

İNSAN ZEKÂSINDAN YAPAY ZEKÂYA

Dr. Burcu ALAN

Prof. Dr. Fikriye KIRBAĞ ZENGİN



İKSAD
Publishing House

İNSAN ZEKÂSINDAN YAPAY ZEKÂYA

Dr. Burcu ALAN¹

Prof. Dr. Fikriye KIRBAĞ ZENGİN²



¹ Fırat Üniversitesi, Eğitim Bilimleri Enstitüsü, Matematik ve Fen Bilimleri Eğitimi Ana Bilim Dalı, Elâzığ, Türkiye. burcualan@outlook.com, Orcid ID: 0000-0003-3429-0942

² Fırat Üniversitesi, Eğitim Fakültesi, Matematik ve Fen Bilimleri Eğitimi Bölümü, Elâzığ, Türkiye. fzengin@firat.edu.tr, Orcid ID: 0000-0002-0547-8746

Copyright © 2023 by iksad publishing house

All rights reserved. No part of this publication may be reproduced, distributed or transmitted in any form or by any means, including photocopying, recording or other electronic or mechanical methods, without the prior written permission of the publisher, except in the case of brief quotations embodied in critical reviews and certain other noncommercial uses permitted by copyright law. Institution of Economic Development and Social

Researches Publications®

(The Licence Number of Publicator: 2014/31220)

TURKEY TR: +90 342 606 06 75

USA: +1 631 685 0 853

E mail: iksadyayinevi@gmail.com

www.iksadyayinevi.com

It is responsibility of the author to abide by the publishing ethics rules.

Iksad Publications – 2023©

ISBN: 978-625-367-081-8

Cover Design: İbrahim KAYA

May / 2023

Ankara / Turkey

Size = 16 x 24 cm

ÖNSÖZ

Bizzat insan zekâsı tarafından geliştirilmiş olan yapay zekâ, herkesin üzerinde hemfikir olduğu bir tanımı olmayan, farklı tanımlara maruz kalan bir bilim dalıdır. Yapay zekânın sosyolojiden tıbbi bilimlere, mühendislikten psikolojiye ve daha birçok alanda uygulanıyor olması yapay zekâ alanında çok farklı tanımların ortaya çıkmasına sebebiyet vermektedir. Çünkü farklı alanlarda çalışmasını yürüten araştırmacılar kendi alanlarının vermiş olduğu eğilim doğrultusunda tanım yapmaktadırlar. Kurzweil (1990), yıllar önce yapay zekâyı tanımlarken, insanlar tarafından gerçekleştirildiğinde zekâ gerektiren işlevleri yerine getiren makineler yaratma sanatı olarak ifade etmiştir. Bu tanımın üzerinden oldukça uzun bir zaman geçmesine rağmen, yapay zekâyı tanımlamak için hala etkili bir başlangıç noktası sağladığı düşünülmektedir. Geleceğe yön verecek stratejik bir teknoloji haline gelen yapay zekânın gelişimi ile birlikte akıllı telefonlar, arama motorları, yüz tanıma, makine çevirisi, akıllı tıbbi tedavi ve otonom sürüş gibi modern topluma olumlu değişiklikleri de beraberinde getirmiştir. İnsanlar farkında olsun ya da olmasın yapay zekâ insanların günlük işlerine ve yaşamlarına fazlasıyla nüfuz etmiş ve yaşam tarzlarını önemli düzeyde değiştirmiştir.

Günümüz dünyasının en popüler teknolojilerinden olan yapay zekâdan endüstri, enerji, sağlık, iletişim ve yazılım geliştirme, sesli asistanlar, konum bulma, bilgiye hızla ulaşma, sosyal medya, eğlence, finans, bankacılık gibi hemen hemen her alanda aktif bir şekilde yararlanmaktadır. Birçok alanı etkisi altına alan yapay zekânın eğitimde de kullanılıyor olması aslında hiç şaşırtıcı değildir. Yapay zekâ birçok alanda etkisini göstermiş ve oldukça fazla sayıda çalışmaya konu olmuştur. Ancak eğitimde diğer alanlara ya da sektörlerle kıyasla etkisi sınırlı kalmış olsa da son yıllarda artan bir ivme yakalamış ve bu sektörde de önemli başarılar kazanmıştır. Yapay zekâ teknolojisinin, 1950’li yıllarda kavram olarak ilk ortaya atılışından günümüze kadar geçen zamanda eğitim alanında kullanımı giderek artmış ve kullanım alanlarına yenileri eklenmiştir. Birçok kişi yapay zekânın eğitim alanında uygulanmadığını düşünse de yapay zekâ çoktan sınıf ortamına girmiş ve “akıllı, uyarlanabilir ya da kişiselleştirilmiş öğrenme sistemleri” gibi kavramlarla dünya çapında gerek liselerde gerekse üniversitelerde eğitimi çok farklı boyutlara taşımayı

başarmıştır. Bu süreç daha fazla öğrenciden daha fazla veri toplanması ve analiz edilmesi ile devam etmektedir.

Bu kitap Prof. Dr. Fikriye KIRBAĞ ZENGİN danışmanlığında Burcu ALAN tarafından hazırlanan “Fen Öğretiminde Yapay Zekâ ile Belirlenen Çoklu Zekâ Alanlarına Göre Hazırlanmış E-Öğrenme Ortamlarının Farklı Değişkenler Açısından İncelenmesi” başlıklı doktora tez çalışmasının ilgili bölümlerinden oluşmaktadır.

Gerek yüksek lisans gerekse doktora eğitimim boyunca her koşulda bilgi birikimini, desteğini, ilgisini, katkısını, sevgi ve şefkatini esirgemeyen, bana güvendiğini her zaman hissettiren, hayatım boyunca hep yanımda olmasını arzu ettiğim değerli danışmanım Prof. Dr. Fikriye KIRBAĞ ZENGİN hocama bu süreçteki yol göstericiliği için sonsuz teşekkür eder saygı ve şükranlarımı sunarım.

Saygılarımızla,

Prof. Dr. Fikriye KIRBAĞ ZENGİN
Dr. Burcu ALAN

İÇİNDEKİLER

ÖNSÖZ.....	İ
İÇİNDEKİLER.....	İİİ
BİRİNCİ BÖLÜM.....	5
1.GİRİŞ.....	5
İKİNCİ BÖLÜM	8
2. KURAMSAL ÇERÇEVE ve İLGİLİ ARAŞTIRMALAR	8
2.1. Zekâ.....	8
2.2. Zekâyı Etkileyen Faktörler.....	9
2.3. Çoklu Zekâ Kuramı	11
2.4. Çoklu Zekâ Alanları ve Özellikleri	11
2.4.1. Sözel-Dilbilimsel Zekâ	11
2.4.2. Mantıksal-Matematiksel Zekâ	13
2.4.3. Bedensel-Kinestetik (Duyudevinimsel) Zekâ	14
2.4.4. Görsel Uzamsal Zekâ.....	16
2.4.5. Müzikal-Ritmik Zekâ.....	17
2.4.6. Sosyal- Bireylerarası Zekâ.....	18
2.4.7. Özedönük-Bireysel Zekâ.....	19
2.4.8. Doğacı-Doğa Zekâsı	20
2.5. Yapay Zekâ	22
2.5.1. Yapay Zekânın Eğitimde Kullanımı	27
2.5.2. Eğitimde Yapay Zekâ Uygulamaları.....	29
2.6. Makine Öğrenmesi	36
2.6.2. Araştırmada Kullanılan Makine Öğrenmesi Algoritmaları.....	38
2.6.3. Makine Öğrenmesinin Eğitimde Kullanılması.....	44
2.7. E-Öğrenme Ortamları.....	46
2.8. İlgili Araştırmalar	47
2.8.1. Yapay Zekâ-Makine Öğrenmesi Alanında Yapılan Araştırmalar ..	47
2.8.2. Çoklu Zekâ Alanında Yapılan Çalışmalar	68
KAYNAKÇA	81

BİRİNCİ BÖLÜM

1.GİRİŞ

Eğitim sektörü, önemli eğitimsel dönüşümlere ve geleneksel öğretim programı ve öğretim yöntemleri üzerine büyük eleştirilere maruz kalmıştır (Alsalthi, 2020). Dembo (2010)'a göre eğitim sektöründeki dönüşümler içinde, öğrenme sürecinin merkezi olarak öğrenene ve öğrenenin öğrenme sürecinde oynaması gereken rolün yanı sıra öğretmenin öğrenme süreçlerini desteklemesi ve kolaylaştırması rolünü üstlenmesine yönelik ilgi de yer almaktadır. Psikolog Howard Gardner tarafından 1970'lerin sonu ve 1980'lerin başında ortaya atılan çoklu zekâ teorisi, insanların birbirinden oldukça bağımsız sekiz veya daha fazla zekâ ya sahip olduğunu göstermektedir. Teorinin ortaya çıkışı eğitim ve öğrenim alanında devrim yaratmış, sadece tek bir zekâ türünü tanıyan ve eğitimde tek bir yöntem kullanan geleneksel zekâ kavramına meydan okumuş ve bunun sonucu olarak birçok öğrencinin etkili eğitim fırsatlarından mahrum kaldığı düşüncesine sebebiyet vermiştir (Alsalthi, 2020). Gardner (2011)'e göre eğitim sistemi, öğretmenleri öğrencilerin farklı tercihlerini ve entelektüel güçlerini dikkate almaya ve onlara bu güçlerine tutarlı bir şekilde öğretmeye teşvik ederek önemli ölçüde geliştirilebilir. Bu açıdan bakıldığında çoklu zekâ kuramına dayalı öğretim programlarının benimsenmesi, öğrenmeyi teşvik etmek için umut vadeden bir seçenek haline gelmektedir (Ferrero ve ark., 2021). Gardner (2011), her zaman çoklu zekâ teoreminin farklı şekillerde uygulanabileceğinin mümkün olduğunu savunmuş ve zekâ türlerini kullanmak ve geliştirmek için de bazı özel araçlar tavsiye etmiştir. Çoklu zekâ teorisi; öğrencilerin ihtiyaçlarının, stillerinin, zekâlarının, potansiyellerinin dâhil edilmesine ve dikkate alınmasına olanak tanıdığı için amaca muazzam bir şekilde hizmet edebilir, öğretme ve öğrenme sürecine elzem bir katkı sağlayabilir (Alsalthi, 2020).

İçerisinde bulunduğumuz çağın öğrencileri, önceki nesillerden birçok açıdan farklılaşmaktadır. Bunlar; öğrenme ihtiyaçları, bireysel farklılıkları, motivasyonları, derslerden beklentileri, derslere karşı tutum ve davranışları olarak sıralanabilir. Öğrenme sürecinin öğrencilerin beklentilerine cevap

verecek nitelikte olmasında günümüz teknolojilerinin sunduğu imkân ve fırsatlardan yararlanılmaktadır (Bulun ve ark., 2004). Özellikle Fen Bilimleri Dersi, teknoloji entegrasyonuna oldukça elverişli bir ders olması, soyut ve bilimsel kavramları içerisinde barındırması, bu kavramların öğretilmesinde farklı öğretim yöntem ve tekniklerin kullanılmasında, teknolojiden yararlanılmasını üst seviyeye çıkarmaktadır (Ayas ve ark., 2001). Birçok araştırma da fen bilimleri dersi kapsamında güncel teknolojilerden yararlanıldığı görülmektedir. Bu teknolojilerden biri de yapay zekâdır.

Yapay zekâ uygulamaları, eğitim sistemlerinin etkinliğini ve kalitesini artırmak amacıyla öğrencilerin öğrenme yörüngelerini anlamak için mevcut veri kümelerinden anlamlı içgörüler üretmeye yardımcı olma konusunda büyük bir potansiyele sahiptir. Her bir öğrenci için özel öğrenme gereksinimine göre özelleştirilmiş çalışma materyalleri ve testleri oluşturmaktan bunları değerlendirmeye, bir eğitmeni potansiyel öğrenme engelleri konusunda uarmaktan, bir insan konuşmasını simüle ederek bir öğrencinin sorularını yanıtlamaya kadar birçok alanda eğitim sisteminin şeklini ve yapısını büyük ölçüde değiştirecek kadar derinlere nüfuz etmiş durumdadır (Bhutoia, 2022). Eğitimde yapay zekâ; daha kişiselleştirilmiş ve uyarlanabilir öğrenme sunarak, öğretmenlerin, öğrencilerin öğrenme sürecini anlamalarını teşvik ederek, her zaman ve her ortamda makine destekli sorgulama yaparak anında geri bildirim sağlamaktadır (Chiu ve ark., 2022). Böylelikle öğrenme, öğretme, değerlendirme ve eğitim yönetimini iyileştirme konusunda yapay zekânın muazzam bir potansiyele sahip olduğu düşünülmektedir. Eğitim araştırmaları ile yapay zekânın en önemli alanlardan biri olduğu ifade edilmektedir (Chiu ve ark. 2022). Eğitimde yapay zekâ, öğrenme deneyimlerini kişiselleştirerek eğitime önemli bir katkı sağladığı için eğitimcilerin ve araştırmacıların giderek daha fazla ilgilenmeye ve bu alanda çalışma yapmaya başladığı bir konu haline gelmiştir (Shaikh ve ark., 2022; Su ve Yang, 2022). Ancak hala çok az sayıda insan yapay zekânın ve makine öğreniminin eğitim ve öğretim hayatına girdiğinin farkındadır (Shaikh ve ark., 2022).

Terim ve Tanımlar

Zekâ: Psikologların görüşlerine göre muhakeme yolu ile sonuca ulaşma yeteneği, eğitimcilerin görüşlerine göre öğrenme yeteneği, bilgisayarla ilgilenen bilim insanlarının görüşlerine göre bilgi işleme yeteneği, biyologların görüşlerine göre ise çevreye uyum sağlama yeteneğidir (Kahyaoglu, 2013).

Çoklu Zekâ Kuramı: Howard Gardner'ın, Harvard Üniversitesi projesi "Proje Sıfır" kapsamında gerçekleştirmiş olduğu, normal ve yetenekli çocuklardan yola çıkarak bilişsel potansiyellerinin gelişimi ve beyindeki hasarlardan dolayı zekâ bozuklukları alanında yaptığı araştırmanın bir ürünü olarak ortaya çıkan bir kuramdır (Demirel ve ark., 2006). Bu kuram; bilişsel bilim, gelişimsel psikoloji ve nörobilimden faydalanılarak her bireyin zekâ seviyesinin özerk güçler ya da yetenekler tarafından oluştuğunu ve en az sekiz tane gücün (zekânın) var olduğunu savunmaktadır (Demirel, 1999).

Yapay Zekâ: Herhangi bir canlı organizmadan faydalanılmadan, tamamen yapay araçlar ile oluşturulan, insanlar gibi davranış ve hareketler yapabilen, insanlara özgü nitelikler olduğu varsayılan hissetme, düşünme, muhakeme yürütme, karar verme, öğrenme, anlam çıkartma, genelleme yapma ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin işlevleri bilgisayarın veya bilgisayar denetimli bir makinenin yerine getirme yeteneğidir (Nabiyev, 2016).

Makine Öğrenmesi: Makine öğrenmesi, bilgisayarların örnek verileri ya da geçmiş deneyimleri kullanarak başarımlarını artıracak şekilde programlanmasıdır (Alpaydın, 2013). Makine öğrenmesi, istatistik kuramını kullanarak model oluşturur, çünkü temeli gözlenmiş bir örneklemeden çıkarım yapmaktır.

E-Öğrenme Ortamları: Bilgi ve iletişim teknolojileri aracılığıyla, yerel ve internet gibi geniş iletişim ağlarından yararlanılarak, bilgi ve öğretim amaçlı çoklu ortam uygulamalarına zaman ve mekândan bağımsız bir şekilde ulaşma ve elektronik öğrenme ortalarında etkileşim sağlayan öğretim etkinliklerinin gerçekleştirilmesidir (Gülbahar, 2012).

İKİNCİ BÖLÜM

2. KURAMSAL ÇERÇEVE ve İLGİLİ ARAŞTIRMALAR

Bu bölümde; zekâ kavramına, zekâyı etkileyen faktörlere, çoklu zekâ kuramına, çoklu zekâ alanlarına, yapay zekâyâ, eğitimde yapay zekânın kullanımına, makine öğrenmesine, araştırma kapsamında kullanılan makine öğrenmesi algoritmalarına, makine öğrenmesinin eğitimde kullanımına, e-öğrenme ortamlarına ve ilgili araştırmalara yönelik bilgilere değinilmiştir.

2.1. Zekâ

İnsan beyni diğer canlılarda bulunmayan kendi türüne özgü birtakım özelliklere sahiptir ve bu özellikler insanı diğer canlılardan daha üstün kılmaktadır (Bostrom, 2018). Her canlının öne çıkan bir takım belirleyici özelliği vardır. İnsanlar için öne çıkan özellik ise beyni ile kullandığı zekâsıdır.

Yıllardır üzerinde araştırma yapılan zekâ kavramı, esasında soyut bir kavramdır. Bu sebeple de sürekli ilgi duyulan, sınırları çizilmeye çalışılan, sorgulanan bir canlı özelliği haline gelmiştir. Aristoteles'e kadar dayandırılan zekâ kavramının, bilimsel lüteratür de kullanılan Latince "intelligence" sözcüğünü, Aristoteles'in "dia-noesis" teriminin hemen hemen aynı çeviri olarak ilk kullanan kişi Cicero'dur (Bümen, 2005). 19. yüzyılda zekâ terimi ile ilgili çalışmalar hız kazanmış, oldukça fazla farklı fikir ortaya çıkmış, araştırmacılar tarafından çeşitli sınıflamalar yapılmış ve bu hızlı gelişimin yansımaları günlük yaşamımıza yoğun bir şekilde dâhil olmuştur.

Zekâ kavramı üzerine fikirler yürütülürken, araştırmacılar bireylerin zihinsel yapıları ile davranışlarına bakarak birtakım çıkarımlarda bulunmuşlardır. Bu çıkarımlara göre zekâ; bazen çevreye ayak uydurma, bazen bir testten alınan puan bazen ise problem çözme olarak düşünülmüştür (Bümen, 2005). Zekâ; psikologların görüşlerine göre muhakeme yolu ile sonuca varma kabiliyeti, eğitimcilerin görüşlerine göre öğrenme kabiliyeti, bilgisayarla meşgul olan bilim insanlarının görüşlerine göre bilgi işleme kabiliyeti, biyologların görüşlerine göre ise çevreye uyum sağlama kabiliyetidir (Kahyaoğlu, 2013).

2.2. Zekâyı Etkileyen Faktörler

Zekâyı etkileyen faktörleri belirlemek amacıyla geçmişten günümüze dek birçok araştırma yapılmıştır. Bu araştırmalarda çevresel ve biyolojik faktörlerin zekânın gelişiminde ne düzeyde etkili olduğu sorusuna odaklanılmıştır. Bu sorunun gündeme gelmesinin sebebi zekânın sadece kalıttan etkilendiğini ve zekânın sadece çevreden etkilendiğini savunan araştırmacıların kendi düşüncelerinin doğruluğuna yönelik olarak tartışma ortamı yaratmaları yatmaktadır (Gürel ve Tat, 2010).

17. yüzyıl İngiliz düşünürü John Locke zekânın gelişimini çevrenin etkilediğini, 18. yüzyıl Fransız düşünürü Jean Jacques Rousseau ise zekânın gelişimini kalıtımın etkilediğini öne sürmüştü ve bu iki farklı bilim adamının birbirleri ile çelişen düşünceleri sonucunda araştırmacılar çevrenin ve kalıtımın zekâ üzerindeki etkisini incelemeye başlamışlardır. Yapılan çalışmalar sonucunda zekânın gelişimin etkileyen çevre ve kalıtımın yüzde oranları net olarak saptanabilse de yapılan son araştırmalar ile kalıtım faktörünün zekâyı etkisinin bir takım çevresel faktörler ile belirlendiği ve dolayısıyla kalıtım ve çevrenin zekâ gelişimi üzerine etkisinin net bir şekilde belirleme ihtimalinin olmayacağı vurgulanmıştır (Bartholomew, 2005).

Zekânın gelişimini etkileyen etkenler, biyolojik etkenler ve çevresel etkenler olarak iki grupta incelenebilir. Biyolojik etkenler; kalıtım, beyin sinir hücrelerinin yapısı, doğum öncesi ve doğum sırasındaki imkânlar olarak sıralanabilir (Gürel ve Tat, 2010). Çevresel etkenler ise; kaynaklara ulaşım imkânı, coğrafi etkenler, ailesel etkenler, tarihsel-kültürel etkenler ve durumsal etkenler olarak sıralanabilir (Armstrong, 1994).

Kalıtım: Kalıtımın temel birimi olan genler, bir organizmanın özelliklerini belirlemektedir. Zekâyı doğrudan etkileyen, ebeveynlerin beyin ve sinir sistemlerinin fiziksel özellikleri kalıtım ile çocuğa geçmektedir (Gürel ve Tat, 2010).

Beyin sinir hücrelerinin yapısı: Beyin sinir hücrelerinin yapısının zekânın gelişimini etkilediği düşünülmektedir. Sinir hücreleri ne kadar doğru ve hızlı bir şekilde çalışırsa buna paralel olarak düşüncelerinde daha doğru ve hızlı işlendiğini sağladığı düşünülmektedir (Hamilton, 1996).

Doğum öncesi ve doğum sırasındaki imkânlar: bireyin doğum öncesindeki ve doğum sırasında maruz kaldığı birtakım tahribatları

kapsamaktadır. Örneğin, hamilelik sürecinde anne alkol ve nikotin alıyorsa, virüse, tehlikeli gazlara ve kimyasal maddelere maruz kalmışsa, kötü bir beslenme alışkanlığı varsa ve anne ile bebek arasında kan uyuşmazlığı varsa bu gibi problemlerin bebekte zekâ geriliğine yol açtığı sonucuna varılmıştır (Gürel ve Tat, 2010). Doğum esnasında zekâ gelişimini etkileyecek faktörler olarak ise; erken doğum, geç doğum ve zorlu gerçekleşen doğumlar sayılabilir (Bernstein ve ark., 1994).

Kaynaklara ulaşım imkânı: Bir aile sosyo-ekonomik olarak çok yetersiz bir seviyede ise çocuğuna sunacağı imkânlarda buna paralel olarak yetersiz olacaktır. Örneğin piyano, keman gibi müzik enstürümanların alamama durumunda çocuğun müzik zekâ alanının güçlenmesi oldukça zorlaşır.

Coğrafi etkenler: Zekâ türlerinden hangisinin daha güçlü ya da baskın olduğu bireyin yetişmiş olduğu coğrafyaya göre değişkenlik göstermektedir. Örneğin köy ortamında büyümüş bir çocuğun şehirde büyümüş bir çocuğa kıyasla doğacı ve bedensel zekâsının daha çok geliştirebileceği söylenebilir.

Ailesel etkenler: Toplumun en küçük birimi olan aile, zekâ gelişiminde en temel çevresel etmenlerdendir. Çocuklarının ne istediğini göz ardı eden aileler kendi arzu ve beklentileri doğrultusunda çocuklarının zekâ alanı gelişiminin seyrini değiştirebilmektedirler. Örneğin bir çocuğun ressam olma isteğini dikkate alamayarak avukat olmasını isteyen aile çocuğun dil zekâsını destekleyecek adımlar atmaktadır.

Tarihsel-kültürel etkenler: Bireyin dünyaya geldiği ve sonra hayatını sürdürdüğü dönem, zekâsının gelişmesinde oldukça önemlidir. Örneğinde o dönemde okullarda fene ve matematiğe dayalı eğitimler ve programlar varsa ve bunlara diğer alanlardan daha fazla ağırlık veriliyorsa o bireylerin mantıksal-matematiksel zekâsı gelişir.

Durumsal etkenler: Çocuk kalabalık bir aile ortamında büyümüş ve kalabalık bir aile de hayatını idame ettiriyorsa, yapısında sosyal olma anlayışı olmadığı takdirde kendisine vakit ayırması ve kendisini geliştirmesi için diğer akranlarına kıyasla daha kısıtlı bir zamana sahiptir.

2.3. Çoklu Zekâ Kuramı

Psikolog Howard Gardner tarafından 1970'lerin sonu ve 1980'lerin başında ortaya atılan çoklu zekâ teorisi, insanların birbirinden oldukça bağımsız sekiz veya daha fazla zekâya sahip olduğunu göstermektedir. Teorinin ortaya çıkışı eğitim ve öğrenim alanında devrim yaratmış, sadece tek bir zekâ türünü tanıyan ve eğitimde tek bir yöntem kullanan geleneksel zekâ kavramına meydan okumuş ve bunun sonucu olarak birçok öğrencinin etkili eğitim fırsatlarından mahrum kaldığı düşüncesine sebebiyet vermiştir (Alsalhi, 2020).

2.4. Çoklu Zekâ Alanları ve Özellikleri

Harvard Üniversitesinde eğitim profesörlerinden biri olan Howard Garner çok yönlü araştırmalarının neticesinde 1983 yılında "Zihin Çerçevesi: Çoklu Zekâ Kuramı" adlı kitabında zekânın yedi farklı formu olduğunu savunmuştur. 12 yıl aradan sonra ise yedi farklı zekâ türüne ek olarak sekizinci zekâ olarak doğa zekâsını da eklemiştir (Campbell ve Campbell, 1999). Gardner'ın savunduğu zekâ türlerine aşağıdaki gibidir:

1. Sözel-Dilbilimsel Zekâ
2. Mantıksal-Matematiksel Zekâ
3. Bedensel- Duyudevinimsel Zekâ
4. Görsel-Uzamsal Zekâ
5. Müzikal-Ritmik Zekâ
6. Sosyal- Bireylerarası Zekâ
7. Özedönük-Bireysel Zekâ
8. Doğacı-Doğa Zekâsı

2.4.1. Sözel-Dilbilimsel Zekâ

İnsan zekâsının üstün bir örneği ve en önemli boyutunun dil olduğunu söyleyen Gardner, dilin toplumsallık için vazgeçilmez olduğu vurgulamaktadır (Demirel ve ark., 2006). Dil, insanlığın varoluşundan itibaren insan beynini geliştirmiştir. Okuma sayesinde, insanlar görmediği nesnelere, yerlere, süreçlere ve kavramları öğrenir ve bu sayede kavramları insanlar için tanıdık hale getirir. Yazma ise konuşmacı ile henüz hiç karşı

karşıya gelmeden haberleşmeyi sağlar. Kelimelerle düşünme yeteneği sayesinde anıları analiz eden insan, problemlere çözüm üretir ve geleceğe yönelik planlar yapar (Campbell ve ark., 1996).

Dil zekâsı, bir dilin temel işlevlerini alenen kullanabilme yeteneği ya da sözcükler zekâsıdır. (Bümen, 2005). Dilin tüm formlarını içeren sözel-dilbilimsel zekâ, hikâye, roman, gazete, şiir okuma; mektup, rapor, şiir vb. yazma; belirli bir kitle karşısında söylev vermek, çevrede bulunan insanlarla iletişim kurmak, çevrede bulunan insanları dinleme ve ayrıca karşısındaki kişinin hem söylediklerinin hem de söylemeyi düşündüklerini anlama gibi davranışları içermektedir (Bümen, 2005).

Lazear (2000)'a göre bu zekânın özündeki kapasiteler; düzeni ve sözcüklerin anlamını kavrama, açıklama-öğretme-öğrenme, mizaha dayalı anlatım, yazılı ya da sözlü olarak etkili hitabet-ikna-güdüleme yeteneği, hatırlama-geri getirme ve metalinguistik analizdir.

Sözel-dilbilimsel zekâsı güçlü olan öğrenenler (Bümen, 2005; Demirel ve ark., 2006);

- Etkili dinleme (anlama, açıklama, özetleme, yorumlama)
- Etkili konuşma (amaçlar doğrultusunda farklı kişilere anlamlı, ikna edici, inandırıcı ve heyecanlı bir şekilde nasıl konuşacağını bilme)
- Etkili okuma yapabilme (okuduğunu anlayabilme, açıklamabilme, özetleyebilme, yorumlayabilme ve hatırlayabilme)
- Etkili yazma (anlama, heceleme ve noktalama, gramer kurallarını uygulama ve etkili kelimeleri kullanma)
- Dinleme ve dönüt verme (ses, ritim, renk ve farklı iletilere)
- Başkasının davranışını yapabilme (konuşma, okuma, ses, yazma vb.)
- Okuyarak, yazarak, dinleyerek ve tartışarak öğrenme
- İsimler, yerler ve tarihler konusunda güçlü bir hafızaya
- Zengin bir kelime haznesine
- Doğru söyleyiş becerisine
- Yeni dilleri kolaylıkla öğrenme becerisine
- Hikâye, şiir, fıkra vb. türlerinde kitaplar okuma, yazma ve anlatma becerisi
- Kelime oyunlarında ve tekerlemelerde başarılıdırlar.

2.4.2. Mantıksal-Matematiksel Zekâ

Mantıksal-matematiksel zekâ, sayılar ve akıl yürütme zekâsı olarak veya daha kapsamlı hali ile tümevarım ve tündengelim mantığı ile akıl yürütme, birbirleri ile alakalı kavramlar ve soyut problem çözüme, düşünceler arasındaki karışık ilişkileri anlama kabiliyeti olarak tanımlamıştır (Bümen, 2005). Mantıksal-matematiksel zekâ ağırlıklı olarak “bilimsel düşünme” ve “tündengelimci-tümevarımcı düşünme” yi hatırlatmaktadır. Mantıksal-matematiksel zekâ, kavramları tanımayı, geometrik şekiller ve sayılar gibi soyut sembollerle çalışmayı, bilginin bölümleri arasında bağlantıları görmeyi ve ilişkiler kurmayı gerektirir (Demirel ve ark., 2006).

Gardner, mantıksal-matematiksel zekânın izlerinin nesnel dünyasıyla tanışmaya kadar sürülebileceğini ifade etmiştir. Küçük bir çocuk nesnel dünyasıyla karşılaştığında, onları düzenli hale getirerek, ardından tekrar tekrar düzenleyerek ve sayarak, mantıksal-matematiksel alanla alakalı olarak ilk ana bilgisini öğrenmektedir. Mantıksal-matematiksel zekâ ile nesnel dünyasının birbirinden ayrılması bu ilk aşamadan itibaren hızlı bir şekilde başlamaktadır. Ardından küçük çocuk, artık insanların nesnel üzerinde yapabileceği işleri, bu işlerin arasındaki bağlantıyı veya mevcut işlerle ilgili ortaya konabilecek teklifleri ve bu teklifler arasındaki bağlantıyı değerlendirebilir duruma gelmektedir. Gelişim süreci bir zincir olarak düşünüldüğünde insan nesnelere önermelere, eylemlerden eylemler arasındaki bağlantılara, duyuşal motor döneminden soyut düşünceye ve son olarak ise bilim ve mantığın zirvesine ulaşırlar (Gardner, 2004).

Mantıksal-matematiksel zekânın sadece sayılar ile ilgili olmadığını iddia eden Lazear, bu zekânın içerisinde barındırdığı “mantık” kısmının çoğunlukla gözden kaçtığını ifade etmiştir. Bu zekânın özündeki kapasitelerin ise; soyut yapıları tanıma, tümevarım yoluyla akıl yürütme, tümünden gelim yoluyla akıl yürütme, bağlantı ve ilişkileri ayırt etme, karmaşık hesaplamalar yapma ve bilimsel yöntemi kullanma olarak sıralamıştır (Lazear, 2000). Soyut işlemlere karşı oldukça hassas ve duyarlı olan bu zekâyâ sahip bireyler, hesaplayarak, kategori ve sınıflara ayırarak, mantık yürüterek, genelleme yaparak soyut ilişkiler üzerinde çalışarak çok daha iyi bir şekilde öğrenirler (Durmuş, 2013). Karışık resimlerden şekil çıkarma, benzer şeyleri eşleştirme, bulmaca, matematik ve problem çözüme gibi konulardan hoşlanan bu

bireylerin mesleklerine; muhasebeciler, bilim insanları, matematikçiler, bilgisayar programcıları, mühendisler ve istatistikçiler örnek olarak verilebilir (Demirel ve ark., 2006).

Mantıksal-matematiksel zekâsı güçlü olan öğrenenler (Bümen, 2005; Demirel ve ark., 2006);

- Nesnelerin aralarındaki bağlantıyı algılama,
- Hipotez kurma ve kurulan hipotezi test etme,
- Soyut düşünme becerisine sahip olma,
- Deneyle tasarlama, uygulama ve neticeyi kestirme,
- Olayların nasıl ortaya çıktığına yani oluşumu üzerinde düşünme gücüne,
- Mantığa dayalı problemlerin çözümü sürecinde üstün beceriye sergileme,
- Problem çözüm basamaklarını kullanarak hesap yapabilme, eldeki sayısal verileri grafik formlarında görsele dökebilme ve istatistikleri yorumlayabilme,
- Matematik alanındaki problemleri çözme sürecinde teknolojiyi kullanma,
- Bilgisayar teknolojisi, mühendislik, hesap uzmanlığı, hukuk, kimya gibi meslek gruplarına karşı ilgili olma,
- Yer, zaman, sebep ve sonuç ilişkilerini ortaya çıkarma kabiliyetine sahiptirler.

2.4.3. Bedensel-Kinestetik (Duyudevinimsel) Zekâ

Gardner, yüzyılımızın geleneği olan beden ve zekânın birbirinden ayrı olarak incelenmesinin yanlış bir yaklaşım haline geldiğini savunmuştur. Bedensel-kinestetik zekâ beden ile zekâyı fiziksel bir performansta birleştirir. Başka bir deyişle duygu ve düşünceleri ifade ederken ya da problemleri çözerken bedeni kullanma kabiliyetidir (Demirel ve ark., 2006). Bu zekâ vücut hareketlerini kontrol edebilmeyi ve yorumlamayı, aynı zamanda zihin ile vücut arasında bir uyum oluşturmayı sağlamaktadır (Bümen, 2007). Bu zekâ boyutunun en belirgin özelliğinin zihin-kas koordinasyonundaki üstün başarı olduğu ifade edilmektedir (Demirel ve ark., 2006). Sadece atletik

yapıya sahip olanların bedensel-kinestetik zekâlarının geliştiğini düşünmek yanlış bir öngörüdür. Bir pilotun uçakta göstergelerin ince ayarlarını yapması esnasında göstermiş olduğu performans ya da bir kalp cerrahinin açık ameliyat sırasında göstermiş olduğu ince-devinim kontrolü bu zekânın gelişimini gözler önüne sermektedir (Bellanca, 1997).

Bu zekânın özündeki kapasitelerin ise; bedeninin farkında olma, vücut hareketlerini kontrol etme, önceden planlanmış olan vücut hareketlerini kontrol etme, beden ve zihin arasında bir bağ kurma, pandomim yetenekleri, bedeni tamamıyla iyi kullanma olarak sıralanmıştır (Lazear, 2000). Bedensel-kinestetik zekâsı gelişmiş olan mesleklere; aktörler, dansçılar, atletler, heykeltıraşlar ve zanaatkârlar örnek olarak verilebilir (Armstrong, 2003).

Bu zekâ alanı yüksek olan bireyler, hareket ederek öğrenir ve uzun süre hareketsiz duramazlar, çeşitli spor dalları ile uğraşırlar, hareket etmeyi, dans etmeyi, dokunmayı severler, model maket yapma ya da ürün oluşturmak gibi fiziksel aktivitelere katılırlar, el becerisi gerektiren işlerde maharetlidirler, söylenenlerden çok yapılanları akıllarında tutarlar, rol yapma alanlarında da kabiliyetleri vardır (Vural, 2004).

Uzun zamandır yaparak yaşayarak öğrenme eğitimde önem kazanmıştır. Bedensel-kinestetik zekânın yaparak yaşayarak öğrenmeye en çok hizmet eden zekâ alanı olduğu düşünülmektedir (Demirel ve ark., 2006).

Bedensel-Kinestetik zekâsı güçlü olan öğrenenler, (Bümen, 2005; Demirel ve ark., 2006);

- Nesnelere temas ederek tanıma isteği,
- Zamanlama konusunda başarılı olma,
- Somut öğrenime daha fazla eğilimli olma,
- Fiziksel performans gerektiren oyunlarda başarılı olma,
- Dans etmekten ve spor yapmaktan hoşlanma ve bu konularda başarılı olma,
- Uzun süre hareketsiz bir şekilde duramayıp sürekli bir kıvılcama ihtiyacı hissetme,
- Nesnelere parçalarına ayırıp daha sonra tekrar birleştirip bütün hale getirme becerisine,

- Vücudunu kontrol altında tutma becerisine ve koordinasyonu sağlamada başarılı olma,
- El becerisi gerektiren işlerde ortaya başarılı ürünler çıkarma gücüne sahiptirler.

2.4.4. Görsel Uzamsal Zekâ

Gardner, uzamsal zekânın özünü, görsel dünyayı doğru şekilde algılamak, bu ilk algının üzerinde çeşitli değişim ve dönüşümler yapabilmek, bir fiziksel uyarıcı olmadan da görsel deneyimi tekrardan üretebilmek olarak açıklamıştır (Gardner, 2004). Bu zekâ türünde beyin sözcüklere ulaşmadan önce resimler ve imajlar ile düşünür. Yani bu zekânın dili, desenler, resimler, şekiller, imajlar, dokular, renkler ve diğer görsel sembollerdir (Lazear, 2000).

Görsel-uzamsal zekâ türü gelişmiş olan insanlar zihinlerinde birtakım resimler oluştururlar ve daha sonra bunları çizerler. Bunun yanı sıra, renkleri kullanma, yaratıcılık, harita okuma gibi becerileri iyi gelişmiş ve oldukça iyi hayal güçlerine sahiptirler (Demirel ve ark., 2006). Ayrıca görsel sunumları sever, okurken sözcüklerden ziyade resimlerden daha iyi anlar, görsellerden ve tasarımlardan zevk alır, sanat aktivitelerinden hoşlanırlar.

Bu zekânın özündeki kapasiteler ise; hayal gücü, zihinde canlandırma, uzayda yer-yol bulma, grafik temsili, uzaydaki nesnelere arasındaki ilişkiyi tanıma, imajlarla zihinsel manevralar yapma ve objeler arasındaki benzerlikleri/farklılıkları tanıma olarak sıralanmıştır (Lazear, 2000). Görsel-uzamsal zekâsı gelişmiş olan mesleklere; ressam, mimar, heykeltıraş, bahçıvan, grafik tasarımcılar ve katoğraflar örnek verilebilir. Bu meslek gruplarındaki bireyler zihinlerindeki imgeleri, oluşturmak ve geliştirmekte oldukları yeni nesnelere iletirler. Bu şekilde görsel algılar, eski bilgilerle, tecrübeyle, duygularla ve simgelerle birleşir ve yeni bir görüntü ortaya çıkar (Bellanca, 1997).

Görsel-uzamsal zekânın göstergeleri olarak; hayal kurma, fikir ya da duygu-düşüncelerini ifade etmek için boya, renkli ve keçeli kalemler kullanma, tasarım yapma, görsel detaylarla ilgilenme, ayrıntılı bir şekilde tasvirler yapabilme, zihinde haritalar oluşturma, üç boyutlu düşünebilme, heykel-mimari-grafik-resim gibi alanlara ilgi duyma olarak sıralanabilir (Demirel ve ark., 2006).

Görsel-Uzamsal zekâsı güçlü olan öğrenenler, (Bümen, 2005; Demirel ve ark., 2006);

- Resim, kroki, heykel, karikatür, çizim, maket gibi modeller ortaya çıkarma becerisine,
- Hayal kurma becerisine,
- Üç boyutlu görsellere karşı hassas olma,
- Düşüncelerini ya da fikirlerini ifade etmede boya, renkli keçeli kalemler ya da kil tarzı malzemeler ile çalışma
- Renklere ve şekillere karşı hassas olma,
- Materyallerde kelimelerden ziyade resimlere ve çizimlere dikkatini verme
- Görsel imgeleri yazılara oranla çok daha iyi akılda tutma becerisine,
- Detaylı tasvirler yapabilme,
- Lego, origami, yap-boz gibi görsel içerikli oyunlarda başarılı olma,
- Zihinde nesnelere tasarlama, haritalar oluşturma gibi becerilere sahiptirler.

2.4.5. Müzikal-Ritmik Zekâ

Müzikal-ritmik zekâ diğer zekâ alanlarıyla ilişkili olmayabilen, kendine özel kuralları ve düşünme yapılarına sahip olan bir alandır (Gardner, 2004). Lazear müziksel-ritmik zekâ ile ilgili olarak önemli bir nokta üzerinde durmuştur. Çevredeki çeşitli seslerden anlamlar çıkarabilme, arabanın motor sesinden yola çıkarak bir problem olup olmadığını anlayabilme, insanların ses tonundan ruhsal durumu hakkında çıkarımlarda bulunma gibi davranışlar ilk başta müziksel-ritmik zekânın ilgili bir kısmı olarak algılanmasa da aslında bu zekânın önemli bir parçası olan yetilerdir (Lazear, 2000). Bu zekâ diğer zekâ türlerine kıyasla çok küçük yaşlarda gelişmeye başlayan zekâ alanıdır.

Müziksel-ritmik zekânın özündeki kapasiteler ise; müzikle ilgili şemalar oluşturma, müziğin ve ritmin yapısına önem verme, seslere karşı hassasiyet ve duyarlılık gösterme, melodi, ses ve ritimleri taklit etme ve tanıma, ritimlerin ve tonların çeşitli özelliklerini kullanma olarak sıralanmıştır (Lazear, 2000).

Bu zekâsı yüksek olan bireyler, notasını görmediği müzikleri tanıyabilir, enstrüman çalabilir, seslere karşı oldukça duyarlı, çalarken ritim tutabilir, şarkı söylemeyi kolaylıkla öğrenebilir, müziği hayatlarına kolaylıkla entegre edebilir, şarkı söylemeyi sever ve seslere-notalara ve ritimlere karşı özel ilgi duyarlar (Vural, 2004).

Müzikal-Ritmik zekâsı güçlü olan öğrenenler, (Bümen, 2005; Demirel ve ark., 2006);

- Farklı müzik türlerini, stillerini, kültürel yönden değişimini tanıma, ayırt etme ve ilgi duyma becerisine,
- İyi bir düzeyde müzik kulağına,
- Şarkı söyleme kabiliyetine,
- Bir ya da daha fazla sayıda müzik enstrümanını çalma yeteneğine,
- Kendine özgü besteler yapma ve enstrümanlar tasarlama becerisine,
- Belli ya da farklı bir müzik türünde kişisel bir müzik arşivi oluşturma âdetine,
- Müzikle mırıldanma ve ritm tutma isteğine,
- Çeşitli sesleri (insan sesi, çevredeki sesler ve müzikal sesler gibi) seslere karşı duyarlı olma, ilgiyle dinleme ve tüm bunlar karşısında tepki gösterebilme becerisine,
- Müziğe yönelik mesleklere karşı ilgi duyma becerisine sahiptirler.

2.4.6. Sosyal- Bireylerarası Zekâ

Sosyal-bireylerarası zekâ, çevredeki bireylerle iletişim kurma, bu kişilerin ruh hallerini tanıma, bireyleri anlama gibi birtakım davranışları içerisinde barındırır (Bümen, 2007). Liderlik özellikleri ağır basan bu bireyler arkadaş çevrelerinde oldukça popüler olmalarının yanı sıra arkadaşlarına değer verir, onları düşünür ve onlar için endişe ederler (Çakan, 2006). Grup çalışmaları, takım oyunları ve grup projeleri yapmaktan hoşlanır ve grup içerisinde yardımlaşma, dayanışma halinde olarak birbirlerine olabildiğince destek olurlar (Demirel ve ark., 2006).

Bu zekâsı gelişmiş olan bireylerin özellikleri arasında, karşıdaki bireyin duygularına, inançlarına, meraklarına ve korkularına empati gösterme, yargılamadan dinleme ve bireylerin mevcut performansını çeşitli yollarla en

üst seviyeye çıkarmalarında yardımcı olmak gibi davranışlar sıralanabilir (Bellanca, 1997). Bu bireyler çok sayıda arkadaş edinebilir, insanlarla konuşmaktan ve çeşitli gruplara dâhil olmaktan hoşlanırlar. İnsanları dinlemeyi, anlamayı, düzenlemeyi, yönetmeyi, iletişim kurmayı çok severler ve bu becerileri geliştirmiştir. Bu zekâsı güçlü olan insanlar, yönetim, öğretmenlik, danışmanlık, pazarlama, işletme, psikolojiler ve politika gibi alanlarda yeteneklerinin iyi kullanarak başarılı bir şekilde çalışabilirler (Campbell ve ark., 1996).

Sosyal-kişilerarası zekânın özündeki kapasiteler ise; insanlarla etkili iletişim kurma, bireyin ruhsal durumunu anlayabilme, grupta iş birliği içerisinde çalışma, karşıdaki kişiyle empati kurabilme, karşıdaki bireyin bakış açısıyla dinleme, sinerji kazanma ve yaratma olarak sıralanmıştır (Lazear, 2000).

Sosyal- Bireylerarası zekâsı güçlü olan öğrenenler, (Bümen, 2005; Demirel ve ark., 2006);

- Arkadaşlar ortamında daha mutlu olma duygusu,
- Bireylerle ilişki kurmada oldukça rahat,
- İkna etme kabiliyeti yüksek,
- Empati kurma becerisi yüksek,
- Paylaşma, iş birliği içerisinde bulunma ve öğretme isteği yüksek,
- Grup çalışmalarında çoğunlukla liderlik görevini üstlenme eğiliminde olma
- Problem yaşayan kişilere yardımcı olma alışkanlığı,
- Kendini başkalarını yerine koyarak onları içtenlikle dinleyip ne söylediklerini ve ne hissettiklerini anlama gibi becerilere sahiptirler.

2.4.7. Özedönük-Bireysel Zekâ

Gardner günlük hayattaki en önemli zekânın özedönük- bireysel zekâ olduğunu belirtmiştir. Kişinin kendisi ile ilgili bilgisinin olması, kendini tanıması ve bu bilgiler ışığında kararlar almasıdır (Armstrong, 2000). Kişinin kim olduğunu bilmesi ve hangi duyguları neden hissettiğini düşünmesi bu zekâ kapsamındadır (Demirel ve ark., 2006). Birey kendi coşkularının sınırlarının farkında ise, davranışlarını yönetirken emin adımlarla

ilerleyebiliyor ise bu kişi özedönük zekâsı güçlü olan bir bireydir (Bümen, 2007). Bu zekâsı güçlü olan bir birey zamanında düşünebilme, cevaplayabilme ve kendini değerlendirebilme konusunda diğer bireylere kıyasla daha başarılıdır (Bellanca, 1997).

Kişilerin birtakım soruları yanıtlaması öze dönük zekâ ile yakından ilgilidir. Bu sorular; “Tek kaldığımda beni hangi etkinlikler dinlendire bilir?, Ben gerçekten kimim?, Sinirli olduğum bir durumda bunu hangi yöntem ile yenebilirim?, Kişisel gelişimim adına neler yapıyorum? gibi sorulardır (Bümen, 2007). Din adamları, psikologlar, felsefeciler, yazarlar, şairler ve araştırmacılar özedönük-bireysel zekânın meslek grupları olarak sayılabilir (Demirel ve ark., 2006).

Özedönük-bireysel zekânın özündeki kapasiteler ise; konsantrasyon, düşünsellik, yürütücübiliş/üstbiliş, değişik duyguların farkında olma, “öz” ü tanıma ve değer verme ve son olarak yüksek düzeyli düşünme ve akıl yürütmedir (Lazear, 2000).

Özedönük-bireysel zekâsı güçlü olan öğrenenler, (Bümen, 2005; Demirel ve ark., 2006);

- Güçlü ve zayıf yönleri hakkında objektif davranabilme,
- Kendine güvenme,
- Özgürlüğüne düşkün olma,
- Başarı ve başarısızlıklarında ders çıkarma becerisine,
- Kendisiyle barışık olma ve kendisine saygı duyma becerisine,
- Kendini iyi hissettiren en az bir tane hobiye,
- Grup çalışmalarından ziyade kendi kendine çalışma ve öğrenme becerisine,
- Günlük tutma,
- Kendi yaşamına dair bir hedef belirleme ve başarma gibi becerilere sahiptirler.

2.4.8. Doğacı-Doğa Zekâsı

Gardner doğa zekâsı gelişmiş olan bireyler için; canlılara, bulutlara, taşlara karşı hassas olmak, doğada bulunan varlıkları sınıflandırmak ve bu varlıklar hakkındaki düzenlemeleri takip ederek aşına olmak gibi sözler

kullanmaktadır (Demirel ve ark., 2006). Bu zekâ alanında gelişmiş olan kişiler küçük yaşlardan itibaren doğa olayları ve hayvanlar ile ilgili öykülerden hoşlanır, doğadaki canlı ve cansız varlıkların isimlerinin ve özelliklerini kolayca öğrenebilir, taş-tüy-kelebek-fosil-deniz kabuğu gibi şeyleri biriktirerek koleksiyon yapmaktan hoşlanırlar. Doğada yaşanabilecek başkalarının fark etmesi zor olan çok küçük değişiklikleri dahi fark edebilir, benzerlikleri, farklılıkları ve anormal durumları kolaylıkla ayırt edebilirler. Yürüyüş, kamp ve dağcılık gibi doğa ile iç içe açık hava ortamında yapılan faaliyetleri seven bu bireylerin aynı zamanda duyuusal becerileri de bir hayli güçlüdür (Demirel ve ark., 2006).

Doğa zekâsı gelişmiş olan kişiler çok küçük yaşlardan itibaren kendilerini gösterebilirler. Örneğin 3-4 yaşlarındaki bir çocuk çoğu yetişkine kıyasla dinazorları çok daha iyi tanımlayabilmektedir. Charles Darwin ve Kaptan Cousteau çok bilinen doğa zekâsı gelişmiş olan insanlardır (Bümen, 2007).

Arkeologlar, zoologlar, biyologlar, çevre bilimciler, çiftçiler, ziraat mühendisleri, jeologlar ve meteorologlar doğa zekâsına ait meslek grupları olarak sayılabilir (Demirel ve ark., 2006).

Doğacı-Doğa zekâsının özündeki kapasiteler ise; doğa ile bütün haline gelme, doğal bitki örtüsüne karşı duyarlı olma, canlılar ile etkileşim halinde olma ve onları koruma, doğanın verdiği tepkilere karşı hassas ve farkında olma, doğadaki canlıları tanıma ve onları sınıflandırma ve son olarak bitki yetiştirmedir (Lazear, 2000).

Doğacı-Doğa zekâsı güçlü olan öğrenenler, (Bümen, 2005; Demirel ve ark., 2006);

- Doğada meydana gelen değişimlere karşı duyarlı olma,
- Bitki türlerine, bakımına ve yetiştirilmesine karşı duyarlı olma,
- İklim olaylarına ve mevsimlere karşı ilgi duyma,
- Çevre bilinci yüksek,
- Doğal yaşamın bir parçası olmaktan dolayı mutlu olma,
- Doğa da bulunan gerek canlı gerek cansız varlıklara karşı ilgi duyma, onları tanıma ve sınıflandırabilme,
- Evcil hayvan besleme isteğine,

- Doğadaki bazı canlılardan (böcek, kelebek vb.) koleksiyon yapma,
- Çevreci faaliyetlere katılmak, lider görevler üstlenme eğilimine,
- Botanik bahçeleri, hayvanat bahçeleri ve tarihi müzeleri gezme isteğine sahiptirler.

2.5. Yapay Zekâ

Eğitim disiplini “zekâ nedir?” sorusuna yönelik henüz tam anlamıyla bir cevap vermezken yapay zekânın ne olduğu konusunda net bir tanım yapmak oldukça zordur. Yapay zekâ herkesin üzerinde hemfikir olduğu bir tanımı olmayan, farklı tanımlara maruz kalan bir bilim dalıdır. Yapay zekânın sosyolojiden tıbbi bilimlere, mühendislikten psikolojiye ve daha birçok alanda uygulanıyor olması (Doğan, 2002), yapay zekâ alanında çok farklı tanımların ortaya çıkmasına sebebiyet vermektedir. Çünkü farklı alanlarda çalışmasını yürüten araştırmacılar kendi alanlarının vermiş olduğu eğilim doğrultusunda tanım yapmaktadırlar. Bu durumda tanımlarda bazen felsefi boyut ağır basarken bazense teknik bir dil hâkim olmaktadır. Bu tanımlardan bazıları şu şekildedir:

Kaplan ve Haenlein (2019), yapay zekâyı dış verileri yorumlayan ve uyarılma yolu ile belirli bir hedefi ya da görevi yerine getirmek için bu öğrenmeleri öğrenen ve kullanan sistemler olarak tanımlamaktadır. Chiu ve arkadaşları (2022), akıllı varlıklarla ilişkilendirilen görevleri dijital bir makinenin yerine getirme yeteneğidir. Nabiyeve ve Erümit (2020)’ e göre yapay zekâ, bir canlı organizmadan yararlanmaksızın, bütünüün yapay araçlar ile oluşturulduğu insan davranışlarına benzer nitelikte hareketler sergileyebilen, insanlara ait olan düşünme, karar verme, hissetme, muhakeme yürütme ve öğrenme gibi davranışların yapılabilmesi için bilgisayarın kontrolünde olan teknolojiye verilen isimdir. Nilsson (2010)’a göre yapay zekâ, makinelere zekâ kazandırmaya adanmış faaliyetlerdir. Slage yapay zekâyı tanımlarken “Sezgisel programlama temelinde bir yaklaşım” olarak ifade etmiş, Tesler ise yapay zekâyı şimdiye kadar yapılmayanlardır diye bir tanım yapmıştır (Nabiyeve ve Erümit 2020). Kurzweil (1990), yıllar önce yapay zekâyı tanımlarken, insanlar tarafından gerçekleştirildiğinde zekâ gerektiren işlevleri yerine getiren makineler yaratma sanatı olarak ifade etmiştir. Bu tanımın üzerinden oldukça uzun bir zaman geçmesine rağmen,

yapay zekâyı tanımlamak için hala etkili bir başlangıç noktası sağladığı düşünülmektedir (Mertala ve ark., 2022). Öncelikle bu tanım yapay zekânın tek başına zeki olmadığını, fakat zeki olduğu düşünülen görevleri başarı ile tamamlayabileceğini öne sürmektedir. İkinci olarak ise tanım, yapay zekânın dijital olduğunu vurgulamaktadır.

Yapay zekâ birçok uzman tarafından yapılan farklı tanımlara maruz kalsa da henüz evrensel olarak kabul edilmiş bir tanımı sahip olmayan “bulanık bir kavram” olarak kalmıştır (Emmert-Streib ve ark, 2020; Kaplan ve Haenlein, 2019). 1956 yılında gerçekleştirilen Dortmund Konferansı’nda John McCarthy, Marvin L.Minsky, Nathaniel Rochester ve Claude E. Shannon tarafından yapay zekâ kavramı olarak bir öneri mektubunda belirtilmiş olmasına karşılık kavramın yaratıcı olarak John McCarthy kabul edilmektedir (Coppin, 2004).

Makine zekâsının insan zekâsıyla karşılaştırılmasına dayanan üç zekâ aşaması ve dönemi yapay zekâ araştırmacıları topluluğu tarafından tanımlanmıştır. Bunlar ilki dar ya da zayıf zekâ, ikincisi yapay genel ya da güçlü zekâ, üçüncüsü ise yapay süper zekâdır. Yapay dar ya da zayıf zekâ olarak adlandırılan ilk aşama, şundaki mevcut duruma karşılık gelen yani bugüne karşı başarılı bir şekilde gerçekleştirilmiş (Fjelland, 2020), tek bir göreve ya da hedefe ulaşabilmek için bağımsız bir şekilde makine öğrenimi gerçekleştirebilen aşamadır. Bu zekâyı örnek olarak; kendi kendini süren arabaların tamamı, satranç ve go oynamak, yüz tanıma, internette arama, hesaplamalı fotoğrafçılık, tahmine dayalı öneriler ve konuşma tanıma/ses asistanları, Google translate verilebilir. Hedefe odaklı olan yani hangi görevi yapmaya planlandysa o görevi tamamlama konusunda oldukça zeki olan yapay dar zekâ, her ne kadar akıllı görünse de bir dizi sınırlama ve kısıtlamalar altında çalıştığı için bazen zayıf yapay zekâ olarak da adlandırılır. Yapay zekânın ikinci aşaması olan yapay genel zekâ ise makine zekâsının doğal insan zekâsına rakip olarak ayarlandığı yapay zekâdır. Bir durum karşısında tıpkı bir insan gibi düşünebilir, anlayabilir ve hareket edebilir. Bu aşamada makine zekâları kendi algılarına sahip olabilmeye, karmaşık kararlar verebilmeye ve ilgisiz düşünceler arasında çoklu görev yapabilmeye yetisine sahip olabilecektir. Yapay zekâ araştırmacıları ve bilim insanları henüz genel yapay zekâyı ulaşamamışlardır. Son aşama olan yapay süper zekâ ise artık makine zekâsının

insan zekâsını aştığı, insanların kapasite sınırını aştığı karmaşık orijinal düşünceleri ve yaratıcılığı gerçekleştirebildiği zaman olarak ifade edilmektedir (Dickson, 2017).

Yapay zekânın ele aldığı konular; problem çözümü, oyunların modellenmesi, bilgilerin modellenmesi, otomatik teorem ispatı, uzman sistemler, doğal dilin işlenmesi, ses işleme, örüntü tanıma, bilgisayar yaratıcılığı ve robotik olarak büyük sınıflara ayrılabilir (Nabiyev ve Erümit, 2020).

17. yüzyılın ortasından günümüze kadar bilgisayar teknolojileri ile yapay zekânın geçirmiş olduğu evrim ve bu süre zarfında alanda yaşanan önemli gelişmeler Şekil 1'deki gibi özetlenebilir.

- Charles Babbage ve Ada Lovelace tarafından ilk programlanabilir makine tasarlanmıştır.
- Warren McCulloch ve Welter Pitts tarafından kurulan sinir ağlarının temelleri, beyin ve hesaplama makineleri arasındaki paralellikleri ortaya koymuştur.
- Alan Turing, bir makinenin zekâsını test etmenin bir yolu olarak Turing testini tanıtmıştır.
- Dartmount konferansında “Yapay zekâ” kavramı ortaya çıktı.
- Bir doğal dil işleme programı olan ELİZA oluşturuldu.

İkinci dönem, 1971-2000 yılları arasındaki zaman dilimini kapsamakla birlikte uzmanlaşma ve mantık evresi olarak tanımlanmaktadır. Bu dönemde uzman sistemler, YSA’ların ve modeller ile çalışan uygulamaların geliştirilmiştir.

- Edward Feigenbaum, insan uzmanların kararlarını taklit eden uzman sistemleri oluşturdu.
- Bilgisayar programı olan Deep Blue, dünya satranç şampiyonu Garry Kasparov’u yendi.

Üçüncü dönem, 2001-2019 yılları arasındaki zaman dilimini kapsamakla birlikte bilgiyi öğrenme ve bilgiyi anlamlandırma evresi olarak tanımlanmaktadır. Bu dönemde derin öğrenme ve büyük veri işleme yöntemlerinin geliştirilmiştir. Ayrıca yapay zekâ teknolojisinin uygulamalarının günlük hayatımıza entegre edilmesi bu dönemde gerçekleşmiştir.

- İrobot engellerden kaçınan otonom bir elektrikli süpürge olan Roomba’yı piyasaya sürdü.
- Google, kentsel koşullara uygun ilk kendi kendine giden arabayı üretti.
- IBM’ den Watson ABD’deki oyun şovu Jeopardy şampiyonlarını yendi.
- Siri, Google Asistan, Cortana, Alexa gibi kişisel asistanlar soruları cevaplamak ve basit görevleri yerine getirmek için konuşma tanımayı kullanmaya başladı.
- Lan Goodfellow Çekişmeli Üretici Ağları (GAN) tanıttı.

- Google tarafından geliştirilmiş olan Alphago programının, profesyonel Go oyuncusu Koreli Lee Se-dol' u 4-1 yendi.
- Birçok üniversitenin Yapay Zekâ alanında dersleri var.

2.5.1. Yapay Zekânın Eğitimde Kullanımı

İnsan ve diğer canlı türler tarafından sergilenen doğal zekâ ile mukayese edildiğinde canlı olmayan bir varlık tarafından gösterilen makine zekâsına yapay zekâ denir (Leahy ve ark., 2019). Geleceğe yön verecek stratejik bir teknoloji haline gelen yapay zekânın gelişimi ile birlikte akıllı telefonlar, arama motorları, yüz tanıma, makine çevirisi, akıllı tıbbi tedavi ve otonom sürüş gibi modern topluma olumlu değişiklikleri de beraberinde getirmiştir (Li ve Wang, 2020). İnsanlar farkında olsun ya da olmasın yapay zekâ insanların günlük işlerine ve yaşamlarına fazlasıyla nüfuz etmiş ve yaşam tarzlarını önemli düzeyde değiştirmiştir.

Günümüz dünyasının en popüler teknolojilerinden olan yapay zekâdan endüstri, enerji, sağlık, iletişim ve yazılım geliştirme, sesli asistanlar, konum bulma, bilgiye hızla ulaşma, sosyal medya, eğlence, finans, bankacılık gibi hemen hemen her alanda aktif bir şekilde yararlanmaktadır. Birçok alanı etkisi altına alan yapay zekânın eğitimde de kullanılıyor olması aslında hiç şaşırtıcı değildir. Yapay zekâ birçok alanda etkisini göstermiş ve oldukça fazla sayıda çalışmaya konu olmuştur. Ancak eğitimde diğer alanlara ya da sektörlere kıyasla etkisi sınırlı kalmış olsa da son yıllarda artan bir ivme yakalamış ve bu sektörde de önemli başarılar kazanmıştır (Murphy, 2019). Yapay zekâ teknolojisinin, 1950'li yıllarda kavram olarak ilk ortaya atılışından günümüze kadar geçen zamanda eğitim alanında kullanımı giderek artmış ve kullanım alanlarına yenileri eklenmiştir. Birçok kişi yapay zekânın eğitim alanında uygulanmadığını düşünse de yapay zekâ çoktan sınıf ortamına girmiş ve "akıllı, uyarlanabilir ya da kişiselleştirilmiş öğrenme sistemleri" gibi kavramlarla dünya çapında gerek liselerde gerekse üniversitelerde eğitimi çok farklı boyutlara taşımayı başarmıştır. Bu süreç daha fazla öğrenciden daha fazla veri toplanması ve analiz edilmesi ile devam etmektedir.

Yapay zekâ teknolojisinin eğitimde kullanılmasının amacı diğer teknolojilerde de olduğu gibi öğrenmeleri desteklemek, öğrenme ortamlarına yenilerini eklemek ve böylelikle eğitimin kalitesini, niteliğini artırarak eğitimi

en verimli hale getirmektir. Bunun yanı sıra öğrencilerin günümüz teknolojilerinden olan yapay zekânın mantığını anlamalarını, nasıl tasarlanacağını ve kullanılacağını öğrenerek hayatlarının ileri süreçlerinde kullanabilecekleri bilgi birikimi oluşturmalarını sağlamaktır (Korucu ve Biçer, 2020). Tüm bu amaçlar doğrultusunda eğitimde yapay zekâ teknolojisinden yararlanılmaya çalışılmakta ve daha fazla nasıl yararlanır sorusuna cevap bulmak adına yapılan çalışmaların sayısı günden güne hız kazanmaktadır. Yapay zekânın eğitimde farklı rolleri üstlendiği söylemek mümkündür.

Baker ve arkadaşları (2019), okullarda kullanılan eğitimsel yapay zekâ araçlarına öğrenciye yönelik, öğretmene yönelik ve sisteme yönelik olmak üzere üç farklı perspektiften yaklaşmıştır. Öğrenciye yönelik olan yapay zekâ araçları “akıllı öğretim sistemleri” ya da “uyarlanabilir”, “kişiselleştirilmiş” ya da “farklılaştırılmış” öğrenme platformları ile öğrencilerin bilgiyi alma ve anlama konusunda bireysel ihtiyaçlarına yanıt veren yazılımlardır. Bu platformlar öğrencilerin ihtiyaçlarına göre öğrenme materyali düzenleyebilir, otomatik geri bildirim sağlayabilir, öğrenciler arasındaki iş birliğini kolaylaştırabilir ve öğrencinin bilgisindeki güçlü yanları, zayıf yanları veya boşlukları tespit edebilir. Öğretmene yönelik olan yapay zekâ araçları yönetim, değerlendirme, geri bildirim ve intihal tespiti gibi görevleri otomatikleştirerek öğretmenin mevcut iş yükünü azaltmak ve öğretmeni çeşitli açılardan desteklemek için kullanılmaktadır. Bunun yanı sıra öğretmene öğrencilerin ve sınıfın ilerlemesi hakkında bilgi verir. Bir öğretmenin iş yükünün azalması ya da zamandan kazanması öğretimin diğer yönlerine yatırım yapmasına fırsat vermektedir. Sisteme yönelik olan yapay zekâ araçları ise öğrenciye yönelik ve öğretmene yönelik olan araçlardan daha geniş bir görev yelpazesi için kullanılır fakat eğitimde yapay zekânın en az yaygın olan kategorisidir. Fakülteler ya da kolejler arasındaki yıpranma modellerini izlemek için, kurumsal düzeyde yöneticiler için bilgi sağlayan sistemlerdir.

Eğitim alanında yapay zekâ teknolojisinden etkilenen birçok bölümün olduğuna yapmış olduğu çalışmasında yer veren Rana ve arkadaşları (2021), eğitimde yapay zekâ çalışmalarına yönelik olarak uyarlanabilir, derecelendirme ve öğrenciye anında ve anlamlı bir şekilde geri bildirim

sağlama gibi başlıklar altında çalışmasına odaklanmıştır. Chassignol ve arkadaşları (2018), Yapay zekânın eğitim üzerindeki etkisini belirlemek ve bu alana geniş bir bakış açısı sunmak amacıyla yaptığı çalışmasında, eğitim sürecinin yapay zekâdan etkilenebilecek dört ana bölümünü ele almıştır. Bunlar; içerik, öğretim yöntemleri, değerlendirme ve iletişimdir. İçerik ve öğretim yöntemleri olarak; eğitim içeriğinin özelleştirilmesi, kişiselleştirilmiş öğrenme ve eğitici robotlar kavramlarına, değerlendirme olarak kitlesel açık çevrimiçi kursların değerlendirmesinde basitleştirme ve öğrenmedeki boşlukların belirlenmesi konularına, son olarak ise iletişim başlığı altında akıllı öğretim sistemleri üzerinde durulmuştur. Diğer alanlarda olduğu gibi eğitimde de kullanılan mevcut yapay zekâ uygulamaları yapay zekâ topluluğunun dar ya da zayıf olarak adlandırdıkları gruba dâhildir (Murphy, 2019).

2.5.2. Eğitimde Yapay Zekâ Uygulamaları

Eğitimde yapay zekânın uygulama alanları; uzman sistemler, akıllı öğretici sistemler ve diyalog tabanlı öğretici sistemler başlıkları altında incelenebilir (Arslan, 2020).

Uzman Sistemler, 1960'lı yıllarda Nobel Fizyoloji ve Tıp Ödülü Sahibi J. Lederberg'in spektrograf verilerinin bilgisayarlı yorumları üzerine gerçekleştirmiş olduğu çalışmalar ile ortaya çıkan (Nabiyev, 2003), adından da anlaşılacağı üzere herhangi bir alanda tecrübe kazanmış kişi veya kişilerin yapabileceği seviyedeki görevleri, çok sayıda yapay zekâ algoritmaları kullanarak yapabilen bilgisayar programları olarak ifade edilebilir. Baştan sona insan zekâsına ve tecrübelerine dayanarak oluşturulan uzman sistemlerin aktif olarak kullanılabilmesi için bilgi tabanı, bilgi yenileme, karar mekanizması ve ara yüz olmak üzere dört ana modüle gereksinim vardır (Önder, 2003). Bir insan yaşamı boyunca yeni bilgiler edinmekte, yıllar içerisinde görüşleri değişmekte, derinleşmekte ve olgunlaşmaktadır. Uzman sistemlerde de durum benzer şekilde, bilgi tabanını büyütebilmeli ve yeni bilgiler eklenmesi ile birlikte yeniden programların yazılması durumu ortadan kaldırılmalıdır (Nabiyev, 2003). Uzman sistemlerin eğitim amaçlı kullanıldığı alanlardan biri uzaktan eğitimidir (Uzun ve ark., 2021). Uzaktan eğitim sürecinde öğrenciye verilen kişiselleştirilmiş yanıtlar ve problemler

aracılığıyla elde ettiği yanıtlar ile uzman sistemler veri tabanını genişletmektedir. En çok bilinen uzman sistem örneği Stanford Üniversitesinden Profesör Feigenbaum, Lederberg ve Buchanan tarafından, tıp alanında bakteri enfeksiyonları ve tedavileri hakkında danışmanlık yapacak MYCIN adını verdikleri bilgisayar programıdır (Doğaç, 2015). Yapay zekânın bir uygulama alanı olan uzman sistemler, birkaç yönden yapay zekâdan farklılık göstermektedir. Bunlardan ilki, yapay zekâ insan zekâsını taklit ederek bir problemi çözmeye odaklanırken uzman sistemler herhangi bir konuda uzmanlaşmış kişilerin çözebileceği problemlere odaklanır. Dolayısıyla uzman sistemlerde, alana yönelik olarak oluşturulan bilgi veri tabanı oldukça önemlidir. Bir diğer farklılık ise uzman sistemlerin genellikle insan tecrübesine dayalı olmasıdır. Eğitim alanında uzman sistemler ile öğrenme stratejilerinin belirlenmesi, yabancı dil öğretimi, başarıların tahmin edilmesi, sınav sonuçlarının değerlendirilerek eğitimin temel bileşenlerinden olan öğrenci, öğretmen ve veliye geri bildirimlerin sağlanması ve öğrenme modelinin seçilmesi gibi birçok alanda kullanılabilir (Korucu ve Biçer, 2020).

Akıllı Öğretici Sistemler, bilgisayar destekli öğretimin bazı eksik kalan yanlarının kapatılması adına yapılan çalışmalar sonucunda ortaya çıkan bir uygulama alanıdır. 1960 ve 1970’li yıllar bilgisayar destekli öğretimin altın çağı olarak ifade edilmektedir. 1970’li yıllarda en bilinen bilgisayar destekli öğretim örneği İllinois Üniversitesi tarafından geliştirilmiş olan PLATO’ dur (Arslan, 2020). PLATO ile aynı anda bazıları interaktif olan binlerce öğrenci üniversitenin standart ders materyallerine ulaşmasına olanak sağlıyordu. Ancak PLATO hem işleyiş hem de öğretim içeriği açısından her öğrenci için aynı yapıya sahipti. Bunun üzerine BDÖ uygulamalarının öğrencilerin bireysel ihtiyaçlarını karşılayabilecek ve yapay zekâ tekniklerini kullanabilecek şekilde yeniden düzenlenmesi üzerine yeni çalışmalar ve yaklaşımlar üzerine odaklanılmıştır. Çalışmalar sonucunda SCHOLAR adında ilk akıllı öğretici sistem uygulaması ortaya çıkmıştır (Carbonell, 1970). SCHOLAR’ ın gelişiminden günümüze kadar çok fazla akıllı öğretici sistemler gelmiştir (WHY, BUGGY, SOPHIE ve LISP Tutor) (Arslan, 2020). Eğitimde yapay zekâ alanında en sık kullanılan uygulamalardan olan akıllı öğretici sistemler (Holmes ve ark., 2019), her öğrencinin seviyesine uygun ve

adım adım ilerlemelerine imkân tanıyan bireyselleştirilmiş öğrenme ortamları sağlamaktadır (Alkhatlan ve Kalita, 2018)

Diyalog Tabanlı Öğretim Sistemleri, CIRCSIM ilk olarak gelişimine 1980 yılında İllinois Teknoloji Enstitüsü' nde bilgisayar destekli öğretim sistemi olarak başlamış 2000'li yıllara kadar ise CIRCSIM-tutor 3. Versiyon ile ilerlemiştir. Bu sistem birinci sınıfta eğitim gören tıp fakültesi öğrencilerinin kavram yanlışlarını tanımlayabilen ve mevcut hataları iyileştirebilmek için açıklamalar yapan yararlı bir öğretim sistemi olarak düşünülmüş ve tasarlanmıştır (Arslan, 2020). Sistem aracılığı ile yürütülen diyalog, beklenti ve kavram yanlışlarına göre öğrenciye dönüt sağlar. Öncelikle sistem, öğrencinin vermiş olduğu doğru cevapları yani beklentileri ve sıklıkla ifade edilen geçersiz cevapları yani kavram yanlışlarını kayıt altına alır. Daha sonra sistem, öğrencinin vermiş olduğu cevapların öngörülen beklentileri ne düzeyde karşıladığını ve kavram yanlışlarını tespit ederek öğrenciye uygun olan dönütü verir.

1960'lı yıllardan itibaren yapay zekâ çalışmaları artan bir ivme yakalamış ve insan gibi düşünebilen makineler üretmekten ziyade, daha gerçekçi ve erişilebilir hedef olan insan beyninin problem çözme becerisinin modellenmesine yönelik algoritmalar, programlar ve çeşitli sistemler geliştirmeye odaklanılmıştır (Coppin, 2004). Bu durum, YSA, bulanık mantık, uzman sistemler, ajanlar, doğal dil işleme, makine öğrenmesi, bayes ağları, genetik algoritmalar, derin öğrenme, konuşma tanıma ve bilgisayarla görme gibi çok sayıda yapay zekâ tekniklerinin gelişimine zemin hazırlamıştır (Talan, 2021). Yapay zekâ oldukça detaylı ve geniş bir alandır. Eğitimde kullanılış amacına göre farklı yollar izlenmekte ve her bir amaca yönelik olarak farklı bir teknikten yararlanılmaktadır. Bu her bir teknik ile makinelere farklı bir özellik kazandırılmaktadır (Korucu ve Biçer, 2020).

Yapay zekâ uygulamaları, eğitim sistemlerinin etkinliğini ve verimliliğini artırmak, öğrencilerin öğrenme yörüngelerini anlamak ve veri kümelerinden anlamlı içgörülerini üretmeye yardım sağlamak için büyük bir potansiyel güce sahiptir (Bhutoria, 2022). Temel amacı insan zekâsını ihtiyaç duyulan bazı karmaşık görevlerde yetkin olabilmek için makinenin insan düşüncesini simüle etmesini sağlamak olan yapay zekânın araştırma ve çalışma alanı oldukça geniş ve çeşitlidir (Li ve Wang, 2020). Bilgi işleme,

doğal dil işleme, örüntü tanıma, oyunlar, otomatik programlama, otomatik teorem ispatı, uzman sistemler, akıllı robotlar, bilgi tabanları alanında dünya çapında başarıya ulaşan yapay zekâ, derin öğrenme, veri madenciliği, akıllı kontrol ve YSA' da önemli ilerlemeler kaydetmiştir (Li ve Wang, 2020). Bu alanlarda yapılan birçok çalışma mevcuttur (Savcı ve ark., 2022; Tekin, 2014).

Eğitimde yapay zekâ uygulamalarının çalışıldığı farklı birçok araştırma incelendiğinde, yapay zekâ uygulamalarının eğitim ve öğretime sağladığı katkılar genel anlamda aşağıdaki gibi sıralanabilir (Bhutoria, 2022; Chassignol ve ark., 2018; Coşkun ve Gülleroğlu, 2021; İşler ve Kılıç, 2021; Korucu ve Biçer, 2020; Li ve Wang, 2020; Murphy, 2019):

- Bir öğrenci için özel öğrenme gereksinimlerine göre özelleştirilmiş çalışma materyali ve özelleştirilmiş testler oluşturabilir ve bunları değerlendirebilir.
- Öğretmeni potansiyel öğrenme engelleri konusunda uyarabilir.
- Bir insan konuşmasını simüle ederek bir öğrencinin sorularına cevap verebilir.
- Yapay zekâ destekli öğrenme sistemlerinin etkileşimli bir doğaya sahip olması, geri bildirim almaya, bu bildirimlerden yola çıkarak öğrencilerin ihtiyaç ve gereksinimlerini tespit edip anlamaya yardımcı olur. Bir sonraki aşamada ise tahmine dayalı algoritmalar kullanarak öğrenen için en uygun öğrenme seçimlerini belirler.
- Yapay zekâ teknolojisi ile öğretim kaynakları çeşitlendirilip geliştirilebilir.
- Sanal asistanlar, öğretmenlerin karmaşık öğretim tasarımını tamamlamalarına yardımcı olabilir. Görüntü tanıma teknolojisi ile öğretmenler ev ödevlerini düzeltme yükünden kurtulabilir ve böylelikle öğretmen öğretime odaklanmak için daha fazla zamana ve enerjiye sahip duruma gelir.
- Sanal gerçeklik ve bilgisayarlı görme vasıtasıyla öğrenciler evden çıkmadan önce pratik öğretim alabilirler.
- İnsan-bilgisayar etkileşim teknolojisinin kullanılması ile robot asistanlar öğrenciler ile çevrimiçi iletişim kurabilir ve ortak yaşanabilecek problemlere çözümler sunabilir.

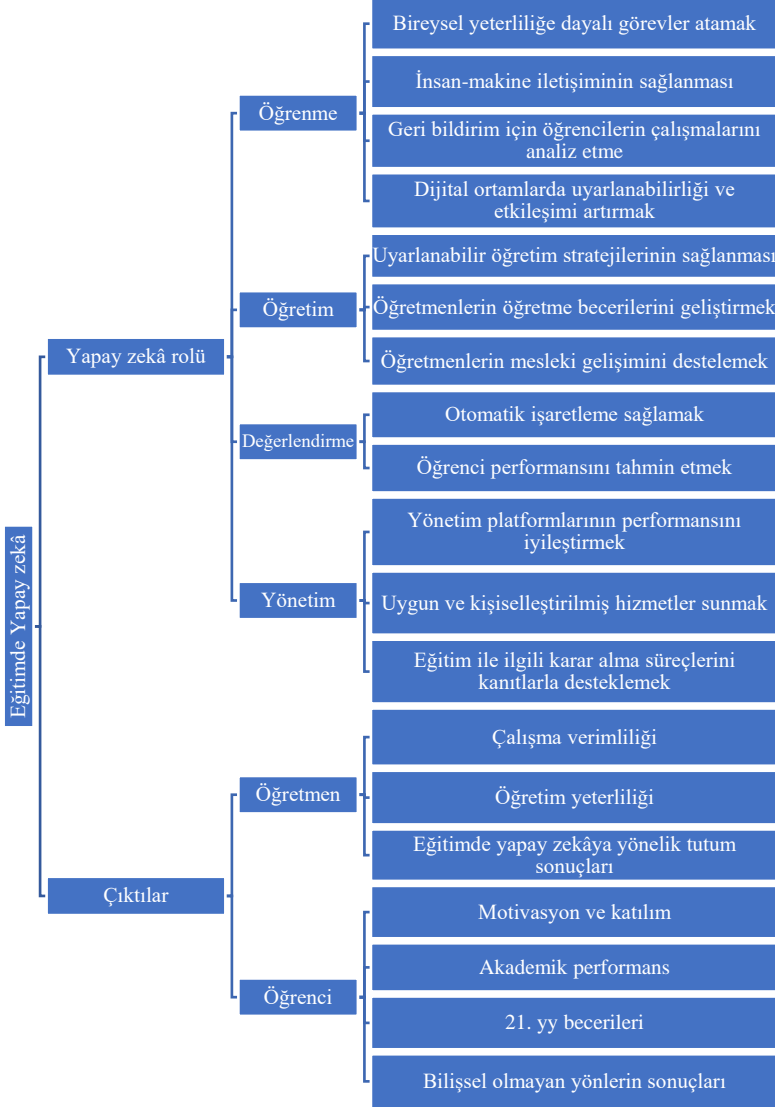
- Arzu edilmeyen öğrenci davranışları ve performansına yönelik olarak erken aşamada uyarı vererek öğretmenlerin ve okul yönetiminde farkındalık oluşturabilir.
- Eğitimde öğretmenlerin ve okul yönetiminin yaptığı bazı işlerin otomatik olarak yapılarak hem iş gücünden hem de zamandan kar edilerek bu işlere ayrılması gereken zamanın farklı eğitim alanlarında kullanılması sağlanabilir (öğrenci kayıt işlemleri, kayıt işlemleri için gerekli evrakların toplanıp-güncellenmesi ya da silinmesi, öğrenci ödevlerinin toplanması ve bu ödevlerin kontrollerinin yapılması, öğrenci testlerinin değerlendirilip notlandırılması işlemlerinin yapılması, genel konular hakkında velilere bildirim sağlanması gibi).
- Yapay zekâ teknolojisi ile öğretmen ve öğrencilerin motivasyonları, başarı ve dikkat durumları, performansları gibi eğitimin niteliğinin etkileyebilecek faktörlerin hangi değişkenlere bağlı olarak farklılaştığını belirlemek için kullanılabilir.
- Öğrencilerin mevcut bilgi boşluklarını tespit etmede, ilgi ve yeteneklerinin hangi yönde olduğunu belirlemede kullanılabilir.
- Öğretmenlerin hangi noktalarda zorlandıklarını tespit etmede kullanılabilir.
- Okulu bırakma durumu olan öğrencileri hangi faktörlerin etkilediğini bulmada kullanılabilir.
- Öğrencilerin öğrenme stillerini baz alarak stile göre ders içeriklerini sunmada, öğrencilerin ders seçim aşamalarına destek sağlamada kullanılabilir.
- Bir öğrencinin öğrenme eksikliği yaşama durumunda gerektiğinde konuya yönlendirme de kullanılabilir.
- Öğrenciye anında geri bildirim veren sistemler oluşturulabilir ve okulu ya da dersi bırakma oranlarının minimum seviyeye çekmek adına çözümler sunulabilir.
- İnternetin yaygınlaşması ile birlikte öğrenme ortamlarına internet aracılığıyla ulaşma eğitimde evrensellik rolünü gözler önüne sermiştir. Ayrıca öğrenme ortamlarının yapay zekâ teknolojisi ile desteklenmesi sonucunda bilgiye ulaşma da yeni fırsatlar ve yeni avantajların

kullanıcılara sunulması kolaylaşmıştır. Örneğin yapay zekâ teknolojileri destekli öğrenme ortamlarını kullanan kişiler dünyanın farklı yerlerinden istedikleri kişiler ile iletişim kurabilir, açılan kurslar sayesinde ise farklı kültür, farklı üniversite, farklı bölüm ve farklı dillerde eğitimin alınabilmesine yönelik olanaklar sunulmaktadır.

- Görme, yürüme, işitme gibi farklı engelleri olan öğrencilerin ya da çeşitli sebeplerden ötürü okula devam etme şansı olmayan öğrencilere yapay zekâ ile desteklenmiş öğrenme ortamları (uzaktan öğretim, açık öğretim, e-öğrenme vb.) sunularak yapay zekâ teknolojisinin eğitimde fırsat eşitliğini sağladığı söylenebilir.
- Yapay zekâ teknolojisinden faydalanan günümüzde birçok öğretim platformu mevcuttur. Bu öğrenme platformları kişilerin ilgi, ihtiyaç ve yeteneklerini baz alarak uygun öğrenme içeriği sunabilmekte ve bu platformlar aracılığıyla üniversitelerin açmış oldukları kurslardan bireyler yararlanabilmekte yapay zekâda dahil olmak üzere çeşitli eğitimler alınabilmektedir. Bu perspektiften bakıldığında yapay zekâ teknolojilerinden yaşam boyu öğrenmelerin desteklenmesi sağlanırken aynı zamanda yapay zekânın öğrenilmesi içinde imkânlar sunulmaktadır.
- Yapay zekâ teknikleri kullanılarak; öğrenci performans ve başarıların tahmin edilmesinde, öğrencilerin ilgi, yetenek ve ihtiyaçlarının tahmin edilmesinde, öğrencinin hangi dersi seçeceğinin tahmin edilmesinde, öğrencilerin dersi ya da okulu bırakıp bırakmayacağını tahmin edilmesinde, tıpkı öğrencilerde olduğu gibi öğretmenlerinde performans ya da başarılarının tahmin edilmesinde ve en az iki değişken arasındaki ilişkinin tespit edilmesinde (çalışmaya ayrılan süre ile alınan not, ilgi duyulan alan ile üniversitede tercih edilen bölüm gibi) kullanılabilir.
- Kişisel asistanlar ve Chatbot'lar gibi doğal dil işleme uygulamaları ile diller arasında çeviriler, imla yanlışlıklarının düzeltilmesi ve makale özetleri gibi birçok alanda birçok işlem yapılabilmektedir.

Chiu ve arkadaşları (2022) çalışmalarında, 2012-2021 yılları arasındaki eğitimde yapay zekâ çalışmalarını inceleyerek bu alanın fırsatlarını ve zorluklarını anlayabilmeyi amaçlamışlardır. İncelenen 92 çalışmanın

sonucunda; temel eğitim alanlarında yapay zekâ teknolojilerinin 13 rolünü, yedi öğrenme sonucunu ve 10 ana zorluğunu belirleyerek araştırmacılara sunmuştur. Eğitimde yapay zekânın rolü ve çıktılarına ilişkin maddeler Şekil 2 'de verilmiştir.



Şekil 2. Yapay Zekâ Uygulamalarının Eğitimdeki Roller ve Çıktıları

Kaynak: Chiu ve ark., (2022)

Yapılan makale incelemeleri sonucunda ise eğitimde yapay zekânın zorlukları şu şekilde özetlenmiştir; *kişiselleştirilmiş/uyarlanabilir öğrenme için ilgili öğrenme kaynaklarının yetersiz olması, yapay zekâ tahmin modelleri için uygun verilerin seçilmesi, yapay zekâ teknolojileri ile öğretimde kullanımları arasında bağlantı eksikliğinin olması, öğrenme için disiplinler arası yapay zekâ teknolojilerinin eksikliği, öğrenciler arasındaki dijital uçurumu genişleterek eğitim eşitsizliğini kötüleştirmek, öğretmenler arasında yapay zekâ teknolojileri konusunda yetersiz bilginin olması, öğrenciler ve öğretmenler arasında yapay zekâya yönelik olumsuz tutumlar, sosyo-duygusal yönlerle ilişkin eğitimde yapay zekâ araştırmalarının eksikliği, eğitimde yapay zekâ araştırmasında eğitim perspektiflerinin eksikliği; eğitimde yapay zekânın etkisiz değerlendirme yöntemleridir* (Chiu ve ark., 2022).

Eğitim sektörü yapay zekâ teknolojilerinden önemli düzeyde etkilenmektedir (Chassignol ve ark., 2018). Yapay zekânın insanları ve toplumu nasıl etkilediğine dair bir araştırma sunan bildiride, akıllı özel ders sistemleri, öğretim robotları ve uyarlanabilir öğrenme sistemleri gibi araç ve teknolojiler vasıtasıyla “yapay zekâ uygulamalarının günümüz eğitimcileri ve öğrencileri tarafından K-12 ve üniversite ortamları arasında bazı farklılıklar ile birlikte sıklıkla kullanıldığını” belirtmişlerdir (akt., Chassignol ve ark., 2018).

Hayatımızın birçok alanında kullandığımız yapay zekâ teknolojisinin eğitim alanında da kullanılıyor olması bu sektörde yaşanacak büyük gelişmelerin habercisi niteliğindedir. Eğitim sisteminin dört büyük bileşeni olan, öğretmen, öğrenci, veli ve eğitim örgütünün yapay zekâ ile eğitim entegrasyonundan etkileneceği aşikârdır.

2.6. Makine Öğrenmesi

Öğrenme denildiği zaman akla ilk gelen bir insan veya evcil bir hayvan iken, yerine makinelerin öğrenebileceğini düşünmek ilk etapta oldukça zor gibi görünse de yapay zekâ farklı bilimlerin ortak çalışmaları sonucunda makinelerin de öğrenmesini mümkün hale getirmiştir (Kartal, 2015). Bir işi ya da görevi bilgisayarda gerçekleştirebilmek için öncelikle o işin algoritmasını bilmek gerekir (Alpaydın, 2013). Algoritma ise bilgisayara

yapacağı işin aşamalarını kesin ve belirsizlikten uzak bir şekilde söyleyen bir dizi talimatlardır (Domingos, 2017). Bazı işler için bilinen algoritma varken bazı işler için ise bilinen bir algoritma yoktur. Örneğin; istemediğimiz elektronik postaların ayıklanmasında girdi olarak bir yazı dosyası olan elektronik bir posta düşünelim. Çıktı ise mevcut dosyanın istenip istenmediğini temsil eden bir evet ya da hayır işaretidir. Burada amaç girdiden yola çıkarak çıktının belirlenmesidir. Ancak bu iş için bilinen bir algoritma olmadığı gibi, postaların istenip istenmediği de zaman içinde değişebildiği gibi kişiden kişiye de değişkenlik gösterebilir. Bu durumda hem istenen e postaların olduğu hem de istenmeyen e postaların olduğu bir veri kümesi kullanarak bir elektronik postayı neyin istenmeyen yaptığını bu verilerden öğrenebiliriz. Diğer bir ifadeyle, bilgisayarın kendi başına bu görev için bir algoritma oluşturabilmesini isteriz. Bu şekilde mevcut algoritması olmayan ancak verisi olan uygulamalar için bu tür makine öğrenmesi yaklaşımlarına ihtiyacımız vardır (Alpaydın, 2013).

Yapay zekânın alt disiplinlerinden birisi olan makine öğrenmesi (Alpaydın, 2014; Aylak ve ark., 2021) sıklıkla yapay zekâ ile karıştırılmaktadır. Makine öğrenmesinin birçok alanda oldukça hızlı, büyük ve başarılı bir şekilde gelişmekte olması mağrur ebeveyni olan yapay zekâyı daha şimdiden arka planda bırakmıştır (Domingos, 2017). Büyük, gerçek dünya veri kümelerinde sarmal yapıları anlamak için tercih edilen bilim dalı olarak ortaya çıkan makine öğrenmesi (Deshpande ve Kumar, 2018), bir bilgisayarın açıkça programlanmadan eldeki mevcut verilerden öğrenmesini sağlayan (Samuel, 1959) günümüzün popüler teknolojilerinden biridir. Geron (2021)'e göre verilerden yola çıkarak öğrenen bilgisayarları programlamaya makine öğrenmesi denir. Daha mühendislik odaklı bir tanımı ise Mitchell (1997) yapmıştır. Mitchell (1997)'e göre makine öğrenmesi; belli bir T görevi ve P performans ölçütü için şayet P performans ölçütü, T görevinde E tecrübeleriyle artıyorsa bu E tecrübelerinden öğrendiği söylenen bilgisayar programıdır. Belirli bir veri kümesine ve temel alınan bir algoritmaya dayalı tahminler ile modeller oluşturmayı amaçlayan makine öğrenimi yöntemleri aynı zamanda gözden kaçırılması olası olan örüntüleri bulmak için çok büyük miktarlardaki verileri dahi inceleyebilme fırsatı sağlamaktadır (Camacho ve

ark., 2018). Türkçe literatürde “makine öğrenmesi” olarak karşımıza çıkan bu kavram “yapay öğrenme” olarak da ifade edilmektedir (Alpaydın, 2013).

Deneyimler ve örnek veriler kullanılarak pratik problemleri çözmek için kullanılan makine öğrenmesi algoritmaları belirli bir görevin performansını optimize etmeyi hedeflemektedir (Burkov, 2020). Bir makine, deneyimler ile performansını yükselttiğinde artık o makinenin öğrenmiş olduğu varsayılmaktadır (Harrington, 2012). Makine öğrenmesi, verilerden kural öğrenebilen, değişikliklere ayak uydurabilen, deneyimler ile performansını yükseltebilen yazılımları tasarlamakla uğraşmaktadır (Blum, 2007). Hal Daume III (2012)’ e göre makine öğrenmesi en basit hali ile geçmiş deneyimlerden gelecek hakkında tahminlerin yapılmasıdır.

Makine öğrenmesi genel anlamda, makineye verilen veri setinin işlenerek mevcut veriden anlamlı sonuçlar çıkarılması ve bu sonuçlara dayalı olarak geleceğe ya da bilinmeyene yönelik tahminlerde bulunulması mantığına dayanmaktadır. Makine öğrenmesi alanın temelini ise matematik, bilgisayar ve istatistik bilimleri oluşturmaktadır (Harrington, 2012; Paper, 2018)

2.6.2. Araştırmada Kullanılan Makine Öğrenmesi Algoritmaları

K- En Yakın Komşu Algoritması (K-Nearest Neighbour-KNN)

Fix ve Hodges 1951 tarafından ilk kez tanıtılan KNN kuralı, basitliği sezgiselliği ve verimliliği sayesinde istatistiksel örüntü sınıflandırmasında iyi bilinen ve sıklıkla kullanılan parametrik olmayan sınıflandırıcılardan biridir (Gou ve ark., 2011). KNN algoritması, eğitim örnekleminin çalışma esnasında hafızada olması gerektiğinden hafıza tabanlı sınıflandırma (Memory-Based Classification), sınıflandırma doğrudan eğitim örneklerine dayandığından örnek tabanlı (Example-Based Classification) ya da vaka tabanlı sınıflandırma (Case-Based Classification) ve son olarak algoritmanın sınıflandırmaya başlama süresi çalıştırma için rötarlı olduğundan dolayı tembel öğrenme (Lazy Learning) olarak da isimlendirilmektedir (Cunningham ve Delany, 2021). Denetimli makine öğrenimi algoritmalarından biri olan KNN algoritması (Goel, 2021), mevcut veri kümesinin hepsini model olarak kullanmakta ve tüm eğitim veri setini bellekte saklayarak diğer öğrenme algoritmalarından farklılaşmaktadır (Jackson, 1988). Verilerin dağılımı

hakkında çok az ya da hiç ön bir bilgi bilinmiyorsa en basit sınıflandırma tekniği olarak kullanılabilir (Devroye ve Wagner, 1982). Mesafeye dayalı algoritmalarından birisi olan KNN algoritması, verilerin birbirleriyle olan benzerlik ve uzaklıklarını esas alarak sınıflama işlemi gerçekleştirmektedir. Bu teknikte verilerin tümü bir örüntü uzayında muhafaza edilir. Bilinmeyen bir veri geldiğinde ise verinin hangi sınıfa dâhil olduğunu belirlemek için örüntü uzayı araştırılır ve sınıfı bilinmeyen veriye en yakın olan k adet veri belirlenir. Uzaklık ölçümlerinde farklı ölçüm teknikleri vardır ancak Öklid ve Manhattan sıklıkla kullanılan ölçütlerdir (Cunningham ve Delany, 2021). Ardından veri kendisine yakın olan bu k adet veri içerisinde hangisine daha çok benziyor ise onun sınıfına atanır (Ayık ve ark., 2007).

KNN algoritması; anlaşılması ve uygulanması kolay olan, hafıza tabanlı olduğu için yeni verilere uyum sağlayan yönü açısından oldukça avantajlıdır. Geniş veri seti karşısında hesaplama süresinin de artması yani tembel denetimli öğrenme algoritması olması, dengesiz veri setlerinde performansının düşük olması yani veri setinin dengelenme ihtiyacına gerek olması, ilgisiz özniteliklerde çok hızlı hataya düşmesi ve k değerine bağlı olması KNN algoritmasının dezavantajları arasında yer almaktadır (Bhatia, 2010).

Naive Bayes Sınıflandırıcısı

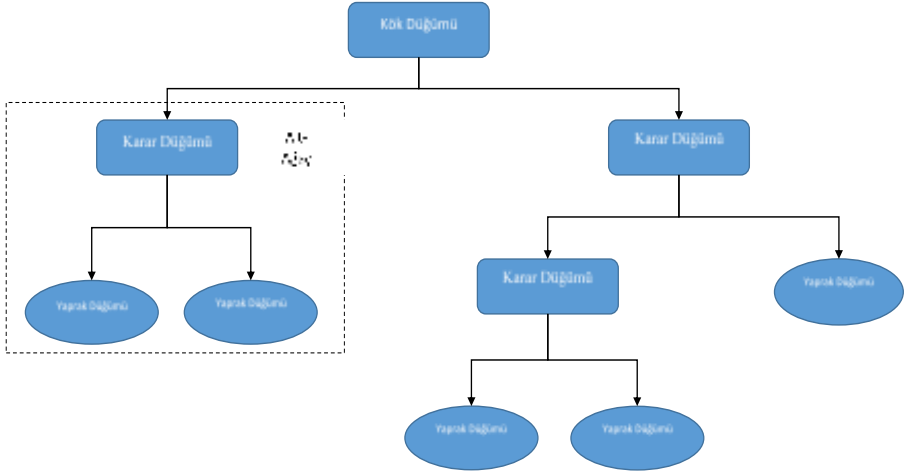
Adını matematikçi Thomas Bayes (1702-1761)'ten alan NB sınıflandırıcısı, bayes teoremine dayanan olasılıksal sınıflandırma algoritmalarındandır (McNamara ve ark., 2006). NB sınıflandırıcısı, gerçekleştiği bilinen bir duruma dayalı olarak yeni bir durumun ortaya çıkma olasılığını verir (Gürsoy ve Varol, 2021). Temelde NB algoritması her bir değişken için her durumun olasılığını hesap eder. Ardından ise elde edilen olasılık değerinin yüksekliğine göre sınıflandırma yapar (Özlen, 2022). Veri madenciliği ve makine öğrenmesi alanlarında en etkili ve verimli tümevarımsal öğrenme algoritmalarından biri olan NB (Zhang, 2004), basit olmasına rağmen birçok farklı öğrenme problemlerinde iyi performans sergileyerek bu alanda çalışma yapan araştırmacıları şaşırtmıştır. NB sınıflandırıcısı; farklı özellikteki fazla sayıda veri setini iyi işleyebilmekte

(Malhotra, 2015), dengesiz veri kümelerinde çalışabilme özelliğine sahip (Erbay Mermer, 2022) ve cüzi miktardaki eğitim verisiyle oldukça başarılı işler çıkarabilmektedir (Shi ve Manduchi, 2003).

Karar Ağaçları (Decision Tree- DT)

İşlem adımlarının hızlı olması, sonuçlarının kolay yorumlanabilmesi, veri tabanı sistemlerine kolayca entegre edilebilmesi ve güvenilirliğinin daha yüksek olması gibi özellikleri sayesinde oldukça popüler olan KA denetimli makine öğrenmesi modelidir (Han ve Kamber, 2006; Witten ve ark., 2011). Karmaşık veri setlerine uydurabilecek güçlü algoritmalarından biri olan KA aynı zamanda günümüzün en güçlü makine öğrenmesi algoritmalarından birisi olan RO'ların temel bileşenidir (Geron, 2021). Hem sınıflandırma hem de bağlanımda kullanılabilecek oldukça etkin olan KA, böl ve yönet yöntemini kullanarak veri setini belirli kurallar uygulayarak küçük alt gruplara bölmektedir (Alpaydın, 2013; Balaban ve Kartal, 2015). KA, kararın verilebilmesi amacıyla ağaca benzer bir yapı oluşturmaktadır (Zhang, 2006). Tıpkı gerçek bir ağaçtaki gibi dal, yaprak gibi bazı özel terimler kullanılmaktadır. Bir KA'nda karar düğümleri, yaprak düğümleri, kök düğümleri ve dallar mevcuttur. Karar düğümleri veri setinde karar vermek, tahmin ya da sınıflandırma yapmak için kullanılan niteliklerdir. Ayrıca karar düğümleri iki ya da daha fazla dala ayrılabilir (Balaban ve Kartal, 2015). Kararları tutma görevi ise yaprak düğümlerine aittir. Hem yaprak düğümler hem de kök düğüm cevaplanacak soruları ve kriterleri içlerinde barındırırlar. Düğümler arasındaki bağlantıları ise dallar gösterir (Gürsakal, 2017). Kök düğüm ağacın en tepesinde bulunan başlangıç noktasıdır. Ağacın kökünden başlanarak yaprak düğümlere kadar sıralı bir yol izlenerek bir karara ulaşılabilir (Balaban ve Kartal, 2015). KA, şekil olarak bir akış diyagramına da benzerler ve bu diagramlar farklı kararların sonuçlarını temsil ederler. Ağacın yapısı baştan sabit olmamakla birlikte verinin altında yatan işlevin karmaşıklığına bağlı olarak dallar ve yapraklar eklenerek ağaç büyür (Alpaydın, 2013). KA'nda bulunan düğüm sayısı, sınıflandırma performansı açısından oldukça önemlidir. Çünkü düğüm sayısı çok olan yani boyut olarak büyük olan ağaçlar yavaş çalışırken, düğüm sayısı az olan küçük boyutlu

ağaçlar hızlı çalışmalarına karşın sınıflandırmada başarılı değillerdir (Uysal, 2013). Daha iyi bir performans elde edilmesi amacıyla en uygun boyuttaki ağacı elde etmek için sınıflandırma işlemine herhangi bir faydası olmayan bölümler ağaçtan çıkarılarak sadece performansı ve doğruluk değerini artırmak amacıyla budama işlemi yapılır. Bu işlem ağaç oluşturulurken yapılabildiği gibi ağaç oluşturulduktan sonraki aşamada da yapılabilir. KA algoritmalarına; CART, CHAID, C4.5, ID3, MARS, QUEST, SPRINT, SLIQ örnek verilebilir (Albayrak ve Koltan Yılmaz, 2009).



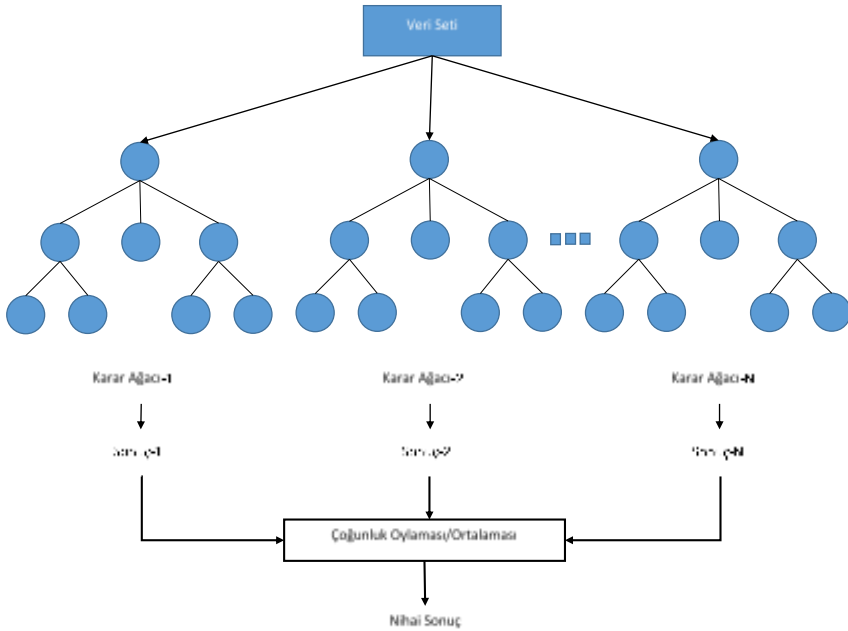
Şekil 3. KA Yapısı Örneği

Kaynak: Sarker, (2021)

Rastgele Orman (Random Forest-RF)

Yüksek boyutlu sınıflandırma ve çarpık problemlerde başarısı ispatlanmış çok popüler ve güçlü olan RO algoritması denetimli makine öğrenmesi algoritmalarından biridir (Azar ve ark., 2014; Breiman, 2001).

Hem sınıflandırma hem de regresyon problemlerine çözüm sağlayan bu algoritma aynı zamanda hem sürekli hem de kategorik değerler içinde uygundur (Sarker, 2021). Breiman (2001), birden fazla KA modelinden RO modelinin oluştuğunu ve ağaç sayısı arttıkça RO algoritmasının sınıflandırma performansının da arttığını ifade etmiştir. Yani birbirinden bağımsız olarak eğitilmiş birden fazla KA ile bu KA'ından her birine ait tahminlerin birleşmesi sonucunda RO modeli oluşmaktadır. Her bir KA modeline ait olan sınıf değerleri tahminleri birleştirildikten sonra oylamaya sunulur. Sonuçta çoğunluk oyu ya da ortalamaları sınıf değerleri nihai tahmin değeri olarak belirlenir. Böylece aşırı yüklenme problemi en aza indirilir ve tahmin doğruluğu ve kontrollüğünü artırır (Pedregosa ve ark., 2011). Böylelikle, çoklu KA'na sahip RO, tek bir KA tabanlı modelden tipik olarak daha doğrudur (Sarker ve ark., 2019).



Şekil 4. RO Yapısı Örneği

Kaynak: Sarker, (2021)

RO algoritması ile ilgili yapılan çalışmalar incelendiğinde, başlangıçta belirtilmiş olan ağaç sayısını geçiyorsa, sınıflandırma performansını dikkate değer bir düzeyde artırmadığı görülmüştür (Oshiro ve ark., 2012)

Destek Vektör Makineleri (Support Vector Machine-SVM)

Denetimli öğrenme yöntemlerinden biri olan DVM, sınıflandırma problemlerine ek olarak regresyon analizi içinde kullanılabilir (Keerthi ve ark., 2001). 1992 yılında Boser, Guyon ve Vapnik tarafından geliştirilen DVM (Boser ve ark., 1992), fazla sayıda öznelik ile çalışabilmesi ve sınıflandırma problemlerinde oldukça iyi sonuçlar vermesinden dolayı sıklıkla tercih edilen bir yöntemdir. DVM, sınıflandırmayı bir doğrusal veya doğrusal olmayan bir fonksiyonun kullanılması şartıyla yerine getirir ve mevcut veriyi birbirinden ayırmak amacıyla en uygun fonksiyonun tahmin edilmesi temeline dayanır (Özkan, 2016). Bu algoritma ile sınıflara eşit mesafede bulunan bir hiper düzlem oluşturulur ve bu hiper düzlem yardımıyla sınıflar ayrılır (Ayhan ve Erdoğan, 2014). Oluşturulan bu hiper düzleme en yakın iki sınıfın örneklerine destek vektörleri denir. Destek vektörleri hiper düzlemi ortada bırakarak birbirine paralel iki sınır çizgisi oluşturur. Algoritma hem sınır genişliğini hem de sınırın konumunu küçültüp büyütür sınıfları ayırmaya çalışır (Büyükköçer, 2019).

DVM, veri setinin doğrusal olarak ayrılıp ayrılmama durumuna bağlı olarak doğrusal DVM ve doğrusal olmayan DVM olarak iki gruba ayrılmaktadır (Ayhan ve Erdoğan, 2014).

Yapay Sinir Ağları (Artificial Neural Networks-ANN)

Beynimizde bulunan biyolojik sinir hücrelerinin bir araya gelerek oluşturduğu ağlardan ilham alınarak oluşturulmuş bir makine öğrenmesi modeli olan YSA (Geron, 2021), birçok alanda başarılı bir şekilde uygulanmaktadır (Alpaydın, 2013). YSA bilgiyi insan beyninin yaptığına benzer bir şekilde işler. YSA kendi kendine öğrenme düzenekleridir. Yani bir programcının geleneksel kabiliyetini gerektirmez. YSA öğrenmeye ek olarak, bilgiler arasında bağlantılar oluşturma ve ezberleme kabiliyetine de sahiptir (Elmas, 2007). Ağ, bir problemi çözmek için paralel bir biçimde çalışan fazla

sayıda birbirine yüksek seviyede bağılı işlem ögesinden yani nörondan oluşur. Sinir ağları belirli bir görevi gerçekleştirmek için programlanmaz ve örneklerden öğrenir (Maind ve Wankar, 2014). Bir YSA yapay nöron ağlarından yani başka bir deyişle düğümlerden oluşur. Sıklıkla kullanılan sinir ağının yapısı üç katmandan oluşmaktadır. Bunlar; girdi katmanı, gizli (ara) katman ve çıktı katmanıdır (Hastie ve ark., 2001). Her bir katmanda yapay sinir hücreleri olan nöronlar mevcuttur. YSA' da veri setine ait örnekler öncelikle giriş katmanı ile ağa iletilir. Ardından bilinmeyen örneklerin hangi sınıf değerlerine ait olacağını tespit etmek amacıyla nöronlar arasında çeşitli bağlantılar kurulur. YSA'nın başlıca uygulama alanları tahmin, sınıflandırma ve modelleme olarak ifade edilebilir.

Ekstra Ağaç Sınıflandırıcı (Extra Tree Classifier)

Makine öğrenmesi algoritmalarından olan RO algoritmasının farklı bir uyarlaması olan EA algoritmasında modelin eğitimi, veri kümesinin kopyalarının kullanılması ile yapılmaktadır. EA algoritmasını RO algoritmasından farklı olan başlıca iki noktası vardır. Bunlardan ilki öznitelik ve düğümlerin kesim noktası belirlenirken rastgele seçim yapılmasıdır. İkincisi ise ağaçların her birinin yeniden örneklenmesi yerine verilerin tamamının kullanılması ile büyütülmesidir (Mishra ve ark., 2017). EA sınıflandırıcısı, bazı veri analizine ait problemlerin çözümündeki karmaşıklığı ve işlem yükünü hafifletmesine rağmen bazı büyük veri kümelerinin analizinde performansı düşüktür. Bu yöntem istatistiksel açıdan incelendiğinde ise genellikle bias artışına neden olurken varyansı düşürmektedir (Geurts ve ark., 2006).

2.6.3. Makine Öğrenmesinin Eğitimde Kullanılması

Yapay zekânın alt boyutlarından biri olan (Alpaydın, 2013; Aylak ve ark., 2021) ve birçok farklı alanda karşımıza çıkan makine öğrenmesi, eğitimde de farklı amaçlar doğrultusunda kullanılmaktadır. Makine öğreniminin eğitim alanında uygulanıyor olması bilim insanları ve araştırmacılar için oldukça ilgi çekici bir durum haline gelmiştir (Bacos, 2020).

Makine öğrenimi eğitim alanında birçok farklı amaç doğrultusunda kullanılmaktadır. Bunlar genellikle, öğrenci performansının tahmin edilmesi, kişiselleştirilmiş öğrenme, otomatik notlandırma, öğrenme stillerinin belirlenmesi, öğrencilerin ilerlemelerinin takip edilmesi, öğrencilerin okulu bırakıp bırakmayacaklarının tahmin edilmesi vb. konulardır (Akmeşe ve ark., 2021; Aldeman ve ark., 2021; Costa-Mendes ve ark., 2021; Hu, 2021; Khan ve ark., 2021; Kucak ve ark., 2018; Yu, 2021). Kucak ve arkadaşları (2018), çalışmasında eğitimde makine öğrenmesi kullanımına yönelik olarak yapılan çalışmaları kategorize etmiştir. Bu kapsamda eğitimde makine öğrenmesinin kullanım alanlarını inceledikleri 67 çalışma sonucunda 4 başlık altında toplamıştır. Bunlar; öğrenci performanslarının tahmin edilmesi, öğrencilerin test edilmesi ve adil derecede notlandırılması, kalıcılığın iyileştirilmesi-öğrenciyi elde tutmanın iyileştirilmesi, öğretmen ve kurum personellerinin desteklenmesidir. Makine öğrenmesi, okulu bırakma konusunda risk altındaki öğrencilerin tespit edilmesinde kullanılarak öğrencilerin okulu bırakma sorununu çözme konusunda da büyük bir ilgi görmüştür. Çünkü zamanında planlamayı etkili bir şekilde kolaylaştırmıştır (Mduma ve ark., 2019). Eğitimde makine öğrenmesi alanında yapılan çalışmalar incelendiğinde çalışmaların öğrencilerin performanslarının tahmin edilmesinde yoğunlaştığı görülmektedir (Ahmad ve ark., 2020; Ahmad ve Shahzadi, 2018; Mrinal ve Taruna, 2014; Rodriguez Hernandez ve ark., 2021). Genel olarak eğitimde makine öğrenmesi uygulamalarını özetlemek gerekirse; öğrencilere makine öğrenmesini öğretmek, eğitimde sınıflandırma ve tahminde bulunma amacıyla çalışmalar yapılmaktadır. İlgili çalışmalar bölüm sonunda verilmiştir.

Dogra (2018), eğitim alanında birçok gelişim ve değişimin olduğunu ve makinelerin manuel birçok görevi eğitim alanında üstleneceğini belirterek eğitimin iyileştirilmesinde kullanılabilecek makine öğrenimini sekiz başlık altında toplamıştır. Bunlar; okullarda kişiselleştirilmiş öğrenme, etkili organize öğrenme süreçleri, öğretmenlerin ve öğrencilerin performansları için geri bildirim, öğrencinin eğitiminde ileriye dönük yapay zekâ tahminleri, yapay zekâ yazılımları aracılığıyla yansız derecelendirme, öğrenciye öğrenme yollarını önermede, yardıma ihtiyacı olan öğrenci ile müsait olan öğretmeni eşleştirmede ve eğitimsel deneyler olarak belirlenmiştir.

Eğitimde makine öğrenmesi alanında yapılan çalışmalar genellikle öğrenci başarısı ve performansının tahmin edilmesi üzerinedir. Tosunoğlu ve ark., (2021), Web of Science veri tabanında 2015 ile 2019 yılları arasında eğitim bilimleri alanında makine öğrenmesi yöntemleri kullanılarak yazılmış olan makaleleri belirli kriterler doğrultusunda seçerek toplamda 184 makaleyi incelemişlerdir. İnceleme sonucunda bu çalışmalarda en çok tercih edilen algoritmaların KA, DVM, NBv e YSA olduğunu tespit etmişlerdir. Makalelerin %63'ü nicel, %18'i karma, %15'i nitel ve %4'ü alan yazın derleme şeklinde gerçekleştirilmiştir. Çalışmalarda örneklem olarak en fazla %35.3 oranla lisans öğrencileri ardından ise %17.39 oranla ortaöğretim öğrencileri ile çalışılmıştır. Örneklem aralığı %29.7 oranla en fazla 101-1000 arasında tercih edilmiştir. Çalışmalar öğretim alanına göre incelendiğinde en fazla eğitim/öğretim ile bilgisayar/bilişim teknolojileri alanında çalışmaların yapıldığı bu sıralamayı sağlık ve mühendislik disiplinlerinin takip ettiği tespit edilmiştir. Veri toplama aracı olarak en çok %34.02 oranla veri tabanları/log kayıtları ardından ise %19.59 ile sınav/test/ödev/kurs sonuçları kullanılmıştır.

2.7. E-Öğrenme Ortamları

Bir ülkenin kalkınmasındaki en önemli unsurlardan biri eğitimidir. Koronavirüs Hastalığı (COVID-19) ile birlikte salgının yayılmasını engellemek amacı ile okullar, üniversiteler ve diğer birçok devlet kurumları kapılarını kapatmak zorunda kalmış ve yüz yüze eğitime bir süreliğine ara verilmiştir. Dünya çapında 1.7 milyardan fazla öğrenci bu durumdan etkilenmiş ve 160 ülke pandemi nedeniyle kapanmayı uygulamıştır (United Nations Educational, Scientific and Cultural Organization [UNESCO], 2020). Bu durumda COVID-19'un öğrenci nüfusunun %91'ini veya daha da fazlasını etkilediği söylenmektedir (Sukendro ve ark., 2020). Kriz, toplumları birçok alanda zorluklara maruz bırakmış olsa da teknolojilerin kullanımı açısından ise fırsat oluşturmuştur. Başka bir söylemle, öğrenme sürecini değiştirmede, sürdürülebilir öğretimi desteklemede ve uzaktan eğitim sırasında dünyanın dört bir yanındaki öğrencilere bir eğitim ortamı sağlamada teknolojilerin rolüne dair geniş perspektifler sağlamıştır (Abbasi ve ark., 2020). Salgın süreci boyunca, eğitim alanında geri kalmamak ve eğitimin doğru yolda ilerlemesi adına ülkeler büyük çabalar sarf etmiştir. Okulların kapanması ile

birlikte, teknolojinin eğitim amaçlı kullanımı gerekliliği ön plana çıkmış, uzaktan eğitimi iyileştirmek için çevrimiçi teknolojinin yoğun bir şekilde kullanılmasına odaklanılmış ve bu konuda birçok araştırmacı çalışma yürütmüştür (Mailizar ve ark., 2020; Wang ve ark., 2020). COVID-19 sürecinde kullanılan teknolojilerden biri de çeşitli dijital teknolojilerin kullanıldığı e-öğrenme ortamlarıdır. Schworm ve Gruber (2012)' e göre e-öğrenme, öğrencilerin bağımsız olmalarını sağlamak amacı ile öğrenme merkezli öğrenmeyi geliştiren internet tabanlı bir öğrenme sürecine verilen addır. İlk olarak 1999 yılında bilişsel davranış terapisi sistemleri üzerine bir konferansta kullanılan, sanal ve çevrimiçi öğrenme olarak da adlandırılan e-öğrenme kavramı, dijital medya kullanımı yoluyla sağlanan bir öğrenme sistemini ifade etmektedir (Shaikh ve ark., 2022). E-öğrenme entegrasyonunun amacı, yüz yüze öğrenmenin daha esnek, etkili ve verimli olmasına katkı sağlamak yani desteklemektir (Sukendro ve ark., 2020). E öğrenmenin en önemli özellikleri, özellikle beşinci nesil telekomünikasyonun (5G) yaygınlaşması ile birlikte, öğrenme materyallerine her zaman ve her yerden erişimin sağlanabilmesidir (Makableh ve ark., 2023). E-öğrenme bilgi ve başarının gelişimini, eğitim maliyetlerinin düşürülmesini ve eğitime erişimi kolaylaştırdığından dolayı küresel ekonominin en önemli sektörlerinden biri olmayı başarmıştır. Salgın döneminde eğitimde e-öğrenme uygulamalarına yönelik olarak bazı çalışmalar yapılmıştır (Abbasi ve ark., 2020; Favale ve ark., 2020). Bununla birlikte bu alanda hala eksiklik olduğu ve e-öğrenme uygulamalarının belirli konularda hala sınırlı olduğu düşünülmektedir (Sukendro ve ark., 2020). Pandemi süreci, tüm dünya da küresel boyutta yaşanabilecek çeşitli problemler ile karşı karşıya kalma ihtimalimiz gerçeğini gözler önüne sermiştir. Bu amaçla uzaktan eğitim sürecine dair nitelikli çalışmalara olan ihtiyaç her zamankinden daha fazladır.

2.8. İlgili Araştırmalar

2.8.1. Yapay Zekâ-Makine Öğrenmesi Alanında Yapılan Araştırmalar

Tosun (2007), gerçekleştirdiği çalışmasında, üniversite öğrencilerinin akademik başarılarını tahmin etmede YSA ve KA algoritmalarını kullanarak sınıflandırmayı ve bu algoritmaların analiz sonuçlarını karşılaştırmayı

amaçlamıştır. Çalışmada öğrencilerin demografik bilgileri ile akademik bilgilerinden oluşan anket ile veriler toplanmıştır. KA ile yapılan tahminlere göre 216 öğrenci başarısız bulunmuştur. Gerçekte ise bu 216 öğrencinin 189' u başarısızdır. Yani bu durumda model başarılı olan 27 öğrenciyi başarısız olarak tahmin etmiştir. Model 208 öğrenciyi ise başarılı olarak bulmuştur. Gerçekte ise bu 208 öğrencinin 173'ü başarılıdır. Bu durumda model 35 öğrenciyi başarısız oldukları halde başarılı olarak tahmin etmiştir. KA algoritmasına ait model sonuç olarak %86 oranda bir başarıya ulaşmıştır. YSA kullanılarak oluşturulan model ise sonuç olarak %91.77 oranda bir başarıya ulaşmıştır. Sonuç olarak YSA ile oluşturulan model KA ile oluşturulan modelden daha yüksek bir başarıya ulaşmıştır.

Bahçeci ve Gürol (2010), akıllı öğretim sistemleri ile bir öğrencinin derse yönelik durumunu tespit edebilen uzman bilgi modülü ile alan bilgisi ve kural tabanı olmak üzere toplamda iki bileşen halinde bir sistem tasarlamışlardır. Öğretim konularını içerisinde barındıran bir ders olarak alan bilgisi bileşeni, konulara yönelik egzersizlerde öğrenciye ait hataları bulmak ve isteğe bağlı olarak ipuçları, gerekli açıklama ve kişiselleştirilmiş geri bildirimler vermek adına oluşturulmuş birtakım kurallar listesidir. Tasarlanmış olan akıllı öğretim sisteminin amacı, öğrencinin bilgisini, alan bilgisi ile aynı seviyeye getirmektir. Akıllı sistemin ölçme modülü aracılığıyla bir öğrencinin derse yönelik durum bilgisi insana gereksinim duymadan belirlenebilmektedir. Akıllı öğretim sistemi modelinde, etkileşimli problem çözme desteği kullanılmıştır ve böylelikle problem çözümünün her adımında akıllı yardım desteği sağlanmaktadır. Bu aşamada öğrencinin yaptığı hatalara yönelik anında ve kişiselleştirilmiş geri bildirimler verilmektedir. Süreç boyunca öğrencilerin bilgileri ve performansları kayıt altına alınarak öğrenciye sunulmaktadır. Bu durum öğrencinin konular hakkında öğrenip öğrenmediğini, egzersizleri ve testleri yapıp yapmadığı gibi sayısal verileri görme imkânı sağlamaktadır.

Kayabaş (2011), çalışmasında uzaktan eğitimde öğrenci destek sistemi olarak kullanılabilir bir yapay zekâ sohbet ajanı geliştirmeyi ve kullanılabilirliğini belirlemeyi amaçlamıştır. Bu amaç doğrultusunda Artificial Intelligence Markup Language (AIML) tabanlı bir sohbet ajanı geliştirerek Anadolu Üniversitesi Uzaktan Eğitim Sisteminde kullanıma

başlanmıştır. Cabbar Destek adı verdiği bu yapay zekâ sohbet ajanına yönelik öğrencilerin memnuniyet düzeylerinin ortaya yakın ama zayıf olduğu, erkek öğrencilerin kadın öğrencilere kıyasla memnuniyet düzeylerinin daha yüksek olduğu bulunmuştur. Öğrenenlerin daha önce herhangi bir yapay zekâ kullanma durumları ile Cabbar Destek'e memnuniyet düzeyleri arasında ilişki olduğu sonucuna ulaşılmıştır. Daha önce yapay zekâ uygulaması kullanmış olan öğrenenlerin Cabbar Destek'e ilişkin memnuniyet düzeyleri daha yüksek bulunmuştur. Çalışmaya katılan öğrenenlerin yapay zekâ uygulamalarının uzaktan eğitim kurumlarında kullanılmasına yönelik tutumları incelendiğinde ise; %52.1'i yapay zekâ uygulamalarının faydalı olacağını düşünürken, %33.3'ü ise olumsuz görüş bildirmişlerdir.

Tepedan (2011), YSA ve LR yöntemlerini kullanarak Türk öğrencilerin PISA başarılarının yordanmasında bu iki yöntemin performanslarını karşılaştırmayı amaçlamıştır. Çalışmada 2003, 2006 ve 2009 yıllarında gerçekleştirilen PISA'ya katılan toplamda 14.793 öğrenciye ait test ve anket sonuçları kullanılmıştır. Öğrencilerin matematik başarıları, fen bilimleri başarıları ve okuma başarıları ayrı ayrı yordanmıştır. Yordama amacıyla kullanılan YSA modelinin ve Lojistik Regresyon (LR) modelinin performansları karşılaştırılmıştır. Çalışmanın sonuçlarına göre, matematik başarılarını %78.6'lık bir performansla YSA, % 76.8'lik bir performans ile de LR modeli tahmin etmiştir. Fen bilimleri başarılarını %78.5'lik bir performansla YSA, %78.1'lik bir performans ile de LR modeli tahmin etmiştir. Son olarak okuma başarılarını % 79.4 'lük bir performansla YSA, %78.4'lük bir performans ile de LR modeli tahmin etmiştir. Çalışma ile öğrencilerin başarılarının yordanmasında YSA modelinin LR modeli gibi oldukça iyi sonuçlar verdiği, öğrenci başarılarının tahminine yönelik çalışmalarda güvenle kullanılabilceği tespitinde bulunulmuştur.

Yavuzalp (2012), deneysel araştırma modellerinden olan tek gruplu öntest sontest desene göre tasarladığı çalışmasında, e-öğrenme ortamlarında kullanılan öğrenme stil ve stratejilerinin web kullanım madenciliği ile analiz edilmesini amaçlanmıştır. Türkçe, matematik, sınıf ve okul öncesi öğretmenliğinde öğrenim görmekte olan öğrencilerin bulunduğu çalışma grubunda veriler, Kolb'un öğrenme stili envanteri ile güdülenme ve öğrenme stratejileri ölçeği ile toplanmış ve analiz edilmiştir. Veriler analiz edildiğinde;

öğretmen adaylarının e-öğrenme ortamları kullandıkları süre zarfında öğrenme stillerinde ve stratejilerinde değişimlerin meydana geldiği sonucuna ulaşılmıştır. Adayların kullandıkları öğrenme stillerinin öntest-sontest dağılımları arasında farklılıklar olduğu tespit edilmiştir. Güdülenme ve öğrenme stratejileri ölçeğinden elde edilen veriler analiz edildiğinde ise; adayların öntest-sontest ölçek puanlarında istatistiksel açıdan anlamlı bir farklılık tespit edilmemiştir. Ancak ölçeğin mevcut alt boyutlarının bazıları arasında anlamlı farklılıklar tespit edilmiştir. Öğrenme stilleri ile öğrenme stratejileri arasındaki ilişkiyi tespit etmek amacıyla, her iki ölçeği de oluşturan alt boyutlar arasında korelasyon analizi yapılmıştır. Bu analiz sonucunda öğrenme stilleri ölçeğindeki aktif deneyim ve yansıtıcı gözlem alt boyutları ile güdülenme ve öğrenme stratejileri alt boyutları arasında anlamlı ilişkiler bulunmuştur. Çalışma süresince yapılan tüm analizler ve elde edilmiş olan veri madenciliği modeli ile öğretmen adaylarının web kullanım davranışlarından öğrenme stillerinin tespit edilmesinin mümkün olduğu ancak güdülenme ve öğrenme stratejilerinde elde edilen yapay zekâ modelinin başarıya ulaşamadığı sonucuna ulaşılmıştır.

Erümit (2014), matematikte hareket problemlerinin çözümü için yapay zekâ tabanlı bir öğretim ortamı tasarlamış, tasarladığı bu ortamı öğrencilere uygulamış ve değerlendirmiştir. 30 aylık bir süreçte gerçekleşen çalışmada öncelikle öğrencilerin problem çözme zarfında yaşadıkları güçlükler tespit edilmiş ve mevcut güçlüklerin giderilmesi amacıyla yapay zekâ tabanlı uzaktan eğitim ortamı tasarlanmış ve bu tasarım yapılırken Polya' nın problem çözme basamakları temel alınmıştır. ARTIMAT (Artificial Intelligence and Math) adı verilen uzman sistem pilot uygulama sonucunda hem öğrenci hem de uzman görüşleri doğrultusunda son halini almıştır. Ardından yarı deneysel desen doğrultusunda kontrol grubu ve deney grubu ile asıl uygulamaya geçilmiştir. Kontrol grubunda bulunan öğrenciler geleneksel sınıf ortamında problem çözme eğitimini gerçekleştirirken, deney grubunda bulunan öğrenciler ARTIMAT üzerinden problem çözme eğitimini gerçekleştirmiştir. Çalışma da veri toplama aracı olarak, öğrencilerin öntest-sontest sınavları, gözlemci notları ile öğrenci ve öğretmenler ile yapılan mülakatlar kullanılmıştır. Verilerin analizi sonucunda, tasarlanan ARTIMAT' ın

öğrencilerin problem çözme yöntemlerinin geliştirdiğini, ders başarılarını artırdığını ve öğretmenlere önemli bir katkı sağladığı tespit edilmiştir.

Mrinal ve Taruna (2014), mühendislik fakültelerindeki lisans öğrencilerinin akademik performansını tahmin etmek için en iyi sınıflandırma modelini sağlamayı amaçlamışlardır. 1000 öğrenciden toplanan akademik performans ve demografik bilgiler ile toplamda 18 öznitelik üzerinde çalışma yürütülmüştür. Öğrencilerin akademik performans tahminleri için KA algoritmasına dayalı Çok Düzeyli Sınıflandırma Modeli önerilmiştir. İki seviyeden oluşan bu modelin ilk seviyesinde; KA, tembel öğrenen, YSA ve NB olmak üzere dört sınıflandırma modeli oluşturulmuş, değerlendirilmiş ve karşılaştırılmıştır. Araştırmanın sonucunda KA modelinin %99.79 ile en yüksek doğruluğu elde ettiği bulunmuştur. Öğrencilerin akademik performanslarının tahmin edilmesinde en uygun algoritmanın KA olduğu belirtilmiştir.

Gray ve arkadaşları (2014), çalışmanın ilk yılında başarısız olma ihtimali olan üniversite öğrencilerini belirlemek amacıyla İrlanda Teknoloji Enstitüsü Blanchardstown' da öğrenim görmekte olan 1. sınıf öğrencileri ile çalışmayı yürütmüşlerdir. Çalışmada 1074 öğrenciye ait veriler ile veri seti oluşturulmuştur. Veri setinde yaş, cinsiyet, önceki akademik performans gibi bilgiler yer almıştır. Çalışmada altı farklı sınıflandırma tekniği kullanılmıştır. Bunlar; NB, KA, LR, DVM, YSA ve KNN algoritmasıdır. Modellerin doğruluğu çapraz doğrulama kullanılarak değerlendirilmiş ve modeller sonraki bir akademik yılda uygulandığında elde edilen sonuçlar ile kıyaslanmıştır. Çalışmanın sonunda en yüksek doğruluğa sahip olan algoritmanın %73.3'lük bir değerle DVM olduğu en düşük doğruluğa sahip olanın ise LR olduğu tespit edilmiştir. Genç öğrenciler üzerinde eğitilen modellerin iyi bir tahmin doğruluğuna sahip olduğunu ve yeni bir öğrenci grubuna uygulanabildiğini, ancak daha büyük öğrencilerin modellerinin daha az doğru olduğunu ve yeni bir öğrenci grubuna uygulanabilir olmadığı sonucuna ulaşılmıştır.

Kaur ve ark., (2015), 152 lise öğrencisinin verilerini kullanarak öğrenci performanslarını tahmin etmek ve analiz etmek amacıyla farklı sınıflandırma tekniklerini kullanmışlardır. Veri setindeki risk altında bulunan öğrencilerin tespit edilmesinde en iyi algoritmayı bulmak için 5 sınıflandırıcı

belirlenmiştir. Bunlar; Çok Katmanlı YSA, NB, Sıralı Minimal Optimizasyon, J48- KAve Azaltılmış Hata Oranlı KA'larıdır. Bu sınıflandırma algoritmaları ile istatistikler oluşturulmuş ve doğruluğu tahmin etmek ve aralarında en iyi performansı gösteren sınıflandırma algoritmasını tespit etmek için beş farklı sınıflandırıcının karşılaştırılması yapılmıştır. Değişkenlerin sıralanması aşamasında WEKA' nın Ranker Search yöntemi kullanılmıştır. Sonuç olarak lise öğrencilerinin bilgilerinden oluşan veri seti için en iyi doğruluğu %75'lik bir oranla Çok Katmanlı YSA algoritması vermiştir. Diğer algoritmaların doğruluk değerleri ise %65 ile %70 arasında değişen değerlere sahiptir.

Singh ve ark., (2016), ilköğretim öğrencilerinin önceki sınav notlarını kullanarak performanslarını hangi faktörlerin etkilediğini ve öğrencilerin gelecek dönem notlarını belirlemek amacıyla 50 farklı okuldan öğrencilere ait veriler toplanmıştır. Sınıflandırma algoritmaları olarak KA, NB ve Zero R kullanılmıştır. KA algoritması %85.53'lük bir değerle en yüksek doğruluğu elde etmiştir. NB ile KA'nın doğruluk oranları oldukça yakındır. Zero R'nin ise doğruluk değeri diğer iki sınıflandırma algoritmasından daha düşüktür. Ayrıca okul türünün öğrenci performansını etkilemediği sonucuna da ulaşılmıştır.

Namlı (2016), bulanık mantık ile belirlenmiş çoklu zekâ türlerine göre düzenlenmiş öğrenme ortamlarının, Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü 2. ve 3. Sınıf öğrencilerinin akademik başarılarına etkisini tespit etmeyi amaçlamıştır. Araştırmanın verileri, çoklu zekâ ölçeği ve başarı testi ile toplanmıştır. Kümeleme analizi ile belirlenen deney ve kontrol gruplarında işleyiş; kontrol grubunda düz anlatım ile deney grubunda ise Adobe Flash Professional CS6 ile hazırlanmış olan bilgisayar destekli öğretim materyalleri ile gerçekleşmiştir. Veriler bağımlı ve bağımsız t-testi ve ANCOVA analizine tabi tutulmuştur. Yapılan analizler sonucunda deney ve kontrol grubunun başarı testi ön-test puanları arasında istatistiksel olarak anlamlı bir farklılık tespit edilmemiştir. Hem deney grubu hem de kontrol grubunun ön-test başarı puanları ile son test başarı puanları arasında son test lehine anlamlı farklılık tespit edilmiştir. Ayrıca deney grubu son-test ile kontrol grubu son-test başarı puanları arasında deney grubunun lehine anlamlı farklılık tespit edilmiştir.

Özdemir (2016), çalışmasında sınıflandırma tekniklerinin kullanarak lise düzeyindeki öğrencilerin akademik başarılarının belirlenmesini amaçlamıştır. Öğrencilerin akademik başarısını etkileyen; sosyoekonomik değişkenler ile kaygı, akademik güdülenme, tükenme, öğretmenlerinin depresyon düzeyi gibi faktörler ele alınmış ve okul idaresinden öğrenciye ait yıl sonu başarı ortalaması ile devamsızlıklarına yönelik bilgiler alınmıştır. Araştırmanın veri setini İstanbul il sınırında yer alan sosyo-demografik olarak çeşitliliklere sahip ilçelerdeki lise düzeyi okullarda öğrenim gören öğrenci bilgileri oluşturmuştur. Toplamda 2371 öğrenciden veri toplanmıştır. Ancak 819' kadın, 887'si erkek olmak üzere toplamda 1706 kişinin verisinin kullanılabilir durumda olduğu tespit edilmiştir. Çalışmada sınıflandırma teknikleri olarak, KNN, LR, C4.5- KA, NB ve DVM kullanılarak çeşitli modeller oluşturulmuştur. Hold-out ve tabakalı k-kat çapraz geçirme yöntemleri ile modellerin performansları denetlenmiştir. Yapılan analizler sonucunda kullanılan sınıflandırma tekniklerinin içerisinde C4.5- KA algoritmasının diğer algoritmalara kıyasla akademik başarının öngörülmesinde daha başarılı sonuçlar ürettiği bulunmuştur.

Kunt (2017), öğrencilerin sahip oldukları öğrenme stilleri ile matematiksel ispat çeşitlerine yönelimleri arasındaki ilişkiyi yapay zekâ metotlarından biri olan YSA modelini kullanarak gösterebilmeyi amaçlamıştır. Çalışmada nitel araştırmalarda sıklıkla kullanılan amaçlı örnekleme yöntemlerinden biri olan ölçüt örnekleme kullanılmıştır. Ayrıca çalışmada kullanılan YSA modelinin eğitilmesi aşamasında ileri beslemeli geri yayımlı ağ bağlantısı kullanılmıştır. Matematiğin 4 farklı alanı olan geometri, sayılar, cebir ve olasılık konuları ile ilgili 4 farklı soru geliştirilmiştir. Çalışmada, öğrencilerin kendilerine en yakın olan önermeden en uzak olan önermeye doğru bir sıralama oluşturmaları istenmiş ve bu sıralamalar giriş vektörü olarak kullanılmıştır. Öğrencilerin mevcut öğrenme stilleri ise çıktı vektörü olarak kullanılmıştır. Çalışmanın sonucunda ise modelin üretmiş olduğu sonuçlar ile tahmini öğrenme stilleri arasında tutarlılık gözlenmiştir.

Rovira ve ark., (2017), öğrencilerin okulu bırakmasını önlemek ve akademik olarak performanslarını artırmak amacıyla öğretmenlerin rolünün her zamankinden daha önemli olduğunu vurgulayarak, öğrencilerin akademik

verilerinin içine hapsolmuş ilgili bilgileri gün yüzüne çıkarmak için veriye dayalı bir sistem önermektedir. Veriye dayalı olan bu sistem özellikle makine öğrenmesi tekniklerine dayanmakta ve öğrencilerin okulu bırakma eğilimleri ve ders notları ile ilgili tahminlerin yanı sıra bireye özel ders önerileri de yapacak şekilde geliştirilmiştir. Sınıflandırıcılar olarak; LR, NB, DVM, RO ve Adaboost kullanılmıştır. Okulu bırakma tahminindeki makine algoritmaları %90 civarında bir doğruluğa ulaşmışlardır ancak RO ve Adaboost her ikisinde sırasıyla %76 ve %73'lük bir F1 puanı elde ederek bırakma tahmininde daha iyi performans göstermişlerdir. Bu çalışma ile okulu bırakma ihtimali olan öğrencilerin tespit edilmesinde makine öğrenmesi tekniklerinin gücünü kanıtlar bir niteliğe sahiptir.

Hoffait ve Schyns (2017), 2011–2012, 2012–2013 ve 2013–2014 yıllarında Liège Üniversitesi'ne (ULg) ilk kez kayıt yaptıran 11.496 öğrencinin çeşitli demografik bilgilerinden yararlanarak yüksek başarısızlık riski taşıyan öğrencileri tespit etmek için RO, LR ve YSA algoritmalarının performanslarını karşılaştırmışlardır. Gerçekleştirilen analizler sonucunda LR en yüksek doğruluğa sahip iken ikinci sırada YSA algoritması, üçüncü sırada ise RO algoritması yer almıştır.

Costa ve arkadaşları (2017), çalışmalarında programlamaya giriş dersi alan ve başarısız olma ihtimali yüksek olan öğrencileri erken tahmin etmek amacıyla sinir ağları, KA1, DVM ve NB teknikleri kullanmışlardır. Çalışmada iki ayrı veri kaynağı kullanılmıştır. Bu veri kaynaklarından ilki, 2013 yılında üniversitenin uzaktan eğitim olarak yürütülen programlamaya giriş dersini alan 262 lisans öğrencisine ait bilgilerden oluşmaktadır. Öğrenci bilgileri içerisinde; yaş, cinsiyet, şehir, medeni durum, gelir, sınıf, dönem gibi birçok özneliği içermektedir. Veri kaynaklarından ikincisi ise 2014 yılında üniversite kampüsü içerisinde yürütülen programlamaya giriş dersini alan 161 lisans öğrencisine ait bilgilerden oluşmaktadır. Çalışma sonucunda analizi yapılan tekniklerin başarısız olması yüksek ihtimal olan öğrencileri erken tespit edebildiği, algoritmalarda yapılan ince ayardan sonra mevcut tekniklerin bazılarının etkinliğinin arttığı sonucuna ulaşılmıştır. Ayrıca uygulanan dört teknik içerisinde en iyi performansa sahip olan tekniğin DVM olduğu tespit edilmiştir.

Babić (2017) çalışmasında akademik performansın akademik motivasyon ile yakından ilişkili olduğunu ifade etmiş ve Osijek’ teki Eğitim Fakültesinde tüm düzeylerde öğrenim görmekte olan öğrencilerin “Öğrenme Yönetim Sistemi” derslerindeki davranışlarını baz alarak akademik motivasyonlarını tahmin etmek amacıyla bir sınıflandırma modeli geliştirmiştir. Bu amaç doğrultusunda makine öğrenimi sınıflandırıcılarından KA, YSA ve DVM kullanmıştır. Modellerin performansında istatistiksel olarak anlamlı bir farklılık olup olmadığını belirlemek için ise t-testi kullanmıştır. Çalışmanın sonucunda, Öğrenme Yönetim Sistemi dersindeki davranışlarına göre öğrencilerin akademik motivasyonlarının tahmin edilmesinde kullanılan tüm sınıflandırıcıların başarılı olduğu ancak YSA modelinin diğerlerine oranla daha başarılı olduğu bulunmuştur. Bu model %76,92’lik bir genel sınıflandırma doğruluğu üretmiş ve ortalamanın altında bir akademik motivasyon düzeyine sahip olan öğrencileri diğer iki sınıflandırıcıya göre oldukça yüksek tahmin etmiştir.

Ciolacu ve arkadaşları (2018), çalışmalarında eğitim 4.0’da yapay zekâyı teşvik etmek amacıyla yenilikçi bir yaklaşım sunmayı hedeflemiştir. Çalışmanın nihai amacı, makine öğrenmesi teknikleri olan DVM ve YSA uygulayarak öğrencilerin sınavlardaki başarısızlık oranının azaltmaktır. Bu bağlamda, öğrencilerin final sınavına katılmadan önce final puanları tahmin edilmeye çalışılmıştır. Uygulama matematik ve bilgi yönetimi dersleri alan yükseköğretim öğrencileri üzerinde gerçekleştirilmiştir. Matematik dersini alan öğrencilerden, erken tanıma sistemi kullanılarak risk altında bulunan 21 öğrenci tespit edilmiştir. Benzer şekilde Bilgi Yönetimi dersinde işletme alanında risk altında olan 38 öğrenciyi, işletme bilişiminde ise risk altında olan 20 kişiyi tanımlamıştır. Sınavı geçebilmeleri için öğrenme stratejilerini gözden geçirmeye ihtiyaç duyduklarına yönelik profesörden kişiselleştirilmiş bir dikkat e postası almışlardır. Böylelikle başarısızlık oranı yaklaşık olarak yarı yarıya düşmüştür.

Miguéis ve arkadaşları (2018), bir kamu araştırma üniversitesinin Avrupa Mühendislik Okulu’ndaki 2003 ile 2015 yılları arasında öğrenim görmüş 2459 öğrencinin verilerini kullanarak, bu öğrencilerin akademik kariyerlerinin ilk yılının sonunda elde edilen bilgileri genel akademik performanslarının kestirmek için kullanmışlardır. Her bir öğrencinin ulaşacağı

performans düzeyini tahmin etmek için; RO, DVM, KA, torbalı ağaçlar, güçlendirilmiş ağaçlar ve NB olmak üzere toplamda 6 farklı sınıflandırma tekniği kullanılmıştır. Çalışma da önerilen modelin öğrencilerin akademik yolunun başlangıç aşamasında, öğrencilerin performans seviyelerini %95'in üzerinde bir doğrulukla tahmin ettiği sonucuna ulaşılmıştır. 6 farklı sınıflandırma tekniği içerisinde RO'nın diğer sınıflandırma tekniklerine kıyasla üstün olduğu bulunmuştur. RO tarafından desteklenen model, doğruluk açısından %96.1 performans seviyesine ulaşabilmişken, en kötü sonuçlar NB sınıflandırma tekniğinin tarafından desteklenen modelde olmuştur. Ayrıca öğrencilerin genel akademik performanslarını tahmin etmek için en uygun özneliklerin, öğrencilerin kayıt ortalama notu ile kayıt sınavı ortalama notu olduğu sonucuna ulaşılmıştır.

Ahmad ve Shahzadi (2018), öğrencilerin akademik performans açısından risk altında olup olmadığını belirlemek için YSA ile bir model oluşturmayı amaçlamışlardır. Sosyal bilimler de okuyan 300 öğrencinin; önceki başarıları, ev ortamları, öğrenme becerileri, çalışkanlık-gayretlikleri ve akademik etkileşimlerine ait veriler kullanılarak model oluşturulmuştur. Risk altında olmayan öğrencilerin sınıflandırılmasında, eğitim örnekleminde %95'in üzerinde ve holdout örnekleminde ise %85'in üzerinde bir doğruluk oranına ulaşılmıştır. Araştırmacılar, önermiş oldukları modelin akademik dereceye göre öğrencilerin risk altında olup olmadıklarını tahmin etmek için kullanılabileceğini ifade etmişlerdir.

Aydoğan ve Zırhlıoğlu (2018), öğrencilerin dönem bitiminde elde edeceği başarı ölçülerini önceden öngörebilecek, gerek duyulduğunda ise uygun müdahaleler ile öğrencilerin başarı düzeylerini artırmaya yönelik tedbirler alabilmeyi hedefledikleri çalışmalarında, YSA algoritmasını kullanarak bir model geliştirmişlerdir. 1049 öğrenciden toplanan veriler doğrultusunda analizler gerçekleştirilmiştir. Öğrencilerin dönem sonunda elde edecekleri başarı ölçüleri YSA ile geliştirilen model ile kestirilmiştir. YSA ile tahmin edilen başarı ölçüsü ile gerçekteki başarı ölçüleri arasındaki korelasyon değeri 0.911 olarak tespit edilmiştir.

Kartal ve arkadaşları (2019), makine öğrenmesi tekniklerini (KNN, NBS ve C4.5 -KA algoritmasını) ve Kolb Öğrenme Stilleri Envanterini kullanarak öğrencilerin öğrenme stillerini belirlemek amacıyla bir model

oluşturmayı ve oluşturulan modelin temel alındığı, mobilden ve webden ulaşılabilen bir uygulama geliştirmeyi hedeflemişlerdir. Öğrencilerden toplanan veriler ile makine öğrenmesi teknikleri kullanılarak en iyi performans gösteren model belirlenmiş ve uygulama tasarlanmıştır. Böylelikle hem öğrencilerin öğrenme stillerinin belirlenmesi daha kolay ve kısa bir süreçte gerçekleşecek hem de öğreticilerin öğrencilerin belirlenmiş öğrenme stillerine uygun olarak eğitim etkinliklerini tasarlamalarına imkân sağlanacaktır.

Eryılmaz ve Jaballa (2019), çalışmalarında öğrenme stillerine göre kişiselleştirilmiş öğrenme ortamlarının öğrencilerin akademik başarıları üzerindeki etkilerini değerlendirerek bir model önerisinde bulunmayı amaçlamışlardır. Çalışmanın örneklem grubunu Ankara'daki özel bir üniversitede okumakta olan, bilgisayara ve programlamaya giriş dersini alan Mühendislik Fakültesi 1. Sınıf öğrencisi oluşturmaktadır. Öntest ve sontest kontrol gruplu desenin kullanıldığı araştırmada, kişiselleştirme özellikleri olmayan bir çevrimiçi ortam ile VARK öğrenme stilleri modeli baz alınarak tasarlanmış kişiselleştirilmiş çevrimiçi öğrenme ortamlarında öğrenciler 14 haftalık süreçte ders materyallerine ulaşım sağlamışlardır. Çalışma sonucunda öğrenme stilleri baz alınarak kişiselleştirilmiş ve kişiselleştirilmemiş ortamlarda çalışan öğrencilerin akademik başarılarında anlamlı bir farklılık olup olmadığına bakılmıştır. Ayrıca öğrenme stilleri baz alınarak tasarlanmış kişiselleştirilmiş çevrimiçi ortamda, tek bir öğrenme stilini tercih eden öğrenciler ile birden fazla öğrenme stiline göre çalışmayı tercih eden öğrencilerin akademik başarılarında anlamlı bir farklılık olup olmadığına da bakılmıştır. Veri toplamak amacıyla; VARK öğrenme stilleri ölçeği ve araştırmacılar tarafından geliştirilmiş 20 maddeden oluşan akademik başarı ölçeği kullanılmıştır. Araştırmanın sonucunda, kişiselleştirilmiş öğrenme ortamlarında çalışan öğrencilerin akademik başarı puanları ile kişiselleştirilmemiş öğrenme ortamlarında çalışan öğrencilerin akademik başarı puanları arasında kişiselleştirilmiş ortamda çalışan öğrencilerin lehine anlamlı bir farklılık tespit edilmiştir. Ayrıca birden fazla öğrenme stilini tercih eden öğrencilerin akademik başarılarının, tek bir öğrenme stilini seçen öğrencilerin akademik başarılarından daha yüksek olduğu sonucuna da ulaşılmıştır.

Özkan (2019), ilişkisel tarama modeli kesitsel desende yürütmüş olduğu çalışmasında, fen bilgisi öğretmen adaylarının fen ve teknoloji okuryazarlığına yönelik öz yeterlik algıları ile akademik başarıları not ortalamalarına göre sınıflandırılmalarında yapay zekâ metotlarından biri olan YSA yönteminin performansını incelemeyi amaçlamıştır. Bu amaç doğrultusunda 2., 3., ve 4., sınıfta lisans eğitimlerine devam etmekte olan toplam 118 fen bilgisi öğretmen adayı ile çalışmıştır. Fen ve teknoloji okuryazarlığına ilişkin öz yeterlik algısı ölçeği ile kişisel bilgi formu (yaş, cinsiyet, not ortalamaları) veri toplama aracı olarak kullanılmıştır. Veriler analiz edilirken MATLAB R2015a programından faydalanılarak YSA yöntemi uygulanmıştır. YSA modeli olarak ise çok katmanlı, ileri beslemeli ve geri yayımlı model çalışma için tercih edilmiştir. Öğretmen adaylarının; fen ve teknoloji okuryazarlığına ilişkin öz yeterlik algısı ifadeleri, yaş ve cinsiyetleri giriş verisi olarak seçilirken, adayların not ortalamaları ise çıkış verisi olarak seçilmiştir. Gerçekleştirilen analiz sonuçlarına göre oluşturulan YSA algoritması, çalışmanın amacını %22.2 hata oranı ile gerçekleştirmiştir.

Lau ve arkadaşları (2019), üniversite eğitim kalitesinin iyi tahminlerini sağlamak amacıyla geleneksel istatistiksel değerlendirmelerin yeterli olmadığını düşünerek çalışmalarını planlamışlardır. Hem geleneksel istatistiksel analiz hem de sinir ağı modellemesi/öğrenci performansının tahmini ile bir yaklaşım sunmuşlardır. Çalışmanın verileri bir Çin Üniversitesinden, 2011-2013 giriş yılı için 275 kadın, 810 erkek olmak üzere toplamda 1000 öğrencinin sosyo ekonomik geçmişleri ve giriş sınavı sonuçları üzerinden toplanmıştır. Bu veriler, öğrencilerin genel not ortalamasını değerlendirmek ve tahmin etmek için kullanılmıştır. Sinir ağı, 11 girdi değişkeni, iki gizli nöron katmanı ve bir çıktı katmanı ile modellenmiştir. Sinir ağı modelinin performansı, hata performansı, regresyon, hata histogramı, karışıklık matrisi ve alıcı çalışma karakteristikleri eğrisinin altındaki alan aracılığıyla değerlendirilmiştir. Çalışmanın sonucunda, YSA modeli %84,4' lük iyi bir tahmin doğruluğu elde etmiştir.

Saa ve arkadaşları, (2019), çalışmalarında son on yılda artan, özellikle veri madenciliği yöntem ve tekniklerini kullanarak, öğrencilerin yükseköğretimdeki performanslarını etkileyen önemli faktörleri belirlemeye yönelik olarak yapılan çalışmaları analiz etmeyi amaçlamışlardır. Bu amaç

doğrultusunda öğrencilerin performanslarını etkileyen en çok çalışılan faktörleri ve bu faktörleri belirlemek için uygulanan en yaygın veri madenciliği tekniklerini belirlemeyi hedeflemişlerdir. 2009-2018 yılları arasında toplam 420 araştırma makalesinden 36'sı sistematik bir literatür taraması yaklaşımı uygulanarak gözden geçirilmiş ve analiz edilmiştir. Analiz sonucunda, öğrencilerin performansını etkileyen en yaygın faktörlerin 4 ana kategori altında toplandığı tespit edilmiştir. Bu ana kategoriler; öğrencinin önceki notları ve sınıf performansı, öğrencilerin demografik bilgileri, öğrencileri sosyal bilgileri ve öğrencilerin e-öğrenme etkinliğidir. Ayrıca öğrencilerin faktörlerini tahmin etmek ve sınıflandırmak için ise kullanılan en yaygın veri madenciliği tekniklerinin; KA, NBS ve YSA olduğu sonucuna ulaşılmıştır.

Yıldız ve Börekçi (2020), çalışmalarında sınıflandırma problemlerini çözmeyi amaçlamışlar ve dokuzuncu sınıf öğrencilerinden toplamış oldukları çeşitli veriler üzerinde veri madenciliği yöntemlerini uygulayarak bir görüş geliştirmeyi amaçlamışlardır. Çalışma kapsamında, öğrenciler ve aileleri hakkında demografik bilgiler, öğrenme etkinliklerine dahil olma alışkanlıkları, bilime yönelik epistemolojik inançları ve öğrencilerin ders çalışma rutinleri ile ilgili veriler toplanmıştır. Denetimli sınıflandırma algoritmalarından; KA, YSA, DVM, KNN, RO, NB ve LR kullanılmış ve tahmin doğrulukları karşılaştırılmıştır. Makine öğrenmesi algoritmalarından YSA algoritmalarının tahmin doğruluğu %98.6 ile en yüksek değere sahip çıkmıştır. Toplanan verilerin sınıflandırmayı etkilediği ve dolayısıyla bu değişkenler ile akademik başarı arasında bir ilişki olduğu sonucuna ulaşılmıştır.

Verma ve arkadaşları (2020), mühendislik fakültelerinde öğrenim gören öğrencilerin depresyon, stres ve kaygı gibi ruhsal durumlarını etkileyen faktörlerin neler olduğunu tahmin etmek amacıyla makine öğrenmesi yöntemlerinden olan LR ve DVM kullanmışlardır. 513 öğrenciden çevrimiçi ve çevrimdışı anketler kullanılarak veriler toplanmıştır. Modellerin performansını ölçmek için doğruluk, kesinlik, geri çağırma ve AUC-ROC eğrişi performans metrikleri kullanılmıştır. Gerçekleştirilen analizler sonucunda LR da elde edilen doğruluk %67 iken, DVM de elde edilen doğruluk %86.64 olarak tespit edilmiştir.

Ahmad ve arkadaşları (2020), çalışmalarında geleneksel ve makine öğrenimi yaklaşımlarını kullanarak öğrencilerden toplamış oldukları demografik ve akademik faktörler ile performansa dayalı tahminlerde bulunmayı amaçlanmışlardır. Çalışmanın örneklemini fizik bölümünde okuyan lisans ve yüksek lisans öğrencilerinden oluşan 90 kişi oluşturmuştur. Öğrencilerin akademik performanslarının ölçülmesinde yordayıcıların önemli bir rol üstlendiği sonucuna ulaşılmıştır. YSA'nın, öğrencilerin akademik performansını tahmin etmek için geleneksel istatistiksel yöntemler yerine kullanılabilir en iyi araç olduğu kanıtlanmıştır.

Cruz-Jesus ve arkadaşları, (2020), yapay zekâ tekniklerinin kullanarak öğrencilerin akademik başarılarını en iyi tahmin eden modeli tespit etmeye çalışmıştır. Çalışmada Portekiz Eğitim Bakanlığı Eğitim ve Bilim İstatistikleri Genel Müdürlüğü tarafından anonimleştirilmiş veri seti kullanılmıştır. 2014-2015 yıllarında 10, 11 ve 12. Sınıfta okuyan devlet liselerindeki toplam 110.627 kişiye ait verilerde, öğrencilere ait demografik bilgiler, öğrenci ailelerinin finansal bilgileri, okul ve okulun konumu hakkında bilgilerin olduğu toplamda 16 tane öznelik mevcuttur. Öğrencilerin akademik başarılarının tahmin edilmesinde YSA, KA, aşırı rastgele ağaçlar, RO, DVM, KNN ve LR algoritmaları kullanılmıştır. Çalışmanın sonucunda yapay zekâ tekniklerinin geleneksel yöntemle kıyasla tahmin bakımından daha iyi bir performansa sahip olduğu görülmüştür. Öğrencilerin akademik başarılarını tahmin etmede ise en iyi performansı gösteren algoritmanın RO olduğu tespit edilmiştir.

Blasi ve Alsuwaiket (2020), yükseköğretim kurumlarının karşı karşıya kaldığı en önemli problemlerden birinin öğrencilerin sergiledikleri yanlış davranışlar olduğundan yola çıkarak, üniversite kampüslerinde bu tür davranışlara sebep olan faktörleri belirlemek ve bu suistimalleri azaltmak için çalışmalarını gerçekleştirmişlerdir. Veri madenciliği sürecini yönetmek amacıyla CRISP-DM metodolojisi adımları gerçekleştirilmiş ve J48- KA ile YSA algoritmaları kullanılmıştır. Çalışmada yedi faktör dikkate alınmıştır. Bunlar; öğrenci branşı, cinsiyeti, öğrenci seviyesi, Kümülatif GPA, adres, etnik köken ve aylara göre suistimal zamanı. Kullanılan her iki teknik sonuçları karşılaştırılmıştır ve her iki teknik içinde doğruluk sonuçları yüksek iken, J48-KA, YSA' dan daha yüksek bir doğruluk vermiştir.

Abbasođlu (2020), ortaokul öđrencilerinin demografik bilgileri ile sosyoekonomik durumlarına yönelik verilerinin öđrencilerin yıl sonuna ait başarı ortalamalarına etkisini belirlemeyi amaçlamıştır. Bu amaç doğrultusunda dört farklı okulda 5,6,7 ve 8. Sınıfta öđrenim görmekte olan toplamda 27 bağımsız deđişkenen oluşan 1395 ortaokul öđrencisinin verilerinden faydalanılmıştır. Öđrencilerin yıl sonuna ait başarı ortalamalarının tahmininde WEKA programı kullanılarak, LR, doğrusal DVM, doğrusal olmayan DVM, RO, NB, KNN, YSA ve bagging olmak üzere çok sayıda sınıflandırma yöntemleri denenmiş ve elde edilen sonuçlar kıyaslanmıştır. Model deđerlendirme yöntemi olarak doğruluk ölçütü kullanılmıştır. Sınıflandırıcı algoritmaların uygulanması neticesinde ortaokul öđrencilerinin yıl sonu genel başarı ortalamasını en iyi tahmin eden algoritma LR olarak bulunmuştur.

Şimşek ve Canbay (2021), öđrencilerin uzaktan eğitim sürecinde yaşadıkları zorlukları en az seviyeye indirgemek amacıyla, öđrencilerin motivasyon gereksinimleri doğrultusunda bir mentor tarafından verilebilecek desteđe ihtiyaç duyup duymadıklarını tespit etmek amacı ile makine öđrenmesi yaklaşımlarını kullanmışlardır. Çalışma ile öđrencilere mentor kavramı ile birlikte dışsal motivasyon sağlanması böylelikle fırsat eşitliđi sunulması amaçlanmıştır. Çalışma Ürdün Üniversitesi öđrencileri ile gerçekleştirilmiş olup veri kümesi anket ile toplanmış veriler ile oluşturulmuştur. Çalışmada KNN, DVM, RO ve NB algoritmaları kullanılmıştır. Çalışmanın sonucunda DVM %95 F1 skoru ile en yüksek başarıyı gösteren sınıflandırıcı olarak tespit edilmiştir. Çalışma kapsamında kullanılan diđer sınıflandırıcılarda da benzer sonuçlar elde edilmiştir.

Şahin (2021), 328 kişiden oluşan ortaokul öđrencilerinden bazı bilgileri (demografik özellikler, sosyo-ekonomik bilgiler ve ders notları) toplayarak yılsonu ađırlıklı not ortalamalarını makine öđrenmesi yöntemlerini kullanarak tahmin etmeyi amaçlamıştır. Ayrıca başarıya etki eden öznelilikleri de tespit etmeyi hedeflemiştir. İstanbul a bağlı Tuzla ilçesinde bulunan bir ortaokuldan temin edilen veri seti üzerinden özellik seçimi yapılmış ve başarı üzerinde en çok etkiye sahip olan deđerşkenler bulunmuş ve modelleme yapılırken bu nitelikler kullanılmıştır. Çalışmanın amacı doğrultusunda; KNN, KA, NB, LR, YSA, RO, DVM olmak üzere toplamda yedi tane makine öđrenmesi

algoritması uygulanmış ve oluşturulan modellerin başarımlarını performansları kıyaslanmıştır. Modellerin başarımlarını ve performanslarını değerlendirme amacıyla, doğruluk, duyarlılık, kesinlik, F ölçütü, Roc Auc skoru metriklerinden ve de karmaşıklık matrisinden faydalanılmıştır. Yedi algoritma içerisinde başarımlarını performansını değerlendirmesi açısından en başarılı model RO olarak bulunmuştur. Başarıya en fazla etki eden niteliklerin ise öğrencinin akademik geçmişine ait bilgiler olduğu tespit edilmiştir. Öğrencilerin devamsızlık sayısı da başarıyı etkileyen diğer önemli nitelik olarak belirlenmiştir. Sosyoekonomik özellikler ile demografik bilgiler öğrenci başarımları üzerinde fazla bir etkiye sahip olmazken tahmin başarımlarına katkı sağlamışlardır. Çalışmanın sonunda RO modeli kullanılarak ortaokul düzeyindeki öğrencilerin akademik başarımlarının tahminine yönelik örnek bir sistem araştırmacı tarafından geliştirilmiş ve kullanıma sunulmuştur.

Bastem (2021), öğrencilerin akademik başarımlarının tahmin edilmesi amacıyla Portekiz de bulunan iki farklı okulda eğitim gören öğrencilere ait bilgilerden faydalanılarak veri seti oluşturulmuştur. Bu bilgilere Kaggle web sitesinden ulaşılmış ve veri setinin içerisinde her bir öğrenciye özgü toplamda 33 adet öznelik yer almıştır. Bu öznelikler içerisinde; demografik bilgiler, okul notları, okul bilgileri ve sosyal bilgileri yer almıştır. Öğrencilerin akademik performans tahminlerinin yapılması amacıyla makine öğrenmesi algoritmalarından olan KA, LR ve RO olmak üzere üç farklı algoritma kullanılmıştır. Veri setinin %70'i eğitim, %30'u ise test verisi olarak kullanılmıştır. Bu üç farklı algoritma kullanılarak, karmaşıklık matrisi, kesinlik, doğruluk ve auc değerleri bulunmuştur. Seçilen algoritmaların hangi miktarda veride daha iyi performans gösterdiği tespit etmeye çalışılmıştır. Sonuçlara göre; 649 öğrenci verisi için en yüksek derinlik 2 değeriyle en iyi doğruluk oranını KA vermiştir. LR algoritması ise 395 öğrenciye ait veri için en iyi doğruluğu vermiştir. Öğrencilerin demografik bilgilerinin, okul notlarının, okul bilgileri ve sosyal bilgilerinin akademik performans tahmininde kullanılabileceği sonucuna ulaşılmıştır.

Ali ve arkadaşları (2021), yapmış oldukları “Yapay Zekâ odaklı bir gelecekte yaratıcılar, düşünürler ve vatandaşlar olarak çocuklar” adlı çalışmalarında ortaokul öğrencilerine bir yaratma aracı olarak üretken yapay zekâ teknikleri tanıtılırken aynı zamanda bunların toplumsal ve etik etkileri

hakkında eleştirel tartışmalara odaklanılmıştır. Çalışma 38 ortaokul öğrencisi ile gerçekleştirilmiştir. Bu öğrencilere üretken modellemeyi, bunun Deepfakes oluşturmak için nasıl kullanıldığını, Deepfakes'i tanımaya yardımcı olan ipuçlarını ve yanlış bilgilerin yayılmasını ve tüm bunların etkilerini tanıtan öğrenme etkinlikleri sunulmuştur. Öğrenciler ise üretici medyanın inandırıcı olabileceğini fakat doğru olmayabileceğini ve doğru olmayan bilginin yayılmasına katkıda sağlayacağını anlamışlardır. Bunların yanı sıra yanlış olan bilginin neden zararlı veya kalıcı olabileceğini de belirleyebilmişlerdir. Öğrenciler, Deepfakes'in sosyal medyada varlığını çevreleyen politikalar hakkında görüşlerini dile getirmişlerdir. Bu yaklaşımın, öğrencilere teknolojinin hem üretken uygulamalarını hem de potansiyel olumsuz etkilerini oluşturan diğer teknik sistemleri tanıtmak amacıyla kullanılabilmesi sonucuna ulaşılabilir.

Vartiainen ve arkadaşları (2021), yeni nesil çocukların, iş piyasalarını alt üst eden ve insanların günlük hayatlarını önemli derecede değiştiren makine öğrenimi sistemleriyle büyüyor olmasına rağmen okullardaki bilgisayar eğitimine gereken önemin verilmediği düşüncesi ile çalışmalarının amaçlarını belirlemişlerdir. Çalışma ile ortaokul öğrencilerinin kendi makine öğrenimi uygulamalarının ortak tasarımcıları ve yapımcıları olmalarını desteklemek amacıyla pedagojik bir çerçeve sunulmuştur. Finlandiya'daki bir ilkokulun 6. Sınıfında yürütülen bu çalışmada 12-13 yaş arasında olan toplamda 34 öğrenci ile 2 haftalık bir süreç zarfında 3 atölye çalışmasını içermektedir. Çalışmanın verileri, bir çocuk resminden, öğrencilerin tasarım fikirlerinden, iş birliği ile tasarlanan uygulamalardan ve proje sonunda yapılan yapılandırılmış grup görüşmelerinden toplanmıştır. Çalışmanın sonuçlarına göre; makine öğrenimi tabanlı teknolojilerle uygulamalı keşiflerin öğrencileri gerçek hayattaki sorunları çözmek için yüz tanıma, jestler veya ses tanımadan yararlanan çeşitli tasarım fikirleri geliştirmede nasıl desteklendiğini gözler önüne sermiştir. Ayrıca makine öğrenimi uygulamalarının iş birliği içerisinde tasarlanmasının, öğrencilerin makine öğrenmesi ilkelerine, iş akışlarına ve günlük pratiklerindeki rolüne ilişkin kavramsal anlayışlarını geliştirmeleri için umut verici bir giriş noktası sağladığını göstermiştir. Makalenin sonu, öğrencilerin makine öğrenimi çağında yazılım tasarımcısı ve yenilikçi

olmaları için nasıl destekleneceklerine ilişkin bir tartışma ile sona erdirilmiştir.

Rodriquez Hernandez ve arkadaşları (2021), yükseköğretim de öğrencilerin akademik performansını tahmin etmek amacıyla YSA'nın uygulanmasına yönelik sistematik bir prosedürü test etmek ve akademik performansın iyi bilinen birkaç tahmin edicisinin önemini analiz etmeyi hedeflemişlerdir. Çalışmanın örneklem grubunu, Kolombiya'daki devlet ve özel üniversitelerinden toplamda 162.030 (% 40 erkek ve % 60 kadın) öğrenci oluşturmuştur. Çalışmada kullanılan veriler 2016 yılında SABER PRO sınavına giren Kolombiyalı üniversite öğrencilerinin yaklaşık 200.000 kaydını içermekte iken eksik ve yanlış veriler silindikten sonra toplamda 162.030 veri kaydı ile çalışma yürütülmüştür. Bu verilerin içerisinde her bir öğrenciye ait; yaş, cinsiyet, SABER 11 sınavından aldıkları puan, sosyoekonomik bilgileri, lise özellikleri, akademik programları, çalışmaları hakkında çeşitli bilgileri içermektedir. "Yüksek performans" grubu için çalışmada geliştirilen model test aşamasında, öğrencilerin %82'sini doğru bir şekilde sınıflandırırken, "düşük performans" grubu için çalışmada geliştirilen model test aşamasında, öğrencilerin %71'ini doğru bir şekilde sınıflandırmıştır. Bulgulardan hareketle, öğrencilerin akademik performansını yüksek veya düşük olarak sınıflandırmak için YSA sistematik olarak uygulamanın mümkün olduğu sonucuna ulaşılmıştır. Ayrıca öğrencilerin, yükseköğretime başlamadan önceki akademik başarı, sosyoekonomik koşulları ve lise özelliklerinin öğrencilerin yükseköğretimdeki akademik performanslarının önemli yordayıcıları olduğu bulunmuştur.

Kabathova ve Drlik (2021), mevcut eğitim verilerinin ışığında öğrencilerin okul terk durumlarının erken dönemde ve kesin bir şekilde tespit edilmesinin öneminden ötürü, yapılan çalışmada farklı makine öğrenmesi algoritmalarını kullanarak üniversite öğrencilerinin okulu terk edip etmeyeceklerini tahmin etmeye yönelik bir çalışma yürütülmüştür. Çalışmanın veri kümesini dört akademik yıldan toplanan veriler oluşturmuştur. Çalışma kapsamında LR, NB, KA, RO, DVM ve YSA algoritmaları kullanılmış ve kesinlik, doğruluk, F1 ve AUC-ROC eğrileri puanları karşılaştırılarak en iyi performansa sahip algoritma belirlenmiştir.

Performans tahminleri sırasıyla; %96.8 ile RO, %92.4 ile LR, %88.3 ile KA, %88 ile YSA, %85 ile DVM ve %76.5 ile NB'dir.

Pallathadka ve arkadaşları (2021), Portekiz Minho Üniversitesi tarafından başımlanan, 649 öğrenciye ait 33 öznelik ile oluşturulan veri seti üzerinden çalışmalarını gerçekleştirmişlerdir. Mevcut veri setine çeşitli makine öğrenmesi algoritmalarını uygulayarak öğrenci performanslarının sınıflandırılmasını ve tahmin edilmesini amaçlamışlardır. NB, ID3, C4.5 ve DVM algoritmalarını veri setine uygulamışlardır. Algoritmalar doğruluk ve hata oranı gibi özellikler dikkate alınarak değerlendirilmiştir. Çalışmanın sonucunda DVM'nin bir öğrenci performansı veri kümesini sınıflandırmak adına en doğru teknik olduğu bulunmuştur.

Özen (2021), çalışmasında STEM alanlarındaki öğretmen adaylarına yönelik geliştirilen makine öğrenmesi yönteminin planlanması, uygulanması ve değerlendirmesini amaçlamış ve bu amaç doğrultusunda fen bilimleri ve matematik öğretmenliği bölümlerinde eğitimlerine devam eden 74 öğretmen adayı ile çalışmasını gerçekleştirmiştir. 8 hafta boyunca makine öğrenmesi eğitiminin çevrimiçi platform üzerinden yürütüldüğü bu çalışmada, karma yöntem desenlerinden biri olan açımlayıcı desen kullanılmıştır. Çalışma tek gruplu öntest-sontest zayıf yarı deneysel desen ile yürütülmüştür. Veriler; Çevrimiçi derslere katılım ölçeği, moodle aktivite verileri, başarı testi, odak grup görüşmesi formu, derse katılım formu ve demografik veriler formu aracılığı ile toplanmış ve analizler yapılmıştır. Analizler sonucunda; verilen makine öğrenmesi eğitiminin STEM alanındaki öğretmen adaylarının akademik başarılarını artırdığına ve süreç boyunca katılımın yüksek düzeyde olduğuna ulaşılmıştır.

Yağcı (2022), bir devlet üniversitesinde 2019-2020 güz döneminde Türkçe I dersini alan 1854 lisans öğrencisinin ara sınav notlarını, final sınav notlarını, Fakülte ve bölüm bilgilerinin kullanarak bir veri seti oluşturmuştur. Lisans öğrencilerinin ara sınav notlarını kaynak veri olarak kullanarak final sınav notlarını tahmin etmek amacıyla makine öğrenmesi algoritmalarını kullanarak bir model geliştirmeyi hedeflemiştir. Diğer çalışmalardan farklı olarak öğrencilere ait as sayıda öznelik ile model geliştirmiştir. Öğrencilerin final sınav notlarını tahmin etmek için; KNN, LR, RO, DVM ve NB algoritmalarının öncelikle performansları hesaplanmış daha sonra ise

karşılaştırılmıştır. Çalışmanın sonucunda önerilen modelin %70-75 sınıflandırma doğruluğuna sahip olduğu bulunmuştur. Yapılan hesaplamalar sonucunda RO, KNN ve DVM algoritmalarının öğrencilerin final başarı notlarını tahmin etmede daha doğru sonuçlarla performans gösterdiği, KNN algoritmasının ise final notlarını tahmin etmede en düşük performansı gösterdiği tespit edilmiştir.

Kaya (2022), öğrencilerin akademik başarılarını hangi faktörlerin etkilediğini tespit etmek amacıyla iki farklı veri seti üzerinde çalışmasını yürütmüştür. Birinci veri setini Hindistan'ın Assam eyaletinde daha önceden yapılan bir çalışmadan elde edilmiş olan veriler ile oluşturmuştur. Portekiz'in Alentejo Bölgesinde iki farklı devlet okulundan ölçekler ile toplanmış veri setleriyle de ikinci veri setini oluşturmuştur. Çalışmada makine öğrenmesi algoritmalarından RO, DVM ve aşırı gradyan güçlendirmesi kullanılarak öğrencilerin akademik başarılarına etki eden faktörler tespit edilmeye çalışılmıştır. Elde edilen sonuçlar ise F-1 score ve doğruluk sonuçları ile doğrulanmış ve karşılaştırılması yapılmıştır. Kullanılan üç farklı algoritmanın içerisinde öğrencilerin akademik başarılarının etkileyen faktörlerin belirlenmesinde en iyi sonucu veren algoritmanın Aşırı Gradyan Güçlendirmesi'nin olduğu sonucuna ulaşılmıştır. Ayrıca çalışmanın sonucunda hesaplanmış olan başarı ölçüleri ile öğrencilerin akademik başarısını etkileyen faktörlerin alan yazındaki benzer araştırmalar ile karşılaştırıldığında dikkate değer şekilde benzerlik gösterdiği görülmüştür.

İlgili Araştırmaların Değerlendirilmesi

Yapılan literatür taramasında konu kapsamında ulaşılan ilgili araştırmalara yönelik genel bir değerlendirme yapılacak olunursa, yapay zekâ teknolojisi dünya çapında uzun yıllardır birçok sektörde hızlı bir şekilde gelişimini sürdürürken eğitim alanındaki yansımaları diğer sektörlerle oranla sınırlı kalsa da ülkemizde dahil olmak üzere iyi bir ivme yakaladığını söylemek güç değildir. Birçok araştırmacı için eğitimde yapay zekâ konusu güncelliğini ve popülerliğini korumakla birlikte her geçen gün bu alanda yapılan çalışmaların sayısında bariz bir artış yaşanmaktadır. Bu çalışmalar irdelendiğinde diğer birçok teknolojiye olduğu gibi öğrenmeleri desteklemek,

öğrenme ortamlarına yenilerini eklemek ve böylelikle eğitimin kalitesini, niteliğini artırarak eğitimi birçok açıdan en verimli hale getirmek ve planlama sürecinden değerlendirme sürecine kadar tüm eğitim sürecini kolaylaştırmak amaçlanmaktadır. Yapay zekâ teknolojisinin ve bu teknolojinin beraberinde getirdiği makine öğrenmesi kavramının eğitim alanında uygulamalarına yönelik olarak gerçekleştirilmiş olan çalışmaların amacına ve üstlendiği rollere, hangi örneklem grubunda ne amaçla çalışıldığına, amaç doğrultusunda kullanılan yöntemlere ve sonuçlara paragraf şeklinde aşağıda değinilmiştir.

Gerek yurtiçinde gerekse yurt dışında gerçekleştirilmiş olan çalışmalarda örneklem grubu olarak çoğunlukla üniversite öğrencileri seçilmiştir (Ahmad ve Shahzadi, 2018; Ahmad ve ark., 2020; Aydoğan ve Zırhlıoğlu, 2018; Babıç, 2017; Ciolacu ve ark., 2018; Costa ve ark., 2017; Eryılmaz ve Jaballa, 2019; Gray ve ark., 2014; Hoffait ve Schyns, 2017; Kartal ve ark., 2019; Kayabaş, 2011; Lau ve ark., 2019; Migueis ve ark., 2018; Mrinal ve Taruna, 2014; Namlı, 2016; Özen, 2021; Özkan, 2019; Pallathadka ve ark., 2021; Rodriquez Hernandez ve ark., 2021; Rovira ve ark., 2017; Saa ve ark., 2019; Tosun, 2007; Verma ve ark., 2020; Yağcı, 2022; Yavuzalp, 2012). Lise öğrencilerinin (Cruz-Jesus ve ark., 2020; Erümit, 2014; Kaur ve ark., 2015; Özdemir, 2016; Tepehan, 2011), ortaokul öğrencilerinin (Abbasoğlu, 2020; Ali ve ark., 2021; Kunt, 2017; Vartiainen ve ark., 2021) ve ilköğretim öğrencilerinin (Singh ve ark., 2016) örneklem grubu olarak seçildiği çalışmaların sayısı üniversite öğrencilerine oranla oldukça düşük seviyededir. Üniversite öğrencilerinin okudukları bölümler ise oldukça değişkendir. Mühendislik fakültesi, eğitim fakültesi, fen edebiyat fakültesi, tıp fakültesi gibi birçok farklı bölümde okuyan üniversite öğrencilerinin bilgileri üzerinde çalışmalar yürütülmüştür.

Gerçekleştirilen çalışmalar araştırma amaçlarına göre gruplandırıldığında; öğrencilerin performansları ve performanslarını etkileyen faktörlerin tespit edilmesinde (Kaur ve ark., 2015; Lau ve ark., 2019; Migueis ve ark., 2018; Mrinal ve Taruna, 2014; Pallathadka ve ark., 2021; Rodriquez Fernandez ve ark., 2021; Saa ve ark., 2019; Singh ve ark., 2016), öğrencilerin akademik başarılarının tahmin edilmesinde ve başarıyı etkileyen faktörlerin tespit edilmesinde (Abbasoğlu, 2020; Aydoğan ve Zırhlıoğlu, 2018; Bastem, 2021; Cruz ve Jesus, 2020; Kaya, 2022; Özdemir, 2016; Şahin,

2021; Tosun, 2007; Yağcı, 2022), öğrencilerin akademik motivasyonlarının tahmin edilmesinde (Babic, 2017), öğrencinin derse yönelik durumunun tespit edilmesinde (Bahçeci ve Gürol, 2010), öğrencilerin öğrenme stil ve stratejilerinin tespit edilmesinde (Eryılmaz ve Jaballa, 2019; Kartal ve ark., 2019; Yavuzalp, 2012), öğrencilerin dönem sonunda elde edecekleri başarı ölçülerini kestirmede (Aydoğan ve Zırhlıoğlu, 2018), öğrencilerin ruhsal durumlarını etkileyen faktörlerin tespit edilmesinde (Verma ve ark., 2020), öğrencinin derse ya da okula devam edip etmeyeceğinin tahmin edilmesinde (Rovira ve ark., 2017), akademik başarı ve akademik performans açısından risk altında bulunan öğrencilerin erken dönemde tespit edilmesinde (Ahmad ve Shahzadi, 2018; Ciolacu ve ark., 2018; Costa, 2017; Hoffait ve Schyns, 2018), PISA sonuçlarının yordanmasında (Tepehan, 2011), kişiselleştirilmiş öğrenme ortamlarının akademik başarıya etkisi (Eryılmaz ve Jaballa, 2019) olarak tespit edilmiştir.

İncelenen çalışmalarda kullanılmış olan sınıflandırma algoritmaları analiz edildiğinde, bazı çalışmalarda tek bir algoritma kullanılarak başarı oranı değerlendirilirken bazılarında çok sayıda algoritmanın kullanılarak başarı oranlarının kıyaslandığı görülmektedir. En sık kullanılan algoritmaların YSA, KA, NB ve DVM olduğu tespit edilmiştir. Ardından LR, RO, KNN’inde çalışmalarda sıklıkla kullanıldığına rastlanmıştır. Bu algoritmaların dışında Sıralı minimal optimizasyon, Zero R, REPTree ve Gradyan Artırmaları algoritmaları kullanılan diğer modellerdir. Bu çalışma kapsamında literatürde en sık kullanılan YSA, KA, NB, DVM, KA ve KNN algoritmalarına ek olarak EA algoritmasında kullanılarak öğrencilerin baskın zekâ türlerini en iyi tahmin eden modelin oluşturulması amaçlanmıştır.

2.8.2. Çoklu Zekâ Alanında Yapılan Çalışmalar

Gürçay ve Eryılmaz (2005), geleneksel öğretim ile çoklu zekâ kuramına dayalı öğretimin dokuzuncu sınıf öğrencilerinin fizik başarılarına etkisini tespit etmek amacıyla çalışmayı gerçekleştirmişlerdir. Bu amaç doğrultusunda ölçme aracı olarak; Çoklu zekâ anketi ve Fizik başarı testi (Coulomb konusunda) kullanılmıştır. Çalışma bir devlet okulunda 268 dokuzuncu sınıf öğrencisi ile gerçekleştirilmiştir. Ölçeklerin her ikisi ön test olarak deney ve

kontrol gruplarına uygulanmıştır. Son test olarak ise sadece başarı testi uygulanmıştır. Deney grubunda dersler Çoklu Zekâ Kuramına uygun olarak gerçekleştirilirken kontrol grubunda dersler geleneksel öğretimle gerçekleştirilmiştir. Deney grubunda öğrenciler en yüksek zekâ alanlarına göre görsel-uzamsal zekâ, sözel-dibilimsel zekâ, mantıksal matematiksel zekâ ve sosyal-kişilerarası zekâ alanlarında gruplara ayrılmıştır. Uygulama üç hafta gerçekleştirilmiş ve başarı testi her iki gruba da son test olarak uygulanmıştır. Çalışmanın sonucunda geleneksel öğretime kıyasla çoklu zekâ kuramına dayalı öğretim alan deney grubu dokuzuncu sınıf öğrencilerinin fizik başarılarında anlamlı bir etkisi olduğu tespit edilmiştir.

Uçak (2006), Çoklu Zekâ Kuramı' na göre hazırlanmış öğretim etkinliklerinin, yedinci sınıf öğrencilerinin, "Maddenin Sınıflandırılması ve Dönüşümleri" konusuna yönelik fen bilgisi dersine yönelik başarılarına ve tutumlarına etkisini belirlemeyi amaçlamıştır. Aynı zamanda öğrenilen bilgilerin akılda kalıcılığına etkisi olup olmadığını da test etmiştir. Öğrencilerin süreç boyunca hazırladıkları bireysel gelişim dosyaları araştırmacı tarafından incelenmiş ve velilerin dersin işleniş konusundaki görüşleri de araştırılmıştır. 2005-2006 eğitim öğretim yılının güz döneminde gerçekleştirilen çalışmada 27 deney, 27 kontrol olmak üzere 54 yedinci sınıf öğrencisi ile çalışılmıştır. 4 hafta süren çalışmada kontrol grubunda dersler düz anlatım ve soru cevap şeklinde yürütülürken, deney grubunda dersler Çoklu Zekâ Kuramı' na uygun olarak yürütülmüştür. Veri toplama aracı olarak; Başarı testi, Fen Bilgisi Tutum Ölçeği ve öğrencilerin bireysel gelişim dosyaları kullanılmıştır. Sonuç olarak, "Maddenin Sınıflandırılması ve Dönüşümleri" konusunun Çoklu Zekâ Kuramı' na uygun olarak işlenmesi, yedinci sınıf öğrencilerinin başarılarına ve fen bilgisi dersine yönelik tutumlarına ve edindikleri bilgilerin kalıcılığına anlamlı düzeyde bir katkı sağlamıştır. Çalışmanın nitel verilerinin nicel verileri destekler nitelikte olduğunun vurgusu yapılmıştır.

Balım (2006), fen konularının öğretiminde çoklu zekâ kuramına dayalı olarak yapılan öğretimin öğrencilerin başarılarına ve kalıcılığına etkisini incelemiştir. Ön test son test kontrol gruplu yarı deneysel desenin kullanıldığı çalışma da 29 deney grubu, 30 kontrol grubu olmak üzere 59 kişiden oluşan 6. Sınıf öğrencileri çalışmanın örneklemini oluşturmuştur. Çalışmanın

bulgularına göre çoklu zekâ kuramına uygun olarak gerçekleştirilen etkinlikler sonunda deney grubunun başarı ortalaması ve kalıcılık puanlarıyla, geleneksel öğretim ile gerçekleştirilen ders sonunda kontrol grubunun başarı ortalaması ve kalıcılık puanları arasında deney grubu lehine anlamlı farklılık tespit edilmiştir. Aynı zamanda kontrol grubu öğrencilerinin ön test ve son testlerinin arasında da anlamlı bir farklılık çıkmış ve geleneksel yönteminde öğrenci başarısı üzerine etkili olduğu kanaatine varılmıştır.

Şengül (2007), çoklu zekâ kuramı temelli öğretimin altıncı sınıf öğrencilerinin Fen ve Teknoloji dersi tutumlarına, dolaşım sistemi akademik başarılarına ve çoklu zekâ alanlarına etkisini incelemiştir. 2005-2006 eğitim öğretim yılında bir devlet okulunda öğrenim gören 52 öğrenci ile çalışmıştır. Kontrol grubunda dolaşım sistemi konusu geleneksel öğretim yöntemleri ile işlenirken deney grubunda aynı konu çoklu zekâ temelli öğretim ile işlenmiştir. Toplamda 5 hafta süren çalışmada veriler, Dolaşım Sistemi Başarı Testi, Fen Tutum Ölçeği ve Çoklu Zekâ Envanteri ile öntest ve son test olarak hem deney grubu öğrencilerine hem de kontrol grubu öğrencilerine uygulanmıştır. Çalışmanın sonucunda dolaşım sistemi akademik başarı testinde ve çoklu zekâ envanterinde, deney grubu öğrencileri ile kontrol grubu öğrencilerinin ortalama puanları arasında deney grubunun lehine anlamlı bir fark bulunurken, gruplar arasında fene karşı tutumda anlamlı bir farklılık tespit edilmemiştir.

Ateş (2007), altıncı sınıflarda çoklu zekâ kuramına dayalı Fen ve Teknoloji dersi “Maddenin tanecikli yapısı” ünitesinin işlenmesinin öğrencilerin akademik başarılarına ve fen dersine yönelik tutumlarına etkisini belirlemeyi amaçlamıştır. Bu amaç doğrultusunda; Çoklu zekâ envanteri, Fen dersine karşı tutum ölçeği, Maddenin tanecikli yapısına yönelik hazırlanan başarı testi ile öğrenme stilleri envanteri kullanılmış ve deney-kontrol gruplarına uygulanmıştır. Toplamda 42 altıncı sınıf öğrencisi ile çalışma yürütülmüş olup deney grubunda dersler çoklu zekâ kuramına uygun olarak işlenirken, kontrol grubunda geleneksel öğretim ile ders işlenmiştir. Başarı testi deney ve kontrol grubuna öntest-sontest olarak uygulanırken diğer veri toplama araçları her iki gruba da bir kez uygulanmıştır. Çalışma 12 haftalık bir zaman diliminde tamamlanmıştır. Çalışma sonucunda, maddenin tanecikli yapısı başarı testinde kontrol ve deney grubu arasında deney grubunun lehine

anlamalı bir farklılık tespit edilmiştir. Fene karşı tutumlarında gruplar arasında anlamalı bir farklılık bulunmamıştır. Ayrıca cinsiyet değişkeninin de her iki grupta akademik başarıyı etkilemediği tespit edilmiştir.

Öngören ve Şahin (2008), çoklu zekâ kuramının, ilköğretim yedinci sınıf “kuvvet, hareket ve enerji” ünitesinin öğretiminde öğrenci başarısına etkisini incelemeyi amaçlamışlardır. Çalışma kontrol ve deney gruplarında bulunana toplam 60 öğrenci ile yürütülmüştür. Veriler başarı testi ve görüşme formu aracılığı ile toplanmış ve analiz edilmiştir. Çalışmanın bulguları; çoklu zekâ kuramına uygun olarak öğretim görenlerin, geleneksel öğretim ile görenlere kıyasla daha başarılı olduklarını göstermiştir. Ayrıca deney grubundaki öğrenciler dersin işlenişi konusunda daha olumlu düşüncelere sahip olduklarını ifade etmişlerdir.

Demirci ve Yağcı (2008), “yaşamımızı yönlendiren elektrik” ünite bazında çoklu zekâ kuramı baz alınarak hazırlanmış olan etkinliklerin, ilköğretim altıncı sınıf öğrencilerinin başarıları üzerine etkisinin incelendiği çalışmada ön test son test yarı deneysel yöntem kullanılmıştır. Öğretim öncesi ve sonrasında veri toplama aracı olarak; çoklu zekâ envanteri ve elektrik başarı testi her iki grupta yer alan öğrencilere uygulanmıştır. Araştırmanın sonuçları; “yaşamımızı yönlendiren elektrik” ünitesinde çoklu zekâ kuramına dayalı öğretim gören öğrencilerin, geleneksel öğretim yöntemine göre öğretim gören öğrencilerden daha başarılı olduğu göstermiştir. İki grup arasında çoklu zekâ alanları arasında ise anlamalı bir farklılık tespit edilmemiştir.

Hasenekoğlu ve Gürbüzöğlü (2009), ikinci sınıf fen bilgisi öğretmen adaylarının, Çoklu Zekâ Kuramı’na dayalı hazırlanan öğretim etkinliklerinin protein sentezi konusundaki bilgilerinin kalıcılığına etkisini araştırmışlardır. 2007-2008 öğretim yılının bahar döneminde üç hafta süresince gerçekleştirilen çalışmada yarı deneysel yöntem kapsamında 34 deney grubu, 30 kontrol grubu olmak üzere toplamda 64 öğretmen adayı ile birlikte çalışılmıştır. Kontrol grubunda dersler geleneksel yaklaşıma dayalı olarak işlenirken deney grubunda dersler Çoklu Zekâ Kuramına dayalı olarak hazırlanmış ders planları ile işlenmiştir. Araştırmacı tarafından geliştirilen protein sentezi başarı testi uygulama öncesi ve sonrasında ön-test ve son test olarak uygulanmıştır. Ayrıca uygulama bittikten dört hafta sonra her iki gruba kalıcılık testi yapılmıştır. Çalışmanın sonucunda her iki grupta protein

sentezi başarı testi puanlarında artış olduğu ancak bu artışın Çoklu Zekâ kuramına dayalı işlenen deney grubunda daha fazla olduğu tespit edilmiştir. Aynı şekilde kalıcılık testi sonuçlarında da deney grubu öğrencilerinin bilgi kalıcılık düzeyleri kontrol grubuna kıyasla daha yüksek çıkmıştır. Geleneksel yaklaşıma dayalı olarak protein sentezinin işlendiği kontrol grubunda bilgilerin çok fazla hatırlanmadığı sonucuna ulaşılmıştır.

Altun (2009), çoklu zekâ kuramına dayalı öğretimin, yedinci sınıf öğrencilerinin Fen Bilgisi dersi Maddenin Yapısı ve Özellikleri ünitesi bazında uygulanmasının öğrenci başarılarına etkisini incelemeyi ve sonuçlar ışığında önerilerde bulunmayı amaçlamıştır. Ön test son test kontrol gruplu tasarımın kullanıldığı çalışmada, 104'ü deney grubu, 47'si ise kontrol grubu olmak üzere toplamda 151 öğrenci çalışmanın örneklemini oluşturmuştur. Deney grubunda dersler çoklu zekâ kuramına uygun olarak gerçekleştirilirken, kontrol grubunda geleneksel öğretim yöntemine bağlı kalınmıştır. Çalışmanın sonucunda deney grubunun lehine anlamlı farklılık olduğu tespit edilmiştir.

Oral ve Doğan (2010), Çoklu Zekâ Kuramının Ortaöğretimde “Elektrik” Konularını Öğrenme Sürecine Etkisi Üzerine Yaptıkları Çalışmada, Öğrencilerin Zekâ Alanını Tespit Etmeyi, Geleneksel Yöntem ile Çoklu Zekâ Kuramının Öğrencilerin Fizik Başarıları Üzerinde Nasıl Bir Etkiye Sahip Olduğunu Tespit Etmeyi Amaçlamışlardır. Çalışma Üç Farklı Lisenin Birinci Sınıfında Öğretim Gören Toplamda 164 Öğrenci İle Gerçekleşmiştir. Veri Toplama Aracı Olarak “Öğrenciler İçin Çoklu Zekâ Envanteri” İle Fizik Başarı Testi Kullanılmıştır. Çalışmanın Sonuçlarına Göre, Elektrik Konularının Öğretiminde Kullanılan Çoklu Zekâ Tabanlı Öğretim İle Ders İşleyen Deney Grubu Öğrencileri, Geleneksel Yöntem İle Ders İşleyen Kontrol Grubu Öğrencilerinden Daha Başarılı Olmuşlardır. Başarının En Çok M-R, S-D, S-K ve Doğacı Zekâ Gruplarındaki Öğrencilerin Öğrenmesi Üzerine Etki Ettiği Sonucuna Ulaşılmıştır.

Akpınar ve arkadaşları (2010), çalışmalarında Türkiye’de ilköğretim okullarında çoklu zekâ teoreminin öğrenme-öğretme sürecinde kullanılmasında ciddi problemlerle karşılaşıldığını ifade ederek bu sorunların neler olduğunu öğretmen görüşlerine dayalı olarak belirlemeyi amaçlamışlardır. Bu amaç doğrultusunda Diyarbakır ilinde görev yapmakta

olan 514 sınıf öğretmenine likert tipi bir ölçek uygulayarak verileri analiz etmişlerdir. Çalışmanın sonucunda sınıf öğretmenlerinin çoklu zekâ teoremini kısmen bildikleri, faydalı olduğunu düşündükleri ve kısmen de olsa öğretim sürecini planlarken dikkate aldıkları tespit edilmiştir. Ayrıca öğretmenlerin çoklu zekâ teorisinden yararlanırken çoklu zekâ teorisi hakkında yetersiz eğitim, değerlendirme güçlükleri, zaman baskısı, kalabalık sınıf ortamı ve birbiri ile uyumlu olmayan öğretim materyalleri gibi durumlardan ötürü birçok zorlukla karşı karşıya kaldıkları belirlenmiştir.

Akkuzu ve Akçay (2011), çalışmalarında öğrencilerin ilgi ve ihtiyaçlarından yola çıkarak çoklu zekâ kuramı tabanlı bir öğretim ortamı geliştirmişlerdir. Bu kapsamda öğrencilerin zekâ türlerine göre birçok farklı etkinlik hazırlamışlardır. Bu etkinliklerin 10. Sınıfta öğrenim gören öğrencilerin başarılarına, kimyaya yönelik tutumlarına, periyodik özelliklerin çeşitliliğinde bilginin kalıcılığı üzerindeki etkileri tespit etmeyi amaçlamışlardır. 37 kontrol grubu, 38 deney grubu olmak üzere toplamda 75 kişiden oluşan 10. Sınıf öğrencisi çalışmanın örneklemini oluşturmuştur. Literatür verilerine dayalı olarak geleneksel yazılı materyallere alternatif olarak; hikâyeler, kavram haritaları, bulmacalar, müzik, grup oyunları, çeşitli fotoğraflar ile öğretim materyalleri oluşturulmuştur. Çalışma toplamda 8 hafta sürmüştür. Çalışmanın sonuçlarında başarı boyutu açısından çoklu zekâ kuramının öğrencilerin başarıları ve tutumları üzerinde geleneksel yöntemle kıyasla daha olumlu bir etkiye sahip olduğu, ayrıca bilgilerin kalıcılığı anlamında da geleneksel yöntemle kıyasla daha etkili olduğu tespit edilmiştir. Yapılan görüşmelerin analizleri de nicel bulguları destekler niteliktedir.

Altınsoy (2011), çoklu zekâ kuramı'nın mevcut öğretim yöntemine kıyasla ilköğretim madde ve ısı ünitesi kapsamında altıncı sınıf öğrencilerinin başarılarına, tutum ve algılamalarına etkisini incelediği çalışmasında ilköğretim 6. Sınıf fen ve teknoloji müfredatına çoklu zekâ kuramının uygulanabilirliğini göstermeyi amaçlamıştır. Ön test son test kontrol grup tasarımı ile gerçekleştirilen çalışmanın örneklemini 25 deney grubu, 25 kontrol grubu olmak üzere toplamda 50 ilköğretim altıncı sınıf öğrencisi oluşturmuştur. Çalışma haftada 4 ders saati olmak üzere toplamda 6 haftalık bir süreçte gerçekleştirilmiştir. Ön bilgi testi, başarı testi, tutum ve algılama testi kullanılarak veriler toplanmıştır. Verilerin analizinde, gruplar arası

karşılaştırmalarda, başarı testi ile tutum ve algılama testi açısından deney ve kontrol grupları arasında istatistiksel olarak anlamlı bir fark olduğu tespit edilmiştir.

Stanciu ve arkadaşları (2011), öğretmen ve öğrenme sürecine çoklu zekâ teorisi perspektifinden yaklaşmanın öğrenme güçlüğü yaşayan bir grup ilköğretim öğrencisi üzerindeki etkisini belirlemeyi amaçlamışlardır. Çalışmada üçüncü ve dördüncü sınıfa kayıtlı olan 36 öğrenme güçlüğü çeken öğrenciler iki gruba ayrılmıştır. Deney grubunda çoklu zekâ teorisinden öğretim tekniklerine dayalı bir müdahale programı ile süreç sürdürülürken kontrol grubunda geleneksel öğretim ve öğrenme yöntemlerinden faydalanılmıştır. Sekiz haftada boyunca gerçekleştirilen çalışmada öğrenciler, daha geniş bir müfredat alanı olan “Matematik ve Fen Bilimleri kapsamında “Hayvan Bedenleri” adlı bir konu üzerinde çalışmışlardır. Süreç boyunca öğrenme güçlüğü yaşayan öğrencilerin her biri kendi zekâ türüne göre uyarlanmış çeşitli girdilere tabi tutulmuştur. Kontrol grubu öğrencileri ise aynı konuyu geleneksel yaklaşımla çalışmıştır. Çalışmanın sonucunda, çoklu zekâ kuramından türetilen öğretim tekniklerine dayalı bir müdahale programının, öğrenme güçlüğü yaşayan öğrencilerde akademik sonuçlarda önemli bir iyileşmeyi sağladığı sonucuna varılmıştır.

Abdi ve arkadaşları (2013), çoklu zekâ temelli öğretim stratejisinin ilköğretim beşinci sınıf öğrencilerinin fen bilimleri dersindeki akademik başarılarına etkisini incelemiştir. 20 deney grubu, 20 kontrol grubu olmak üzere 40 öğrenci ile çalışılmıştır. Deney grubundaki öğrenciler ile ders çoklu zekâ temelli öğretim ile gerçekleştirilirken, kontrol grubunda dersler geleneksel öğretim ile yürütülmüştür. 8 hafta süren deneysel çalışmada veri toplama aracı olarak fen bilimleri ile ilgili başarı testi kullanılmıştır. Verilere uygulanan ANCOVA analizi sonucunda, geleneksel öğretim sonucundaki öğrenci başarısının, çoklu zekâyaya dayalı öğretim sonucundaki öğrenci başarısından daha düşük olduğu tespit edilmiştir.

Özdoğru Şenel (2016), 7. Sınıf ışık ünitesini baz alarak çoklu zekâ kuramına uygun hazırlanmış olduğu etkinliklerin öğrencilerin öğrenmesine ve öğrenmenin kalıcılığa etkisini incelemek amacıyla çalışmasını gerçekleştirmiştir. 30 deney, 30 kontrol olmak üzere toplamda 60 öğrenci çalışmanın örneklemini oluşturmuştur. Veri toplama aracı olarak; Çoklu zekâ

gözlem formu, ünite başarı testi ve görüşme formu kullanılmıştır. 4 hafta boyunca haftada 4 saat olarak deney grubunda çoklu zekâ kuramına uygun hazırlanmış olan etkinlikler ile ders işlenirken kontrol grubunda geleneksel yönteme uygun olarak ders işlenmiştir. Uygulamalar öncesinde ve sonrasında veri toplama araçları öğrencilere uygulanmıştır. Birde uygulama bitiminde dört ay sonrasında öğrenmenin kalıcılığını tespit etmek amacıyla başarı testi tekrar uygulanmıştır. Elde edilen nicel verilerin analizi sonucunda; çoklu zekâyâ uygun olarak hazırlanmış uygulamalar ile işlenen dersin geleneksel yönteme kıyasla hem öğrencilerin öğrenmesinde hem de öğrenilen bilgilerin kalıcılığında istatistiksel olarak anlamlı olduğu sonucuna ulaşılmıştır. Ayrıca yapılan görüşmelerin analizinde, çoklu zekâyâ yönelik hazırlanan etkinlikler sayesinde öğrencilerin derse ilgi ve isteklerinin arttığı ve dersleri daha zevkli buldukları sonucuna ulaşılmıştır.

Şahan (2018), çoklu zekâ destekli eğitim modelinin fen bilimleri öğretiminde kullanımının, öğrencilerin akademik başarısı ve fen tutumları üzerindeki etkisinin araştırmayı amaçlamıştır. Çalışmanın örneklemini sekizinci sınıfta okuyan 18 deney grubu, 18 kontrol gurubu olmak üzere toplamda 36 öğrenci oluşturmaktadır. Ön test son test kontrol gruplu yarı deneysel desen çerçevesinde gerçekleştirilen çalışmada veri toplama aracı olarak; kişisel bilgiler, fen bilgisi tutum ölçeği, çoklu zekâ envanteri ve fen bilgisi başarı testi kullanılmıştır. Deneysel çalışmanın üç haftada tamamlanması sonucunda ölçek verileri analiz edilmiştir. Çalışmanın sonuçlarına göre; deney ve kontrol grupları arasında başarı ön test puanları ile TEOG neti arasında anlamlı bir farklılık tespit edilmezken, başarı son test puanı açısından deney grubunun lehine anlamlı bir farklılık tespit edilmiştir. Bunun yanında deney grubunda fen tutum açısından anlamlı düzeyde farklılık tespit edilirken kontrol grubunda fen tutum açısından anlamlı bir farklılık tespit edilememiştir.

Hajhaşimi ve arkadaşları (2018), öğrencilerin çoklu zekâ puanları ile cinsiyet ve yaşları arasında bir ilişki olup olmadığını incelemiştir. Ayrıca video destekli öğrenme modülünde öğrencilerin hangi çoklu zekâyı önemli olarak algıladıklarını tespit etmeyi amaçlamışlardır. Karma yöntem ile yürütülen çalışmada öncelikle öğrencilerin çoklu zekâ profillerini belirlemek amacı ile çoklu zekâ envanteri uygulanmış ardından ise öğrenciler ile görüşme

yapılmıştır. Araştırmanın örneklemini 236 üniversite öğrencisi oluşturmuştur. Ayrıca öğrencilere ait bazı demografik bilgiler (yaş, cinsiyet, akademik düzey vb.) toplanmıştır. Araştırmanın bulgularına göre öğrencilerin içsel zekâ türünde yüksek, varoluşsal zekâ türünde ise düşük olduğu sonucuna ulaşılmıştır. Öğrencilerin diğer ileri seviyede gelişmiş olan zekâları ise bedensel-kinestetik zekâ ile sözel-dilsel zekâ olarak bulunmuştur. Ayrıca öğrencilerin çoklu zekâ profilleri ile cinsiyet ve yaş kategorileri arasında anlamlı farklılıklar tespit edilmiştir. Mülakatların analiz sonuçları, zekâ kuramı baz alınarak hazırlanan videoların öğrencilerin zekâ türlerine ve yeteneklerine hitap edebileceğini ortaya koymuştur.

Taşçı (2019), Fatih Projesi destekli çoklu zekâ kuramına uygun olarak hazırlanmış uygulamaların, dokuzuncu sınıf öğrencilerinin kuvvet ve hareket konusunun öğretimine etkisini incelemek amacıyla 200 lise öğrencisi ile çalışmasını yürütmüştür. Araştırma, ön test son test kontrol gruplu yarı deneysel desen çerçevesinde yürütülmüştür. Deney grubunda dersler fatih projesi destekli çoklu zekâ kuramına uygun olarak işlenirken, kontrol grubunda dersler geleneksel yöntemle işlenmiştir. Çalışmanın sonuçlarına göre; ünitenin Fatih projesi destekli çoklu zekâ kuramına uygun olarak işlendiği deney grubu öğrencilerinin fizik başarılarında önemli düzeyde bir artış tespit edilmiştir. Ayrıca mantıksal-matematiksel zekâsı baskın olan öğrencilerin diğer öğrencilere kıyasla fizik başarılarındaki artış oranlarının daha yüksek olduğu belirlenmiştir.

Kural (2020), 2006-2019 yılları arasında yapılan, programda ön görülen öğrenme yöntemine kıyasla, çoklu zekâ kuramına dayalı olarak gerçekleştirilmiş çalışmaların öğrencilerin, fen dersi akademik başarılarına ve fen tutumlarına etkisini meta analiz yöntemi kullanarak genel etki büyüklüğünü hesaplamayı amaçlamıştır. Araştırmanın amacına hizmet edecek olan 44 çalışma akademik başarı için seçilirken, 25 çalışma ise fen dersine yönelik tutum için seçilmiştir. Gerçekleştirilen çalışmaların sonuçları değerlendirildiğinde çoklu zekâ kuramı baz alınarak yapılan öğrenmenin öğrencilerin akademik başarıları üzerindeki etki büyüklüğü 1,024 iken fen dersine karşı tutumları üzerindeki etki büyüklüğü 1,978 olarak hesaplanmıştır. Sonuç olarak çoklu zekâ kuramına dayalı öğrenmenin, programda önerilen

öğrenme yöntemine oranla, öğrencilerin fen akademik başarılarına ve fen tutumlarına olumlu yönde etki ettiği ifade edilmiştir.

Yüce (2020), çalışmasında altıncı sınıf Fen ve Teknoloji dersi konularının Çoklu Zekâ Kuramına uygun olarak işlendiği ve öğrencilerin başarılarına ve edindikleri bilgilerin kalıcılığına yönelik gerçekleştirilmiş yedi lisansüstü tezi eleştirel bakış açıcı ile analiz etmeyi amaçlamıştır. Belgesel tarama ve doküman analizi türünde çalışmasını yürütmüştür. Yapılan çalışmaların tamamında deneysel yöntemin kullanıldığını tespit etmiş ancak oluşturulan kontrol ve deney gruplarının genellikle denk gruplar olmamasını araştırmaların sonucunu etkilediğini ifade etmiştir. Çoklu Zekâ Kuramına uygun olarak hazırlanan öğretim yönteminin geleneksel öğretim yaklaşımına kıyasla öğrencilerin başarılarını olumlu yönde etkilediği tezlerin ortak sonucu olarak belirtilmiştir. Ayrıca Çoklu Zekâ Kuramına uygun öğretim yönteminin öğrencilerin derslerine olan ilgilerini yüksek oranda artırdığı araştırmacılar tarafından gözlenmiştir. İncelenen altı çalışmada öğrencilerin edindikleri bilgilerin kalıcılığının araştırmacılar tarafından ölçüldüğü sadece bir araştırmacının ölçmediği tespit edilmiştir.

Tüysüz ve Geban (2020), dokuzuncu sınıf öğrencileri ile yürütmüş oldukları çalışmada, 5E öğrenme döngüsü modeli ve çoklu zekâ temelli öğretimlerin, öğrencilerin kimyasal özellikler ünitesi kavramlarındaki başarılarına kimya dersine karşı tutumlarına, kimya öğrenmeye yönelik motivasyonlarına ve hatırlama düzeylerine etkisini belirlemeyi amaçlanmışlardır. Yarı deneysel desenin kullanıldığı çalışmada kontrol grubunda dersler geleneksel öğretim metodu ile işlenmiştir. Çalışmanın sonuçlarına göre 5E öğrenme döngüsü modeli ve çoklu zekâ temelli öğretimin öğrencilerin kimyasal özellikler başarılarına, kimyaya olan tutumlarına, kimya öğrenmeye yönelik motivasyonlarına ve hatırlama düzeylerine geleneksel öğretim metoduna kıyasla daha etkili olduğu sonucuna ulaşılmıştır. Ayrıca çalışmada öğrencilerin öz-yeterlilik ve kaygı ortalamaları da incelenmiş, gruplar arasında herhangi bir farklılık bulunamamıştır.

Nulhakim ve Berlian (2020), ilkokuldaki kız ve erkek öğrencilerin çoklu zekâ yeteneklerini incelemek amacıyla gerçekleştirdikleri çalışmalarında 2016-2017 eğitim öğretim yıllarında Cilegon'da bir ilkokulda öğrenim görmekte olan 35 deney gurubu, 36 kontrol grubu olmak üzere

toplamda 71 öğrenci ile çalışmıştır. Deney grubunun tamam çoklu zekâ ile öğrenmeyi kullanan erkek öğrencilerden, çoklu zekâ yaklaşımı ile öğrenmeyi kullanan kız öğrencilerden oluşturulmuştur. Çalışmanın bulgularında, deney grubu ile kontrol grubunun çoklu zekâ becerileri arasında istatistiksel olarak anlamlı bir fark olduğu ve deney grubun ortalama puanlarının kontrol grubuna kıyasla daha yüksek olduğu tespit edilmiştir. Bu sonuçların, deney grubu öğrencilerinin görsel–uzamsal, mantıksal-matematiksel, müzik, sosyal-kişilerarası ve bedensel-kinestetik zekâ alanlarındaki ortalama çoklu zekâ yetenekleri puanlarının daha yüksek olmasından kaynaklandığını ifade etmişlerdir. Kontrol grubundaki kız öğrencilerin ise çoklu zekâ yetenekleri puan ortalamalarının sözel-dilbilimsel, doğacı ve içsel-özedönük alanlarında daha yüksek olduğu sonucuna ulaşılmıştır. Genel olarak deney grubundaki erkek öğrencilerin çoklu zekâ araştırma sonuçlarının kontrol grubundaki kız öğrencilerin çoklu zekâ araştırma sonuçlarından daha iyi olduğu sonucuna varılmıştır.

Darmawan ve Hilmawan (2020), çalışmalarında ilköğretim öğrencilerinin çoklu zekâ türlerini ve zekâ türlerini etkileyen faktörleri tespit etmeyi amaçlamışlardır. Araştırmada betimsel analiz yöntemi kullanılmıştır. Veri toplama aracı olarak, gözlem, doküman analizi ve görüşme formu kullanılmıştır. Araştırmanın örneklemini ilköğretim ikinci sınıfta öğrenim görmekte olan 6 öğrenci oluşturmaktadır. Verilerin analizi sonucunda, çoklu zekânın tüm öğrencilerde yaygın olmasa dahi iyi bir gelişim hızında olduğuna ulaşılmıştır. İlköğretim öğrencilerinin ağırlıklı olarak gelişmiş zekâları, sözel-dilsel zekâ, mantıksal -matematiksel zekâ ve bedensel-kinestetik zekâdır. Bir sonraki en baskın zekâlar ise içsel, müziksel ve kişilerarası zekâdır. Görsel-uzamsal zekâ ile doğa zekâsının ise hala teşvik ve geliştirilmeye ihtiyaç duyulduğu belirtilmiştir. Öğrencilerin çoklu zekâ potansiyellerini etkileyebilecek faktörlerin çevre ve teşvik-uyarılma olduğu belirlenmiştir. Ayrıca yapılan görüşmelerde ebeveynlerin müdahalesinin öğrencilerin çoklu zekâ potansiyellerini teşvik edebileceği sonucuna da ulaşılmıştır.

Torreón ve Sumayang (2021), çoklu zekâ temelli hazırlanmış olan sınıf içi etkinliklerinin ilköğretim altıncı sınıf öğrencilerinin akademik başarılarına etkisini tespit etmeyi amaçlamışlardır. Veri toplama aracı olarak “demografik bilgiler anketi” ve “sınıfta çoklu zekâ” anketi kullanılmış, bir devlet okulunda

okuyan 200 altıncı sınıf öğrencisine ve 20 öğretmene uygulanmıştır. Çalışmanın bulgularına göre, çoklu zekâ temelli olarak hazırlanmış sınıf etkinliklerinin öğrencilerin akademik başarısına etkileri arasında anlamlı bir ilişki olduğu tespit edilmiştir. Bu bulgulardan hareketle çoklu zekâ kuramına dayalı öğretimin öğrencilerin akademik başarılarını artırabileceği sonucuna ulaşılmıştır.

İlgili Araştırmaların Değerlendirilmesi

Yapılan literatür taramasında konu kapsamında ulaşılan ilgili araştırmalara yönelik genel bir değerlendirme yapılacak olunursa, çoklu zekâ kuramının eğitimde tek bir yöntem kullanan geleneksel zekâ kavramına meydan okuduğu, birçok araştırmaya konu olduğu ve fen eğitiminde de sıklıkla kullanıldığını söylemek mümkündür. Çoklu zekâ kuramının fen eğitimi alanında uygulamalarına yönelik olarak gerçekleştirilmiş olan çalışmaların amacına, hangi örneklem grubunda daha fazla çalışıldığına ve sonuçlara paragraf paragraf aşağıda değinilmiştir.

Gerek yurtiçinde gerekse yurt dışında fen eğitimi alanında gerçekleştirilmiş olan çalışmalarda örneklem grubu olarak çoğunlukla ortaokul öğrencileri seçilmiştir (Abdi ve ark., 2013; Altun, 2009; Altınsoy, 2011; Ateş, 2007; Balım, 2006; Demirci ve Yağcı, 2008; Öngören ve Şahin, 2008; Özdoğru Şenel, 2016; Şahan, 2018; Şengül, 2007; Terreon ve Sumayang 2021; Uçak, 2006). Lise öğrencilerinin seçildiği çalışmalar (Akkuzu ve Akçay, 2011; Gürçay ve Eryılmaz, 2005; Oral ve Doğan, 2010; Taşçı, 2019; Tüysüz ve Geban, 2020), ilköğretim öğrencilerinin (Darmawan ve Hilmawan 2020; Nulhakim ve Berlian, 2020) ve üniversite öğrencilerinin örneklem olarak seçildiği (Akpınar ve ark., 2010; Hasenekoğlu ve Gürbüzöğlü, 2009; Haşhaşimi ve ark., 2018) çalışmalara kıyasla daha fazladır.

Gerçekleştirilen çalışmalarda genellikle, çoklu zekâ kuramına dayalı öğretim ile geleneksel öğretimin öğrencilerin akademik başarılarına, tutumlarına ve bilgide kalıcılığına etkisi incelenmiştir. Bu çalışmalarda çoklu zekâ kuramına dayalı işlenen fen derslerinin, geleneksel öğretim ile işlenen fen dersine kıyasla öğrencilerin akademik başarılarını olumlu yönde etkilediği sonucuna ulaşılmıştır (Abdi ve ark., 2013; Akkuzu ve Akçay, 2011; Altun,

2009; Altınsoy, 2011; Ateş, 2007; Balım, 2006; Demirci ve Yağcı, 2008; Gürçay ve Eryılmaz, 2005; Hasenekoğlu ve Gürbüzöğlü, 2009; Oral ve Doğan, 2010; Öngören ve Şahin, 2008; Özdoğru Şenel, 2016; Şahan, 2018; Şengül, 2007; Taşçı, 2019; Terreon ve Sumayang 2021; Uçak, 2006). Bazı çalışmalarda çoklu zekâ kuramına dayalı işlenen fen derslerinin, geleneksel öğretim ile işlenen fen dersine kıyasla öğrencilerin tutumlarını olumlu yönde etkilediği (Akkuzu ve Akçay, 2011; Altınsoy, 2011; Şahan, 2018; Uçak, 2006), bazılarında ise bir etkiye sebep olmadığı sonucuna ulaşılmıştır (Ateş, 2007; Şengül, 2007). Bazı çalışmalarda ise çoklu zekâ kuramına dayalı işlenen fen derslerinin, geleneksel öğretim ile işlenen fen dersine kıyasla öğrencilerin bilgilerindeki kalıcılığı olumlu yönde etkilediği sonucuna ulaşılmıştır (Akkuzu ve Akçay, 2011; Balım, 2006; Hasenekoğlu ve Gürbüzöğlü, 2009; Özdoğru ve Şenel, 2016; Uçak, 2006). Bu çalışma kapsamında literatürden farklı olarak, öğrencilerin baskın zekâ türlerinin bir makine öğrenmesi algoritması ile oluşturulmuş model yardımı ile tahmin edilmesi ve baskın zekâ türlerine uygun e-öğrenme ortamında fen eğitimi almalarını sağlamak amaçlanmıştır.

KAYNAKÇA

- Abbasi, S., Ayoob, T., Malik, A. ve Memon, S. I. (2020). Perceptions of students regarding E-learning during COVID-19 at a private medical college. *Pakistan journal of medical sciences*, 36 (COVID19-S4), 57-61. <https://doi.org/10.12669/pjms.36.COVID19-S4.2766>
- Abbasoğlu, B. (2020). Ortaokul öğrencilerinin akademik başarılarının eğitsel veri madenciliği yöntemleri ile tahmini. *Veri Bilimi*, 3(1), 1-10.
- Abdi, A., Laei, S. ve Ahmadyan, H. (2013). The effect of teaching strategy based on multiple intelligences on students' academic achievement in science course. *Universal Journal of Educational Research*, 1(4), 281-284. <https://doi.org/10.13189/ujer.2013.010401>
- Ahmad, S., Hussain, I., Ahmad, R. ve Din, M. N. U. (2020). Performance based prediction of the students in the physics subject using traditional and machine learning approach at higher education level. *International Journal of Innovation in Teaching and Learning (IJITL)*, 6(1), 174-190. <https://doi.org/10.35993/ijitl.v6i1.997>
- Ahmad, Z. ve Shahzadi, E. (2018). Prediction of students' academic performance using artificial neural network. *Bulletin of Education and Research*, 40(3), 157-164.
- Akkuzu, N. ve Akçay, H. (2011). The design of a learning environment based on the theory of multiple intelligence and the study its effectiveness on the achievements, attitudes and retention of students. *Procedia Computer Science*, 3, 1003-1008. <https://doi.org/10.1016/j.procs.2010.12.165>
- Akmeşe, Ö. F., Kör, H. ve Erbay, H. (2021). Use of machine learning techniques for the forecast of student achievement in higher education. *Information Technologies and Learning Tools*, 82(2), 297-311. <https://doi.org/10.33407/itlt.v82i2.4178>
- Akpınar, B., Selim, E.F. ve Emrullah, Y. (2010). Problems encountered in the applications of multiple intelligence theory in primary schools in Turkey. *Procedia-Social and Behavioral Sciences*, 9, 1873-1877. <https://doi.org/10.1016/j.sbspro.2010.12.416>

- Ali, S., DiPaola, D., Lee, I., Sindato, V., Kim, G., Blumofe, R. ve Breazeal, C. (2021). Children as creators, thinkers and citizens in an AI-driven future. *Computers and Education: Artificial Intelligence*, 2, 100040, 1-11. <https://doi.org/10.1016/j.caeai.2021.100040>
- Alkhatlan, A. ve Kalita, J. (2018). Intelligent tutoring systems: A comprehensive historical survey with recent developments. 1-31. <https://doi.org/10.48550/arXiv.1812.09628>
- Alpaydın, E. (2013). *Yapay öğrenme* (2nd Ed). Boğaziçi Üniversitesi Yayınevi.
- Alpaydın, E. (2014). *Introduction to machine learning*. MIT Press.
- Alsahhi, N. R. I. (2020). The representation of multiple intelligences in the science textbook and the extent of awareness of science teachers at the intermediate stage of this theory. *Thinking Skills and Creativity*, 38, 100706. <https://doi.org/10.1016/j.tsc.2020.100706>
- Altınsoy, A.B. (2011). *Fen ve teknoloji dersinde çoklu zekâ kuramına dayalı öğretimin öğrencilerin başarılarına etkisi* [Yayımlanmamış yüksek lisans tezi]. Selçuk Üniversitesi.
- Altun, Ç. (2009). *Fen bilgisi öğretiminde “maddenin yapısı ve özellikleri” ünitesinin kavranmasında çoklu zekâ kuramına dayalı öğretimin öğrenci başarısına etkisi* [Yayımlanmamış yüksek lisans tezi]. Kafkas Üniversitesi.
- Armstrong, T. (1994). *Multiple intelligences in the classroom*. ASCD.
- Armstrong, T. (2000). *Multiple intelligences in the classroom*. Curriculum Development Publishing
- Armstrong, T. (2003). *Multiple intelligences of reading and writing*. Association for Supervision & Curriculum Development.
- Arslan, K. (2020). Eğitimde yapay zekâ ve uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Ateş, R. Ö. (2007). *6. sınıflarda maddenin tanecikli yapısı konusunun çoklu zekâ kuramına dayalı öğretimi* [Yayımlanmamış yüksek lisans tezi]. Balıkesir Üniversitesi.
- Ayas, A., Karataş, F.Ö., Ünal, S. ve Çalık, M. (2001, Eylül,7-8). *Gazlar konusyla ilgili bilgisayar yazılımlarının yeterliliklerinin araştırılması ve örnek bir yazılım geliştirilmesi* [Sözlü Sunum]. Yeni

- Bin yılın Başında Türkiye'de Fen Bilimleri Eğitimi Sempozyumu, Maltepe Üniversitesi Eğitim Fakültesi, İstanbul.
- Aydoğan, İ. ve Zırhloğlu, G. (2018). Öğrenci başarılarının yapay sinir ağları ile kestirilmesi. *Van Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi*, 15(1), 577-610. <http://dx.doi.org/10.23891/efdyu.2018.80>
- Ayhan, S. ve Erdoğmuş, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Aylak, B., Oral, O. ve Yazıcı, K. (2021). Yapay zekâ ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezeri Journal of Science and Engineering*, 8(1), 74-93. <https://doi.org/10.31202/ecjse.776314>
- Ayık, Y. Z., Özdemir, A. ve Yavuz, U. (2007). Lise türü ve lise mezuniyet başarısının, kazanılan fakülte ile ilişkisinin veri madenciliği tekniği ile analizi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 441-454.
- Azar, A. T., Elshazly, H. I., Hassanien, A. E. ve Elkorany, A. M. (2014). A random forest classifier for lymph diseases. *Computer methods and programs in biomedicine*, 113(2), 465-473. <https://doi.org/10.1016/j.cmpb.2013.11.004>
- Babić, I. Đ. (2017). Öğrenci akademik motivasyonunu tahmin etmede makine öğrenmesi yöntemleri. *Hırvat Yöneylem Araştırması İncelemesi*, 443-461.
- Bacos, C. A. (2020). Machine learning and education in the human age: a review of emerging technologies. In *Advances in Computer Vision: Proceedings of the 2019 Computer Vision Conference (CVC), Volume 2 1* (pp. 536-543). Springer International Publishing.
- Bahçeci, F. ve Gürol, M. (2010). Eğitim de akıllı öğretim sistemleri uygulamalarına yönelik bir model önerisi. *Engineering Sciences*, 5(2), 121-128.
- Baker, T., Smith, L. ve Anissa, N. (2019). Educ-AI-tion rebooted? Exploring the future of artificial intelligence in schools and colleges. Retrieved May, 12, 2020.

https://media.nesta.org.uk/documents/Future_of_AI_and_education_v5_WEB.pdf

- Balaban, M. E. ve Kartal, E. (2015). *Veri madenciliği ve makine öğrenmesi temel algoritmaları ve R Dili ile uygulamaları*. Çağlayan Kitabevi.
- Balım, A. G. (2006). Fen konularının çoklu zekâ kuramına dayalı öğretiminin öğrencilerin başarılarına ve kalıcılığa etkisi. *Eurasian Journal of Educational Research (EJER)*, (23), 10-19.
- Bastem, H. N. (2021). *Student academic performance prediction via artificial intelligence using machine learning algorithms* [Unpublished master's thesis]. Çankaya University.
- Bellanca, J. (1997). *Active learning handbook for the multiple intelligences classroom*. Skylight Training and Publishing.
- Bernstein, A. Douglas, Clarke A. Steward, Edward J. Roy, Thomas K. Srull ve Christopher D. Wickens (1994). *Psychology*. Houghton Mifflin Company.
- Bhatia, N. (2010). Survey of nearest neighbor techniques. *International Journal of Computer Science and Information Security*, 8(2), 302-305. <https://doi.org/10.48550/arXiv.1007.0085>
- Bhutoria, A. (2022). Personalized education and artificial intelligence in United States, China, and India: A systematic Review using a Human-In-The-Loop model. *Computers and Education: Artificial Intelligence*, 3, 100068, 1-18. <https://doi.org/10.1016/j.caeai.2022.100068>
- Blasi, A. H. ve Alsuwaiket, M. (2020). Analysis of students' misconducts in higher education using decision tree and ann algorithms. *Engineering, Technology & Applied Science Research*, 10(6), 6510-6514. <https://doi.org/10.48084/etasr.3927>
- Blum, A. (2007). Machine learning theory. *Carnegie Mellon University, School of Computer Science*, 26, 1-4.
- Boser, B. E., Guyon, I. M. ve Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144-152). <https://doi.org/10.1145/130385.130401>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.

- Bulun M., Gülnar B. ve Güran M. S. (2004). Eğitimde mobil teknolojiler. *The Turkish Online Journal of Educational Technology*, 3(2), 165-169.
- Burkov, A. (2020). *Machine learning engineering*, QC, True Positive Incorporated.
- Bümen, Nilay, T. (2005). *Okulda çoklu zekâ kuramı* (3. Baskı). Pegem Yayıncılık.
- Büyükkeçeci M. (2019). *Evaluation of the relationship between the stability of feature selection techniques and classification performance in data mining* [Yayımlanmamış doktora tezi]. Yaşar Üniversitesi.
- Camacho, D. M., Collins, K. M., Powers, R. K., Costello, J. C. ve Collins, J. J. (2018). Next-generation machine learning for biological networks. *Cell*, 173(7), 1581-1592.
<https://doi.org/10.1016/j.cell.2018.05.015>
- Campbell, L., Campbell, B. ve Dickinson, D. (1996). *Teaching & Learning through Multiple Intelligences*. Allyn and Bacon, Simon and Schuster Education Group, 160 Gould Street, Needham Heights, MA 02194-2315.
- Campbell, L. ve Campbell, B. (1999). *Multiple intelligences and student achievement: Success stories from six schools*. ASCD.
- Carbonell, J. R. (1970). AI in CAI: An artificial-intelligence approach to computer-assisted instruction. *IEEE transactions on man-machine systems*, 11(4), 190-202.
- Chassignol, M., Khoroshavin, A., Klimova, A. ve Bilyatdinova, A. (2018). Artificial Intelligence trends in education: a narrative overview. *Procedia Computer Science*, 136, 16-24.
<https://doi.org/10.1016/j.procs.2018.08.233>
- Chiu, T. K., Xia, Q., Zhou, X., Chai, C. S. ve Cheng, M. (2022). Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 4, 100118, 1-15.
<https://doi.org/10.1016/j.caeai.2022.100118>

- Ciolacu, M., Tehrani, A. F., Binder, L. ve Svasta, P. M. (2018, October, 25-28). *Education 4.0-Artificial Intelligence assisted higher education: early recognition system with machine learning to support students' success*. In 2018 IEEE 24th International Symposium for Design and Technology in Electronic Packaging (SIITME), Iasi, Romani
- Cruz-Jesus, F., Castelli, M., Oliveira, T., Mendes, R., Nunes, C., Sa-Velho, M. ve Rosa-Louro, A. (2020). Using artificial intelligence methods to assess academic achievement in public high schools of a European Union country. *Heliyon*, 6(6), e04081. <https://doi.org/10.1016/j.heliyon.2020.e04081>
- Coppin, B. (2004). *Artificial intelligence illuminated*. Jones & Bartlett Learning.
- Costa, E. B., Fonseca, B., Santana, M. A., de Araújo, F. F. ve Rego, J. (2017). Evaluating the effectiveness of educational data mining techniques for early prediction of students' academic failure in introductory programming courses. *Computers in human behavior*, 73, 247-256. <https://doi.org/10.1016/j.chb.2017.01.047>
- Costa-Mendes, R., Oliveira, T., Castelli, M. ve Cruz-Jesus, F. (2021). A machine learning approximation of the 2015 Portuguese high school student grades: A hybrid approach. *Education and Information Technologies*, 26(2), 1527-1547. <https://doi.org/10.1007/s10639-020-10316-y>
- Coşkun, F. ve Gülleroğlu, H. D. (2021). Yapay zekânın tarih içindeki gelişimi ve eğitimde kullanılması. *Ankara University Journal of Faculty of Educational Sciences (JFES)*, 54(3), 947-966. <https://doi.org/10.30964/auebfd.916220>
- Cunningham, P. ve Delany, S. J. (2021). K-nearest neighbour classifiers-a tutorial. *ACM Computing Surveys (CSUR)*, 54(6), 1-25. <https://doi.org/10.1145/3459665>
- Çakan, S. H. (2006). *Çoklu zekâ teorisinin kimya eğitiminde uygulanması* [Yayımlanmamış yüksek lisans tezi]. Hacettepe Üniversitesi
- Darmawan, N. H. ve Hilmawan, H. (2020). Multiple intelligence potential and influencing factors for elementary school students analysis. In *International Conference on Elementary Education*, 2(1), 643-663.

- Demirci, N. ve Yağcı, Z. (2008). Fen bilgisi dersi “yaşamımızı yönlendiren elektrik” ünitesinin çoklu zekâ kuramı etkinliklerine göre değerlendirilmesi. *Eğitimde Kuram ve Uygulama*, 4(1), 79-97.
- Demirel, Ö. (1999). *Planlamadan değerlendirmeye öğrenme sanatı*. Pegem Yayınları
- Demirel, Ö., Başbay, A. ve Erdem, E. (2006). *Eğitimde çoklu zekâ kuram ve uygulama*. Pegem Yayıncılık.
- Deshpande, A. ve Kumar, M. (2018). *Artificial intelligence for big data: Complete guide to automating big data solutions using artificial intelligence techniques*. Packt Publishing. Ltd.
- Devroye, L. ve Wagner, T. J. (1982). 8 nearest neighbor methods in discrimination. *Handbook of Statistics*, 2, 193-197.
- Dickson, B. (2017). Dar, genel ve süper yapay zekâ nedir [Blog yazısı]-
<https://bdtechtalks.com/2017/05/12/what-is-narrow-general-and-super-artificial-intelligence/>
- Doğaç, A. (2015). MYCIN I - Uzman sistemler. *Elektik Mühendisliği*. 7(7), 87-91.
- Doğan, A. (2002). *Yapay zekâ*. Kariyer.
- Domingos, P. (2017). *Master algoritma* (2. Baskı). (T.Göbekçin, Çev.). Paloma Yayınevi.
- Durmuş, F. (2013). *Çoklu zekâ kuramıyla öğretimde bazı alternatif değerlendirme teknikleri kullanımının öğrencilerin matematik başarı, tutum, hatırlama ve üst biliş becerilerine etkileri* [Yayımlanmamış doktora tezi]. Marmara Üniversitesi.
- Elmas, Ç. (2007). *Yapay zeka uygulamaları (yapay sinir ağı, bulanık mantık, genetik algoritma)*. Seçkin Yayın Evi.
- Emmert-Streib, F., Yli-Harja, O. ve Dehmer, M. (2020). Explainable artificial intelligence and machine learning: A reality rooted perspective. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(6), 1-8. <https://doi.org/10.1002/widm.1368>
- Erbay Mermer, Ş. (2022). *Minnesota çok yönlü kişilik envanteri için makine öğrenmesi temelli bireyselleştirilmiş bilgisayarlı test uygulamasının geliştirilmesi* [Yayımlanmamış doktora tezi]. Hacettepe Üniversitesi.

- Erümit, A. K. (2014). *Polya'nun problem çözme adımlarına göre hazırlanmış yapay zekâ tabanlı öğretim ortamının öğrencilerin problem çözme süreçlerine etkisi* [Yayınlanmamış doktora tezi]. Karadeniz Teknik Üniversitesi.
- Eryılmaz, M. ve Jaballa, R. (2019). Öğrenme stillerine göre kişiselleştirilmiş çevrimiçi öğrenme ortamları için bir model önerisi. *Turkish Studies-Information Technologies and Applied Sciences*, 14(2), 179-192.
- Favale, T., Soro, F., Trevisan, M., Drago, I. ve Mellia, M. (2020). Campus traffic and e-Learning during COVID-19 pandemic. *Computer networks*, 176, 107290. <https://doi.org/10.1016/j.comnet.2020.107290>
- Ferrero, M., Vadillo, M. A. ve León, S. P. (2021). A valid evaluation of the theory of multiple intelligences is not yet possible: Problems of methodological quality for intervention studies. *Intelligence*, 88, 101566, 1-14. <https://doi.org/10.1016/j.intell.2021.101566>
- Fjelland, R. (2020). Why general artificial intelligence will not be realized. *Humanities and Social Sciences Communications*, 7(1), 1-9. <https://doi.org/10.1057/s41599-020-0494-4>
- Gardner, H. (2004). *Zihin çerçeveleri çoklu zekâ kuramı*. Alfa Yayınları.
- Gardner, H. E. (2011). *The unschooled mind: How children think and how schools should teach*. Basic Books.
- Geron, A. (2021). *Scikit-Learn, Keras ve TensorFlow ile uygulamalı makine öğrenmesi* (Çev. B. Aksoy ve Ö. Kaya). Buzdağı Yayınevi.
- Geurts, P., Ernst, D. ve Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63(1), 3-42.
- Goel, R. (2021, July, 12). *Heart Disease Prediction Using Various Algorithms of Machine Learning*. In Proceedings of the International Conference on Innovative Computing & Communication (ICICC).
- Gou, J., Xiong, T. ve Kuang, Y. (2011). A novel weighted voting for k-nearest neighbor rule. *Journal of Computers*, 6(5), 833-840. <http://doi.org/10.4304/jcp.6.5.833-840>
- Gray, G., McGuinness, C. ve Owende, P. (2014, February). *An application of classification models to predict learner progression in tertiary*

- education. In 2014 IEEE International Advance Computing Conference (IACC) (pp. 549-554). IEEE.
- Gülbahar, Y. (2012). *E-öğrenme*. Pegem Akademi.
- Gürçay, D. ve Eryılmaz, A. (2005). Çoklu zekâ alanlarına dayalı öğretimin öğrencilerin fizik başarısına etkisi. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 29(29), 103-109.
- Gürel, E. ve Tat, M. (2010). Çoklu zekâ kuramı: Tekli zekâ anlayışından çoklu zekâ yaklaşımına. *Journal of International Social Research*, 3(11).
- Gürsakal, N. (2017). *Makine öğrenmesi ve derin öğrenme*. Dora Yayınevi.
- Gürsoy, G. ve Varol, A. (2021, June, 28-29). *Prediction of arrhythmia with machine learning algorithms*. In 2021 9th International Symposium on Digital Forensics and Security (ISDFS), Elazig, Turkey.
- Hal Daumé III 2012, A Course in Machine Learning, http://ciml.info/dl/v0_8/ciml-v0_8-ch08.pdf.
- Han, J. ve Kamber, M. (2006). *Data mining: concepts and techniques (the Morgan Kaufmann Series in data management systems)*, 2nd Edition, Morgan Kaufmann Publishers, ISBN: 978-1-55860-901-3.
- Han, J., Kamber, M. ve Pei, J. (2011). Data transformation and data discretization. *Data mining: Concepts and techniques*, 111-118.
- Harrington, P. (2012). *Machine Learning in Action*. Manning Publications.
- Hasenekoğlu, İ. ve Gürbüzöğlü, S. (2009). Çoklu zekâ kuramına dayalı işlenen protein sentezi konusunun öğrencilerin bilgilerindeki kalıcılığına etkisi. *Ahi Evran Üniversitesi Kırşehir Eğitim Fakültesi Dergisi*, 10(3), 49-59.
- Hastie, T., Friedman, J., Tibshirani, R., Hastie, T., Friedman, J. ve Tibshirani, R. (2001). Prototype methods and nearest-neighbors. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*.
- Heuser, S.V. (2019, 06 Mart). From deep blue to alexa: the history of artificial intelligence. 20 Kasım 2022 tarihinde <https://blog.solvatio.com/en/from-deep-blue-to-alexa-the-history-of-artificial-intelligence> adresinden erişilmiştir.
- Hoffait, A. S. ve Schyns, M. (2017). Early detection of university students with potential difficulties. *Decision Support Systems*, 101, 1-11. <https://doi.org/10.1016/j.dss.2017.05.003>

- Holmes, W., Bialik, M. ve Fadel, C. (2019). *Artificial intelligence in education: Promises and implications for teaching and learning*. Center for Curriculum Redesign.
- Hu, J. (2021). Teaching evaluation system by use of machine learning and artificial intelligence methods. *International Journal of Emerging Technologies in Learning (iJET)*, 16(5), 87-101. <https://doi.org/10.3991/ijet.v16i05.20299>
- Jackson, H. (1988). Machine learning. *Expert Syst.*, 5(2), 132–150. <http://doi.org/10.1111/j.1468-0394.1988.tb00341>
- Jin, X. B., Su, T. L., Kong, J. L., Bai, Y. T., Miao, B. B. ve Dou, C. (2018). State-of-the-art mobile intelligence: Enabling robots to move like humans by estimating mobility with artificial intelligence. *Applied Sciences*, 8(3), 1-39. <https://doi.org/10.3390/app8030379>
- Kabathova, J. ve Drlik, M. (2021). Towards predicting student's dropout in university courses using different machine learning techniques. *Applied Sciences*, 11(7), 1-19. <https://doi.org/10.3390/app11073130>
- Kahyaoğlu, M. (2013). Ortaöğretim öğrencilerinin zekâ alanları ile çevreye yönelik tutumları arasındaki ilişkinin değerlendirilmesi. *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi*, 46(2), 159- 178.
- Kaplan, A. ve Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15-25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kartal, E. (2015). Sınıflandırmaya dayalı makine öğrenmesi teknikleri ve kardiyolojik risk değerlendirmesine ilişkin bir uygulama[Yayınlanmamış doktora tezi]. İstanbul Üniversitesi.
- Kartal, E., Biber, S. K., Biber, M., Özyaprak, M., Şimşek, İ. ve Tuncer, Can (2019). Makine öğrenmesi Tekniklerini ve Kolb Oluşturma Stilleri Envanterini Kullanarak Temel Oluşturma Stillerinin belirlenmesi için Bir Model Önerileri. *Kastamonu Eğitim Dergisi*, 27 (5), 1875-1892. <https://doi.org/10.24106/kefdergi.2863>
- Kaur, P., Singh, M. ve Josan, G. S. (2015). Classification and prediction based data mining algorithms to predict slow learners in education

- sector. *Procedia Computer Science*, 57, 500-508.
<https://doi.org/10.1016/j.procs.2015.07.372>
- Kaya, F. H. (2022). *Identifying the factors affecting students' academic achievement using machine learning algorithms* [Unpublished master's thesis]. Konya Teknik Üniversitesi.
- Kayabaş, İ. (2011). *Yapay zeka sohbet ajanlarının uzaktan eğitimde öğrenci destek sistemi olarak kullanılabilirliği* [Yayımlanmamış yüksek lisans tezi]. Anadolu Üniversitesi.
- Keerthi, S. S., Shevade, S. K., Bhattacharyya, C. ve Murthy, K. R. K. (2001). Improvements to Platt's SMO algorithm for SVM classifier design. *Neural computation*, 13(3), 637-649.
- Khan, I., Ahmad, A. R., Jabeur, N. ve Mahdi, M. N. (2021). An artificial intelligence approach to monitor student performance and devise preventive measures. *Smart Learning Environments*, 8(1), 1-18.
<https://doi.org/10.1186/s40561-021-00161-y>
- Korucu, A. T. ve Biçer, H. (2020). Eğitimde yapay zekanın rolleri ve eğitsel yapay zekâ uygulamaları. Nabiyev, V. ve Erümit, A.K. (Ed.), *Eğitimde yapay zekâ, kuramdan uygulamaya* (38-56) içinde. Pegem Akademi.
- Kučak, D., Juričić, V. ve Đambić, G. (2018). Machine learning in education- a survey of current research trends. *Annals of DAAAM & Proceedings*, 29, 406-410.
<https://doi.org/10.2507/29th.daaam.proceedings.059>
- Kunt, A. (2017). *Ortaokul 8. sınıf öğrencilerinin matematiksel ispata yönelimlerinin yapay sinir ağı modeli kullanılarak incelenmesi* [Yayımlanmamış yüksek lisans tezi]. Dokuz Eylül Üniversitesi.
- Kural, E. (2020). *Çoklu zekâ kuramına dayalı fen öğretiminin akademik başarıya ve derse yönelik tutuma etkisi: Bir meta-analiz çalışması* [Yayımlanmamış yüksek lisans tezi]. Cumhuriyet Üniversitesi.
- Kurzweil, R. (1990). *The age of intelligent machines*. MIT Press.
- Langley, P. (1996). *Elements of machine learning*. Morgan Kaufmann.
- Lau, E. T., Sun, L. ve Yang, Q. (2019). Modelling, prediction and classification of student academic performance using artificial neural

- networks. *SN Applied Sciences*, 1(9), 1-10. <https://doi.org/10.1007/s42452-019-0884-7>
- Lazear, D. (2000). *The intelligent curriculum: Using multiple intelligences to develop your students' full potential*. Zephyr Press.
- Leahy, S. M., Holland, C. ve Ward, F. (2019). The digital frontier: Envisioning future technologies impact on the classroom. *Futures*, 113, 102422, 1-10. <https://doi.org/10.1016/j.futures.2019.04.009>
- Mailizar, A., Abdulsalam, M. ve Suci, B. (2020). Secondary school mathematics teachers' views on E-learning implementation barriers during the COVID-19 pandemic: The case of Indonesia. *Avrasya Matematik, Fen ve Teknoloji Eğitimi Dergisi*, 16(7), 1-9. <https://doi.org/10.29333/ejmste/8240>
- Maind, S. B. ve Wankar, P. (2014). Research paper on basic of artificial neural network. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2(1), 96-100.
- Maqableh, W., Alzyoud, F. Y., & Zraqou, J. (2023). The use of facial expressions in measuring students' interaction with distance learning environments during the COVID-19 crisis. *Visual informatics*, 7(1), 1-17. <https://doi.org/10.1016/j.visinf.2022.10.001>
- Malhotra, R. (2015). A systematic review of machine learning techniques for software fault prediction. *Applied Soft Computing*, 27, 504-518.
- Mertala, P., Fagerlund, J. ve Calderon, O. (2022). Finnish 5th and 6th grade students' pre-instructional conceptions of artificial intelligence (AI) and their implications for AI literacy education. *Computers and Education: Artificial Intelligence*, 3, 1-11. <https://doi.org/10.1016/j.caeai.2022.100095>
- Miguéis, V. L., Freitas, A., Garcia, P. J. ve Silva, A. (2018). Early segmentation of students according to their academic performance: A predictive modelling approach. *Decision Support Systems*, 115, 36-51. <https://doi.org/10.1016/j.dss.2018.09.001>
- Mishra, G., Sehgal, D. ve Valadi, J. K. (2017). Quantitative structure activity relationship study of the anti-hepatitis peptides employing random forests and extra-trees regressors. *Bioinformatics*, 13(3), 60-62. <https://doi.org/10.6026/97320630013060>

- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill Science/Engineering/Math.
- Mrinal, P. ve Taruna, S. A (2014). Multi-level classification model pertaining to the student's academic performance prediction. *International Journal of Advances in Engineering & Technology*, 7(4), 1329-1341.
- Murphy, R. F. (2019). *Artificial intelligence applications to support K-12 teachers and teaching: A review of promising applications, opportunities, and challenges*. Perspective. RAND Corporation.
- Nabiyev, V. (2003). *Yapay zekâ*. Seçkin Yayıncılık.
- Nabiyev, V. (2016). *Yapay zeka: Stratejili oyunlar-örüntülü tanıma-doğal dil işleme* (5. Baskı). Seçkin Yayıncılık.
- Nabiyev, V. ve Erümit, A.K. (2020). Yapay zekanın temelleri. Nabiyev, V. ve Erümit, A.K. (Ed.), *Eğitimde yapay zeka, kuramdan uygulamaya* (2-34) içinde. Pegem Akademi.
- Namlı, N. A. (2016). *Bulanık mantık ile belirlenmiş çoklu zekâ alanlarına göre düzenlenmiş öğrenme ortamlarının öğrencilerin akademik başarılarına etkisi* [Yayımlanmamış Yüksek Lisans Tezi]. Çukurova Üniversitesi.
- Nilsson, N.J. (2018). Yapay zekâ geçmişi ve geleceği (1. Baskı). (M. Doğan, Çev.). *Boğaziçi Üniversitesi Yayınevi* (Orijinal eserin basım tarihi, 2010).
- Nulhakim, L. ve Berlian, L. (2020). Investigation of multiple intelligence of primary school students. *Jurnal Inovasi Pendidikan IPA*, 6(1), 101-113. <https://doi.org/10.21831/jipi.v6i1.29478>
- Oral, İ. ve Doğan, O. (2010). Ortaöğretimde çoklu zekâ kuramının elektrik konularını öğrenme sürecine etkisinin araştırılması. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (23), 159-171.
- Oshiro, T. M., Perez, P. S. ve Baranauskas, J. A. (2012, July, 13-20). *How many trees in a random forest?*. In Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, Berlin, Germany.
- Önder, H. H. (2003). Uzaktan eğitimde bilgisayar kullanımı ve uzman sistemler. *TOJET: The Turkish Online Journal of Educational Technology*, 2(3), 142-146.

- Öngören, H. ve Şahin, A. (2008). Çoklu zekâ kuramı tabanlı öğretimin öğrencilerin fen bilgisi başarılarına etkileri. *Pamukkale Üniversitesi Eğitim Fakültesi Dergisi*, 23(23), 24-35.
- Özdemir, Ş. (2016). *Eğitimde veri madenciliği ve öğrenci akademik başarı öngörüsüne ilişkin bir uygulama* [Yayımlanmamış doktora tezi]. İstanbul Üniversitesi.
- Özdoğru Şenel, S. (2016). *Çoklu zekâ kuramına göre düzenlenen etkinliklerin 7. sınıf ışık ünitesinin öğrenilmesi ve öğrenmenin kalıcılığı üzerine etkisi* [Yayımlanmamış yüksek lisans tezi]. Gazi Üniversitesi.
- Özen, E.N. (2021). *STEM alanındaki öğretmen adayları için geliştirilen makine öğrenmesi öğretiminin planlanması, uygulanması ve değerlendirilmesi* [Yayımlanmamış yüksek lisans tezi]. Bahçeşehir Üniversitesi.
- Özkan, Ç. (2016). *Veri madenciliği yöntemleri* (3. Baskı). Papatya Yayın Evi.
- Özkan, İ. (2019). *Fen ve teknoloji okuryazarlığına ilişkin öz yeterlik algısı ile akademik başarı arasındaki ilişkinin yapay sinir ağı ile analizi* [Yayımlanmamış yüksek lisans tezi]. Burdur Mehmet Akif Ersoy Üniversitesi.
- Özlen, T. (2022). *Servikal kanserlerin teşhisinde kullanılan makine öğrenmesi algoritmalarının karşılaştırmalı analizi* [Yüksek Lisans Tezi]. İstanbul Aydın Üniversitesi.
- Paper, D. (2018). *Data Science fundamentals for Python and MongoDB*. Apress Media.
- Pallathadka, H., Wenda, A., Ramirez-Asís, E., Asís-López, M., Flores-Albornoz, J. ve Phasinam, K. (2021). Classification and prediction of student performance data using various machine learning algorithms. *Materials today: proceedings*. <https://doi.org/10.1016/j.matpr.2021.07.382>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplass, J., Passos, A., Cournapeau, D., Brucher, M. ve Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *The Journal of Machine Learning Research*, 12, 2825-2830.

- Rana, P., Gupta, L. R., Kumar, G. ve Dubey, M. K. (2021, April, 28-30). A taxonomy of various applications of artificial intelligence in education. In *2021 2nd International Conference on Intelligent Engineering and Management (ICIEM)*. IEEE.
- Rodríguez-Hernández, C. F., Musso, M., Kyndt, E. ve Cascallar, E. (2021). Artificial neural networks in academic performance prediction: Systematic implementation and predictor evaluation. *Computers and Education: Artificial Intelligence*, 2, 100018. <https://doi.org/10.1016/j.caeai.2021.100018>
- Rovira, S., Puertas, E. ve Igual, L. (2017). Data-driven system to predict academic grades and dropout. *PLoS one*, 12(2), 1-21. <https://doi.org/10.1371/journal.pone.0171207>
- Saa, A. A., Al-Emran, M. ve Shaalan, K. (2019). Factors affecting students' performance in higher education: a systematic review of predictive data mining techniques. *Technology, Knowledge and Learning*, 24, 567-598. <https://doi.org/10.1007/s10758-019-09408-7>
- Sağiroğlu, Ş., Erler, M. ve Beşdok, E. (2003). *Mühendislikte yapay zekâ uygulamaları-I: Yapay sinir ağları*. Ufuk Kitap Kırtasiye Yayıncılık.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal Of Research And Development*, 3(3), 210-229. <https://doi.org/10.1147/rd.33.0210>
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN computer science*, 2(3), 1-21. <https://doi.org/10.1007/s42979-021-00592-x>
- Sarker, I. H., Kayes, A. S. M. ve Watters, P. (2019). Effectiveness analysis of machine learning classification models for predicting personalized context-aware smartphone usage. *Journal of Big Data*, 6(1), 1-28. <https://doi.org/10.1186/s40537-019-0219-y>
- Savcı, M., Tekin, A. ve Elhai, J. D. (2022). Prediction of problematic social media use PSU using machine learning approaches. *Current Psychology*, 41(5), 2755–2764. <https://dx.doi.org/10.1007/s12144-020-00794-1>
- Schworm, S. ve Gruber, H. (2012). E-Learning in universities: Supporting help-seeking processes by instructional prompts. *British Journal of*

- Educational Technology*, 43(2), 272-281.
<https://doi.org/10.1111/j.1467-8535.2011.01176.x>
- Shaikh, A. A., Kumar, A., Jani, K., Mitra, S., García-Tadeo, D. A. ve Devarajan, A. (2022). The role of machine learning and artificial intelligence for making a digital classroom and its sustainable impact on education during COVID-19. *Materials Today: Proceedings*, 56, 3211-3215. <https://doi.org/10.1016/j.matpr.2021.09.368>
- Shi, X. ve Manduchi, R. (2003, June, 16-12). *A study on Bayes feature fusion for image classification. In 2003 Conference on Computer Vision and Pattern Recognition Workshop, Madison, Wisconsin, USA.*
- Stanciu, D., Orban, I. ve Bocos, M. (2011). Applying the multiple intelligences theory into pedagogical practice. Lessons from the Romanian primary education system. *Procedia-Social and Behavioral Sciences*, 11, 92-96.
- Su, J. ve Yang, W. (2022). Artificial intelligence in early childhood education: A scoping review. *Computers and Education: Artificial Intelligence*, 3, 100049. <https://doi.org/10.1016/j.caeai.2022.100049>
- Sukendro, S., Habibi, A., Khaeruddin, K., Indrayana, B., Syahrudin, S., Makadada, F. A. ve Hâkim, H. (2020). Using an extended technology acceptance model to understand students' use of e-learning during COVID-19: Indonesian sport science education context. *Heliyon*, 6(11), 1-9.
<https://doi.org/10.1016/j.heliyon.2020.e05410>
- Şahan, A. (2018). *Fen bilimleri öğretiminde çoklu zekâ destekli eğitim modelinin öğrenci başarısına ve fen tutumuna etkisi* [Yayımlanmamış yüksek lisans tezi]. Kırıkkale Üniversitesi.
- Şahin, S. (2021). *Makine öğrenmesi yöntemleri ile ortaokul öğrenci başarılarının tespiti ve bir uygulama* [Yayımlanmamış yüksek lisans tezi]. İstanbul Üniversitesi.
- Şengül, S. H. (2007). *Çoklu zekâ kuramı temelli öğretimin ilköğretim altıncı sınıf öğrencilerinin dolaşım sistemi başarıları üzerine etkisi* [Yayımlanmamış yüksek lisans tezi]. Balıkesir Üniversitesi.
- Şimşek, E. ve Canbay, P. (2021). COVID-19 döneminde uzaktan eğitimde mentor gerekliliğinin makine öğrenmesi yaklaşımları ile belirlenmesi

- ve belirleyicilerin açıklanması. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 246-255. <https://doi.org/10.31590/ejosat.948242>
- Talan, T. (2021). Artificial intelligence in education: A bibliometric study. *International Journal of Research in Education and Science (IJRES)*, 7(3), 822-837. <https://doi.org/10.46328/ijres.2409>
- Taşçı, A. N. (2019). *Fatih Projesi destekli çoklu zekâ kuramı uygulamalarının fizik başarısına etkisi: Newton'' un hareket yasaları* [Yayımlanmamış yüksek lisans tezi]. Necmettin Erbakan Üniversitesi
- Tekin, A. (2014). Early prediction of students' grade point averages at graduation: A data mining approach. *Eurasian Journal of Educational Research*, 54, 207-226.
- Tepahan, T. (2011). *Türk öğrencilerin PISA başarılarının yordanmasında yapay sinir ağı ve lojistik regresyon modeli performanslarının karşılaştırılması* [Yayımlanmamış doktora tezi]. Hacettepe Üniversitesi.
- Torreon, L. C. ve Sumayang, C. I. (2021). multiple intelligence-based classroom activities and learners'academic achievement. *American Journal of Multidisciplinary Research & Development (AJMRD)*, 3(2), 37-41.
- Tosun, S. (2007). *Sınıflandırmada yapay sinir ağları ve karar ağaçları karşılaştırılması: Öğrenci başarıları üzerine bir uygulama* [Yayımlanmamış yüksek lisans tezi]. İstanbul Teknik Üniversitesi.
- Tosunoğlu, E., Yılmaz, R., Özeren, E. ve Sağlam, Z. (2021). Eğitimde makine öğrenmesi: Araştırmalardaki güncel eğilimler üzerine inceleme. *Ahmet Keleşoğlu Eğitim Fakültesi Dergisi*, 3(2), 178-199. <https://doi.org/10.38151/akef.2021.16>
- Tüysüz, M. ve Geban, Ö. (2020). The effect of 5E learning cycle and multiple intelligence approach on 9th grade students' achievement, attitude, and motivation toward chemistry on unit of chemical properties. *Bartın University Journal of Faculty of Education*, 9(3), 612-644. <https://doi.org/10.14686/buefad.724352>
- Uçak, E. (2006). *Maddenin sınıflandırılması ve dönüşümleri'' konusunda çoklu zekâ kuramı destekli öğretim yöntemi'nin öğrenci başarısı,*

- tutumu ve hatırda tutma düzeyine etkisi* [Yayımlanmamış yüksek lisans tezi]. Pamukkale Üniversitesi.
- UNESCO, U. (2020). COVID-19 educational disruption and response. UNESCO. <https://en.unesco.org/covid19/educationresponse>
- URL 1 Türkiye Yapay Zeka İnsiyatifi (2017). Yapay zeka zaman çizelgesi. <https://turkiye.ai/kaynaklar/yapay-zeka-zaman-cizelgesi/>
- Uzun, Y., Tümtürk, A. Y. ve Öztürk, H. (2021, November, 1-3). Günümüzde ve gelecekte eğitim alanında kullanılan yapay zekâ. In *1st International Conference on Applied Engineering and Natural Sciences*. Konya, Turkey.
- Vartiainen, H., Toivonen, T., Jormanainen, I., Kahila, J., Tedre, M. ve Valtonen, T. (2021). Machine learning for middle schoolers: Learning through data-driven design. *International Journal of Child-Computer Interaction*, 29, 100281. <https://doi.org/10.1016/j.ijcci.2021.100281>
- Verma, G., Adhikari, S., Khanduri, V., Tandon, S., Rawat, S. ve Singh, P. (2020). Machine learning model for prediction of stress levels in students of technical education. *AIJR Proceedings*, 45-52. <https://doi.org/10.21467/proceedings.100.5>
- Vidakis, N., Barianos, A. K., Trampas, A. M., Papadakis, S., Kalogiannakis, M. ve Vassilakis, K. (2019). Generating education in-game data: The case of an ancient theatre serious game. *CSEDU (1)*, 36-43. <https://doi.org/10.5220/0007810800360043>
- Vural, B. (2004). *Öğrenci Merkezli Eğitim ve Çoklu Zekâ*. Hayat yayıncılık.
- Wang, C. J., Ng, C. Y. ve Brook, R. H. (2020). Response to COVID-19 in Taiwan: Big data analytics, new technology, and proactive testing. *Jama*, 323(14), 1341-1342. <https://doi.org/10.1001/jama.2020.3151>
- Witten, I. H., Frank, E. ve Hall, M. (2011). Data mining: practical machine learning tools and techniques. *Annals of Physics*.
- Yağcı, M. (2022). Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9(1), 1-19. <https://doi.org/10.1186/s40561-022-00192-z>

- Yavuzalp, N. (2012). *E-öğrenme ortamında kullanılan öğrenme stil ve stratejilerinin web kullanım madenciliği ile analizi* [Yayımlanmamış doktor tezi]. Fırat Üniversitesi.
- Yıldız, M. ve Börekçi, C. (2020). Predicting Academic Achievement with Machine Learning Algorithms. *Journal of Educational Technology and Online Learning*, 3(3), 372-392. <https://doi.org/10.31681/jetol.773206>
- Yu, J. (2021). Academic performance prediction method of online education using random forest algorithm and artificial intelligence methods. *International Journal of Emerging Technologies in Learning*, 15(5), 45-57.
- Yüce, F. (2020). Çoklu zekâ kuramına göre düzenlenen fen konularının öğrencilerin başarı ve kalıcılığına etkisi. *Anadolu Kültürel Araştırmalar Dergisi*, 4(1), 25-30.
- Zhang, H. (2004). The optimality of Naive Bayes. *Aa*, 1(2), 3.
- Zhang, K. (2006). Decision tree algoritm.



ISBN: 978-625-367-081-8