi, sahtekarlık tespiti, hisse senedi fiyat tahminleri gibi finansal analizlerde, tehdit tespiti, kimlik doğrulama ve güvenlik olaylarının izlenmesi için sınıflandırma algoritmaları sıklıkla kullanılmaktadır (Sarker, 2021). Piyasa trend tahminleri, mal fiyatları, ekonomik büyüme tahminleri gibi finansal analizlerde, hava kalitesi tahminleri, su kirliliği analizleri gibi çevresel veri analizlerinde, ürün verimliliği, ekipman bakımı ve verimliliği gibi endüstriyel süreçlerin yönetiminde regresyon algoritmaları kullanılmaktadır (Smolic, 2022). İş süreçleri optimizasyonu ve karar verme sistemlerinde, pazarlama, müşteri segmentasyonu ve kampanya optimizasyonu gibi alanlarda karar ağaçları algoritmalarından yararlanır (Chien & Chen, 2008). Spam filtreleme ve e-posta sınıflandırmada (Rusland, Wahid, Kasim & Hafit, 2017), hastalık risk tahminleri gibi sağlık alanlarında (Parthiban, Srivatsa & Rajesh, (2011) bayes algoritmaları tercih edilmektedir. Perakende alanında ürünler arasındaki ilişkilerin analizinde, market sepet analizi ve ürün önerilerinde birliktelik kuralı öğrenmesi algoritmaları kullanılmaktadır (Han, Pei & Kamber, 2011). Görüntü işleme ve tanıma, ses işleme, konuşma tanıma ve otomatik sürüş teknolojileri alanlarında yapay sinir ağ algoritmaları tercih edilmektedir (Luo vd., 2014). Otomatik dil çevirisi, duygu analizi ve duygu tanıma, nesne algılama alanlarında derin öğrenme algoritmaları kullanılır (Polat, 2021). Yüz tanıma, konuşma sinyali işleme ve veri madenciliği alanlarında boyutsallık azaltma uygulamaları kullanılırken (Yıldız ve Sevim, 2020), saldırı tespiti, antivirüsler, web filtreleme çözümleri ve güçlü tanılama alanlarında topluluk algoritmalarından yararlanır (Kuş, Keser, Yolaçan, 2021).

Yapay zeka, her alanda olduğu gibi makine öğrenmesine eğitim alanında da büyük bir katkı sağlamaktadır. Özellikle öğrenme analitiği, öğrenci performansının tahmini ve özelleştirilmiş öğrenme deneyimleri gibi alanlarda makine öğrenme tekniklerinin uygulanmasını mümkün kılmıştır (Yadav & Desmukh, 2023). Öğrencilerin bireysel ihtiyaçlarına daha iyi uyum sağlayan, öğretmenlere öğrenci verileri üzerinden daha etkili geri bildirimler sunan ve öğrenme süreçlerini optimize eden makine öğrenme modelleri, eğitimde daha verimli ve etkili bir yaklaşımın kapılarını açmıştır. İnsan öğrenmesine benzer şekilde yönlendirilen bu modeller, öğrencilere uygun içeriği doğru bir şekilde belirleme kapasitesine de sahiptir (Lisetti, Amini & Yasavur, 2015). Ayrıca, tavsiye sistemleri ve öğrenci takibi gibi uygulamalar, öğrencilerin

öğrenme deneyimlerini zenginleştirmek için yapay zeka teknolojileriyle güçlendirilmiştir.

Makine öğrenmesinde yer alan algoritmalar, belirli bir problemi çözmek için eğitilebilir ve sisteme uyarlanabilir. Bu nedenle, makine öğrenme algoritmalarını kullanmadan önce, problemin analiz edilmesi ve algoritmanın mevcut probleme uygun olup olmadığının belirlenmesi büyük önem teşkil etmektedir.

3. Eğitimde Kullanılan Makine Öğrenme Algoritmaları

3.1. Denetimli Öğrenme Algoritmaları

Eğitimde denetimli makine öğrenme algoritmaları, öğrenci başarısını tahmin etmek, öğrenme materyallerini kişiselleştirmek ve öğrenci davranışlarını analiz etmek vb. için kullanılır. Bu algoritmalarından Doğrusal Regresyon, öğrencilerin sınav başarıları gibi sürekli bir çıktı değişkenini tahmin etmek için kullanılır (Srivani & Bala, 2020). Lojistik Regresyon ise, sınıflandırma problemlerinde yaygın olarak kullanılmaktadır (Raj, 2020). Örneğin, bir öğrencinin belirli bir dersi geçip geçmeyeceğini tahmin etmek için lojistik regresyona başvurulur. Karar Ağaçları (Decision Trees), öğrenci performansını değerlendirmek ve öğrencilerin belirli sonuçlara nasıl ulaştığını anlamak için kullanılmaktadır (Hamsa, Indiradevi & Kizhakkethottam, 2016). Rastgele Ormanlar (Random Forests), birden fazla karar ağacının bir araya gelerek daha güçlü bir tahmin modeli oluşturduğu bir yöntemdir (Kumar, 2020). Öğrenci performansı tahmini ve özelleştirilmiş öğrenme materyali önerileri için kullanılır. Destek Vektör Makineleri (Support Vector Machines), sınıflandırma ve öğrencinin performans tahmininde kullanılabilir (Jahan & Ghosh, 2021). Naif Bayes Sınıflandırıcıları, özellikle metin madenciliği uygulamalarında kullanılır (Aydemir, Işık ve Tuncer, 2021). Öğrenci özgeçmişlerini analiz etmek veya metin tabanlı sınıflandırma yapmak için kullanılabilir. K-En Yakın Komşu (K-Nearest Neighbors, K-NN), benzer özelliklere sahip olan öğrencileri sınıflandırma yapmak için kullanılabilir (Alferre & Maghari, 2018). Gradyan Artırma, öğrenci başarısını tahmin etmek ve özelleştirilmiş öğrenme materyalleri oluşturmak için kullanılabilir (Srikanth, Karthikeya & Rao, 2023). Derin Öğrenme (Deep Learning), yapay sinir ağları kullanarak karmaşık veri yapıları üzerinde çalışmak için kullanılır. Özellikle öğrenci performans analizi ve tavsiye sistemleri için kullanışlıdır (Kızrak, 2018). Kullanıcı-Tabanlı ve İçerik-Tabanlı Filtreleme algoritmaları, öğrencilere özel öğrenme materyali önerileri yapmak için kullanılır (Ghauth & Abdullah, 2010).

3.2. Denetimsiz Öğrenme Algoritmaları

Denetimsiz makine öğrenme algoritmaları, eğitimde veri analizi ve öğrenci davranışlarının anlaşılması için kullanılır. Bu algoritmalarından K-Ortalama algoritması, verilerin düzenliliğini belirlemek, öğrenme sorunlarını doğru bir şekilde teşhis etmek ve etkili öğrenci yönetimi stratejileri geliştirmek için temel sağlamak amacıyla bu belgede öğrencilerin kapsamlı değerlendirme verilerini analiz etmek için kullanılır (Liu, 2022). Örneğin öğrencilerin sınav sonuçlarına veya ilgi alanlarına göre sınıflamaları yapılabilir. PCA algoritması öğrencilerin performansını analiz etmek için kullanılabilir (Borges, Esteves, Araujo, Oliveira & Holanda, 2018). Örneğin, öğrencilerin sınav sonuçlarından veya öğrenme etkinliklerinden elde edilen veriler, PCA ile incelenebilir ve öğrencilerin nasıl gelişebileceği veya hangi konuların daha fazla vurgulanması gerektiği hakkında bilgi sunabilir.

3.3. Yarı Denetimli Öğrenme Algoritmaları

Yarı denetimli makine öğrenme algoritmaları, eğitimde öğrenci performansını izlemek, eğitim materyallerini kişiselleştirmek ve öğrencilerin ihtiyaçlarını daha iyi anlamak için kullanışlıdır. Bu algoritmalarından K-Ortalama kümeleme, öğrencilerin benzer öğrenme stillerine sahip gruplara ayrılmasına yardımcı olur (Borgavakar & Shrivastava, 2017). Bu, eğitim materyallerinin belirli gruplara özelleştirilmesine ve öğrencilere daha iyi bir öğrenme deneyimi sunulmasına olanak tanır. Beklenti maksimizasyonu (Expectation Maximization) algoritması, öğrencilerin akademik olarak nasıl bir performans göstereceğini tahmin etmek için kullanılabilir (Govindasamy & Velmurugan, 2017). Bu, öğrenci başarılarını izlemek ve kişiselleştirilmiş öğrenme planları oluşturmak için kullanışlıdır. t-SNE algoritması, çok boyutlu verileri daha düşük boyutlu temsilcilere dönüştürme yeteneğine sahiptir. Eğitimde, öğrenci davranışlarının daha basit ve anlaşılır bir görselleştirmesini oluşturmak için kullanılmak, okulların akademik performansını tahmin etmek ve performansa etki eden farklı özelliklerin etkisini değerlendirmek, risk altındaki öğrencileri belirlemek veya öğrenci popülasyonu içindeki başarı potansiyelini ortaya çıkarmak için kullanılmaktadır (Van Der Maaten, 2014).

4. Eğitimde Makine Öğrenmesi Uygulamaları

Makine öğrenmesi, eğitim alanında büyük bir etki yaratmış, eğitim kurumları ve öğretmenler de, öğrencilerin ihtiyaçlarına daha iyi uyum sağlaması ve öğrenme süreçlerini daha verimli hale getirmesi için bu teknolojiyi benimsemişlerdir. Makine öğrenmesi mevcut algoritmalarıyla, öğrencilerin öğrenme stillerini ve zorlukları analiz etmeye, bu sayede,

özelleştirilmiş öğrenme programları oluşturmaya ve öğrencilere bireysel geri bildirimler sunmaya imkan vermektedir.

Ayrıca, makine öğrenmesi öğrenci performansını izlemek ve öğrencilerin başarılarını tahmin etmek için de kullanılmaktadır. Makine öğrenmesi eğitim yönetimi ve planlamasında da veriye dayalı tahminler yoluyla daha sağlıklı kararlar alınmasına yardımcı olur(Yadav & Deshmukh, 2023). Örneğin, öğrencilerin hangi derslerinde eksikliklerinin olduğunu, öğrencilere hangi programın daha fazla yardımcı olacağını veya öğrenci popülasyonunun nasıl değiştiğini anlamak için makine öğrenmesi algoritmalarından yararlanır. Eğitim kurumlarının öğrenme süreçlerinde sıklıkla başvurulan uygulama örnekleri aşağıda verilmiştir.

Bireyselleştirilmiş Öğrenme Deneyimleri: Makine öğrenmesi, her öğrencinin öğrenme hızı, ilgi alanları ve güçlü yönlerini dikkate alarak özelleştirilmiş öğrenme planları oluşturabilir (Nafea, 2017). Bu süreç öğrenci verilerinin toplanmasıyla başlar ve öğrencinin güçlü yönlerini, zorlandığı konuları ve öğrenme hızını anlamak için kullanılır. Toplanan veriler, makine öğrenme algoritmaları tarafından analiz edilerek öğrenme davranışlarını anlamak ve öğrencinin hangi konularda daha fazla rehberliğe ihtiyaç duyduğunu belirlemek için kullanılır (Krishna Rao, Gowthami, Hema, Sai Ssaketth & Narendra Babu, 2022). Makine öğrenmesi her öğrenci için bir öğrenme profili oluşturur, öğrencinin ihtiyaçlarına göre ders içeriklerini, çalışma kaynaklarını ve ödevleri tasarlar. Örneğin, bir öğrenci matematikte güçlüyken edebiyatta zorluk çekiyorsa, matematikle ilgili daha fazla içerik ve alıştırmalar sunulabilir. Karyuatri ve arkadaşları (2018) çalışmalarında, dijital yazma asistanlarının öğrencilerin yazma kalitelerini artırdığını ortaya koymuştur. Dijital asistanlar, kullanıcılarına yazmış oldukları metnin türünü ve yazılma amacını dahi göz önüne alarak dil bilgisi, imlâ ve noktalama, kelime seçimi gibi farklı yönlerden bütüncül olarak bakma fırsatı sunmakta ve kolayca bu metni gözden geçirip düzeltmelerine olanak tanımaktadır. Dijital asistanlar bireysel öğrenmeyi, bireysel değerlendirmeyi sağlayan materyallerden biri olarak görülebilir (Aktaş, 2022). Bu süreçte öğrenciye rehberlik etme ve bireysel öğrenmeye destek verme yine makine öğrenmesiyle gerçekleştirilebilmektedir.

Öğrenci Performansı Tahmini: Öğrencilerin önceki verileri kullanılarak gelecekteki başarılarını tahmin etmek makine öğrenmesiyle gerçekleştirilebilir. Örneğin, öğrenci notları, sınav sonuçları, katılım düzeyi gibi veriler analiz edilerek, bir öğrencinin belirli bir konuyu ne kadar iyi anlayabileceği tahmin edilebilir. Bu tahminler öğretmenlere öğrencileri daha iyi anlama ve gerektiğinde yardımcı olma konusunda rehberlik eder. Bu süreç öğrenci

verilerinin toplanması ve analiz edilmesi ile başlar. Veriler kullanarak öğrenci performansını tahmin etmek için uygun bir makine öğrenme modeli seçilir. Bu modeller arasında regresyon modelleri, karar ağacı modelleri veya derin öğrenme modelleri gibi birçok seçenek bulunur (Yadav & Desmukh, 2023). Seçilen model, eğitim verileri üzerinde eğitilir ve ayrı bir veri kümesi kullanılarak değerlendirilir. Modelin tahminleri gerçek performans verileriyle karşılaştırılır ve modelin ne kadar iyi performans gösterdiği belirlenir. Bu tahminler, öğrencinin hangi konularda destek veya rehberliğe ihtiyacı olduğu konusunda bilgi sağlayarak öğrencilere ve eğitimcilere yardımcı olur.

Öğrenci İlerlemesinin İzlenmesi: Öğrencilerin ilerlemelerini takip etmek makine öğrenmesi uygulamaları arasında yer almaktadır. Öğrencilere ait verilerinin toplanması ve analiz edilmesi ile öğrencilerin hangi konularda zorlandığı veya neleri daha iyi anladığı makine öğrenmesi modelleriyle belirlenebilir. Bu modeller arasında zaman serisi analizi için kullanılan modeller, regresyon modelleri veya sınıflandırma modelleri gibi birçok seçenek bulunur (Hasan, Rabby, Islam & Hossain, 2019). Seçilen model, eğitim verileri üzerinde eğitilir ve öğrenci ilerlemesi verilerini gerçek zamanlı olarak analiz eder. Öğrencilerin hangi konularda ilerlediği veya zorlandığı hakkında geri bildirim sağlar. Bu dijital asistanlar, öğrenci ilerlemesini izleme, öğrencilere daha iyi rehberlik etme ve daha etkili bir öğrenme deneyimi sunma konusunda velilere, öğrencilere ve eğitimcilere yardımcı olur.

Öğrenci Geri Bildirimi: Öğrencilere öğrenme süreçleri hakkında geri bildirimde bulunmak makine öğrenmesi modelleriyle gerçekleştirilebilir. Öğrencilere hangi konuları daha fazla çalışmalarını gerektiği veya hangi konuları daha iyi anladıkları hakkında tavsiyeler sunarak, onların eksikliklerini gidermelerine yardımcı olur (Lavanya, 2022). Süreç öğrenci geri bildirimini etkileyebilecek özelliklerin belirlenmesi ve verilerinin toplanması ile başlar. Örneğin, bir öğrencinin belirli bir konuda ne kadar zaman harcadığı veya belirli bir testte hangi soruları yanlış cevapladığı gibi özellikler bu aşamada tanımlanır. Verileri kullanarak öğrenci geri bildirimini tahmin etmek için uygun bir makine öğrenme modeli seçilir. Bu modeller arasında sınıflandırma modelleri, regresyon modelleri veya sıralama modelleri gibi birçok seçenek bulunur (Yadav & Desmukh, 2023). Seçilen model eğitilerek öğrenci verilerini gerçek zamanlı olarak analiz eder ve geri bildirimde bulunarak öğrencilere dijital asistanlık yapar. Dijital asistanlar, öğrencilere daha iyi rehberlik sağlamak ve öğrencilerin öğrenme deneyimini iyileştirmek amacıyla kullanılan makine öğrenme tabanlı öğrenci geri bildirim sürecinin temel adımlarını içerir (Krishna Rao, Gowthami, Hema, Sai Ssaketth & Narendra Babu, 2022). Öğrencilere, eksikliklerini anlama ve gelişmelerini sağlama konusunda önemli bir destek sunar.

Öğretim Materyali Geliştirme: Öğrenci performans verileri, öğrencilerin öğrenme süreçleri hakkında önemli bilgiler içerir. Bu veriler, sınav sonuçları, öğrenci etkileşimleri, ödev tamamlama süreleri ve diğer öğrenci faaliyetlerini içerebilir. Makine öğrenme, bu verileri analiz eder ve öğrenci davranışları hakkında tahminlerde bulunur. Sonuçları öğrencilerin güçlü ve zayıf yönlerini, öğrenme stillerini ve gereksinimlerini anlamak için kullanılabilir. Öğrencilerin hangi konularda daha fazla yardıma ihtiyaç duyduğunu ve hangi materyallere daha fazla ilgi gösterdiklerini belirlemek önemlidir (Nafea, 2023). Öğretim materyali geliştirme sürecinde makine öğrenmesi, öğrencilerin öğrenme deneyimlerini daha etkili ve kişiselleştirilmiş hale getirmeye yardım eder. Bu, öğrencilerin daha iyi öğrenmelerine ve öğretmenlerin öğrencilere daha iyi rehberlik etmelerine olanak tanır.

Sınav ve Soru Hazırlama: Sınav sorularını oluşturma ve sınavların zorluk derecelerini belirleme makine öğrenmesi modelleriyle gerçekleştirilebilir. Bu, öğrencilerin daha adil ve ihtiyaca uygun test edilmesine olanak sağlar (Yadav & Desmukh, 2023). Bu süreçte ilk adım, mevcut sınavlar ve sorularla ilgili verilerin toplanması ve analiz edilmesidir. Bu veriler, soruların zorluk seviyeleri, öğrenci performansı, doğru ve yanlış cevap oranları gibi bilgileri içerir. Elde edilen veriler, bir soru bankası oluşturmak için kullanılır. Bu soru bankası, farklı konularda ve farklı zorluk seviyelerinde sorular içerir. Makine öğrenmesi, yeni sorular oluşturmak için bir model seçer ve bu model veri analizi sonuçları ve hedeflenen soru türü göz önüne alınarak yapılır. Bu süreç, sınav ve soru hazırlama sürecini daha hızlı ve verimli hale getirir. Aynı zamanda öğrencilere daha uygun soruların hazırlanmasını ve sınavların daha etkili bir şekilde yönetilmesini sağlar (Ghareeb, Hussain, Al-Jumeily vd., 2022).

Makine öğrenmesi sınav ve soru hazırlama uygulamaları ile Madde Tepki Kuramı çerçevesinde gerçekleştirilen Bireyselleştirilmiş Bilgisayar Test (BBT) uygulamaları benzer konseptlere dayanır, ancak uygulamaları farklıdır. Sınav ve soru hazırlama uygulamaları, eğitim materyali oluşturma ve sınav yönetimi süreçlerini kolaylaştırırken, BBT öğrencilere kişiselleştirilmiş ölçme deneyimi sunar ve mevcut testin uygulanma şekli testi alan bireylerin yeteneklerine göre biçimlendirilmesine imkan sağlar (Erbay Mermer, 2022). Bu süreçte hedef, tüm katılımcılara önceden belirlenmiş bir soru setini sıra ile uygulamak yerine, soruları testi cevaplayanların verdiği cevaba göre seçerek sormaktadır (Kalender, 2004). Her ikisi de eğitimde önemli roller oynar, ancak odakları ve kullanımları farklıdır.

Bu örnekler, eğitimde makine öğrenmesinin çeşitli yollarla nasıl kullanılabileceğini göstermektedir. Bu teknoloji, öğrencilere daha iyi öğrenme

deneyimleri sunma ve öğretmenlere daha iyi rehberlik etme konusunda büyük potansiyele sahiptir. Ancak bu teknolojiyi etkili bir şekilde kullanmak için doğru veri toplama tekniklerinin kullanılması, toplanan verinin titizlikle analiz edilmesi ve bu verilerdeki öğrenci bilgilerinin güvenliği konularında çok dikkatli olunması gereklidir. Makine öğrenmesi eğitim alanında büyük bir potansiyele sahip olsa da, etik ve güvenlik konularına odaklanmak oldukça önemlidir.

5. Makine Öğrenmesinin Avantajları

Makine öğrenmesi, eğitim alanında daha etkili, veri odaklı ve öğrenci merkezli yaklaşımların geliştirilmesine katkıda bulunur. Öncelikle, makine öğrenmesi öğrencilerin öğrenme deneyimlerini daha kişiselleştirilmiş hale getirir (Nafea, 2022). Bu teknoloji, öğrencilerin bireysel ihtiyaçlarını ve öğrenme tarzlarını daha iyi anlama ve analiz etme yeteneğine sahiptir. Bu da öğrencinin daha iyi anlamasına ve başarılı olmasına yardımcı olur. Makine öğrenmesi aynı zamanda öğrenci başarısını öngörmek için kullanılmaktadır. Öğrenci performansını izlemek ve erken müdahalede bulunmak için bu teknolojiyi kullanmak, öğrencilerin zorluklarını aşmalarına yardımcı olur (Oza, 2022). Eğitimciler, hangi öğrencilerin daha fazla desteğe ihtiyaç duyduğunu daha iyi anlayabilir ve bu öğrencilere daha fazla kaynak tahsis edebilir. 24/7 eğitime erişim bu teknolojinin en büyük avantajlarından biridir. Öğrencilere ve öğretmenlere 24 saat boyunca erişilebilen bir öğrenme kaynağı sağlar (Karandish, 2021). Bu, öğrenmenin zaman ve mekan kısıtlamalarını aşmasına yardımcı olur. Öğrenciler, istedikleri zaman ve istedikleri yerden, kendi hızlarında öğrenme imkanına sahip olurlar. Makine öğrenmesi ayrıca büyük veri analitiği ile birleştirildiğinde, eğitim kurumlarına daha yerinde kararlar alma kapasitesi sağlar (Berret, Murphy & Sullivan, 2012). Böylelikle eğitimin kalitesi artar ve kaynakların daha etkili bir şekilde kullanılması sağlanır.

6. Makine Öğrenmesinin Dezavantajları

Eğitim alanında makine öğrenmesi, birçok avantaj sunsa da bazı dezavantajları da beraberinde getirmektedir. Öncelikle, makine öğrenmesi uygulamaları veriye dayalıdır ve bu verilerin kalitesiz, yanıltıcı veya önyargılı olması durumunda ciddi sorunlar ortaya çıkabilir. Veri eksikliği veya yanlış etiketleme, algoritmaların yanlış sonuçlar üretmesine neden olabilir (Koçoğlu, 2012). Ayrıca, makine öğrenmesi uygulamalarında öğrenci gizliliği konusunda endişeler vardır (Seçkin, 2023). Öğrenci verilerinin toplanması ve kullanılması, gizlilik ihlallerine yol açabilir ve bu, hem etik hem de hukuki sorunlara neden olabilir. Makine öğrenmesinin, eğitim

süreçlerini otomatikleştirmeye yönelik bir eğilimi vardır, ancak bu, insan öğretmenlerin yerini alabileceği anlamına gelmez. Öğrencilerin sosyal ve duygusal ihtiyaçları, bir makine tarafından tam olarak karşılanamayacaktır (Ghaffari, Burgoyne, Debowski & Perez-Acosta, 2019). İnsan etkileşimi, öğrenme deneyiminin önemli bir parçasıdır ve makine öğrenmesi, bu insani boyutu eksik bırakarak öğrencilerin sosyal ve duygusal ihtiyaçlarını tam olarak karşılayamayabilir. Ayrıca, makine öğrenmesi sistemlerinin kurulması ve sürdürülmesi maliyetli olabilir, bu da okullar ve eğitim kurumlarının bu teknolojiyi uygulamak için yeterli kaynaklara ve yeteneklere sahip olmadığı anlamına gelebilir.

7. Gelecekteki Trendler ve Gelişmeler

Eğitimdeki makine öğrenmesi uygulamalarının gelecekteki yönelimleri ve büyüme alanları oldukça heyecan vericidir. Yapay zekanın, özellikle de OpenAI tarafından geliştirilen dil modeli olan ChatGPT'nin eğitimdeki rolü, bu değişimin merkezinde yer almaktadır. ChatGPT'nin eğitimdeki rolü, eğitim uygulamalarının çeşitli yönlerini yeniden şekillendirme potansiyeline sahiptir (Seçkin, 2023). Örneğin, ChatGPT bir öğrencinin belirli bir konuda bir dizi sorusunu yanıtlayabilir ve öğrencinin bu konuyu daha iyi anlamasına yardımcı olabilir. Öğretim planlamasından öğretim materyalleri geliştirmeye, bireyselleştirilmiş öğrenme modüllerinden çok dilli eğitime, 7/24 eğitim erişiminden özel eğitime kadar birçok alanda önemli bir katkılar sağlamaktadır.

Makine öğrenmesi, her öğrencinin öğrenme hızı, ihtiyaçları ve öğrenme tarzlarına göre özelleştirilmiş eğitim programları oluşturmayı desteklemektedir (Nafea, 2017). Öğrencilere, kendi hızlarında ilerleme fırsatı sunulacak ve zayıf yönlerini güçlendirmek için özel materyaller sağlar. Gelecekte, makine öğrenmesi ile desteklenen bireyselleştirilmiş eğitim daha yaygın hale gelecek, öğrencilerin ihtiyaçlarına, öğrenme hızlarına ve güçlü/zayıf yönlerine göre özelleştirilmiş ders planları ve materyaller sunmak için makine öğrenmesi eğitim alanında aktif olarak kullanılacaktır (Krishna Rao, Gowthami, Hema, Sai Ssaket & Narendra Babu, 2022).

Dijital öğretmen asistanları, öğretmenlere ders materyali hazırlama, öğrenci sorularını yanıtlama ve ilerlemeyi izleme konularında destek olmaktadır. Bu asistanlar, öğrencilerle etkileşime girebilir, öğrencilerin sorularına anında dönüt verebilir, öğretmenlerin daha fazla öğrenciye ulaşmalarına yardımcı olurlar (Nafea, 2017). Bireysel öğrenme, öz değerlendirme, yansıtıcı düşünme gibi bireysel süreçlerin ön plana çıktığı, tüm bu süreçlerin yapılandırıcılık anlayışıyla yürütüldüğü bir eğitim öğretim anlayışı da

bu tür dijital ürünlerin yaygın kullanılmasıyla da uyumlu görülmektedir (Aktaş, 2022). Nitekim Yükseköğretim Kurumunun dijitalleşmesi vizyonu da öğrenme, öğretme, ölçme ve değerlendirme sürecinde böyle asistanlardan yararlanılmasını öngörmektedir (Ataş ve Gündüz, 2019; Güllü, 2021; Koral Gümüšoğlu, 2017; Taşkıran, 2017). Bu anlamda bu süreçlerdeki öğrenci, öğretmen ve konu alanı ihtiyaçlarına cevap verecek, geleceğin öğrenme ihtiyaçlarını karşılayabilecek materyaller tasarlanmalı ve bunlar etkin bir şekilde kullanılmalıdır.

Veri madenciliği ve öğrenme analitiği teknolojisinin gelişmesiyle birlikte karmaşık veriler çok kısa zamanda işlenebilecektir. Öğrenci verilerini derinlemesine analiz etme yeteneği ile öğrenci performansını anlama ve eğitim süreçlerini iyileştirme konularında etkili olacaktır. Böylelikle, öğrencilerin başarı elde etmeleri için daha iyi rehberlik sağlayabilecektir. Dünya genelinde çok sayıda çalışma ve kullanım alanı olmasına rağmen ülkemizde analitiklerin kişisel performansları izleme açısından yeterli seviyede kullanılmadığı, ve öğrenme analitiklerinin gelişmekte olan bir alan olduğu vurgulanmıştır (Tutsun, 2021). Gelecekte sanal öğrenme ortamlarının gelişmesi, performans izleme ekranlarının oluşturulması ve bu ekranlara hem öğrenci hem öğretmenin erişebilmesi ve süreç hakkında geri bildirimler sağlanması, eğitimcilerin öğretim tasarımlarında yararlanabilecekleri verileri sağlayan öğrenme analitiği araçlarının geliştirilmesi beklenmektedir.

Yapay zeka Destekli Dil Öğrenimi: Dil işleme teknolojileri, öğrencilere yabancı dil öğrenmeleri için daha fazla destek sağlayacak, simultane çeviri ve dil öğrenme uygulamaları öğrencilerin daha iyi iletişim kurmalarına yardımcı olacaktır. Yapay zeka teknolojileri, dil öğrenimi konusunda büyük bir potansiyele sahiptir. Kişiselleştirilmiş öğrenme deneyimleri, çeviri hizmetleri, anında geri bildirim, büyük veri analizi ve öğrenme materyali üretimi gibi avantajlar, dil öğrenmede öğrencilerine önemli destek sağlamaktadır. Bu anlamda bu süreçlerdeki öğrenci, öğretmen ve konu alanı ihtiyaçlarına cevap verecek, geleceğin öğrenme ihtiyaçlarını karşılayabilecek materyaller tasarlanmalı ve bunlar etkin bir şekilde kullanılmalıdır (Aktaş, 2022).

Oyun tabanlı öğrenme, gelecekte eğitimde önemli bir rolü olması beklenen bir yaklaşımdır. Bu yaklaşım, özellikle çocuklar ve genç yetişkinler arasında öğrenmeyi daha etkili ve eğlenceli hale getirmek için kullanılabilir. Gelecekte, bu tür uygulamaların daha fazla özelleştirileceği ve öğrencilerin öğrenme stillerine ve ihtiyaçlarına daha uygun şekilde geliştirileceği tahmin edilmektedir. Ayrıca, oyun tabanlı öğrenme, karmaşık problemleri çözme, işbirliği yapma ve eleştirel düşünme gibi becerileri geliştirmek için daha fazla kullanılabilir. Teknolojinin ilerlemesiyle birlikte, artırılmış gerçeklik

(AR) ve sanal gerçeklik (VR) gibi yeni teknolojilerin oyun tabanlı öğrenme deneyimlerini daha da zenginleştireceği öngörülmektedir (Al-Ansi, Jaboob, Garad & Al-Ansi, 2023). Öğrenciler, ders içeriklerini daha etkileşimli bir şekilde keşfedebilir ve somut deneyimler yaşayabilirler.

Eğitimde Sanal Gerçeklik (VR) ve Artırılmış Gerçeklik (AR) uygulamaları öğrencilere daha etkileşimli ve deneyimsel öğrenme deneyimleri sunmaktadır. Özellikle tarihi olayları, bilimsel konseptleri veya coğrafi konumları deneyimlemek için kullanılabilir. VR ve AR'nin makine öğrenmesiyle birleştirilmesi, eğitim alanında büyük bir potansiyele sahiptir. Bu, öğrencilerin öğrenme motivasyonlarını artırdığı gibi aynı zamanda da diğer konularda bilgi aktarımı ve yaratıcı düşüncenin geliştirilmesine olanak tanıyacaktır (Bujdoso, Jasz, Csaszar & Farsang, 2019).

Eğitimin-öğretim ortamlarının dijitalleşmesiyle siber tehditlere karşı korunmada daha iyi hazırlık sağlamak için makine öğrenmesini kullanılması daha etkili olacaktır. Siber güvenlik eğitiminde makine öğrenmesi, öğrencilere tehdit analizi becerileri kazandırmak ve güvenlik açıklarını daha etkili bir şekilde ele almak için yardımcı olabilir (Singh, 2023). Aynı zamanda, gerçek dünya tehditlerine karşı savunma stratejilerini geliştirmek ve güncellemek için de kullanılabilir. Bu nedenle, siber güvenlik uzmanlarının makine öğrenme ve yapay zeka alanlarında eğitim almaları önemlidir.

Eğitimde dijitalleşmenin artmasıyla öğrenci verilerinin güvenliği ve etik kullanımı daha fazla vurgulanması gerekmektedir. Eğitim kurumları ve teknoloji sağlayıcıları, veri kullanımı ve paylaşımı konusunda daha şeffaf ve etik bir yaklaşım benimsemeleri gerekmektedir (Guan, Feng & Islam, 2023). Eğitim kurumlarının, bu konuları öğrencilere ve öğretmenlere öğretmesi ve bu konularda rehberlik sağlaması için politikalar ve kaynaklar geliştirmeleri önemlidir. Dijital etik ve gizlilik, sadece bilgi güvenliği açısından değil, aynı zamanda kişisel ve toplumsal sorumluluk açısından da önemli bir rol oynamaktadır.

8. Sonuç

Makine öğrenmesi, eğitim teknolojisini maksimize etmek ve öğrenmeyi ve öğretmeyi daha etkili hale getirmek için tasarlanmıştır. Makine öğrenmesinin öğrencilere kişiselleştirilmiş öğrenme fırsatları sunma, öğretmenlere öğrenci ilerlemesini izleme ve daha iyi öğretim stratejileri ve materyalleri geliştirme konularında önemli bir potansiyel taşıdığı artık yadsınamaz bir gerçektir. Ayrıca, veri analitiği ve yapay zeka teknolojilerinin öğrencilerin güçlü ve zayıf yönlerini belirlemede, içerik önerileri yapmada ve daha etkili geri bildirim sağlamada nasıl kullanılması gerektiği eğitim alanında üzerine çalışılması

gereken bir konulardandır. Gelecekte, makine öğrenmesi ile desteklenen eğitim, öğrencilere kişiselleştirilmiş öğrenme deneyimleri sunacak ve öğretmenlere, öğrencilere daha iyi rehberlik etme imkanı verecektir. Ancak, bu teknolojilerin etik ve gizlilik sorunlarına dikkat edilmesi gerektiğini de unutmamak gerekir. Eğitimde makine öğrenmesinin başarılı bir şekilde uygulanması için dikkatli bir denetim yapılması ve öğrenci gizliliğinin korunması önemlidir. Sonuç olarak, eğitimde makine öğrenmesi, geleceğin öğrenme deneyimlerini şekillendirecek önemli bir faktördür ve bu alandaki gelişmeleri yakından takip etmek öğrencilerin, öğretmenlerin ve eğitim kurumlarının daha iyi eğitim fırsatlarına, daha etkili öğretim stratejilerine ve daha rekabetçi bir geleceğe hazırlanmalarına yardımcı olur. Bu nedenle, eğitim alanında teknolojik gelişmeleri yakından izlemek ve bu gelişmeleri sisteme entegre etmek önemlidir.

9. Kaynakça

- Akbilgiç, O. (2011). *Hibrit radyal tabanlı fonksiyon ağları ile değişken seçimi ve tahminleme: Menkul kıymet yatırım kararlarına ilişkin bir uygulama*. Yayınlanmamış Doktora Tezi, İstanbul Üniversitesi, İstanbul.
- Aktaş, Y. (2022) Türkçenin yabancı dil olarak öğretiminde yazma becerisi için dijital yazma asistanları önerisi. *Bezgek Yabancılar Türkçe Öğretimi Dergisi*, 1(2), 120-132.
- Al-Ansi, A. M., Jaboob, M., Garad, A. & Al-Ansi, A. (2023). Analyzing augmented reality (AR) and virtual reality (VR) recent development in education. *Social Sciences & Humanities Open*, 8(1).
- Alferce, S. & Maghari, A. Y. (2018). *Prediction of student's performance using modified knn classifiers*. Conference: The First International Conference on Engineering and Future Technology (ICEFT), Gaza, Filistin, 24-25 Şubat 2018.
- Araştırmaları Dergisi , 3(4), 30-32. <https://dergipark.org.tr/en/pub/auad/issue/34247/378482>
- Arslan, K. (2017). Eğitimde Yapay Zeka ve Uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Atabay, M., Güllüoğlu, K. ve Şimşek, M. (2023). Sınıf Yönetimi Süreçlerinin Sanal Sınıf Ortamlarına Yansımaları. *International Journal of Computers in Education*, 6, 1(1-18).
- Ataş, H., & Gündüz, S. (2019). *Yükseköğretimde dijital dönüşüm*. İ. E. Çelik (Ed.), Dijital Dönüşüm. Gazi Kitabevi.
- Aydemir, E., Işık, M. Ve Tuncer, T. (2021). Türkçe haber metinlerinin çok terimli naive bayes algoritması kullanılarak sınıflandırılması. *Fırat Üniversitesi Müh. Bil. Dergisi*, 33(2), 519-526.
- Berrett, B., Murphy, J., & Sullivan, J. (2012). Administrator insights and reflections: technology integration in schools. *The Qualitative Report*, 17(1), 200-221. <https://doi.org/10.46743/2160-3715/2012.1815>
- Borgavakar & Shrivastava, (2017). Evaluating student's performance using k-means clustering. *International Journal of Engineering Research & Technology (IJERT)*, 6(5), 114-116.
- Borges, V. R. P., Esteves, S. L., Araujo, P. N., Oliveira, L. C. & Holanda, M. (2018). Using Principal Component Analysis to support students' performance prediction and data analysis. https://www.researchgate.net/publication/328735107_Using_Principal_Component_Analysis_to_support_students'_performance_prediction_and_data_analysis (Erişim tarihi: 10.07.2023).
- Brownlee, J. (2020). Machine learning mastery <https://machinelearningmastery.com/a-tour-of-machine-learningalgorithms/> (Erişim:02.01.2022)

- Bujdoso, G., Jasz, E., Csaszar, Z. M. & Farsang, A. (2019). *Virtual reality in teaching geography*. Conference name: 12th annual International Conference of Education, Research and Innovation, İspanya, 11-13 Kasım 2019.
- Campbell, M., Hoane, A. J. & Hsu, F. (2002). Deep blue. *Artificial Intelligence* 134 (2002) 57–83.
- Chien, C. F., Chen, L. F. 2008. Data mining to improve personnel selection and enhance human capital: a case study in high-technology industry. *Expert Systems with Applications*, 34, 280-290.
- Çömlekçi, O. (2020). *Endüstriyel otomasyon sistemlerinde yapay zeka yöntemleri ile arıza tespiti*. Yayımlanmamış Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi, Bursa.
- Erbay Mermer, Ş. (2022). *Minnesota çok yönlü kişilik envanteri için makine öğrenmesi temelli bireyselleştirilmiş bilgisayarlı test uygulamasının geliştirilmesi*. Yayımlanmamış Doktora Tezi, Hacettepe Üniversitesi, Ankara.
- Foote, K. D. (2021). A Brief History of Machine Learning. <https://www.dataversity.net/a-brief-history-of-machine-learning/> (Erişim tarihi: 12.09.2023).
- Ghaffari, S., Burgoyne, J., Debowski, L. & Pereze-Acosta, A. M. (2019). *The replacement of human teachers with robot teachers in future primary schools and the challenges ahead*. 3. International Conference on learning in STEM, Learning Adventures, Power of Objects in STEM Discovery, Warsaw, Polonya, 21-22 Kasım 2019.
- Ghareeb, S., Hussain, A.J., Al-Jumeily, D. et al. (2022). Evaluating student levelling based on machine learning model's performance. *Discov Internet Things* 2,(3). <https://doi.org/10.1007/s43926-022-00023-0>
- Ghauth, K. I. & Abdullah, N. A. (2010). Learning materials recommendation using good learners' ratings and content-based filtering. *Educational Technology Research and Development*, 58,(6), 711-727.
- Govindasamy, K. & Velmurugan, T. (2017). A study on classification and clustering data mining algorithms based on students academic performance prediction. *International Journal of Control Theory and Applications*, 10(23), 147-160.
- Guan, X., Feng, X. & Islam, A. Y. M. A. (2023). The dilemma and countermeasures of educational data ethics in the age of intelligence. *Humanities and Social Sciences Communications*,10,(138).
- Güllü, O. (2021). *Yükseköğretimde dijitalleşme*. Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Hamsa, H., Indiradevi, S. & Kizhakkethottam, J. J. (2016). Student academic performance prediction model using decision tree and fuzzy genetic algorithm. *Procedia Technology*, 25, (326-332).
- Han, J., Pei, J. & Kamber, M. (2011). *Data mining: concepts and techniques*: Elsevier.

- Hasan, H. M. R., Rabby, A. S. A., Islam, M. T. & Hossain, S. A. (2019). *Machine Learning Algorithm for Student's Performance Prediction*. 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT). doi: 10.1109/ICCCNT45670.2019.8944629.
- Hillier, W. (2023). What's the Best Language for Machine Learning? <https://careerfoundry.com/en/blog/data-analytics/best-machine-learning-languages/#:~:text=Python%20for%20machine%20learning&text=Its%20popularity%20has%20boomed%20in,data%20analytics%20and%20machine%20learning> (Erişim tarihi: 01.08.2023).
- http://aof20.anadolu.edu.tr/bildiriler/Esra_Turhan.doc, Şubat 2008.
- İnal, G. (2021). *Yapay zekâ, veri madenciliği ve büyük veri kavramlarına karşı okul yöneticilerinin algılarının belirlenmesi*. Yayımlanmamış Yüksek Lisans Tezi, Akdeniz Üniversitesi, Antalya.
- Jahan, F. & Ghosh, S. K. (2021). *Prediction of student's performance using support vector machine classifier*. Conference: 11th Annual International Conference on Industrial Engineering and Operations Management, Singapore, 7-11 Mart 2021.
- Karakoyun, M., & Hacıbeyoğlu, M. (2014). Biyomedikal veri kümeleri ile makine öğrenmesi sınıflandırma algoritmalarının istatistiksel olarak karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16, 30-42.
- Karandish, D. (2021). 7 Benefits of AI in Education. <https://thejournal.com/articles/2021/06/23/7-benefits-of-ai-in-education.aspx> (Erişim tarihi: 13.07.2023).
- Kızılkaya, Y. M. Ve Oğuzlar, A. (2018). Bazı denetimli öğrenme algoritmalarının r programlama dili ile kıyaslanması. *Karadeniz Dergisi*, (37).
- Kızrak, A. (2018). Yapay zeka ve derin öğrenmeye başlama rehberi. <https://ayyucekizrak.medium.com/yapay-zekaya-ba%C5%9Flama-rehberi-91e79d3de8e1> (Erişim tarihi: 12.07.2023).
- Koch, R. (2022). History of Machine Learning–A Journey through the Timeline. <https://www.clickworker.com/customer-blog/history-of-machine-learning/> (Erişim tarihi: 19.09.2023).
- Koçoğlu, F. Ö. (2012). Veri madenciliğinde veri ayrıklaştırma yöntemlerinin karşılaştırılması ve bir uygulama. https://www.researchgate.net/publication/263559915_Veri_Madenciliginde_Veri_Ayriklastirma_Yontemlerinin_Karsilastirilmesi_ve_Bir_Uygulama (Erişim tarihi: 14.08.2023).
- Koral Gümüsoğlu, E. (2017). Yükseköğretimde dijital dönüşüm. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 3 (4), 30-42.
- Kumar, A. (2020). Random Forest for prediction (Using Random Forest to predict automobile prices). <https://towardsdatascience.com/random-forest-ca80e56224c1> (Erişim tarihi: 22.07.2023).

- Kuş, İ., Bozkurt Keser, S. & Yolaçan, E. N. (2021). Saldırı tespit sistemlerinde topluluk öğrenme yöntemlerinin kıyaslanması. *Avrupa Bilim ve Teknoloji Dergisi*, (31), 725-734.
- Lavanya, S. (2022). Application of student feedback using machine learning model. *International Journal of Creative Research Thoughts (IJCRT)*, 10(7), 304-308.
- Liu, R. (2022). Data analysis of educational evaluation using k-means clustering method. *Computational Intelligence and Neuroscience*, 2022.
- Luo, W., Xing, J., Milan, A., Zhang, X., Liu, W., Zhao, X., Kim, T.-K. (2014). *Multiple Object Tracking: A Literature Review*. Computer Vision and Pattern Recognition, doi: 10.1016/j.artint.2020.103448.
- Nafea, I. T. (2017). Machine Learning in Educational Technology. <https://www.intechopen.com/chapters/58546> (Erişim tarihi: 10.07.2023).
- Nykon, Y. (2023). Machine Learning in Education: Benefits and Opportunities. <https://intellias.com/benefits-of-machine-learning-in-education/> (Erişim tarihi: 13.08.2023).
- Oza, H. (2022). Benefits Of Machine Learning In Education. <https://www.hdatasystems.com/blog/benefits-of-machine-learning-in-education> (Erişim tarihi: 10.08.2023).
- Parthiban, G., Srivatsa, A. S. K. & Rajesh, A. (2011). Diagnosis of heart disease for diabetic patients using naive bayes method. *Int. J. Comput. Appl.*, 24(3), 7-11.
- Polat, B. (2021). *Türkçe ürün yorumları verisi ile duygu analizi*. Yayınlanmamış Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara.
- Raj, A. (2020). Perfect Recipe for Classification Using Logistic Regression. <https://towardsdatascience.com/the-perfect-recipe-for-classification-using-logistic-regression-f8648e267592> (Erişim tarihi: 22.08.2023).
- Krishna Rao, L. V., Gowthami, B. V., Hema, B., Sai Saketh, A. & Narendra Babu, G. (2022). Analysis of student behavioural patterns by machine learning. *ICT Analysis and Applications, Lecture Notes in Network and Systems*, 517.
- Rusland, N. F., Wahid, N., Kasim, S. & Hafit, H. (2017). Analysis of naive bayes algorithm for email spam filtering across multiple datasets. *IOP Conf. Ser. Mater. Sci. Eng.*, 226 (1), doi: 10.1088/1757-899X/226/1/012091.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science* 2, 160.
- Seçkin, E. (2023). Openai ve chatgpt: makine öğrenmesinin sınırlarını zorlamak. <https://www.suspendplus.com/makine-ogrenmesi/> (Erişim tarihi: 12.09.2023).

- Singh, A. P. (2023). AI in Cyber Security: Advantages, Applications and Use Cases. <https://www.analyticsvidhya.com/blog/2023/02/future-of-ai-and-machine-learning-in-cybersecurity/> (Erişim tarihi: 12.09.2023).
- Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 30-42.
- Smolic, H. (2022). Regression in machine learning- what is it and when to use. <https://graphite-note.com/regression-in-machine-learning-what-is-it> (Erişim tarihi: 02.08.2023).
- Sravani, B. & Bala , M. M. (2020). *Prediction of student performance using linear regression*. International Conference for Emerging Technology (INCET), Hindistan, 5-7 Temmuz 2020.
- Srikanth, A., Karthikeya, A. A. & Rao, B. V. (2023). Student grade prediction using gradient boosting classifier. *Ijariie*, 9,(1) 1758-1763.
- Taşkıran, A. (2017). Dijital çağda yükseköğretim. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 3(1), 96-109. <https://dergipark.org.tr/en/pub/auad/issue/34114/377387>
- Turhan, E. *Web Tabanlı Öğretimde Etkileşim Ve Öğrenci Destek Hizmetlerinin Geliştirilmesi*. Açıköğretim Fakültesi 20. Kuruluş Yılı Nedeniyle, Uluslararası Katılımlı Açık ve Uzaktan Eğitim Sempozyumu, Eskişehir, 3–25 Mayıs 2002.
- Van Der Maaten, L. (2014). Accelerating t-SNE using tree-based algorithms. *J. Mach. Learn. Res.* 15, 3221–3245.
- Weedmark, D. (2021). Machine Learning Modeling: How It Works and Why It's Important. <https://domino.ai/blog/what-is-modeling> (Erişim tarihi: 02.08.2023).
- Yaday, N. R. & Desmukh, S. S. (2023). Prediction of student performance using machine learning techniques: A review. https://doi.org/10.2991/978-94-6463-136-4_63 (Erişim tarihi: 26.08.2023).
- Yazan, M. (2023). Machine Learning Nedir? <https://www.talentcoders.co/machine-learning-hakkinda-her-sey/> (Erişim tarihi: 06.09.2023).
- Yıldız, E. ve Sevim, Y. (2020). Sınıflandırma yöntemleri üzerinde lineer boyut indirgeme yöntemlerinin karşılaştırılması. https://www.emo.org.tr/ekler/f02e5dd09d20169_ek.pdf (Erişim tarihi: 28.08.2023).

