

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

Betül ÇETİN

**MÜHENDİSLİK EĞİTİMİNDE YAPAY ZEKA YÖNTEMLERİ
İLE ÖĞRENME SÜRECİNİN İYİLEŞTİRİLMESİ**

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

ADANA-2022

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MÜHENDİSLİK EĞİTİMİNDE YAPAY ZEKA YÖNTEMLERİ İLE
ÖĞRENME SÜRECİNİN İYİLEŞTİRİLMESİ**

Betül ÇETİN

YÜKSEK LİSANS TEZİ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

Bu Tez 26/12/2022 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Oybirliği/Oyçokluğu ile Kabul Edilmiştir.

Doç. Dr. Yusuf KUVVETLİ
DANIŞMAN

Doç. Dr. Melik KOYUNCU
ÜYE

Dr. Öğr. Üyesi B. İrem SELAMOĞLU
ÜYE

Bu Tez Enstitümüz Tarım Makinaları Anabilim Dalında hazırlanmıştır.
Kod No:

Prof. Dr. Sadık DİNÇER
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ÖZ

YÜKSEK LİSANS TEZİ

**MÜHENDİSLİK EĞİTİMİNDE YAPAY ZEKA YÖNTEMLERİ İLE
ÖĞRENME SÜRECİNİN İYİLEŞTİRİLMESİ**

Betül ÇETİN

**ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

Danışman : Doç. Dr. Yusuf KUVVETLİ
Yıl:2022 Sayfa: 101
Jüri : Doç. Dr. Yusuf KUVVETLİ
: Doç. Dr. Melik KOYUNCU
: Dr. Öğr. Üyesi Birsen İrem SELAMOĞLU

Eğitim toplumların gelişiminde kilit öneme sahiptir. Eğitimin geliştirilmesi öğrenme süreçlerinin iyileştirilmesi ile yakından ilişkilidir. Eğer öğrencilerin öğrenme durumu doğru tespit edilebilirse, öğrenme süreçleri iyileştirilebilir. Bu çalışma, öncelikli olarak bir ders anında ve sonrasında öğrenmenin gerçekleşip gerçekleşmediğini yapay zeka teknikleriyle doğru bir şekilde tespit etmeyi amaçlamaktadır. Bu doğrultuda, seçilen “GAMS optimizasyon yazılımına giriş” dersi için derse hazırlık, ders aşaması ve ders sonrası öğrenme soruları hazırlanmıştır. Hazırlanan sorular geliştirilen web tabanlı “E-Öğrenme Analiz Programı” ile 82 katılımcıya yöneltilerek öğrenme verileri toplanmıştır. Öğrenme verileri ile dört farklı model oluşturulmuştur. Her model Decision Tree, Random Forest, XGBoost ve MLP algoritmalarıyla değerlendirilmiştir. Çalışma sonucunda; Model 1, Model 2, Model 3 ve Model 4 için sırasıyla 0.82, 0.93, 0.89, 0.93 accuracy (doğruluk) değerleri ve 0.81, 0.92, 0.90, 0.92 F1-score (kesinlik-duyarlılık) değerleri elde edilmiştir. Yüksek doğruluk, kesinlik ve duyarlılıkla öğrenme tespiti gerçekleştirilmiştir.

Anahtar kelimeler: Eğitimde Yapay Zeka, Makine Öğrenmesi, Öğrenme Analitiği

ABSTRACT

MSc THESIS

IMPROVING THE LEARNING PROCESS WITH ARTIFICIAL INTELLIGENCE TECHNIQUES IN ENGINEERING EDUCATION

Betül ÇETİN

ÇUKUROVA UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF INDUSTRIAL ENGINEERING

Supervisor : Assoc. Prof. Dr. Yusuf KUVVETLİ
Year: 2022, Pages: 101
Jury : Assoc. Prof. Dr. Yusuf KUVVETLİ
: Assoc. Prof. Dr. Melik KOYUNCU
: Asst. Prof. Dr. Birsen İrem SELAMOĞLU

Education is the key for the development of societies. Improvement of education is closely related to improvement of learning processes. Learning processes can improve if the learning status of the students can be determined accurately. This research firstly aims to determine accurately with artificial intelligence techniques whether learning takes place during and after a lecture. In this context course preparation, course time and post course learning questions were prepared for a selected “Introduction to GAMS optimization software” course. Learning data were collected with the designed web based “E-Learning Analysis Program” by asking the prepared questions to 82 participants. Four different models were created by learning data. Each model is evaluated with Decision Tree, Random Forest, XGBoost and MLP algorithms. As a result of the research, accuracy values for Model 1, Model 2, Model 3 and Model 4 were obtained as 0.82, 0.93, 0.89, 0.93, respectively. And F1-score (precision-recall) values for Model 1, Model 2, Model 3 and Model 4 were obtained as 0.81, 0.92, 0.90, 0.92, respectively. Learning detection has been achieved with high accuracy, precision and recall.

Keywords: Artificial Intelligence in Education, Machine Learning, Learning Analytics

GENİŞLETİLMİŞ ÖZET

Eğitim, toplumların her alanda gelişmesi ve refah seviyesinin artmasında son derece önemli bir faktördür. Çünkü iyi yetişmiş bireyler toplumda üstlendikleri farklı roller ile gelişmişlik seviyesinin artmasına katkı sağlayacaktır. Endüstri 4.0'ın getirdiği yenilikler ve yeni teknolojiler birçok sektörde yeni ihtiyaçlar doğurduğu ve iyileşme potansiyeli sağladığı gibi eğitim sektörünü de etkilemiştir. Bu etki özellikle yüksek öğretim ve daha çok mühendislik bölümleri için hem Endüstri 4.0'ın gerekliliklerini karşılayan yeni mühendis tanımlamalarını ortaya çıkarmış hem de yapay zeka teknolojilerinin yönetim, eğitim verme ve öğrenme gibi eğitimin temel süreçlerinde kullanılmasıyla bu alanlarda iyileşmeler sağlama imkanı doğurmuştur. COVID-19 süreciyle birlikte eğitimde dijitalleşmenin zorunlu hale gelmesi ve eksiklikler ile yeni ihtiyaçları ortaya çıkarması da bu süreci hızlandırmıştır. Bütün bu gelişmeler, yapay zekanın eğitimde kullanımını beraberinde getirmiş ve özellikle son on yılda artan bir ilgiyle literatürde kendine yer bulmuştur.

Bahsedilen gelişmeler doğrultusunda bu tez çalışmasında öncelikle, bir ders bağlamında öğrenmenin gerçekleştiğini ders anı ve sonrasında tespit edecek yapay zeka temelli bir sistem önermek amaçlanmıştır. Bu amaçla bağlantılı olarak öğrenciye özgü içerik oluşturulması için girdi sağlamak, öğrencilerin öğrenme düzeylerine göre tekrar/ek ders içeriği önermek ve farklı eğitim programlarına da uygulanabilen adaptif bir sistem tasarlamak hedefleri belirlenmiştir.

Bu çerçevede, öncelikle bir ders bağlamında derse hazırlık, ders aşaması ve ders sonrası süreçler analiz edilerek öğrenme üzerinde etkili kritik başarı faktörleri belirlenmiştir. Ardından bir mühendislik dersi olan “GAMS optimizasyon yazılımına giriş” dersi seçilmiştir. Seçilen dersin öğrenilmesini ders anı ve sonrasında tespit etmeye yönelik sorular hazırlanarak öğrenme üzerinde etkili olarak belirlenen kritik başarı faktörleriyle eşleştirilmiştir. Çalışma kapsamında tasarlanan “E-Öğrenme Analiz Programı” veri toplama yazılımı aracılığıyla

hazırlanan ders videoları ve öğrenme analiz soruları mühendislik öğrencilerine sunulmuştur. Etik prosedürlere uygun olarak 82 katılımcıdan toplanan verilerle çalışmanın analizleri gerçekleştirilmiştir. Çalışmanın analiz aşamasında dört farklı sınıflandırma modeli oluşturularak seçilen sınıflandırma algoritmaları (Decision Tree, Random Forest, XGBoost, MLP) ile testler gerçekleştirilmiştir. Gerçekleştirilen testler her model ve algoritma için algoritmanın sınıflandırma başarısını değerlendirme metrikleriyle (accuracy, precision, recall, fl-score) değerlendirilmiştir. Bu aşamada algoritma test performans grafikleri ve karışıklık matrislerinden yararlanılmıştır. Oluşturulan her model için kullanılan algoritmaların sınıflandırma başarıları ve model karşılaştırmaları sunulmuştur.

Çalışma sonucunda, genel olarak oluşturulan tüm modellerde kullanılan Decision Tree, Random Forest ve XGBoost sınıflandırma algoritmaları ile yüksek accuracy (doğruluk) ve F1-score (kesinlik-duyarlılık) değerlerine ulaşılmıştır. Bu durum öğrenme süreçlerinin iyileştirilmesinde öğrenmenin tespitinde yapay zeka tekniklerinin kullanılmasının başarısını ortaya koymaktadır. Buradan hareketle öğrenmenin iyileştirilmesinde eğitim süreçlerinin farklılaştırılması, uyarlanması ve kişiselleştirilmesi yoluyla gelişmeler sağlanabileceği öngörülmektedir.

Çalışma sonucunda ayrıca, ders anında öğrenmenin gerçekleşip gerçekleşmediğinin tespitinde bilginin anlaşılması kritik başarı faktörünün yanı sıra derse hazırlık ve ders sonrası süreçler için belirlenen kritik başarı faktörlerinin de etkili olduğu tespit edilmiştir. Ders sonrasında öğrenmenin gerçekleşip gerçekleşmediğinin tespiti ise ders anında öğrenmenin gerçekleşip gerçekleşmediğinin tespitine göre nispeten daha başarılı bir şekilde saptanmış olup, ders sonrasında öğrenmenin gerçekleşmesinde en önemli kritik başarı faktörü dersin kazanımlarının sağlanması olarak gözlenmiştir.

TEŞEKKÜR

Zorlu geçen yüksek lisansım ve tez çalışmam süresince benden hiçbir yardımı esirgemeyen, fedakarlık ve anlayışla daima desteğini hissettiren, sorularıma sabırla cevap veren çok kıymetli danışmanım Doç. Dr. Yusuf KUVVETLİ'ye teşekkürü borç bilirim.

Bu yüksek lisans sürecimde bana güvenen, destek ve yardımlarını esirgemeyen çok kıymetli hocalarım Doç. Dr. Melik KOYUNCU'ya ve Prof. Dr. Ali KOKANGÜL'e teşekkürlerimi takdim ederim.

Her zaman olduğu gibi bu süreçte de yanımda olan, çok kıymetli destek ve yardımlarını hiçbir zaman esirgemeyen sevgili ailem ve kıymetli dostlarıma çok teşekkür ederim.

İÇİNDEKİLER

SAYFA

ÖZ	I
ABSTRACT.....	II
GENİŞLETİLMİŞ ÖZET	III
TEŞEKKÜR.....	V
ŞEKİLLER DİZİNİ	VIII
ÇİZELGELER DİZİNİ	XII
SİMGELER VE KISALTMALAR.....	XIV
1.GİRİŞ	1
1.1. Eğitimde Yapay Zeka	1
1.1.1. Eğitim 4.0.....	1
1.1.2. Yapay Zeka Destekli Eğitim	2
1.1.3. Eğitimde Akıllı Teknolojiler	3
1.2. Çalışmanın Önemi ve Amacı	7
1.3. Çalışmanın Kapsamı	9
1.4. Çalışmanın Adımları ve Organizasyonu.....	10
2. ÖNCEKİ ÇALIŞMALAR	13
3. MATERYAL VE METOT	29
3.1. Materyal.....	29
3.2. Metot.....	35
3.2.1. Veri Toplama Yazılımının Oluşturulması	36
3.2.2. Oluşturulan Modeller	37
3.2.3. Sınıflandırma Algoritmaları	39
3.2.4. Sınıflandırma Algoritmaları Başarısını Değerlendirme Metrikleri ..	46
4. BULGULAR VE TARTIŞMA	47
4.1. Katılımcı İstatistikleri	47
4.2. Algoritma Tahminleri.....	57
4.2.1. Model 1 İçin Algoritma Tahminleri	58

4.2.2. Model 2 İçin Algoritma Tahminleri	64
4.2.3. Model 3 İçin Algoritma Tahminleri	70
4.2.4. Model 4 İçin Algoritma Tahminleri	75
4.3. Algoritma Tahmin Başarıları Karşılaştırmaları.....	81
4.3.1. Model 1 İçin Karşılaştırma	81
4.3.2. Model 2 İçin Karşılaştırma	82
4.3.3. Model 3 İçin Karşılaştırma	84
4.3.4. Model 4 İçin Karşılaştırma	85
4.4. Model Karşılaştırmaları.....	86
5. SONUÇLAR VE ÖNERİLER.....	87
KAYNAKLAR	97
ÖZGEÇMİŞ	101

ŞEKİLLER DİZİNİ

SAYFA

Şekil 3.1. Uygulama Hakkında Bilgilendirme.....	31
Şekil 3.2. Öğrenme Öncesi Genel Sorular (S1,S2,S4)	31
Şekil 3.3. Öğrenme Öncesi Teknik Sorular (S3,S5).....	31
Şekil 3.4. Ders Videosu 1	32
Şekil 3.5. Ders Videosu 1'in Konusuna Dair Ara Soru (S6).....	32
Şekil 3.6. Ders Videosu 2	32
Şekil 3.7. Ders Videosu 2'nin Konusuna Dair Ara Soru (S7)	33
Şekil 3.8. Ders Videosu 3	33
Şekil 3.9. Ders Videosu 4	33
Şekil 3.10. Ders Sonrası Sorular (S10,S11).....	34
Şekil 3.11. Ders Sonrası Teknik Soru (S14).....	34
Şekil 3.12. Model 1 Bileşenleri	37
Şekil 3.13. Model 2 Bileşenleri	37
Şekil 3.14. Model 3 Bileşenleri	38
Şekil 3.15. Model 4 Bileşenleri	39
Şekil 3.16. Karar Ağacı Yapısı.....	40
Şekil 3.17. CART Tarafından Oluşturulan Karar Ağacı	41
Şekil 3.18. ID3 Tarafından Oluşturulan Karar Ağacı.....	41
Şekil 3.19. Rastgele Orman Algoritması Genel Yapısı	42
Şekil 3.20. XGBoost Algoritmasının Genel Yapısı.....	44
Şekil 3.21. MLP Algoritması Genel Yapısı	45
Şekil 4.1. S1 İçin Katılımcı Cevapları	47
Şekil 4.2. S2 İçin Katılımcı Cevapları	48
Şekil 4.3. S3 İçin Katılımcı Cevapları	48
Şekil 4.4. S4 İçin Katılımcı Cevapları	49
Şekil 4.5. S5 İçin Katılımcı Cevapları	49
Şekil 4.6. S6 İçin Katılımcı Cevapları	50

Şekil 4.7. S7 İçin Katılımcı Cevapları	50
Şekil 4.8. S8 İçin Katılımcı Cevapları	51
Şekil 4.9. S9 İçin Katılımcı Cevapları	51
Şekil 4.10. S10 İçin Katılımcı Cevapları	52
Şekil 4.11. Ders İçin Katılımcı Memnuniyet Düzeyleri	53
Şekil 4.12. S12 İçin Katılımcı Cevapları	53
Şekil 4.13. S13 İçin Katılımcı Cevapları	54
Şekil 4.14. S14 İçin Katılımcı Cevapları	54
Şekil 4.15. Katılımcıların Sistemde Kalma Süreleri	55
Şekil 4.16. Katılımcıların Dinlediğini Öğrenme Durumu	55
Şekil 4.17. Katılımcıların Dinlediğini Öğrenme Yüzdeleri	56
Şekil 4.18. Katılımcıların GAMS Kodlama Öğrenme Durumu	56
Şekil 4.19. Katılımcıların GAMS Kodlama Öğrenme Yüzdeleri	57
Şekil 4.20. Model 1 İçin Decision Tree Algoritması Test Performansı	58
Şekil 4.21. Model 1 İçin Random Forest Algoritması Test Performansı	59
Şekil 4.22. Model 1 İçin XGBoost Algoritması Test Performansı	61
Şekil 4.23. Model 1 İçin MLP Algoritması Test Performansı	62
Şekil 4.24. Model 2 İçin Decision Tree Algoritması Test Performansı	64
Şekil 4.25. Model 2 İçin Random Forest Algoritması Test Performansı	65
Şekil 4.26. Model 2 İçin XGBoost Algoritması Test Performansı	67
Şekil 4.27. Model 2 İçin MLP Algoritması Test Performansı	68
Şekil 4.28. Model 3 İçin Decision Tree Algoritması Test Performansı	70
Şekil 4.29. Model 3 İçin Random Forest Algoritması Test Performansı	71
Şekil 4.30. Model 3 İçin XGBoost Algoritması Test Performansı	72
Şekil 4.31. Model 3 İçin MLP Algoritması Test Performansı	74
Şekil 4.32. Model 4 İçin Decision Tree Algoritması Test Performansı	75
Şekil 4.33. Model 4 İçin Random Forest Algoritması Test Performansı	77
Şekil 4.34. Model 4 İçin XGBoost Algoritması Test Performansı	78
Şekil 4.35. Model 4 İçin MLP Algoritması Test Performansı	80

Şekil 4.36. Model 1 Algoritma Accuracy Değerleri	81
Şekil 4.37. Model 1 Algoritma F1-Score Değerleri.....	82
Şekil 4.38. Model 2 Algoritma Accuracy Değerleri	82
Şekil 4.39. Model 2 Algoritma F1-Score Değerleri.....	83
Şekil 4.40. Model 3 Algoritma Accuracy Değerleri	84
Şekil 4.41. Model 3 Algoritma F1-Score Değerleri.....	84
Şekil 4.42. Model 4 Algoritma Accuracy Değerleri	85
Şekil 4.43. Model 4 Algoritma F1-Score Değerleri.....	85





ÇİZELGELER DİZİNİ

SAYFA

Çizelge 1.1. Eğitimde YZ Uygulamaları	3
Çizelge 2.1. Sınıflandırılmış Önceki Çalışmalar Çizelgesi	24
Çizelge 3.1. Öğrenme Analiz Soruları.....	30
Çizelge 3.2. Kritik Başarı Faktörleri (KBF'ler) ve İlişkili Sorular.....	30
Çizelge 4.1. Model 1 İçin Decision Tree Algoritması Karışıklık Matrisi	58
Çizelge 4.2. Model 1 İçin Random Forest Algoritması Karışıklık Matrisi	60
Çizelge 4.3. Model 1 İçin XGBoost Algoritması Karışıklık Matrisi.....	61
Çizelge 4.4. Model 1 İçin MLP Algoritması Karışıklık Matrisi.....	63
Çizelge 4.5. Model 2 İçin Decision Tree Algoritması Karışıklık Matrisi	64
Çizelge 4.6. Model 2 İçin Random Forest Algoritması Karışıklık Matrisi	66
Çizelge 4.7. Model 2 İçin XGBoost Algoritması Karışıklık Matrisi.....	67
Çizelge 4.8. Model 2 İçin MLP Algoritması Karışıklık Matrisi.....	69
Çizelge 4.9. Model 3 İçin Decision Tree Algoritması Karışıklık Matrisi	70
Çizelge 4.10. Model 3 İçin Random Forest Algoritması Karışıklık Matrisi	72
Çizelge 4.11. Model 3 İçin XGBoost Algoritması Karışıklık Matrisi.....	73
Çizelge 4.12. Model 3 İçin MLP Algoritması Karışıklık Matrisi.....	74
Çizelge 4.13. Model 4 İçin Decision Tree Algoritması Karışıklık Matrisi	76
Çizelge 4.14. Model 4 İçin Random Forest Algoritması Karışıklık Matrisi	77
Çizelge 4.15. Model 4 İçin XGBoost Algoritması Karışıklık Matrisi.....	79
Çizelge 4.16. Model 4 İçin MLP Algoritması Karışıklık Matrisi.....	80



SİMGELER VE KISALTMALAR

AdaBoost	: Adaptive Boosting (Uyarlanabilir Güçlendirme)
AFNA	: Adaptive Fuzzy Neural Agent (Adaptif Bulanık Sinir Ajanı)
biLSTM	: bi-directional Long Short Term Memory (Çift Yönlü Uzun Kısa Süreli Bellek)
BOW	: Bag of Words (Kelime Çantası)
CART	: Classification and Regression Tree (Sınıflandırma ve Regresyon Ağacı)
CRF	: Conditional Random Field (Koşullu Rastgele Alan)
GAMS	: General Algebraic Modeling System (Genel Cebirsel Modelleme Sistemi)
GBT	: Gradient Boosted Trees (Gradyan Güçlendirilmiş Ağaçlar)
Gkod	: GAMS kodlama
KBF	: Kritik Başarı Faktörü
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MLP	: Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
MOOC	: Massive Open Online Courses (Kitleli Açık Çevrimiçi Ders)
ORM	: Object Relational Mapping (Nesne İlişkisel Eşleme)
OSCE	: Observed Structured Clinical Exams (Objektif Yapılandırılmış Klinik Muayene)
RMSE	: Root Mean Squared Error (Kök Ortalama Kare Hata)
SVM	: Support Vector Machines (Destek Vektör Makineleri)
XGBoost	: Extreme Gradient Boosting (Aşırı Gradyan Arttırma)
YZ	: Yapay Zeka



1. GİRİŞ

1.1. Eğitimde Yapay Zeka

Eğitim toplumların ekonomik kalkınması, eşitlik ve refah düzeyleri açısından son derece önemli bir faktördür. Eğitimin geliştirilmesi ile akademik başarının artması yoluyla bireylerin, toplumun ve ülkelerin kalkınmasına hizmet edilebilir. Bu amaç doğrultusunda yapılmış çalışmaların çoğunda örnek veriler üzerinde istatistik gibi geleneksel yöntemler kullanıldığı görülmektedir. Ancak veri bilimi ve büyük veri alanlarına yönelik son gelişmeler yapay zekanın eğitim alanına da başarıyla uygulanabilme potansiyelini arttırmaktadır (Cruz-Jesus ve ark, 2020).

Eğitimdeki birçok alt sektöre benzer şekilde bugün çok sayıda üniversite mezun niteliklerini ve eğitim kalitesini iyileştirmeye yönelik kazanımlar sağlamak ve başarısızlık oranlarını azaltarak bölüm bırakma oranlarını düşürmek gibi amaçlarla öğretim ve öğrenmede stratejik önlemler geliştirmede kanıta dayalı yaklaşımları benimseme konusunda baskı altındadır. Bu gelişmeler yapay zekanın eğitimde kullanımını gerekli kılmaktadır (Deo ve ark, 2020).

1.1.1. Eğitim 4.0

Ciolacu ve ark (2017) çalışmalarında Endüstri 4.0'ın gerekliliklerini karşılayan mühendisleri “Uzun İnce Mühendis” (Tall Thin Engineer) olarak isimlendirmişlerdir. Bunlar inovasyon, karmaşık problem çözme, modüler kalite kontrol, yapay zeka yöntemleri, hızlı prototipleme gibi mühendislik ve yaratıcılık, insan yönetimi, eleştirel düşünme, yapay zeka tabanlı karar verme gibi liderlik beceri ve yetkinliklere sahip mühendislerdir.

Endüstri 4.0'ın yüksek kalitede eğitim talebi oluşturması ile geleneksel öğretim ve öğrenme yöntemleri yeniden gözden geçirilerek yenilenme sürecine girmiştir. Bu durum akıllı öğretme ve öğrenme süreçlerine ihtiyaç doğurmuştur. Bu kapsamda yüksek öğretim, öğrencilerin Endüstri 4.0'ın gerekliliklerini karşılayacak

şekilde yetiştirilmesini, endüstri tarafından öğrenci yeterliliklerinin tanınmasını ve endüstri ile akademi arasında yakın bir işbirliğini gerekli kılmıştır. Eğitimde yenilenmenin zorunlu hale geldiği COVID-19 pandemisi ile daha güçlü bir şekilde vurgulanmıştır (Ciolacu ve ark, 2020).

Tüm bu gelişmeler Eğitim 4.0 kavramını ortaya çıkarmıştır. Oryantasyon, dijital hazırlık, etkileşimli varlık, işbirliği, takip ve performans, yansıtma ve motivasyon ile sınav değerlendirme Eğitim 4.0'ın aşamalarıdır (Ciolacu ve ark, 2020).

Yapay zeka, Eğitim 4.0 bağlamında kilit bir rol oynamaktadır. Bu açıdan eğitimcilere öğrencinin performans ve zayıflıklarında etkili faktörleri belirlemede, öğrencilerin bilgi düzeyi doğrultusunda kişiselleştirilmiş bir öğrenci modeli benimsemede, adaptif öğrenme sistemlerinde tahmine dayalı modeller sağlamak için yapay zeka kullanmada ve öğrencilerin müfredatları üzerindeki ilerlemesini izlemede yardımcı olur. Ayrıca Eğitim 4.0 çevrimiçi öğrenme etkinliklerini gerçek zamanlı sensör verileriyle birleştiren çok modlu verilerle öğrenme analitiğini de geliştirmektedir (Ciolacu ve ark, 2018).

1.1.2. Yapay Zeka Destekli Eğitim

Yapay zeka, bir sistemin dış verileri doğru bir şekilde yorumlama, bu verilerden öğrenme ve bu öğrenmeleri esnek uyarlama yoluyla belirli hedef ve görevlere ulaşmak için kullanma yeteneğidir (Kaplan ve Haenlein, 2019).

Diğer bir tanıma göre yapay zeka; öğrenme, problem çözme, örüntü tanıma gibi insan zekasıyla yakından ilişkili farklı bilişsel problemleri çözme becerisine sahip bilgisayar sistemlerinin geliştirilmesini amaçlayan bir bilgisayar bilimi alanıdır (Chassignol ve ark, 2018).

Yapay zeka; doğal dil işleme, bilgisayarla görme, robotik süreç otomasyonu ve karar yönetimi gibi birçok farklı amaçla kullanılabilir. Bir alt alanı olan makine öğreniminin sinir ağları, bulanık mantık, veri madenciliği sistem teknikleri gibi yöntemlerini kullanır (Bojorque ve Pesántez-Avilés, 2019).

Yapay zeka destekli eğitim; akıllı eğitim, yenilikçi sanal öğrenme, eğitimsel veri analizi ve tahmini konularını içerir. Öğrenci ve eğitim kurumlarının değerlendirilmesi, sınavların notlandırılması ve değerlendirilmesi, kişiselleştirilmiş öğretim, çevrimiçi ve mobil uzaktan eğitim yapay zeka destekli eğitimin farklı senaryoları arasındadır (Chen ve ark, 2020).

Bojorque ve Pesántez-Avilés (2019) yapay zekanın eğitimdeki uygulama alanlarını Çizelge 1.1’deki gibi tanımlamıştır.

Çizelge 1.1. Eğitimde YZ Uygulamaları (Bojorque ve Pesántez-Avilés, 2019)

İçerik ve öğrenim yöntemleri	Değerlendirme	İletişim
Eğitim içeriğinin özelleştirilmesi	MOOC değerlendirmesinde basitleştirme	Zeki öğretim sistemleri
Kişiselleştirilmiş öğrenme	Öğrenmedeki boşlukların belirlenmesi	
Eğitim robotları		

Yapay zeka eğitim sistemi genel anlamda öğrenci, öğretim ve bilgi modellerinden oluşan sistem modeli ve akıllı teknolojiler olarak iki kısımda incelenebilen öğretim içeriği, veri ve akıllı algoritmalarından oluşan bir sistemdir (Kim ve ark, 2018).

1.1.3. Eğitimde Akıllı Teknolojiler

Eğitimde akıllı teknolojilerin kullanımı giderek yaygınlaşmaktadır. Öğrencilerin ders materyallerine erişimi, öğretmenlerin ders denetimi, takip yönetim süreçleri ve eğitimdeki etkinlikler gibi birçok alanda teknolojiye yararlanılmakta ve kullanımı süreklilik göstermektedir. Bu bağlamda etkili ve kalıcı öğrenmenin sağlanması ve gelişimi bir zorunluluk haline gelmektedir (Bañeres ve ark, 2020).

Teknolojinin öğretme-öğrenme süreçlerinde uygulanması teknolojiyle güçlendirilmiş öğrenme olarak tanımlanır. Dijital teknolojilerin eğitimde kullanılması yoluyla öğretme ve öğrenme süreçlerinin iyileştirilmesini amaçlar. Öğrenme yönetim sistemleri, mobil öğrenme uygulamaları, sanal artırılmış gerçeklik müdahaleleri, bulut öğrenme hizmetleri, öğrenme için sosyal ağ uygulamaları, video öğrenimi, robotik ve veri madenciliği gibi birçok gelişmekte olan teknoloji teknolojiyle güçlendirilmiş öğrenme kapsamında değerlendirilebilir (Buenaño-Fernández ve ark, 2019).

Eğitim alanında büyük bir etkiyle uygulanan tüm teknolojiler çok miktarda veri üretir ve depolar. Bu veri miktarı geleneksel yöntemlerle işleme ve analiz kapasitesini aştığından veri analizini gerçekleştirmek için diğer teknolojilerin yanı sıra büyük veri, akıllı veri, veri madenciliği ve metin madenciliği gibi yeni teknolojilerle çalışmak gerekli hale gelmiştir. Bu durum makine öğrenimi ve veri madenciliği başta olmak üzere çeşitli istatistiksel yöntem, teknik ve araçlarının etkin kullanımını zorunlu kılmıştır (Buenaño-Fernández ve ark, 2019).

Özellikle yapay zekanın eğitimde etkin bir şekilde kullanımı önemli bir gelişim göstererek farklı bir boyuta taşınmıştır. Yapay zekanın öğrencilerin sadece eğitim materyaline erişiminde değil, aynı zamanda zeki öğretim sistemleri aracılığıyla eğitim süreçlerinin izlenmesi, öğrenmelerinin değerlendirilmesi ve performanslarının takibi konularında da fayda sağladığı iyi bilinmektedir (Bañeres ve ark, 2020).

Zeki öğretim sistemleri, kullanıcı ile yüksek düzeyde eğitim diyalogu sağlayan öğrenen sistemlerdir. Bu sistemlerin merkezinde çalışılan konu alanının bilgi tabanı yer alır. Bilgi tabanı, hem eğitim alanının içeriğiyle temsil edilen nesnel bilgiyi hem de öğretim yöntemlerini ve belirli bir eğitmenin öznel bilgisini içerir. Bu sistemler öğrencilerin bireysel özelliklerine göre belirlenen kriterlere uygun olarak farklı öğrenme içerikleri sunar (Bekmanova ve ark, 2021).

Yaşam boyu öğrenme için en önemli faktör; her yerden, uygun zamanda ve bireysel bir yol izleyerek öğrenebilmektir (Bekmanova ve ark, 2021).

Adaptif eğitim sistemleri, öğrencilere uygun öğrenme yöntem ve içeriği sağlama becerisine sahip olan sistemlerdir. Eğitimde öğrencilerin kişisel becerileri ve gereksinimlerinin belirlenmesi ve karşılanması adaptif e-öğrenme sistemlerinin sağlanmasında kritik öneme sahiptir. Bu nedenle öğrencilere bilgi düzeyi ve türü, kişilik özellikleri ve öğrenme becerilerinin analizine dayanan uygun öğrenme modelleri sunmak da son derece önemlidir (Almohammadi ve ark,2017).

Makine öğrenimi, öğrenme analitiği ve veri madenciliği eğitimle yakından ilişkili teknolojilerdir (Chen ve ark, 2020).

Makine öğrenimi, eğitim verileri olarak bilinen örneklem veri setine dayalı olarak ayırıştırma, anlamlı modeller ve yapılandırılmış bilgi üretme sürecidir. Makine öğrenimi öğrencilere üniversite seçiminde öneri sağlama, en uygun öğretim yönteminin belirlenmesi, öğrencilerin değerlendirilmesi için görüntü tanıma ve performans tahmini gibi eğitimle ilgili alanlarda başarılı bir şekilde uygulanabilir. Bu alanda en sık kullanılan teknikler arasında karar ağacı öğrenmesi, kümeleme algoritmaları, pekiştirmeli öğrenme, Bayes ağları ve tümevarımsal mantık programlama sayılabilir (Chen ve ark, 2020).

Makine öğrenimi; veri madenciliği, denetimli ve denetimsiz öğrenme, pekiştirmeli öğrenme ve derin öğrenme olarak sınıflandırılabilir (Ciolacu ve ark, 2018).

Öğrenme analitiği, öğrenme sürecinin eğitimin gerçekleştirildiği ortam koşullarıyla birlikte doğru anlaşılabilmesi ve etkili şekilde yönetilebilmesi için öğrencilere ait bilgilerin öğrencilerin bireysel özelliklerine göre derlenmesi, ölçülmesi, analiz edilmesi ve yorumlanması şeklinde tanımlanabilir (Siemens ve Baker, 2012).

Öğrenme analitiği, öğrenci ve bilgi nesnelerinin özelliklerinden gelen verilere odaklanır ve eğitim alanına makine öğrenimi teknolojilerini uygular. Bu sayede eğitim yöntemini risk altındaki öğrencilere müdahale etmek, geri bildirim ve öğretim içeriği sağlamak gibi eğitimi öğrencilerin ihtiyaç ve yeteneklerine göre uyarlamayı amaçlar (Chen ve ark, 2020).

Öğrenmeyi geliştirmeyi amaçlayan öğrenme analitiğinin nihai hedefi öğrenci ve eğitim kurumlarının performansını iyileştirmektir. Bu kapsamda öğretim stratejisini iyileştirmek, öğrencilerin ders materyalleri ile etkileşimini belirlemek, potansiyel olarak zorlanan öğrencileri tespit etmek ve uygun önlemler geliştirmek, notlandırma sistemlerini yeniden düzenlemek, gerçek zamanlı analiz ve öğretmenlerin kendi eğitimsel yeterliliklerini yargılamalarına izin vermek konuları öğrenme analitiğinin kullanım amaçları arasında değerlendirilebilir (Berding ve ark, 2022).

Yalnızca notlar, cinsiyet veya bir öğrencinin bir videoyu ne sıklıkta tekrarladığı hakkında bilgi toplamak önemli değildir. Hangi bireysel yeteneklerin, tutum ve inançların mevcut öğrenme davranışına ve sonuçlarına yol açtığını anlamak için öğrenme süreçlerinin doğru bir şekilde analiz edilmesi son derece önemlidir (Berding ve ark, 2022).

Öğrenme analitiği çerçevesinde yapılan çalışmalarda çoğunlukla öğrencilerin sosyal geçmişleri ve demografik özellikleri, tarihsel eğitim kayıtları veya geçmiş not ortalamaları gibi veriler kullanılmaktadır (Berding ve ark, 2022). Kalp atış hızı ve göz takibi gibi çok modlu veriler, sohbet ve forum konuşmaları, video kayıtları, anket ve röportaj gibi veri türleri ise daha az sıklıkta kullanılmıştır (Elsayed ve ark, 2019).

Almohammadi ve ark (2017), eğitimde öğrenme analitiği gibi yöntemlerin giderek önem kazanmasında etkili olan faktörleri aşağıdaki gibi belirtmiştir:

- Eğitim sektöründen derlenen bilgiler bağlamında kullanımı kolay, verilerdeki benzerlikleri tespit edebilen ve karar kuralları ile tahmin modelleri geliştirebilen güçlü makine öğrenimi, istatistik ve veri madenciliği teknik ve prosedürlerinin bulunması,
- Günümüz bilgisayarlarının bilgiyi işlemek ve depolamak için elverişli hale gelmesi ile olgu ve bilgilerin derlenmesinin kolaylaşması,

- Bütçe kısıtlamaları ve artan rekabetin eğitim kurumlarını geliştirmekte olan ülkelerin büyüyen eğitim pazarından yararlanarak öğrencileri derslere devam etmeye motive etmesi, maliyetlerini düşürmeye ve daha kaliteli eğitim sunmaya zorlaması

1.2. Çalışmanın Önemi ve Amacı

Eğitim toplumların ekonomik kalkınması, eşitlik ve refah düzeyleri açısından son derece önemli bir faktördür. Eğitimin geliştirilmesi ile akademik başarının artması yoluyla bireylerin, toplumun ve ülkelerin kalkınmasına hizmet edilebilir. Bu amaç doğrultusunda yapılmış çalışmaların çoğunda örnek veriler üzerinde istatistik gibi geleneksel yöntemler kullanıldığı görülmektedir. Ancak veri bilimi ve büyük veri alanlarına yönelik son gelişmeler yapay zekanın eğitim alanına da başarıyla uygulanabilme potansiyelini arttırmaktadır (Cruz-Jesus ve ark, 2020).

Eğitimdeki birçok alt sektöre benzer şekilde bugün çok sayıda üniversite mezun niteliklerini ve eğitim kalitesini iyileştirmeye yönelik kazanımlar sağlamak ve başarısızlık oranlarını azaltarak bölüm bırakma oranlarını düşürmek gibi amaçlarla öğretim ve öğrenmede stratejik önlemler geliştirmede kanıta dayalı yaklaşımları benimseme konusunda baskı altındadır. Bu gelişmeler yapay zekanın eğitimde kullanımını gerekli kılmaktadır (Deo ve ark, 2020).

Mühendislik eğitimi, farklı disiplinleri içeren birçok konuyu içermektedir. Mühendislik eğitiminin geleceği ile ilgili yayınlanmış olan Graham tarafından 2018 yılında yayınlanan bir raporda mühendislik için gelecek trendleri arasında şunlar yer almaktadır:

- Öğrenci merkezli bir eğitim sunmak için dijital teknolojiler ve aktif öğrenmenin birleşimi,

- Mühendislik çalışmalarında öğrencilere sunulan esneklik, seçim ve çeşitlendirmenin artması,
- Disiplinler arası öğrenme, küresel deneyim ve mühendislik kullanımı ile pozitif sosyal değişim temalarını bir araya getiren müfredat tasarlanması,
- İş tabanlı öğrenme ve kullanıcı merkezli tasarım projeleri gibi deneyimlerin bağlantılı etkinlikler olmaması ve öğrencilerin müfredatın geri kalanında kendi öğrenmelerini yansıtma fırsatının sağlanması.

Tüm bu eğilimler mühendislik eğitiminde farklı yapay zeka uygulamalarının yapılmasına imkan tanımaktadır. Chen ve ark (2020), yaptıkları çalışmalarında yapay zekanın eğitimde kullanılabilecekleri alanları yönetimsel, eğitim vermek ve öğrenmek olarak aşağıdaki gibi üç alana bölmektedir:

- İlk olarak yönetimsel konularda; sınav değerlendirmeleri ve geri dönüş vermek, öğrencilerin eğitim planını öğrenmek ve öğrenciye özgü eğitimler sunmak ve öğrenciye zamanında geri bildirim sunmak örnek verilebilir.
- Eğitim verilmesi ile ilgili olarak, öğrencinin beklentilerini analiz etmek, ders içeriğine göre özel içerikler oluşturmak, eğitimle işbirliği yaparak sınıfın ötesinde eğitim sunmak, öğrenci verilerine özgü eğitim içeriği sunmak ve kişiye özel içerikler oluşturmak örnek verilebilir.
- Son olarak, öğrenme ile ilgili öğrencilerin eksiklerini eğitim esnasında tespit etmek, aldıkları eğitime göre öğrencilere kariyer rehberliği sunmak, öğrenme durumunu tespit ederek öğrenciye özgü akıllı müdahaleler sunmak örnek verilebilir.

Tüm bu çerçeveden bakıldığında, eğitimde yapay zeka kullanımı önemli konulardan birisi olarak görülmekte ve bilimsel literatürde de özellikle son birkaç yılda kendisine uygulama alanı bulmaktadır. Bu tez çalışmasının temel amacı Chen

ve ark (2020) tarafından belirtilen konulardan öğrenme ile ilgili olan başlıklarda yapay zeka kullanım olanaklarını değerlendirmek ve bir sistem önermektir. Tez çalışmasının amacı özetlenecek olursa:

- Öğrenmenin gerçekleştiğini ders anında, ve sonrasında tespit edecek bir yapay zeka sistemi önermek,
- Öğrencilere öğrenme düzeylerine göre tekrar/ek ders içerikleri önerilmesini sağlamak,
- Öğrenciye özgü içerik oluşturulmasına girdi sağlamak,
- Yapay zeka veya çok kriterli karar verme gibi akıllı karar verme yöntemleriyle farklı eğitim programlarına uygulanabilecek adaptif bir sistem tasarlamaktır.

1.3. Çalışmanın Kapsamı

Bu çalışmada, öncelikle bir dersin öğrenilme durumunu ders anında ve sonrasında tespit edecek yapay zeka temelli bir sistem önerilmesi amaçlanmıştır. Bu doğrultuda, bir ders bağlamında derse hazırlık, ders aşaması ve ders sonrası süreçler analiz edilerek öğrenmenin kritik başarı faktörleri belirlenmiştir. Seçilen bir ders (GAMS optimizasyon yazılımına giriş) için belirlenen kritik başarı faktörleriyle ilişkili sorular hazırlanmıştır. Hazırlanan sorular çalışma kapsamında tasarlanan “E-Oğrenme Analiz Programı” ile çevrimiçi olarak, isteğe bağlı katılım seçeneğiyle, etik prosedürlere uygun şekilde katılımcılara sunulmuştur. Bu bağlamda, 82 mühendislik öğrencisi çalışmanın örneklemini oluşturmaktadır. Toplanan veriler oluşturulan modeller doğrultusunda uygun sınıflandırma algoritmalarıyla analiz edilerek ders anında ve sonrasında öğrenmenin tespiti gerçekleştirilmiştir.

Çalışma kapsamında yapılan literatür araştırması neticesinde “eğitimde yapay zeka” konusunu öğrenmenin tespit edilmesine yönelik ele alan bir çalışmaya

rastlanmamıştır. Bu noktada çalışmanın ele aldığı konu, öncelikli amacı, yöntem ve yaklaşımıyla literatüre önemli bir katkı sağlayacağı düşünülmektedir.

Çalışma kapsamında hazırlanan öğrenmenin kritik başarı faktörleri, ilişkili sorular, oluşturulan modeller ve tasarlanan “E-Oğrenme Analiz Programı” çalışmanın özgün katkıları olarak değerlendirilebilir.

1.4. Çalışmanın Adımları ve Organizasyonu

Bu çalışmanın adımları aşağıdaki gibidir:

- 1. Problemin belirlenmesi:** Eğitim toplumların gelişimi için son derece önemlidir. Eğitimin geliştirilmesi ise öğrenme süreçlerinin iyileştirilmesi ile yakından ilişkilidir. Öğrenme süreçlerinin iyileştirilebilmesi için öncelikle öğrenmenin doğru bir şekilde tespit edilmesi gerekir. Bu doğrultuda, bir ders bağlamında ders anı ve sonrasında öğrenmeyi doğru bir şekilde tespit etmek amaçlanmıştır.
- 2. Önceki çalışmaların incelenmesi:** “Eğitimde Yapay Zeka” konusunu ele alan çalışmalar incelenmiştir. İncelenen çalışmalar konusu, kullanılan veri seti, kullanılan algoritma veya önerilen sistem ve sonuçlar şeklinde sınıflandırılarak sunulmuştur.
- 3. Analiz ve veri toplama:** Öncelikle öğrenme süreçleri analiz edilerek öğrenmede etkili kritik başarı faktörleri belirlenmiştir. Ardından bir ders (GAMS optimizasyon yazılımına giriş) seçilerek belirlenen kritik başarı faktörleri ile ilişkili sorular hazırlanmıştır. Seçilen ders için konu anlatım videosu oluşturularak hazırlanan sorularla birlikte tasarlanan veri toplama yazılımı (E-Oğrenme Analiz Programı) ile 82 mühendislik öğrencisinden veriler toplanmıştır.
- 4. Model oluşturma ve algoritma testleri:** Toplanan veriler için uygun sınıflandırma algoritmaları (Decision Tree, Random Forest, XGBoost, MLP) seçilmiş ve dört farklı model oluşturulmuştur. Her model için

kullanılan algoritmalarla testler gerçekleştirilerek grafik ve tablolar şeklinde sunulmuştur.

- 5. Sonuçların başarı metrikleriyle değerlendirilmesi:** Her bir model için kullanılan algoritmalarla elde edilen sonuçlar sınıflandırma algoritmaları başarı metrikleriyle karşılaştırmalı olarak değerlendirilmiş ve sunulmuştur.

Yapılan çalışmanın organizasyonu çerçevesinde, bu çalışmanın ikinci bölümünde “eğitimde yapay zeka” konusunu ele alan çalışmalar incelenmiştir. Üçüncü bölümde, çalışmanın materyalleri, yöntemi, oluşturulan model ve kullanılan algoritmalarla ilgili bilgiler ile sınıflandırma algoritmalarının başarısını değerlendirme metriklerine yer verilmiştir. Dördüncü bölümde, her model için algoritma tahminleri ve karşılaştırmaları ile model karşılaştırmaları yer almaktadır. Çalışmanın son bölümünde ise ulaşılan sonuçlar ve gelecek çalışmalar için öneriler bulunmaktadır.



2. ÖNCEKİ ÇALIŞMALAR

Eğitimde yapay zeka konulu çalışmaların çoğunlukla öğrenci performans ve not tahmini üzerine yoğunlaştığı görülmektedir (Tosunoğlu ve ark, 2021).

Bu çalışmada “Eğitimde Yapay Zeka” konulu önceki çalışmalar öğrenci performans ve not tahmini, kişiselleştirilmiş eğitim ve öğretim kalitesinin iyileştirilmesi konu başlıkları altında incelenmiştir.

Öğrenci performans ve not tahmini konusunu ele alan çalışmalardan bazıları aşağıdaki gibidir:

Koutina ve Kermanidis (2011) çalışmalarında, İyonya’da bir üniversitenin bilişim bölümü yüksek lisans öğrencilerinin final sınav notlarının tahmin edilmesinde en etkili makine öğrenim tekniğinin tespit edilmesi konusunu incelemişlerdir. Bu doğrultuda beş akademik ders seçilerek oluşturulmuş farklı veri setleri üzerinde yaygın olarak kullanılan altı sınıflandırma algoritmasını (karar ağacı, k-en yakın komşu, Naive Bayes, kural tabanlı bir öğrenici, rastgele orman, destek vektör makineleri) test etmişlerdir. Testleri WEKA makine öğrenimi yazılım paketini kullanarak gerçekleştirmişlerdir. Veri kümeleri arasındaki boyut farklılıkları ve dağılım dengesizliklerini düzeltmek için yeniden örnekleme ve özellik seçimi gibi tekniklerden yararlanmışlardır. Yaptıkları çalışma ile % 85 ile % 100 arasında değişen genel tahmin doğruluğu elde ederek Naive Bayes ve 1-NN yöntemlerinin seçilen diğer yöntemlere göre daha iyi tahmin sağladığı sonucuna ulaşmışlardır. Bunun yanı sıra daha iyi tahmin doğruluğu sağlamada öğrencilerin bilişim lisans derecelerinin olması ve sınıfta bulunmalarının sınıflandırıcılar için önemli olduğunu ortaya koymuşlardır.

Ciolacu ve ark (2018) çalışmalarında, eğitim 4.0 bağlamında yapay zeka teknikleri kullanılarak üniversite öğrencilerinin final notlarının tahmini ile riskli öğrencilerin belirlenerek başarısızlık oranlarının azaltılması konusunu ele almışlardır. Bu doğrultuda bir grup iş yönetim ve bilişimi öğrencileri ile üç farklı matematik ve bilgi yönetimi içerikli kursa yönelik veri toplayarak Destek Vektör

Makineleri ve Yapay Sinir Ağları teknikleri ile değerlendirmişlerdir. Bu değerlendirme ile yeni eğitim dönemi için tahminde bulunarak başarısız olma riski yüksek olan öğrencilerin tespit edilmesini amaçlamışlardır. Yaptıkları çalışma ile yapay zeka algoritmalarının başarısız olma riski yüksek öğrencilerin tahmin edilerek başarısızlık oranlarının azaltılmasında yaklaşık olarak %50 oranında iyileşme sağladığını ortaya koymuşlardır.

Hussain ve ark (2018) çalışmalarında, öğrencilerin derse katılımlarının performansları üzerindeki etkisinin makine öğrenme algoritmaları ile değerlendirilmesi konusunu incelemişlerdir. Bu doğrultuda İngiltere’de bir açık üniversitenin sosyal bilimler dersine düşük oranda katılım gösteren öğrencileri tahmin etmek için makine öğrenme algoritmalarını kullanmışlardır. Ardından bu tahminleri öğrenci değerlendirme puanları ile karşılaştırmışlardır. Öğrenci katılımını öğrencilerin ilgili derse ait aktivite türlerine tıklama sayıları, ilk ve son değerlendirme puanları ve derse kaydolmadan önceki en yüksek eğitim seviyelerini dikkate alarak değerlendirmişlerdir. Düşük katılımlı öğrencilerin tahmini için karar ağacı ve Naive Bayes gibi makine öğrenme algoritmalarını kullanmış ve sonuçları karşılaştırmışlardır. Yaptıkları çalışma ile karar ağacı ve Gradient Boosted Trees algoritmalarının düşük katılım gösteren öğrencilerin tahmini için en uygun algoritmalar olduğu ve yüksek katılım gösteren öğrencilerin daha yüksek değerlendirme puanına sahip olduğu sonuçlarına ulaşmışlardır.

Buenaño-Fernández ve ark (2019) çalışmalarında, makine öğrenimi teknikleriyle öğrencilerin geçmiş notlarına dayanılarak final notlarının belirlenmesi konusunu ele almışlardır. Bu doğrultuda bir üniversitenin bilgisayar mühendisliği öğrencilerinin mevcut akademik bilgilerini baz alarak bir dizi deney gerçekleştirmişlerdir. İlk aşamada veriyi toplayarak ön işlemden geçirmiş, ikinci aşamada benzer akademik performans örüntüsüne sahip öğrencilerin gruplandırılmasını sağlamışlardır. Son aşamada ise belirlenen örüntülere göre en uygun denetimli öğrenme algoritmasını seçerek deneyi tamamlamışlardır. Bu aşamaları gerçekleştirmek için veri madenciliğinin sınıflandırma tekniğini ve karar

ağacı algoritmasını kullanmışlardır. Yaptıkları çalışma ile öğrencilerin akademik performanslarını iyileştirerek her akademik dönem için öğrenci devamsızlık oranını azaltmış ve öğrenci performansının tahmin edilmesinde makine öğrenmesi tekniklerinin etkililiğini göstermişlerdir.

Sekeroglu ve ark (2019) çalışmalarında, öğrenci performansının tahmin ve sınıflandırılmasında yapay zeka ve makine öğrenimi yaklaşımlarının etkililiğinin değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda tahmin ve sınıflandırma problem alanlarında farklı eğitim veri kümeleriyle altı deney gerçekleştirmişlerdir. Bu deneyler ile her veri kümesi için belirlenmiş makine öğrenim algoritmalarının etkinliğini test etmiş ve karşılaştırmalı sonuçları sunmuşlardır. Yaptıkları çalışma ile makine öğrenmesi modellerinin eğitimde etkin bir şekilde kullanılabileceğini kanıtlamış ve radyal temel fonksiyonlu sinir ağı modelinin öğrenci performans tahmin ve sınıflandırması için en elverişli yöntem olduğunu ortaya koymuşlardır.

Sharma ve ark (2019) çalışmalarında, öğrencilerin çaba gösterme davranışları ve performanslarının makine öğrenme algoritmaları ile değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda Avrupa’da bir üniversitenin online web tasarımı dersi için 32 kişilik bir öğrenci grubuyla laboratuvar ortamında bir deney gerçekleştirmişlerdir. Deney kapsamında öğrencilere kendi öğrenme durumlarını gözlemlene imkanı tanıyan ve verdikleri cevaplara göre soru sayısı ve soru seçimi yapılan adaptif bir eğitim uygulaması sunmuşlardır. Bu uygulama ile öğrencilerden göz takibi, yüz hareketleri, sıcaklık değeri gibi fizyolojik verileri toplayarak öğrencilerin sorular üzerinde çaba gösterme davranışı ve test performansları üzerindeki etkisini gözlemlemişlerdir. Bu çalışma ile, öğrencilerin adaptif eğitim uygulaması çerçevesinde çaba gösterme ve performans değerlerini öngören farklı özellik kombinasyonlarından en önemli yapıları belirlemeyi amaçlamışlardır. Çalışmada öznel çıkarm ve seçiminde temel bileşenler analizi ile rastgele orman algoritmasını; verilerin tahmin ve değerlendirilmesinde karar ağacı, destek vektör makineleri ve Gauss süreç regresyonu algoritmalarını kullanmışlardır. Yaptıkları çalışma ile öğrencilerin çaba

gösterme davranışları ve performans tahminlerinde en belirleyici olan özellik kombinasyonlarını (göz kırpma, kaş kaldırma, burun kırıştırma gibi) ortaya koymuşlardır. Bu özelliklerin etkili öğrenmenin gerçekleşmesinde yol gösterici birer parametre olarak mevcut eğitim sistemlerine adapte edilebileceği ve öğrencilere başarılarını arttırmaya yönelik geri bildirim sağlanabileceği sonuçlarına ulaşmışlardır.

Chen ve ark (2020) çalışmalarında, Eğitim 4.0 kapsamında yapay zekanın öğrencilerin performansının analiz edilmesinde kullanılması konusunu incelemişlerdir. Bu doğrultuda öğrenim süreçlerinin iyileştirilmesine yönelik olarak öğrenci performans tahmini sağlayan hibritleştirilmiş derin sinir ağı yöntemini önermişlerdir. Bu yöntemle öğrencinin performansını etkileyebilecek dinamikleri belirleyerek derin sinir ağları ile Eğitim 4.0 ortamında öğrencilerin performansının tahmin ve değerlendirilmesini sağlamışlardır. Yaptıkları çalışma ile önerilen yöntemin performans değerlendirmede sıkça kullanılan diğer yöntemlere göre daha iyi tahmin doğruluğu sağladığı ve öğrencilerin akademik başarısını arttıran davranışsal bir modelin tahmin edilmesinde elverişli bir yöntem olduğunu ortaya koymuşlardır.

Cruz-Jesus ve ark (2020) çalışmalarında, lise öğrencilerinin akademik başarılarının farklı yapay zeka teknikleriyle değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda Portekiz’de bulunan devlet liselerinde, 2014-2015 yılları arasında eğitim gören toplam 110.627 öğrencinin akademik başarısını yapay zeka teknikleriyle değerlendiren bir yaklaşım geliştirmişlerdir. Yapay sinir ağları, karar ağaçları, rastgele orman ve destek vektör makineleri gibi makine öğrenim tekniklerini kullanmışlardır. Yaptıkları çalışma ile genel olarak yapay zeka tekniklerinin istatistiksel yöntemlere göre daha iyi performans gösterdiği, öğrencinin bir akademik yılda aldığı birim ders sayısı, eğitim hayatındaki toplam başarısızlık sayısı ve cinsiyetinin öğrencinin bir sonraki yıla geçip geçmemesini etkileyen en kritik faktörler olduğu sonucuna ulaşmışlardır.

Deo ve ark (2020) çalışmalarında, Avustralya’da bir üniversitenin mühendislik lisans öğrencilerinin mühendislik matematiği derslerine ait performanslarının yapay zeka teknikleriyle değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda ilgili üniversitenin mühendislik matematiği (ENM1600) ve ileri mühendislik matematiği (ENM2600) iki seçenekli (online ve yüz yüze) derslerine ait öğrencilerin geçmiş sınav ve ödev notlarını girdi olarak alan ve final puanı ile ağırlıklı puan tahmini yapan aşırı öğrenme makinesi temelli bir model oluşturmuşlardır. Aşırı öğrenme makinesi yönteminin etkililiğini karşılaştırmalı olarak değerlendirebilmek için rastgele orman algoritması ve kural tabanlı volterra modelini aynı veri seti için uygulamışlardır. Model başarılarını test etmek için MAE, MAPE ve RMSE gibi metrikleri kullanmışlardır. Yaptıkları çalışma ile online ve yüz yüze seçenekli mühendislik matematiği derslerinin hepsinde önerdikleri aşırı öğrenme makinesi modelinin diğer modellerden düşük bir tahmin hatası değeriyle daha iyi performans gösterdiğini ortaya koymuşlardır. Önerdikleri yapay zeka metodolojisinin öğrenci öğrenme değişkenleri arasındaki ilişkilerin belirlenmesinde güçlü bir araç olduğuna dikkat çekmişlerdir.

Jani ve ark (2020) çalışmalarında, tıp öğrencilerinin hasta-doktor iletişimini geliştirmek amacıyla tasarlanan Objektif Yapılandırılmış Klinik Muayene (OSCE) sınavlarının makine öğrenimi teknikleriyle değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda OSCE’de standart hasta-öğrenci arasında geçen ifadeleri tek bir klinik senaryoda etiketleyebilen diğer bir klinik senaryodan ifadeleri aktarabilen ve öğrencilerin iletişim performansını değerlendirebilen bir makine öğrenim modeli geliştirmişlerdir. Modelde ifadelerin matematiksel vektörlere dönüştürülmesi için BOW gibi yapıları, modelin tasarımında ise destek vektör makinesi (SVM), koşullu rastgele alan (CRF), çift yönlü uzun kısa süreli bellek (biLSTM) makine öğrenim algoritmalarını kullanmışlardır. Matematiksel vektörlere dönüştürülen ifade ve algoritma kombinasyonlarını istatistiksel yöntemlerle analiz ederek karşılaştırmışlardır. Yaptıkları çalışma ile makine öğrenimi algoritmalarının öğrencilerin klinik iletişim becerilerinin test edilmesinde

kullanılan OSCE sınavı ifade etiketlerinin otomatik olarak oluşturulmasını ve doğru bir değerlendirme yapılmasını sağladığı sonuçlarına ulaşmışlardır.

Rincón-Flores ve ark (2020) çalışmalarında, yapay zekanın eğitimde bir araç olarak kullanılmasıyla öğretme-öğrenim sürecinin iyileştirilmesi konusunu ele almışlardır. Bu doğrultuda fizik dersini alan mühendislik öğrencilerinin akademik performanslarını tahmin etmek amacıyla bir model geliştirmişlerdir. Modeli fizik derslerini veren 5 farklı öğretmen ve toplam 134 öğrenci için 3 farklı değerlendirme dönemini kapsayacak şekilde oluşturmuşlardır. Mühendislik öğrencilerinin akademik performans tahmini için K-en yakın komşu ve Random Forest makine öğrenme algoritmalarını kullanmışlardır. Algoritmaları yüz tanıma ve dönem sonu ders notları gibi biyometrik ve akademik girdilerle beslemişlerdir. Yaptıkları çalışma ile her öğrenci grubu için genel performans tahmininde algoritmaların daha iyi sonuç verdiğini ve yapay zeka algoritmalarının öğretme-öğrenim sürecini ve öğrencilerin akademik performanslarını geliştirmede etkili bir araç olarak kullanılabileceğini ortaya koymuşlardır.

Khan ve ark (2021) çalışmalarında, öğrencilerin bir derse ilişkin akademik performanslarının yapay zeka teknikleriyle tespit edilmesi ve iyileştirilmesi konusunu ele almışlardır. Bu doğrultuda bir üniversitenin lisans öğrencileriyle yüz yüze gerçekleştirilen fonetik ve fonoloji dersindeki performanslarını düşük ya da yüksek olarak tespit eden ve performansı düşük olan öğrenciler için akademik başarılarını arttırmaya yönelik önlemler tasarlayan bir model geliştirmişlerdir. Modelin girdilerini cinsiyet, branş, derse katılım, birinci sınav notları, burs alıp almama durumları ve genel not ortalaması gibi faktörler olarak belirlemiş ve 151 öğrenci için modeli uygulamışlardır. Öğrencilerin performans tahminlerini yapmak için karar ağacı, k-en yakın komşu, yapay sinir ağı ve Naive Bayes sınıflandırma algoritmalarını; algoritma başarısını değerlendirmek için doğruluk, kesinlik, duyarlılık ve Matthews korelasyon katsayısı gibi metrikleri kullanmışlardır. Yaptıkları çalışma ile kullanılan tüm metriklerde karar ağacı algoritması için en iyi tahmin başarısı değerlerini elde etmiş ve öğrenci performansının tahmininde karar

ağacı algoritmasının etkililiğini ortaya koymuşlardır. Geliştirdikleri modeli öğretmenlerin öğrenci değerlendirme sistemine dahil ederek düşük akademik başarı gösteren öğrencilerin durumlarına uygun önlemler tasarlayarak akademik performanslarının iyileştirilmesine katkıda bulunmuşlardır.

Lee ve ark (2021) çalışmalarında, insan-makine iş birlikli öğretimin öğrencilerin öğrenim süreci üzerindeki etkisini makine öğrenim araçlarıyla incelemiştir. Bu doğrultuda öğrencilerin İngilizce dinleme becerileri ile bilgisayar bilimleri ve Go oyunu uygulamaları alanındaki öğrenme performanslarını test etmek için patch learning mekanizmalı adaptif bulanık sinir ajanı (AFNA) modelini geliştirmişlerdir. Önerdikleri modeli Tayvan ve Japonya'daki öğrencilerin öğrenme ve Go oyunu verileri üzerinde PyTorch açık kaynaklı makine öğrenim kütüphanesini ve Python programlama dilini kullanarak test etmişlerdir. Yaptıkları çalışma ile önerilen modelin kullanılan verilere dayalı olarak regresyon modelinin performansını iyileştirebileceğini göstermişlerdir. Ayrıca öğrencilerin eğlenerek öğrenmesi yoluyla okuma ve anlama becerilerinin gelişmesi sağlanmıştır.

Jokhan ve ark (2022) çalışmalarında, eğitimde yapay zeka destekli erken uyarı sistemiyle öğrenci başarısının tahmini ve geliştirilmesi konusunu ele almışlardır. Bu doğrultuda bir üniversitenin online bilgi teknolojisi okuryazarlığı dersini alan 1523 öğrenci için dersi geçip geçemeyeceklerini ders döneminin 6. haftasında tahmin eden bir model geliştirmişlerdir. Modelin girdilerini öğrencilerin her hafta tamamladıkları ders etkinlik yüzdesi, haftalık ortalama oturum açma sayısı ve ders notları olarak belirlemişlerdir. Modelin tahmini için lojistik regresyon, destek vektör makinesi, karar ağacı, sıralı minimum optimizasyon ve rastgele orman gibi bazı algoritmaları kullanmışlardır. Algoritma başarısını değerlendirmek için duyarlılık, özgüllük, doğruluk, kesinlik ve Matthews korelasyon katsayısı metriklerini kullanmışlardır. Yaptıkları çalışma ile rastgele orman algoritmasıyla belirlenen tüm metriklerde en iyi tahmin performansını sağladıklarını ve geliştirdikleri model ile başarısız olma riski olan öğrencilerin %

97,03 doğrulukla tespit edilebildiğini ortaya koymuşlardır. Tasarladıkları erken uyarı sistemi modeliyle başarısız olma riski taşıyan öğrencilerin önceden tespit edilmesi ile düzeltici önlemlerin alınabileceğini, öğrenmenin takibinin sağlanmasıyla öğretim ve öğrenme süreçlerinin geliştirilebileceğini öngörmüşlerdir.

Kişiselleştirilmiş eğitim konusunu ele alan çalışmalardan bazıları aşağıdaki gibidir:

Tekin ve ark (2015) çalışmalarında, yapay zeka bağlamında eğitimin kişiselleştirilmesi konusunu ele almışlardır. Bu doğrultuda öğrencilerin geri bildirim ve sınav sonuçları gibi faktörleri göz önüne alarak öğrencilere en uygun materyal sırası ve içerik önerisi sağlayan e-Tutor adında bir online eğitim sistemi tasarlamışlardır. Yaptıkları çalışma ile her öğrenciye bütün materyalleri sunmak yerine kendi bağlamına en uygun eğitim materyallerinin sunulmasının öğrencilerin nihai not ortalamalarında iyileşme ve büyük ölçüde zaman tasarrufu sağladığını ortaya koymuşlardır.

Villegas-Ch. ve ark (2021) çalışmalarında, COVID-19 dönemi ile eğitimde karşılaşılan sorunları, farklı eğitim modellerini ve öğretme-öğrenim sürecinin geliştirilmesi konusunu büyük veri analizi ve yapay zeka bağlamında ele almışlardır. Bu doğrultuda bilginin alınması, işlenmesi, analiz ve erişimini içeren dört temel aşamadan oluşan Hadoop çerçeveli bir veri analizi modeli önermişlerdir. Bu model yardımıyla farklı öğretme-öğrenme etkinliklerinde karşılaştıkları sorunlara göre öğrencilerin belirlenmesini ve sınıflandırılmasını amaçlamışlardır. Yaptıkları çalışma ile günümüzde üniversitelerin değişimlere hızlı ve etkili şekilde cevap verebilen bir yapı kazanmasının gerekliliğine vurgu yapmışlardır. Bu çerçevede önerdikleri yapay zeka içeren uzman sistem ile akademik performansı etkileyen faktörlerin tespit edilebileceğini ve öğrenci merkezli kişiselleştirilmiş eğitim modelleri ile öğrenmenin geliştirilmesine katkı sağlanabileceğini ortaya koymuşlardır.

Xiao ve Yi (2021) çalışmalarında, yüksekokul ve üniversitelerde eğitimin kişiselleştirilmesi konusunu ele almışlardır. Bu doğrultuda üç aşamalı bir model geliştirmişlerdir. İlk aşamada yüksekokul ve üniversite giriş düzeyindeki öğrencilerin bilgilerini toplayarak modelleme için uygun hale getirmişlerdir. İkinci aşamada yapay zeka tekniklerinden yararlanarak öğrenciler için kişiselleştirilmiş bir eğitim modeli sunmak amacıyla öğrenci özellik seçimine dayalı bir yöntem geliştirmişlerdir. Son aşamada ise geliştirilen kişiselleştirilmiş eğitim modeli temelinde öğrenci gelişimini tahmin etmek için bir yöntem sunmuşlardır. Önerilen modeli 3000 eğitim seti ve 500 test seti için Tensorflow makine öğrenme aracı ve Python programlama dilini kullanarak test etmişlerdir. Yaptıkları çalışma ile önerilen modelin % 95 doğrulukla yüksekokul ve üniversite öğrencileri için kişisel eğitim planı tasarlanmasında elverişli olduğu ve modelin kariyer planlama gibi farklı alanlara da uygulanabileceği sonucuna ulaşmışlardır.

Öğretim kalitesinin iyileştirilmesi konusunu ele alan çalışmalar aşağıdaki gibidir:

Bojorque ve Pesántez-Avilés (2019) çalışmalarında, akademik kalite yönetim sisteminin öğretme-öğrenim sürecinin yapay zeka teknikleriyle sistematik olarak değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda Latin Amerika’da bir üniversitenin öğretme-öğrenim sürecindeki düzensizlikleri belirlemek için müfredat kaynaklarını değerlendirmişlerdir. Değerlendirme için kaynaklar hakkında öğretmenler tarafından yapılan geçmiş dört döneme ait yorumları baz almışlardır. Oluşturulan veri setini metin madenciliği ve yapay sinir ağları tekniklerini kullanarak analiz etmişlerdir. Yaptıkları çalışma ile bilgilerin kontrol edilmesi ve doğrulanması gibi öğretim-öğrenimin karar alma süreçlerinde yapay zeka tekniklerinin kullanılmasının süre avantajı ile daha etkin bir değerlendirme sağladığını ortaya koymuşlardır.

Gaobin ve ark (2020) çalışmalarında, geleneksel beden eğitimi öğretim sisteminin yapay zeka algoritmalarının kullanılmasıyla iyileştirilmesi sürecini ele almışlardır. Bu doğrultuda yapay zeka bulanık algoritmasına dayalı olarak beden

eğitimi öğretim sistemini değerlendiren bir model geliştirmişlerdir. Modelde insan ve makine dilini birleştirerek aralarında etkileşim sağlamak için bulanık kontrol talimatlarını; öğrencilerin hareket süreçlerini belirlemek ve sınıflandırmak için parçacık sürüşü optimizasyon algoritmasını kullanmışlardır. Modeli beden eğitiminin gereksinimleri ve fonksiyonel ihtiyaç analizine dayalı olarak oluşturmuşlardır. Ardından deney ve kontrol gruplarından oluşan bir örneklem üzerinde modeli test etmiş ve sonuçları istatistiksel olarak analiz ederek karşılaştırmışlardır. Yaptıkları çalışma ile önerdikleri yapay zeka bulanık algoritma temelli modelin beden eğitiminde öğrenmeyi sağlamada belirli bir pratik etkiye sahip olduğunu ortaya koymuşlardır.

Li ve Su (2020) çalışmalarında, yapay zeka bağlamında temel eğitimin çevrimiçi öğretim kalitesinin değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda yapay zekanın temel eğitimdeki mevcut durumu ile eksiklik ve sorunları analiz etmiş, çevrimiçi öğretimin temel eğitimin kalitesi üzerindeki etkisini incelemiş ve bu etkinin değerlendirilmesini amaçlayan bir model geliştirmişlerdir. Bu modelde belirlenen kalite göstergelerinin ağırlık ve seviyelerinin tespit edilmesi için ağırlıklı entropi ve gri kümeleme analizi yöntemlerini kullanmışlardır. Yaptıkları çalışma ile benzer çalışmalar için etkili bir referans sağlayarak yapay zeka bağlamında çevrimiçi eğitimin iyileştirilmesine yönelik öğreticilerin kapsamlı okuryazarlığının geliştirilmesi, çevrimiçi öğretim kaynak paylaşımının artırılması, yönetimin iyileştirilmesi ve çevrimiçi öğretime yönelik yatırımların artırılması gibi stratejik önerilerde bulunmuşlardır.

Xiao ve Yi (2020) çalışmalarında, yüksek mesleki eğitimin ders öğretim kalitesinin artırılmasına yönelik olarak değerlendirilmesi konusunu ele almışlardır. Bu doğrultuda üç aşamadan oluşan bir çoklu değerlendirme sistemi geliştirmişlerdir. Bu sistemin ilk aşamasında geleneksel öğretim organizasyonunu yenilemişlerdir. İkinci aşamada yenilenen öğretim organizasyonuna dayalı bir özellik seçim modeli geliştirmişlerdir. Son aşamada ise sistemin değerlendirmeyi sağlaması için makine öğrenimi algoritması kullanmışlardır. Makine öğrenimi

modeli için TensorFlow aracı ile Python yazılım dilini kullanmışlardır. Yaptıkları çalışma ile önerilen sistemin pratik ve etkili çoklu değerlendirmeler sağladığı ve diğer değerlendirme yöntemlerine göre makine öğrenimi temelli çoklu değerlendirmenin daha esnek, zeki ve otomatik olduğu sonucuna ulaşmışlardır.

Ma ve ark (2021) çalışmalarında, yapay zekanın öğretim alanına uygulanmasının yüksekokul ve üniversitelerin gelişimindeki etkisi ve verimli şekilde uygulanması konusunu ele almışlardır. Bu doğrultuda optimizasyon algoritmaları öğretiminin uygulanabilirlik ve verimliliğini geliştirmek için yapay zeka ve sinir ağlarına dayalı bilgisayar destekli bir öğretim sistemi ile hibrit parçacık sürüsü optimizasyon algoritması öğretim modelini önermişlerdir. Önerdikleri algoritma modelinin arama yeteneğini geliştirmek için yapay balık sürüsü algoritmasının kümeleme davranışını temel almışlardır. Önerdikleri sistem ve modelin performansını değerlendirmek için kontrol deneyleri tasarlamışlardır. Yaptıkları çalışma ile önerdikleri sistem ve modelin öğretim alanına uygulandığında öğrencilerin notlarını iyileştirmede etkili olabileceğini ortaya koymuşlardır.

İncelenen çalışmalar aşağıda verilen Çizelge 2.1’de çalışma, konusu, kullanılan veri seti, kullanılan algoritma veya önerilen sistem ve sonuçlar şeklinde sınıflandırılmış olarak sunulmuştur.

Çizelge 2.1. Sınıflandırılmış Önceki Çalışmalar Çizelgesi

Çalışma	Konusu	Kullanılan veri seti	Kullanılan Algoritma/Önerilen Sistem	Sonuçlar
Güner ve Çomak (2011)	Performans/not tahmini	Mühendislik öğrencileri, toplam 434 öğrenci	Destek Vektör Makinesi	%86,36 doğruluk ile Matematik I dersinde başarılı olacak öğrencilerin tahmininin sağlanması, Üniversite giriş sınav puanı ve lise başarısının matematik başarısını etkileyen temel faktörler olarak tespiti
Koutina ve Kermanidis (2011)	Performans/not tahmini	Bilişim bölümü yüksek lisans öğrencileri, toplam 117 öğrenci	Karar Ağacı, K-en Yakın Komşu, Naive Bayes, Rastgele Orman, Destek Vektör Makineleri, Kural Tabanlı Öğrenici	%85-%100 arasında değişen genel tahmin doğruluğu, Naive Bayes ve 1-NN en iyi tahminleyiciler
Agrawal ve Mavani (2015)	Performans/not tahmini	Mühendislik öğrencileri, toplam 70 öğrenci	Yapay Sinir Ağı	Yapay Sinir Ağına Naive Bayes algoritmasına göre daha yüksek başarı göstermesi, öğrencilerin geçmiş başarılarının güncel performansları üzerinde önemli etkiye sahip olması
Sezer (2015)	Kişiselleştirilmiş eğitim	Ortaokul öğrencileri, toplam 66 öğrenci	Ön test-son test kontrol grubu deney	Matematik dersinde kişiselleştirilmiş problem kullanımının öğrenci başarısını olumlu yönde etkilediğinin tespiti
Tekin ve ark (2015)	Kişiselleştirilmiş eğitim	Üniversite öğrencileri	e-Tutor çevrimiçi eğitim sistemi	Öğrencilere en uygun eğitim materyallerinin sunulması, Notlarda iyileşme, Zaman tasarrufu
Rao ve ark (2016)	Performans/not tahmini	Mühendislik öğrencileri, toplam 200 öğrenci	Karar Ağacı, Naive Bayes, Rastgele Orman	Rastgele Orman algoritması ile en yüksek doğruluk değerine ulaşılması
Gök (2017)	Performans/not tahmini	Ortaokul öğrencileri, toplam 1492 öğrenci	Doğrusal Regresyon, K-en Yakın Komşu, Doğrusal Destek Vektör Makinesi, Radyal Tabanlı Fonksiyon, Rastgele Orman, Lojistik Regresyon, Naive Bayes	Türkçe dersi için Rastgele Orman, matematik dersi için Radyal Tabanlı Fonksiyon ve genel başarı ortalaması için Lojistik Regresyon algoritmasının en iyi başarıyı göstermesi
Aydoğan ve Karcı (2018)	Performans/not tahmini	Meslek yüksekokulu öğrencileri, yaklaşık 200 öğrenci	K-en Yakın Komşu, Lojistik Regresyon, Destek Vektör Makineleri, Karar Ağacı, Naive Bayes, Rastgele Orman, K-ortalamlar Algoritması	En iyi sınıflandırma başarısı gösteren algoritmanın Rastgele Orman algoritması olması, öğrenci gelir düzeyi ve sınavlı geçiş sisteminin öğrenci başarısını etkileyen temel faktörler olması
Cialacu ve ark (2018)	Performans/not tahmini	İş yönetim ve bilişim bölümü lisans öğrencileri, farklı büyüklükte 3 farklı veri seti	Destek Vektör Makineleri, Yapay Sinir Ağları	Öğrenci başarısızlık oranlarının azaltılmasında %50 oranında iyileşme

Çizelge 2.1. Sınıflandırılmış Önceki Çalışmalar Çizelgesi (devamı)

Çalışma	Konusu	Kullanılan veri seti	Kullanılan Algoritma/Önerilen Sistem	Sonuçlar
Hussain ve ark (2018)	Performans/not tahmini	Üniversite öğrencileri	Karar Ağacı, Naive Bayes, Gradient Boosted Trees (GBT), JRIP, J48, CART	Düşük katımlı öğrencilerin tespitinde etkili algoritmalar Karar Ağacı ve GBT algoritmaları, Yüksek katımlı öğrenciler daha yüksek performansa sahip
Özkan ve ark (2018)	Performans/not tahmini	Ortaokul öğrencileri, toplam 395 öğrenci	Derin Öğrenme Algoritmaları, Karar Ağacı Algoritmaları (C5, Boosted C5, Regresyon Ağacı), Destek Vektör Makinesi, Rastgele Orman, Lojistik Regresyon	%87 doğrulukla Derin Öğrenme Algoritması ile en iyi sonuca ulaşılması, aile ile ilişki niteliği, arkadaşlarla dışarı çıkma ve annenin eğitim durumunun öğrenci performansını etkileyen en önemli faktörler olarak tespiti
Bojorque ve Pesántez-Avilés (2019)	Öğretim kalitesinin iyileştirilmesi	Müfredat kaynakları hakkında öğretmen değerlendirmeleri	Metin Madenciliği, Yapay Sinir Ağları	Eğitim-öğretimin kontrol ve doğrulama gibi karar alma süreçlerinde iyileşme, Zaman tasarrufu
Buenafío-Fernández ve ark (2019)	Performans/not tahmini	Bilgisayar mühendisliği öğrencileri, 335 öğrenci	Karar Ağacı	Öğrencilerin akademik performansında iyileşme, öğrenci devamsızlık oranlarının azaltılması
Çakır ve ark (2019)	Kişiselleştirilmiş eğitim	İlkokul öğrencileri, toplam 103 öğrenci	Deney ve kontrol gruplarından oluşan kontrollü deney tasarımı	Kişiselleştirilmiş eğitimin öğrenci motivasyonunu artırarak öğrencinin başarısını olumlu yönde etkilemesi
Duygu ve Arıcı (2019)	Performans/not tahmini	Üniversite öğrencileri, toplam 300 öğrenci	Karar Ağacı Algoritmaları (J48, DecisionStump, RepTree), Rastgele Orman Algoritmaları (Random Tree)	Rastgele orman algoritmaları ile daha yüksek başarı sağlanması, öğrenci başarısının çevresel faktörlerden etkilendiğinin tespiti
Hassan ve ark (2019)	Performans/not tahmini	Mühendislik öğrencileri, toplam 4413 öğrenci	Karar Ağacı, Yapay Sinir Ağı, Destek Vektör Makinesi, Rastgele Orman, Bagging, AdaBoost, Stacking, Majority Vote	Majority Vote topluluk sınıflandırıcısı ile en yüksek doğruluk değerinin elde edilmesi
Sekeroglu ve ark (2019)	Performans/not tahmini	Veri seti 1 (649 Portekizce dersi öğrencisi ve 395 Matematik dersi öğrencisi) Veri seti 2 (131 üniversite öğrencisi)	Destek Vektör Regresyonu, Backpropagation (BP), Long Short Term Memory Neural Network, Destek Vektör Makinesi, Gradient Boosting Classifier	Radyal temel fonksiyonlu sinir ağı modelinin öğrenci performans tahmini ve sınıflandırması için etkili yöntem olarak belirlenmesi
Sharma ve ark (2019)	Performans/not tahmini	Üniversite öğrencileri, 32 öğrenci	Karar Ağacı, Destek Vektör Makinesi, Gauss Süreç Regresyonu, Rastgele Orman	Öğrencilerin çaba gösterme davranışı ve performans tahmini için en belirleyici özellik kombinasyonlarının tespiti
Bhutto ve ark (2020)	Performans/not tahmini	İlkokul ve ortaokul öğrencileri, toplam 500 öğrenci	Lojistik Regresyon, Destek Vektör Makinesi	%78 ve %79,3 doğrulukla Lojistik Regresyon algoritmasının %71 ve %73,4 doğrulukla Destek Vektör Makinesine göre daha yüksek başarı göstermesi
Chen ve ark (2020)	Performans/not tahmini	Üniversite öğrencileri, 140 öğrenci	Hibritleştirilmiş Derin Sinir Ağı	Önerilen yöntemin diğer yöntemlere kıyasla daha iyi tahmin doğruluğu sağlaması

Çizelge 2.1. Sınıflandırılmış Önceki Çalışmalar Çizelgesi (devamı)

Çalışma	Konusu	Kullanılan veri seti	Kullanılan Algoritma/Önerilen Sistem	Sonuçlar
Cruz-Jesus ve ark (2020)	Performans/not tahmini	Lise öğrencileri, 110.627 öğrenci	Yapay Sinir Ağı, Karar Ağacı, Rastgele Orman, Destek Vektör Makinesi	Yapay zeka tekniklerinin istatistiksel yöntemlerden daha etkili olması
Deo ve ark (2020)	Performans/not tahmini	Mühendislik öğrencileri, EM dersi için 2088 öğrenci ve AEM dersi için 1457 öğrenci	Yapay Sinir Ağı, Rastgele Orman, Kural Tabanlı Öğrenici	Yapay sinir ağlarını içeren aşırı öğrenme makinesi modelinin en iyi tahmin performansını göstermesi
Gaobin ve ark (2020)	Öğretim kalitesinin iyileştirilmesi	Deney ve kontrol gruplarından oluşan 60 kişilik öğrenci grubu	Bulanık Kontrol Talimatları, Parçacık Sürüşü Optimizasyon Algoritması	Önerilen modelin beden eğitimi öğretiminin sağlamada belirli bir pratik etkiye sahip olması
Jani ve ark (2020)	Performans/not tahmini	Tıp öğrencileri, 121 transkript	Destek Vektör Makinesi, Koşullu Rastgele Alan, Çift Yönlü Uzun Kısa Süreli Bellek Sinir Ağı	Makine öğrenme algoritmalarının tıp öğrencilerinin klinik iletişim becerilerinin gelişmesinde etkili yöntemler olması
Kardaş ve Güvenir (2020)	Performans/not tahmini	Mühendislik öğrencileri, toplam 330 öğrenci	Lineer Regresyon, K-en Yakın Komşu, Lojistik Regresyon, Destek Vektör Makineleri, Çok Katmanlı Algılayıcı (MLP)	%81 doğruluk ile en yüksek performansın Lojistik Regresyon algoritmasıyla elde edilmesi, ödev notlarının dönem sonu sınav puanının belirlenmesinde en önemli faktör olarak tespiti
Li ve Su (2020)	Öğretim kalitesinin iyileştirilmesi	İlkokul öğrencileri	Ağırlıklı Entropi ve Gri Kümeleme Analizi	Yapay zeka bağlamında çevrimiçi eğitimin iyileştirilmesi
Rimi ve ark (2020)	Performans/not tahmini	Ortaokul, lise, üniversite öğrencileri, toplam 149 öğrenci	Karar Ağacı, Naive Bayes, Yapay Sinir Ağı, Destek Vektör Makinesi, K-en Yakın Komşu	Naive Bayes algoritması ile en yüksek doğruluk değerine ulaşılması
Rincón-Flores ve ark (2020)	Performans/not tahmini	Mühendislik öğrencileri, 134 öğrenci	K-en Yakın Komşu, Rastgele Orman	Kullanılan algoritmaların performans tahmininde iyi sonuç vermesi, makine öğrenme algoritmalarının etkili yöntemler olması
Xiao ve Yi (2020)	Öğretim kalitesinin iyileştirilmesi	Üniversite öğrencileri	Yapay Sinir Ağı Temelli Çoklu Değerlendirme Sistemi	Yapay zeka temelli çoklu değerlendirmenin diğer yöntemlere göre daha esnek, zeki ve otomatik olması
Aghalarova ve Bozkurt Keser (2021)	Performans/not tahmini	Ortaokul öğrencileri, toplam 1044 öğrenci	Yapay Sinir Ağı, Rastgele Arama Algoritması	Matematik dersi için %97 ve %92,3; Portekizce dersi için %97,6 ve %87,9 doğruluk değerlerinin elde edilmesi

Çizelge 2.1. Sınıflandırılmış Önceki Çalışmalar Çizelgesi (devamı)

Çalışma	Konusu	Kullanılan veri seti	Kullanılan Algoritma/Önerilen Sistem	Sonuçlar
Khan ve ark (2021)	Performans/not tahmini	Üniversite öğrencileri, 151 öğrenci	Karar Ağacı, K-en Yakın Komşu, Yapay Sinir Ağı, Naive Bayes	Karar ağacının en iyi tahmin başarısı gösteren algoritma olması, öğrencilerin akademik performansında iyileşme
Lee ve ark (2021)	Performans/not tahmini	Öğrenci öğrenme verileri, açık kaynaklı OpenGo tarafından sağlanan Go oyunu verileri, 5930-136.635 veri	Bulanık Sinir Ağı ve Patch Learning Mekanizmalı AFNA Modeli	Regresyon modeli performansının iyileştirilmesi, öğrencilerin okuma-anlama becerilerinin iyileştirilmesi
Ma ve ark (2021)	Öğretim kalitesinin iyileştirilmesi	Kontrol deneyi tasarımı, 50 öğrenci	Yapay Sinir Ağı ve Hibrit Parçacık Sürüşü Algoritması Temelli Öğretim Sistemi	Önerilen sistemin öğretim alanına uygulandığında öğrencilerin notlarının iyileşmesine katkı sağlayacağını öngörülmesi
Rai ve ark (2021)	Performans/not tahmini	Üniversite öğrencileri, toplam 831 öğrenci	Rastgele Orman Algoritması	Rastgele Orman algoritmasıyla Destek Vektör Makinesine göre %15 daha yüksek doğruluk elde edilmesi
Villegas-Ch. ve ark (2021)	Kişiselleştirilmiş eğitim	Üniversite öğrencileri, 18 öğrenci	Hadoop Çerçevesi Veri Analizi Modeli	Akademik performans üzerinde etkili faktörlerin tespit edilmesi, önerilen kişiselleştirilmiş öğrenci modeli ile öğrenmenin geliştirilmesi
Xiao ve Yi (2021)	Kişiselleştirilmiş eğitim	Üniversite öğrencileri, 3500 öğrenci	Özellik Seçimine Dayalı Yapay Sinir Ağı Temelli Model	Önerilen model ile %95 doğrulukla elverişli kişisel eğitim planı tasarlanması
Görmez ve ark (2022)	Kişiselleştirilmiş eğitim	Farklı sektörlerden toplam 164 kişi	K-en Yakın Komşu, Rastgele Orman, Yapay Sinir Ağı	%78,12 doğrulukla Rastgele Orman algoritmasıyla en yüksek başarının sağlanması, ilgi alanının doğru tespiti ile kişiselleştirilmiş içerikle dil öğrenme başarısının artırılması
Jokhan ve ark (2022)	Performans/not tahmini	Üniversite öğrencileri, 1523 öğrenci	Lojistik Regresyon, Destek Vektör Makinesi, Karar Ağacı, Sıralı Minimum Optimizasyon, Rastgele Orman	Rastgele Orman algoritmasının en iyi tahminleyici olması, %97,03 doğrulukla başarısızlık riski taşıyan öğrencilerin tahmin edilmesi
Kayalı ve Buyrukoğlu (2022)	Performans/not tahmini	Ortaokul öğrencileri, 1. veri seti 944 öğrenci ve 2. veri seti 722 öğrenci	Karar Ağacı, Rastgele Orman, Destek Vektör Makinesi	Rastgele Orman ve Destek Vektör Makinesi algoritmalarının öğrenci performans tahmininde etkili algoritmalar olması
Yavuzarslan ve Erol (2022)	Performans/not tahmini	Üniversite öğrencileri, toplam 93 öğrenci	K-en Yakın Komşu, Naive Bayes, Destek Vektör Makinesi, Sınıflandırma ve Regresyon Ağaçları (CART, C5.0)	Oluşturulan tüm veri setleri ile %80'nin üzerinde sınıflandırma tahmin başarısı sağlanması, %97 ile CART ve Destek Vektör Makinesiyle en yüksek tahmin başarısının elde edilmesi

Yapılan literatür araştırması neticesinde incelenen 40 çalışmanın 29'unun öğrenci performans ve not tahminine, 6'sının kişiselleştirilmiş eğitime ve 5'inin öğretim kalitesini iyileştirmeye yönelik yapıldığı sonucuna ulaşılmıştır. Bu noktada literatürde “eğitimde yapay zeka” konulu çalışmaların çoğunlukla öğrenci performans ve notunu tahmin etmeye yönelik olduğu söylenebilir. Kullanılan veri setinin çoğunlukla üniversite öğrencilerinden oluştuğu ve 100 civarında örneklem kullanıldığı söylenebilir. Karar ağacı ve rastgele orman algoritmalarının sıklıkla kullanıldığı ve en yüksek sınıflandırma tahmin başarılarının çoğunlukla bu algoritmalarla elde edildiği gözlenmiştir.

Yapılan bu çalışmada ise öncelikli amaç, bir ders bağlamında öğrenmenin tespit edilmesi yani ders aşamasında ve sonrasında ilgili derse ilişkin öğrenmenin gerçekleşip gerçekleşmediğinin yapay zeka teknikleriyle belirlenebilmesidir. Bu doğrultuda, yapılan literatür araştırmasında “eğitimde yapay zeka” konusunu benzer şekilde (öğrenmenin tespiti) ele alan bir çalışmaya rastlanmamıştır. Yapılan çalışmanın bu noktada literatüre önemli bir katkı sağlayacağı düşünülmektedir.

3. MATERYAL VE METOT

3.1. Materyal

Bu çalışmada öncelikli olarak bir dersin öğrenilme durumunu ders anında ve sonrasında tespit edecek yapay zeka temelli bir sistem önerilmesi amaçlanmıştır. Bu amaç doğrultusunda, matematiksel programlama ve optimizasyon için tasarlanmış bir yazılım olan GAMS (The General Algebraic Modeling System) ile ilgili bir ders seçilmiştir. Bu dersten öğrencilerin edinmesi beklenen kazanımlar ve dersin öğrenilmesinde etkin rol oynayan bazı faktörler dikkate alınarak ders videoları ve öğrenmeyi analiz etmeye yönelik sorular hazırlanmıştır. Ders videoları ve öğrenme analiz soruları çevrimiçi bir ortamda öğrencilere sunulmak amacıyla web tabanlı bir “E-Oğrenme Analiz Programı” tasarlanmıştır. Tasarlanan program mühendislik öğrencilerine isteğe bağlı katılım seçeneğiyle, etik prosedürlere uygun olarak sunulmuştur. Bu bağlamda 82 mühendislik öğrencisi araştırmanın örneklemini oluşturmaktadır. Katılımcılar programa internet ortamında bir link üzerinden tercih ettikleri herhangi bir zamanda erişim sağlayabilmiştir.

Yukarıda bahsedilen çerçevede ders videoları, öğrenme analiz soruları ve “E-Oğrenme Analiz Programı” bu çalışmanın materyallerini oluşturmaktadır.

Çizelge 3.1’de çalışma kapsamında oluşturulan öğrenme analiz soruları görülmektedir. Bu sorular bir dersin öğrenilmesini etkileyen 3 temel süreç (derse hazırlık, ders aşaması ve ders sonrası) baz alınarak hazırlanmıştır. Yapılan süreç analizi ve Çizelge 3.2’de verilen öğrenmenin kritik başarı faktörleri göz önüne alınarak GAMS optimizasyon yazılımına giriş dersinin öğrenme tespit soruları oluşturulmuştur.

Çizelge 3.1. Öğrenme Analiz Soruları

Derse Hazırlık Aşaması (ön sorular)	S1. Derse katılma nedeniniz?
	S2. Ders içeriği/planını incelediniz mi?
	S3. Derse katıldığınız ortam koşulları elverişli mi (stabil internet, sessizlik vb.)?
	S4. Dersin konusuna ilişkin (GAMS yazılımı) ön hazırlığınız var mı? (İnternetten araştırma vb.)
	S5. Matematiksel programlama yaklaşımları (doğrusal programlama, tamsayılı programlama vb.) hakkında bilgi sahibi misiniz?
Ders Aşaması (ara sorular)	S6. Video-1'de anlatılan konulara ilişkin GAMS sorusu
	S7. Video-2'de anlatılan konulara ilişkin GAMS sorusu
	S8. Video-3'de anlatılan konulara ilişkin GAMS sorusu
	S9. Video-4'de anlatılan konulara ilişkin GAMS sorusu
Ders Sonrası (son sorular ve gkod soruları)	S10. Hangisi sizin için en uygun? ("Sadece dinledim" ya da "Not alarak dinledim vb.")
	S11. "Dersi anlaşılır ve öğretici buldum." ifadesine katılma düzeyiniz?
	S12. GAMS kodlama sorusu-1
	S13. GAMS kodlama sorusu-2
	S14. GAMS kodlama sorusu-3

Çizelge 3.2. Kritik Başarı Faktörleri (KBF'ler) ve İlişkili Sorular

KBF'ler	Açıklaması	İlişkili Sorular
KBF1	Öğrencinin kendi öğrenme yollarına ilişkin farkındalığı	S10
KBF2	Dikkat/motivasyon/isteklilik	S1,S2,S3,S4,S5
KBF3	Bilginin anlaşılması	S6,S7,S8,S9
KBF4	Öğrencinin tepkisi/memnuniyeti	S11
KBF5	Dersin kazanımlarının sağlanması	S12,S13,S14

E-Öğrenme CU-EM Tez Çalışması Yazılımı

Adım 1

- 1 Uygulama Hakkında
- 2 Genel Sorular
- 3 Öğrenme Öncesi Sorular
- 4 E-Ders
- 5 E-Değerlendirme

Uygulama Hakkında

Online dersler, eğitim içeriğinin öğrenciye göre özelleştirilmesi konusunda fırsatlar yaratmaktadır. Çukurova Üniversitesi Endüstriyel Mühendisliği Anabilim Dalı Yüksek Lisans programında öğrenciler olan Betül ÇETİN'in tez çalışmasında (ya da gelecekte elde edilecek yayın, patent vb. tüm çıktıları) kullanılmak üzere bu çalışmada aşağıdaki uygulamalar gerçekleştirilecektir:

- Ders öncesi öğrenmeye hazırlığa ilişkin veriler,
- Ders öncesi ders konusuna ilişkin bilgi düzeyinin belirlenmesi,
- E-ders ile öğrenme deneyiminin sağlanması,
- E-ders sonrası öğrenme düzeyinin tespit edilmesi.

Çalışma süresi yaklaşık 30 dakika sürcek olup çalışmanın tamamını sonuçlanana kadar devam ettirmeniz kritik önem arz etmektedir.

☒ Verilerin işlenmesine ve 6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) uygulamaları kapsamında kişisel verilerin araştırma amaçları için kullanılmasına izin veriyorum.

[Sonraki Adım](#)

Şekil 3.1. Uygulama Hakkında Bilgilendirme

E-Öğrenme CU-EM Tez Çalışması Yazılımı

Adım 2

- 1 Uygulama Hakkında
- 2 Genel Sorular
- 3 Öğrenme Öncesi Sorular
- 4 E-Ders
- 5 E-Değerlendirme

Öğrenme Öncesi Genel Sorular

Öğrenme ortamına ilişkin aşağıdaki soruları cevaplayınız.

Dersle katılma nedeniniz?

[Ders Planı](#)

Ders içeriği/planını incelediniz mi?

Dersle katıldığınız ortam koşulları elverişli mi (stabil internet, sessizlik vb.)?

[Geri](#) [İleri](#)

Şekil 3.2. Öğrenme Öncesi Genel Sorular (S1,S2,S3)

E-Öğrenme CU-EM Tez Çalışması Yazılımı

Adım 3

- 1 Uygulama Hakkında
- 2 Genel Sorular
- 3 Öğrenme Öncesi Sorular
- 4 E-Ders
- 5 E-Değerlendirme

Öğrenme Öncesi Teknik Sorular


Dersle ilişkin aşağıdaki soruları cevaplayınız.

Dersin konusuna ilişkin (GAMS yazılımı) ön hazırlığınız var mı? (İnternette araştırma vb.)


Matematiksel programlama yaptığınız mı (doğrusal programlama, tamsayılı programlama vb.) hakkında bilgi sahibisiniz?

[Geri](#) [İleri](#)


Şekil 3.3. Öğrenme Öncesi Teknik Sorular (S4,S5)



Şekil 3.4. Ders Videosu 1




Şekil 3.5. Ders Videosu 1'in Konusuna Dair Ara Soru (S6)




Şekil 3.6. Ders Videosu 2



Şekil 3.7. Ders Videosu 2'nin Konusuna Dair Ara Soru (S7)



Şekil 3.8. Ders Videosu 3



Şekil 3.9. Ders Videosu 4

Şekil 3.10. Ders Sonrası Sorular (S10,S11)

Şekil 3.11. Ders Sonrası Teknik Soru (S14)

Hazırlanan ders videoları ve sorular geliştirilen “E-Oğrenme Analiz Programı” ile katılımcılara sunulmuştur. Şekil 3.1, Şekil 3.2, Şekil 3.3, Şekil 3.4, Şekil 3.5, Şekil 3.6, Şekil 3.7, Şekil 3.8, Şekil 3.9, Şekil 3.10 ve Şekil 3.11 programa ilişkin bölümleri göstermektedir.

Ders aşamasında öğrenmenin tespit edilmesine yönelik her bir ders videosu ile ilişkili olarak 4 ayrı ara soru hazırlanmıştır. “E-Oğrenme Analiz Programı” katılımcılara bu sorulardan rastgele en az bir en fazla 4 soruyu yöneltmektedir. Bu doğrultuda bir katılımcı örneği için oluşturulan Şekil 3.5 ve Şekil 3.7 sırasıyla S6 ve S7 sorularıyla eşleşmektedir.

Ders sonrası teknik soru bölümü için de hazırlanan 3 sorudan (S12,S13,S14) rastgele bir tanesi seçilerek sorulmaktadır. Bu durum bir katılımcı örneği için Şekil 3.11’de gösterilmiştir.

3.2. Metot

Bu çalışmada öncelikli olarak bir dersin öğrenilme durumunu ders anında ve sonrasında tespit edecek yapay zeka temelli bir sistem önerilmesi amaçlanmıştır. Bu ve benzeri amaçlar doğrultusunda çalışmanın yönteminde aşağıdaki adımlar izlenmiştir:

1. Öğrenme süreçleri analiz edilerek öğrenmeyi etkileyen kritik başarı faktörleri belirlenmiştir.
2. Bir ders seçilerek (GAMS optimizasyon yazılımına giriş) belirlenen faktörler doğrultusunda sorular hazırlanmıştır.
3. Seçilen derse ilişkin konu anlatım videosu oluşturulmuştur.
4. Sorular ve konu anlatım videosunun katılımcılara çevrimiçi olarak sunulabilmesi için bir veri toplama yazılımı (E-Öğrenme Analiz Programı) geliştirilmiştir.
5. Veri toplama yazılımı ile mühendislik öğrencilerinden etik prosedürlere uygun olarak veri toplanmıştır.
6. Toplanan veriler için uygun algoritmalar seçilerek dört farklı sınıflandırma modeli oluşturulmuştur.
7. Her bir model için algoritma sonuçları sınıflandırma başarısı metrikleriyle karşılaştırmalı olarak değerlendirilmiştir.

Çalışmada sınıflandırma algoritmalarıyla yapılan testler Python programlama dili ve ilgili makine öğrenmesi kütüphaneleri (Scikit-learn vb) kullanılarak Anaconda-Jupyter yazılım ortamında gerçekleştirilmiştir.

3.2.1. Veri Toplama Yazılımının Oluşturulması


Veri toplama yazılımı bir web servis olarak oluşturulmuştur. Bu kapsamda, Python yazılım dilinde Django kütüphaneleri kullanılarak geliştirme yapılmıştır. Programın ön yüz geliştirmeleri, HTML, JS ve CSS kullanılarak gerçekleştirilmiştir. Bu bağlamda, oluşturulan html formlarıyla birlikte eğitim öncesi, eğitim anında ve eğitim sonrasında sorular sorularak yanıt aranmaktadır. Veri tabanı altyapısında ise, PostgreSQL kullanılmıştır.

Veri toplama yazılımı geliştirilmesinde, en önemli konu tüm eğitim sürecinin kayıt altında alınmasıyla ilgilidir. Bu bağlamda, kullanıcının eğitime başlamak için onay kutusunu işaretlediği anda giriş anı kaydedilir ve uygulama içerisinde harcadığı süre kullanıcı gönder butonuna tıkladığında veri tabanına kaydedilir.

Eğitim öncesinde tüm kullanıcılara aynı sorular sorulur. Eğitim anında ise kullanıcı sisteme girdiğinde üretilen rastgele olasılıklara bağlı olarak eğitim anı değerlendirme soruları sorulur. Bu kapsamda, rastgele soru gösterme olasılığı %30 olarak belirlenmiştir. Eğitim sonrasında ise üç soru alternatifinden birisi eşit olasılıkla uniform rastgele olarak gösterilir.


Yazılım geliştirmede, ORM (Object Relational Mapping – Nesne İlişkisel Eşleme) kullanılmıştır. Sorular, izlenecek videolar, kullanıcılar (anonim) ve izleme kayıtları nesneler olarak tanımlanmış ve buna göre veri tabanı tabloları ve görüntüleme (view) kodları oluşturulmuştur.

3.2.2. Oluşturulan Modeller




Şekil 3.12. Model 1 Bileşenleri

Şekil 3.12’de Model 1’in girdi, çıktı ve kullanılan algoritmalar bileşenleri görülmektedir. Modelin girdi bileşenlerini Tablo 3.1’de verilen ders aşamasında sorulan ara sorular ve katılımcının sistemde kalma süresi oluşturmaktadır. Çıktı bileşeni ise dinlediğini öğrenme olarak belirlenmiştir. Her katılımcıya ilgili sorulardan rastgele şekilde en az 1 en fazla 4 soru yöneltmiştir. Sorulara verilen doğru cevaplara ve sistemde kalma süresine göre katılımcının dinlediğini öğrenip öğrenemediği verilen algoritmalar (Decision Tree, Random Forest, XGBoost, MLP) aracılığıyla tespit edilmek istenmiştir.




Şekil 3.13. Model 2 Bileşenleri

Şekil 3.13'te Model 2'nin girdi, çıktı ve kullanılan algoritmalar bileşenleri görülmektedir. Modelin girdi bileşenlerini Tablo 3.1'de verilen ders sonrası gkod soruları (GAMS kodlama soruları) ve katılımcının sistemde kalma süresi oluşturmaktadır. Çıktı bileşeni ise GAMS skoru olarak belirlenmiştir. Her katılımcıya gkod sorularından rastgele olarak seçilen bir soru yöneltilmiştir. Seçilen soruya verilen doğru cevap ve sistemde kalma süresine göre katılımcının "GAMS skoru" yani verilen bir matematiksel modelin GAMS yazılımı ile kodlanmasının öğrenilip öğrenilmediği belirtilen algoritmalar (Decision Tree, Random Forest, XGBoost, MLP) aracılığıyla tespit edilmek istenmiştir.



Şekil 3.14. Model 3 Bileşenleri

Şekil 3.14'te Model 3'ün girdi, çıktı ve kullanılan algoritmalar bileşenleri görülmektedir. Modelin girdi bileşenlerini Tablo 3.1'de verilen 14 soru ve katılımcının sistemde kalma süresi oluşturmaktadır. Çıktı bileşeni ise dinlediğini öğrenme olarak belirlenmiştir. Sorulara verilen cevaplara ve sistemde kalma süresine göre katılımcının dinlediğini öğrenip öğrenemediği verilen algoritmalar (Decision Tree, Random Forest, XGBoost, MLP) aracılığıyla tespit edilmek istenmiştir.




Şekil 3.15. Model 4 Bileşenleri

Şekil 3.15'te Model 2'nin girdi, çıktı ve kullanılan algoritmalar bileşenleri görülmektedir. Modelin girdi bileşenlerini Tablo 3.1'de verilen 14 soru ve katılımcının sistemde kalma süresi oluşturmaktadır. Çıktı bileşeni ise GAMS skoru olarak belirlenmiştir. Sorulara verilen cevaplara ve sistemde kalma süresine göre katılımcının “GAMS skoru” yani verilen bir matematiksel modelin GAMS yazılımı ile kodlanmasının öğrenilip öğrenilmediği belirtilen algoritmalar (Decision Tree, Random Forest, XGBoost, MLP) aracılığıyla tespit edilmek istenmiştir.

3.2.3. Sınıflandırma Algoritmaları

Decision Tree Algoritması:


Decision Tree (Karar Ağacı) algoritmaları, seçimleri ve sonuçlarını bir ağaç şeklinde gösteren denetimli makine öğrenim yöntemidir (Mahesh, 2020). Karar ağacı algoritmaları veri analitiğinin hem regresyon hem sınıflandırma modelleri ile kullanılabilir (Navada ve ark, 2011).




Şekil 3.16. Karar Ağacı Yapısı (Jijo ve Abdulazeez, 2021)

Bir karar ağacının kök düğüm, karar düğümü ve yaprak düğümlerden oluşan basit yapısı Şekil 3.16’da görülmektedir.

Bir karar ağacı algoritması, ağacın iç düğümlerinin bağımsız değişkenleri içerdiği ve yaprakların olası hedef sınıflara karşılık geldiği ağaç yapısı şeklinde bir sınıflandırma modeli oluşturur. Her iç düğüm değişkenin alabileceği olası değerlere karşılık gelen birkaç dal içerir. Bir karar ağacının oluşturulması her yinelemede bir değişkenin ağaç yapısına katılmak için seçildiği yinelemeli bir sürece dayanır. Böylece ağacın kökündeki değişken en iyi tahmin ediciye karşılık gelir. Karar ağaçları basit bir “if-then-else” kuralı ile çalışır. Bağımsız değişkenlerin ağaçtaki konumu ilgili değişkenin sınıflandırma görevindeki önemini gösterir (Cruz-Jesus ve ark, 2020).



Şekil 3.17. CART Tarafından Oluşturulan Karar Ağacı (Janikow,1998)



Şekil 3.18. ID3 Tarafından Oluşturulan Karar Ağacı (Janikow, 1998)


Karar ağacı algoritmasının düğümlerin yalnızca iki sınıfa dallanabildiği CART (Sınıflandırma ve Regresyon Ağacı) algoritması ve ikiden fazla sınıfa ayrılabilen ID3 (Entropi temelli karar ağacı) gibi algoritma türleri bulunmaktadır

(Géron, 2019). Bu algoritmalar tarafından oluşturulan karar ağacı yapıları Şekil 3.17 ve Şekil 3.18’de görülmektedir. Şekil 3.17’de ağırlık ve yükseklik düğümleri yalnızca 2 ayrı sınıfa dallanırken; Şekil 3.18’de renk ve ağırlık düğümlerinin kırmızı/yeşil/mavi ve küçük/orta/büyük olarak 3 ayrı sınıfa dallanabildiği görülmektedir.

Karar ağacının en önemli avantajı anlama ve yorumlama kolaylığı sağlamasıdır (Khan ve ark, 2021).

Random Forest Algoritması:

Random Forest (Rastgele Orman) algoritmaları, bir dizi ağaç yapısı sınıflandırıcısının birleşimi olan hem sınıflandırma hem de regresyon modellerinde kullanılan denetimli bir makine öğrenim yöntemidir (Liu ve ark, 2012).



Şekil 3.19. Rastgele Orman Algoritması Genel Yapısı (Liu ve ark, 2012)

Rastgele orman algoritmasının genel yapısı Şekil 3.19’da gösterilmektedir. Buna göre gerçek bir T eğitim setinden rastgele seçilerek oluşturulan karar ağaçları ile farklı puan değerleri hesaplanarak en yüksek puanlı değer hedef değişken olarak seçilir.

Rastgele orman algoritmaları, her biri problemin bağımsız değişkenlerinden rastgele seçilen bir alt kümeyi dikkate alan farklı karar ağaçları oluşturur. Bu sayede verilen problemin farklı yönlerini modelleyebilen farklı


yapılara sahip karar ağaçları elde edilir. Bu karar ağaçları içerisinde en yüksek puanlı değer hedef değişken olarak seçilir. Bu yöntem hedef değişkenin daha iyi bir tahminine ulaşılabilmesi açısından elverişlidir. Bu nedenle rastgele orman algoritmasının diğer yöntemlere göre temel avantajlarından biri aşırı uyumu önleme veya azaltma yeteneğidir (Cruz-Jesus ve ark, 2020).

XGBoost Algoritması:

XGBoost (Extreme Gradient Boosting-Aşırı Gradyan Arttırma), ağaç güçlendirme (tree boosting) için ölçeklendirilebilir bir karar ağacı algoritmasıdır (Chen ve Guestrin, 2016).

Gradyan güçlendirme kavramı temel olarak üç aşamadan oluşur. İlk aşamada verilen problem için uygun bir türevlenebilir kayıp fonksiyon belirlenir. İkinci aşamada tahminleri yapmak için zayıf bir öğrenici oluşturulur. Gradyan güçlendirmede bu zayıf öğrenici bir karar ağacıdır. Ağaçlar belirli kısıtlamalar getirilerek açgözlü bir yaklaşımla oluşturulur. Son aşamada ise, kayıp fonksiyon değerini azaltmak için zayıf öğrenici tahminlerini toplayan bir toplama modeli oluşturulur. Ağaçları ekleme işlemi teker teker gerçekleştirilir. Yeni ağaçta üretilen çıktı modelin nihai çıktısını iyileştirmek için önceden üretilen ağaç dizisinin çıktısına eklenir. Bu işlem kayıp fonksiyon için optimum değere ulaşıldığında durur. XGBoost algoritması özünde gradyan güçlendirmeye sahiptir. Ancak gradyan güçlendirmeden farklı olarak zayıf öğrenicilerin eklenmesi işlemi ardışık olarak gerçekleştirilmez. XGBoost daha yüksek hız ve performans sağlayan çok iş parçacıklı bir yaklaşıma sahiptir (Santhanam ve ark, 2016).

XGBoost algoritması bazı yönleriyle gradyan güçlendirme algoritmalarından farklıdır. Bunlardan biri gradyan güçlendirme algoritması yalnızca birinci dereceden Taylor açılımını kullanırken XGBoost algoritmasının kayıp fonksiyonuna ikinci dereceden bir Taylor açılımı eklemesidir. Diğeri ise XGBoost algoritmasının aşırı uyumu (overfitting) önlemek ve model karmaşıklığını azaltmak için amaç fonksiyonunda normalleştirme kullanmasıdır (Song ve ark, 2020).




Şekil 3.20. XGBoost Algoritmasının Genel Yapısı (Song ve ark, 2020)

XGBoost algoritmasının genel yapısı Song ve ark (2020) çalışmalarında yer alan 27 özelliğe göre çekme kuvveti ve plastisite tahmini yapan bir model örneği üzerinde açıklanmıştır. Bu örnek yapı Şekil 3.20’de görülmektedir.

XGBoost algoritmasının ölçeklenebilirliği birkaç önemli sistem ve algoritmik optimizasyondan kaynaklanır. Algoritma bu sayede, tek bir makinede mevcut yöntemlerden on kat daha hızlı çalışır ve dağıtılmış veya sınırlı bellek ayarlarında milyarlarca örneğe ölçeklenir. Paralel ve dağıtılmış hesaplama öğrenmeyi daha hızlı hale getirerek daha hızlı model keşfine olanak tanır. XGBoost algoritmasının başarısının ardındaki en önemli faktör tüm senaryolarda ölçeklenebilirliğidir (Chen ve Guestrin, 2016).

MLP Algoritması:

MLP (Multi Layer Perceptron-Çok Katmanlı Algılayıcı) algoritmaları, bir gizli katmandan oluşan ileri beslemeli yapay sinir ağı modelidir. Katmanların her birinde bir dizi nöron vardır. Giriş vektörü yalnızca giriş katmanı nöronları için geçerlidir; ancak katmanların diğer nöronları için önceki katman nöronlarının çıktıları uygulanır. Girdi ve çıktı katmanlarındaki nöron sayısı problemin girdi ve çıktı sayısına bağlıdır. Yapay sinir ağlarının temel özelliği girdi ve çıktı vektörleri arasındaki karmaşık ilişkileri öğrenme yeteneğidir. Bu mekanizmaya göre sinir ağının farklı bağlantıları için ağırlık ve sapmalar değiştirilerek istenen çıktılar elde edilir. Bu noktada girdi ağı uygulanarak ağın çıktısı istenen çıktı değeri ile karşılaştırılır, istenen girdi ve çıktı örnekleri mevcutsa ağın ağırlık ve sapmaları aralarındaki fark olacak şekilde değiştirilir. Bu şekilde çıktı kabul edilebilir bir seviyeye ulaştırılmaya çalışılır (Askari ve Keynia, 2020).



Şekil 3.21. MLP Algoritması Genel Yapısı (Ting ve Sim, 2017)

MLP algoritmasının genel yapısı Şekil 3.21’de görülmektedir. Buna göre, MLP algoritması girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Her katmanda algılayıcı olarak adlandırılan nöronları içerir. Girdi katmanındaki nöron ağırlıklarına göre ve doğrusal olmayan aktivasyon fonksiyonunu kullanarak çıktı üretir (Ting ve Sim, 2017).

3.2.4. Sınıflandırma Algoritmaları Başarısını Değerlendirme Metrikleri

Sınıflandırma algoritmalarının başarılarını değerlendirmede accuracy (doğruluk), precision (kesinlik), recall (duyarlılık) ve F1-Score (kesinlik-duyarlılık) gibi metrikler kullanılır (Khan ve ark, 2021).

Accuracy: Algoritmanın test verisi içerisinde doğru tahmin ettiği örnek sayısının test veri setindeki tüm örnek sayısına bölünmesiyle elde edilen değerdir (Yavuzarslan ve Erol, 2022).

Precision: Algoritmanın pozitif sınıfa ait yaptığı tahminlerin doğruluğunu gösterir. Algoritmanın doğru tahmin ettiği pozitif sınıfa ait örnek sayısının pozitif olarak sınıflandırdığı tüm örnek sayısına oranıdır (Géron, 2019).


Recall: Algoritmanın pozitif ya da negatif sınıfa ait örnekleri doğru sınıflandırma duyarlılığını gösterir. Algoritmanın ilgili sınıfa ait doğru olarak sınıflandırdığı örnek sayısının o sınıfa ait tüm örnek sayısına oranıdır (Yavuzarslan ve Erol, 2022).

F1-Score: Precision (kesinlik) ve recall (duyarlılık) değerlerinin harmonik ortalamasıdır (Géron, 2019).

4. BULGULAR VE TARTIŞMA


4.1. Katılımcı İstatistikleri

Katılımcıların Tablo 3.1’de verilen öğrenme analiz sorularına verdikleri cevaplar, sistemde kalma süreleri ve öğrenme durumlarına ilişkin istatistiksel bilgiler grafiksel olarak sunulmuş ve açıklanmıştır.




Şekil 4.1. S1 İçin Katılımcı Cevapları

Şekil 4.1’de katılımcıların Tablo 3.1’de S1 koduyla verilen “Derse katılma nedeniniz?” sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 33’ü dersin konusuna ilişkin merak duyduğunu ve eğitimine olumlu yönde katkı sağlayacağına inandığını belirtirken; 49’u sadece deneyimlemek istediğini ifade etmiştir. Bu soru Tablo 3.2’de verilen “dikkat/motivasyon/isteklilik” (KBF2) faktörünün öğrenme üzerindeki etkisi düşünülmüş ve hazırlanmıştır.




Şekil 4.2. S2 İçin Katılımcı Cevapları

Şekil 4.2’de katılımcıların Tablo 3.1’de S2 koduyla verilen “Ders içeriği/planını incelediniz mi?” sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 43’ü ders içeriğini incelerken, 39’u içeriği incelememiştir. Bu soru Tablo 3.2’de verilen “dikkat/motivasyon/isteklilik” (KBF2) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.




Şekil 4.3. S3 İçin Katılımcı Cevapları

Şekil 4.3’te katılımcıların Tablo 3.1’de S3 koduyla verilen “Derse katıldığınız ortam koşulları elverişli mi (stabil internet, sessizlik vb.)?” sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 70’i elverişli bir ortamda derse katıldığını belirtirken 12’si elverişsiz ortam koşullarında derse katıldığını ifade etmiştir. Bu soru Tablo 3.2’de verilen “dikkat/motivasyon/isteklilik” (KBF2) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.



Şekil 4.4. S4 İçin Katılımcı Cevapları


Şekil 4.4'te katılımcıların Tablo 3.1'de S4 koduyla verilen “Dersin konusuna ilişkin (GAMS yazılımı) ön hazırlığınız var mı? (İnternette araştırma vb.)” sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 32’si evet, 50’si hayır cevabı vermiştir. Bu soru Tablo 3.2’de verilen “dikkat/motivasyon/isteklilik” (KBF2) faktörünün öğrenme üzerindeki etkisi düşünüülerek hazırlanmıştır.



Şekil 4.5. S5 İçin Katılımcı Cevapları


Şekil 4.5’te katılımcıların Tablo 3.1’de S5 koduyla verilen “Matematiksel programlama yaklaşımları (doğrusal programlama, tamsayılı programlama vb.) hakkında bilgi sahibi misiniz?” sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 51’i bilgisi olduğunu belirtirken 31’i konuya ilişkin bilgi sahibi olmadığını ifade etmiştir. Bu soru Tablo 3.2’de verilen

“dikkat/motivasyon/isteklilik” (KBF2) faktörünün öğrenme üzerindeki etkisi düşünülmüş ve hazırlanmıştır.



Şekil 4.6. S6 İçin Katılımcı Cevapları


Şekil 4.6’da katılımcıların Tablo 3.1’de S6 koduyla verilen “Video-1’de anlatılan konulara ilişkin GAMS sorusu” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu yönelttiği 80 katılımcıdan 24’ü ilgili soruya doğru cevap verirken 56’sı soruyu yanlış cevaplamıştır. Bu soru Tablo 3.2’de verilen “bilginin anlaşılması” (KBF3) faktörünün öğrenme üzerindeki etkisi düşünülmüş ve hazırlanmıştır.



Şekil 4.7. S7 İçin Katılımcı Cevapları


Şekil 4.7’de katılımcıların Tablo 3.1’de S7 koduyla verilen “Video-2’de anlatılan konulara ilişkin GAMS sorusu” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu

yönelttiği 38 katılımcıdan 10'u ilgili soruya doğru cevap verirken 28'i soruyu yanlış cevaplamıştır. Bu soru Tablo 3.2'de verilen “bilginin anlaşılması” (KBF3) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.




Şekil 4.8. S8 İçin Katılımcı Cevapları

Şekil 4.8'de katılımcıların Tablo 3.1'de S8 koduyla verilen “Video-3'de anlatılan konulara ilişkin GAMS sorusu” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu yönettği 43 katılımcıdan 13'ü ilgili soruya doğru cevap verirken 30'u soruyu yanlış cevaplamıştır. Bu soru Tablo 3.2'de verilen “bilginin anlaşılması” (KBF3) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.




Şekil 4.9. S9 İçin Katılımcı Cevapları

Şekil 4.9’da katılımcıların Tablo 3.1’de S9 koduyla verilen “Video-4’te anlatılan konulara ilişkin GAMS sorusu” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu yönelttiği 39 katılımcıdan 14’ü ilgili soruya doğru cevap verirken 25’i soruyu yanlış cevaplamıştır. Bu soru Tablo 3.2’de verilen “bilginin anlaşılması” (KBF3) faktörünün öğrenme üzerindeki etkisi düşünüülerek hazırlanmıştır.




Şekil 4.10. S10 İçin Katılımcı Cevapları

Şekil 4.10’da katılımcıların Tablo 3.1’de S10 koduyla verilen “Hangisi sizin için en uygun? ("Sadece dinledim" ya da "Not alarak dinledim vb")” sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 21’i dersi daha etkili ve hızlı öğrenmesini sağlayacak tekniklerle (not alma vb) dinlediğini belirtirken 61’i sadece dinlediğini ifade etmiştir. Bu soru Tablo 3.2’de verilen “öğrencinin kendi öğrenme yollarına ilişkin farkındalığı” (KBF1) faktörünün öğrenme üzerindeki etkisi düşünüülerek hazırlanmıştır.



Şekil 4.11. Ders İçin Katılımcı Memnuniyet Düzeyleri


Şekil 4.11’de katılımcıların Tablo 3.1’de S11 koduyla verilen “"Dersi anlaşılır ve öğretici buldum." ifadesine katılma düzeyiniz?" sorusuna verdikleri cevap dağılımları görülmektedir. Buna göre, 82 katılımcıdan 29’u kesinlikle katıldığını, 36’sı katıldığını, 13’ü kararsız olduğunu, 2’si katılmadığını ve 2’si kesinlikle katılmadığını ifade etmiştir. Bu soru Tablo 3.2’de verilen “öğrencinin tepkisi/memnuniyeti” (KBF4) faktörünün öğrenme üzerindeki etkisi düşünülmüş olarak hazırlanmıştır.



Şekil 4.12. S12 İçin Katılımcı Cevapları


Şekil 4.12’de katılımcıların Tablo 3.1’de S12 koduyla verilen “GAMS kodlama sorusu-1” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu yönelttiği 32 katılımcıdan 6’sı soruya doğru cevap verirken 26’sı soruyu yanlış cevaplamıştır.

Bu soru Tablo 3.2’de verilen “dersin kazanımlarının sağlanması” (KBF5) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.



Şekil 4.13. S13 İçin Katılımcı Cevapları


Şekil 4.13’te katılımcıların Tablo 3.1’de S13 koduyla verilen “GAMS kodlama sorusu-2” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu yönelttiği 25 katılımcıdan 2’si soruya doğru cevap verirken 23’ü soruyu yanlış cevaplamıştır. Bu soru Tablo 3.2’de verilen “dersin kazanımlarının sağlanması” (KBF5) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.



Şekil 4.14. S14 İçin Katılımcı Cevapları


Şekil 4.14’te katılımcıların Tablo 3.1’de S14 koduyla verilen “GAMS kodlama sorusu-3” tanımlı soruyu doğru ya da yanlış cevaplama dağılımları görülmektedir. Buna göre, veri toplama yazılımının soruyu yönelttiği 25

katılımcıdan 4'ü soruyu doğru cevaplarken 21'i soruyu yanlış cevaplamıştır. Bu soru Tablo 3.2'de verilen “dersin kazanımlarının sağlanması” (KBF5) faktörünün öğrenme üzerindeki etkisi düşünülerek hazırlanmıştır.




Şekil 4.15. Katılımcıların Sistemde Kalma Süreleri

Şekil 4.15'te katılımcıların sistemde kalma süreleri görülmektedir. Grafiğe göre katılımcıların çoğunlukla yaklaşık ortalama 1800 saniye sistemde bulundukları söylenebilir. Ortalama sistemde kalma süresi yaklaşık 1800 saniye olarak belirlendiğinden katılımcıların çoğunun ders videolarını tamamen izlediği söylenebilir.




Şekil 4.16. Katılımcıların Dinlediğini Öğrenme Durumu

Şekil 4.16’da katılımcıların dinlediğini öğrenme durumları görülmektedir. Dinlediğini öğrenme durumu, Tablo 3.1’de “S6, S7, S8, S9” kodlu olarak ifade edilen ders videoları arasında sorulan sorulara verilen doğru cevaplama durumuna göre değerlendirilmiştir. Bu doğrultuda kendisine yöneltilen soruların en az %50’sine doğru cevap veren katılımcılar başarılı olarak belirlenmiştir. Buna göre, 82 katılımcıdan 28’inin dinlediğini öğrenme alanında başarılı olduğu ve 54’ünün başarısız olduğu Şekil 4.16’da görülmektedir.




Şekil 4.17. Katılımcıların Dinlediğini Öğrenme Yüzdeleri

Şekil 4.17’de katılımcıların dinlediğini öğrenme yüzdeleri görülmektedir. Buna göre, 82 katılımcının %34’ünün dinlediğini öğrenme alanında başarılı olduğu söylenebilir.



Şekil 4.18. Katılımcıların GAMS Kodlama Öğrenme Durumu

Şekil 4.18’de katılımcıların GAMS kodlamasını öğrenme durumları görülmektedir. GAMS kodlamasını öğrenme durumu, Tablo 3.1’de “S12, S13, S14” kodlu olarak verilen ders videoları sonrası gkod sorularını doğru cevaplama durumuna göre değerlendirilmiştir. Bu doğrultuda her katılımcıya bu üç sorudan biri sorulmuştur ve bu soruyu doğru cevaplama durumuna göre öğrenme değerlendirmesi yapılmıştır. Boş ve yanlış cevaplar “başarısız”, doğru cevaplar “başarılı” şeklinde değerlendirilmiştir. Buna göre, 82 katılımcıdan 12’sinin GAMS kodlamasını öğrenme alanında başarılı olduğu ve 70’inin başarısız olduğu Şekil 4.18’de görülmektedir.



Şekil 4.19. Katılımcıların GAMS Kodlama Öğrenme Yüzdeleri


Şekil 4.19’da katılımcıların GAMS kodlamasını öğrenme yüzdeleri görülmektedir. Buna göre, 82 katılımcının %15’inin GAMS kodlamasını öğrenme alanında başarılı olduğu söylenebilir.

4.2. Algoritma Tahminleri

Yapılan çalışmanın örneklemini 82 mühendislik öğrencisi oluşturmakta olup örneklemin % 33’ü (28 katılımcı verisi) algoritmaların test aşamasında, kalanı ise algoritmaların eğitim aşamasında kullanılmıştır. Aşağıda çalışma kapsamında oluşturulmuş olan 4 farklı model için seçilen algoritmaların her biri ile ulaşılan sonuçlar test performans grafiği, karışıklık matrisi tablosu ve ilgili açıklamalar şeklinde sunulmuştur. Bu çalışmada, test performans grafikleri ve

karişıklık matrisi tablolarında yer alan 0 sınıfı “öğrenme gerçekleşmedi” ve 1 sınıfı “öğrenme gerçekleşti” şeklinde tanımlıdır.

4.2.1. Model 1 İçin Algoritma Tahminleri




Şekil 4.20. Model 1 İçin Decision Tree Algoritması Test Performansı

Şekil 4.20’de Model 1 için Decision Tree algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 5’inde sapma olduğu söylenebilir.

Çizelge 4.1. Model 1 İçin Decision Tree Algoritması Karişıklık Matrisi

[[16 1]					
[4 7]]					
		precision	recall	f1- score	support
	0	0.80	0.94	0.86	17
	1	0.88	0.64	0.74	11
	accuracy			0.82	28
	macro avg	0.84	0.79	0.80	28
	weighted avg	0.83	0.82	0.81	28

Çizelge 4.1’de Model 1 için Decision Tree algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 17 test verisinin 16’sını doğru ve 1’ini yanlış sınıflandırmıştır. 1 sınıfına ait 11 test verisinin 7’sini doğru ve 4’ünü yanlış sınıflandırmıştır. Buna göre; Model 1 için Decision Tree algoritması accuracy (doğruluk) değeri 0.82, precision (kesinlik) değeri 0.83, recall (duyarlılık) değeri 0.82, f1-score değeri 0.81 olarak hesaplanmıştır. Decision Tree algoritmasının Model 1’in 5 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.82; kesinlik-duyarlılık (f1-score) başarısı ise 0.81’dir. Bu değerler 1’e yakın olarak gözlendiğinden Decision Tree algoritmasının Model 1 veri seti için başarılı bir tahmin edici olduğu söylenebilir.




Şekil 4.21. Model 1 İçin Random Forest Algoritması Test Performansı

Şekil 4.21’de Model 1 için Random Forest algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 6’sında sapma olduğu söylenebilir.

Çizelge 4.2. Model 1 İçin Random Forest Algoritması Karışıklık Matrisi

[[16 1]					
[5 6]]					
		precision	recall	f1- score	support
	0	0.76	0.94	0.84	17
	1	0.86	0.55	0.67	11
	accuracy			0.79	28
	macro avg	0.81	0.74	0.75	28
	weighted avg	0.80	0.79	0.77	28

Çizelge 4.2’de Model 1 için Random Forest algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 17 test verisinin 16’sını doğru ve 1’ini yanlış sınıflandırmıştır. 1 sınıfına ait 11 test verisinin 6’sını doğru ve 5’ini yanlış sınıflandırmıştır. Buna göre; Model 1 için Random Forest algoritması accuracy (doğruluk) değeri 0.79, precision (kesinlik) değeri 0.80, recall (duyarlılık) değeri 0.79, f1-score değeri ise 0.77 olarak hesaplanmıştır. Random Forest algoritmasının Model 1’in 5 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.79; kesinlik-duyarlılık (f1-score) başarısı ise 0.77’dir. Bu değerler 1’e yakın olarak gözlemlendiğinden Random Forest algoritmasının Model 1 veri seti için başarılı bir tahmin edici olduğu söylenebilir.



Şekil 4.22. Model 1 İçin XGBoost Algoritması Test Performansı


Şekil 4.22’de Model 1 için XGBoost algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 6’sında sapma olduğu söylenebilir.

Çizelge 4.3. Model 1 İçin XGBoost Algoritması Karışıklık Matrisi

[[14 3]					
[3 8]]					
		precision	recall	f1- score	support
	0	0.82	0.82	0.82	17
	1	0.73	0.73	0.73	11
	accuracy			0.79	28
	macro avg	0.78	0.78	0.78	28
	weighted avg	0.79	0.79	0.79	28

Çizelge 4.3’te Model 1 için XGBoost algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 17 test verisinin 14’ünü doğru ve 3’ünü yanlış sınıflandırmıştır. 1 sınıfına ait 11 test verisinin 8’ini doğru ve 3’ünü yanlış sınıflandırmıştır. Buna göre; Model 1 için XGBoost algoritması accuracy

(doğruluk) değeri 0.79, precision (kesinlik) değeri 0.79, recall (duyarlılık) değeri 0.79, f1-score değeri 0.79 olarak hesaplanmıştır. XGBoost algoritmasının Model 1'in 5 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) ve kesinlik-duyarlılık (f1-score) başarısı 0.79'dur. Bu değerler 1'e yakın olarak gözlemlendiğinden XGBoost algoritmasının Model 1 veri seti için başarılı bir tahmin edici olduğu söylenebilir.



Şekil 4.23. Model 1 İçin MLP Algoritması Test Performansı


Şekil 4.23'te Model 1 için MLP algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 12'sinde sapma olduğu söylenebilir.

Çizelge 4.4. Model 1 İçin MLP Algoritması Karışıklık Matrisi

[[15 2]					
[10 1]]					
		precision	recall	f1- score	support
	0	0.60	0.88	0.71	17
	1	0.33	0.09	0.14	11
	accuracy			0.57	28
	macro avg	0.47	0.49	0.43	28
	weighted avg	0.50	0.57	0.49	28

Çizelge 4.4'te Model 1 için MLP algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 17 test verisinin 15'ini doğru ve 2'sini yanlış sınıflandırmıştır. 1 sınıfına ait 11 test verisinin 1'ini doğru ve 10'unu yanlış sınıflandırmıştır. Buna göre; Model 1 için MLP algoritması accuracy (doğruluk) değeri 0.57, precision (kesinlik) değeri 0.50, recall (duyarlılık) değeri 0.57, f1-score değeri ise 0.49 olarak hesaplanmıştır. MLP algoritmasının Model 1'in 5 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.57; kesinlik-duyarlılık (f1-score) başarısı ise 0.49'dur. Bu değerlere göre MLP algoritmasının Model 1 veri seti için başarılı bir tahmin edici olmadığı söylenebilir.

4.2.2. Model 2 İçin Algoritma Tahminleri




Şekil. 4.24. Model 2 İçin Decision Tree Algoritması Test Performansı

Şekil 4.24'te Model 2 için Decision Tree algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 2'sinde sapma olduğu söylenebilir.

Çizelge 4.5. Model 2 Decision Tree Algoritması Karışıklık Matrisi

[[23 0]					
[2 3]]					
		precision	recall	f1- score	support
	0	0.92	1.00	0.96	23
	1	1.00	0.60	0.75	5
	accuracy			0.93	28
	macro avg	0.96	0.80	0.85	28
	weighted avg	0.93	0.93	0.92	28

Çizelge 4.5'te Model 2 için Decision Tree algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 23 test verisinin tamamını doğru sınıflandırmıştır. 1 sınıfına ait 5 test verisinin 3'ünü doğru ve 2'sini yanlış sınıflandırmıştır. Buna göre; Model 2 için Decision Tree algoritması accuracy (doğruluk) değeri 0.93, precision (kesinlik) değeri 0.93, recall (duyarlılık) değeri 0.93, f1-score değeri 0.92 olarak hesaplanmıştır. Decision Tree algoritmasının Model 2'nin 4 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.93; kesinlik-duyarlılık (f1-score) başarısı ise 0.92'dir. Bu değerler 1'e yakın olarak gözlendiğinden Decision Tree algoritmasının Model 2 veri seti için başarılı bir tahmin edici olduğu söylenebilir.




Şekil 4.25. Model 2 İçin Random Forest Algoritması Test Performansı

Şekil 4.25'te Model 2 için Random Forest algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 3'ünde sapma olduğu söylenebilir.

Çizelge 4.6. Model 2 İçin Random Forest Algoritması Karışıklık Matrisi

[[22 1]					
[2 3]]					
		precision	recall	f1- score	support
	0	0.92	0.96	0.94	23
	1	0.75	0.60	0.67	5
	accuracy			0.89	28
	macro avg	0.83	0.78	0.80	28
	weighted avg	0.89	0.89	0.89	28

Çizelge 4.6’da Model 2 için Random Forest algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 23 test verisinin 22’sini doğru ve 1’ini yanlış sınıflandırmıştır. 1 sınıfına ait 5 test verisinin 3’ünü doğru ve 2’sini yanlış sınıflandırmıştır. Buna göre; Model 2 için Random Forest algoritması accuracy (doğruluk) değeri 0.89, precision (kesinlik) değeri 0.89, recall (duyarlılık) değeri 0.89, f1-score değeri 0.89 olarak hesaplanmıştır. Random Forest algoritmasının Model 2’nin 4 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) ve kesinlik-duyarlılık (f1-score) başarısı 0.89’dur. Bu değerler 1’e yakın olarak gözlendiğinden Random Forest algoritmasının Model 2 veri seti için başarılı bir tahmin edici olduğu söylenebilir.



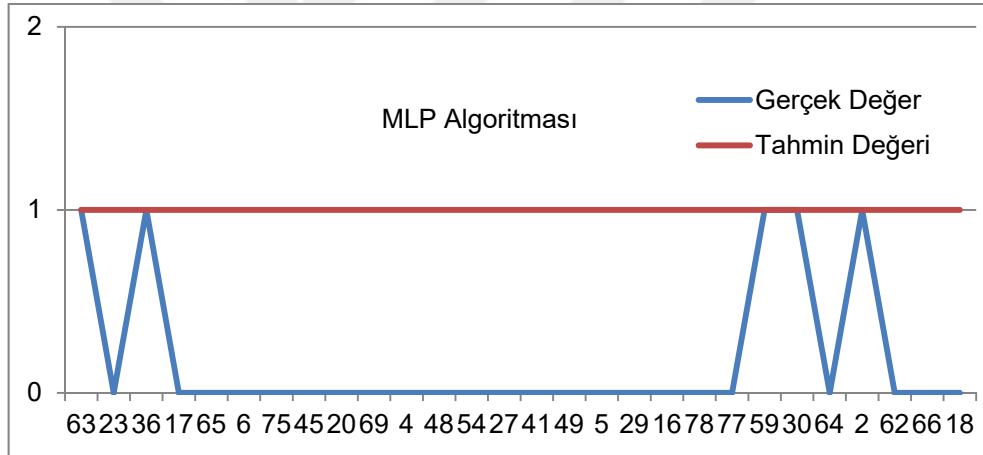
Şekil 4.26. Model 2 İçin XGBoost Algoritması Test Performansı

Şekil 4.26’da Model 2 için XGBoost algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 4’ünde sapma olduğu söylenebilir.

Çizelge 4.7. Model 2 İçin XGBoost Algoritması Karışıklık Matrisi

[[21 2]					
[2 3]]					
		precision	recall	f1- score	support
	0	0.91	0.91	0.91	23
	1	0.60	0.60	0.60	5
	accuracy			0.86	28
	macro avg	0.76	0.76	0.76	28
	weighted avg	0.86	0.86	0.86	28

Çizelge 4.7’de Model 2 için XGBoost algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 23 test verisinin 21’ini doğru ve 2’sini yanlış sınıflandırmıştır. 1 sınıfına ait 5 test verisinin 3’ünü doğru ve 2’sini yanlış sınıflandırmıştır. Buna göre; Model 2 için XGBoost algoritması accuracy (doğruluk) değeri 0.86, precision (kesinlik) değeri 0.86, recall (duyarlılık) değeri 0.86, f1-score değeri 0.86 olarak hesaplanmıştır. XGBoost algoritmasının Model 2’nin 4 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) ve kesinlik-duyarlılık (f1-score) başarısı 0.86’dır. Bu değerler 1’e yakın olarak gözlemlendiğinden XGBoost algoritmasının Model 2 veri seti için başarılı bir tahmin edici olduğu söylenebilir.



Şekil 4.27. Model 2 İçin MLP Algoritması Test Performansı


Şekil 4.27’de Model 2 için MLP algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 23’ünde sapma olduğu söylenebilir.

Çizelge 4.8. Model 2 İçin MLP Algoritması Karışıklık Matrisi

[[0 23]					
[0 5]]					
		precision	recall	f1- score	support
	0	0.00	0.00	0.00	23
	1	0.18	1.00	0.30	5
	accuracy			0.18	28
	macro avg	0.09	0.50	0.15	28
	weighted avg	0.03	0.18	0.05	28

Çizelge 4.8’de Model 2 için MLP algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 23 test verisinin tamamını yanlış sınıflandırmıştır. 1 sınıfına ait 5 test verisinin ise tamamını doğru sınıflandırmıştır. Buna göre; Model 2 için MLP algoritması accuracy (doğruluk) değeri 0.18, precision (kesinlik) değeri 0.03, recall (duyarlılık) değeri 0.18, f1-score değeri 0.05 olarak hesaplanmıştır. MLP algoritmasının Model 2’nin 4 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.18; kesinlik-duyarlılık (f1-score) başarısı ise 0.05’dir. Bu değerler 0’a yakın olarak gözlemlendiğinden MLP algoritmasının Model 2 veri seti için başarılı bir tahmin edici olmadığı söylenebilir.

4.2.3. Model 3 İçin Algoritma Tahminleri




Şekil 4.28. Model 3 İçin Decision Tree Algoritması Test Performansı

Şekil 4.28’de Model 3 için Decision Tree algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 5’inde sapma olduğu söylenebilir.

Çizelge 4.9. Model 3 İçin Decision Tree Algoritması Karışıklık Matrisi

[[15 4]					
[1 8]]					
		precision	recall	f1- score	support
	0	0.94	0.79	0.86	19
	1	0.67	0.89	0.76	9
	accuracy			0.82	28
	macro avg	0.80	0.84	0.81	28
	weighted avg	0.85	0.82	0.83	28

Çizelge 4.9’da Model 3 için Decision Tree algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 19 test verisinin 15’ini doğru ve 4’ünü yanlış sınıflandırmıştır. 1 sınıfına ait 9 test verisinin 8’ini doğru ve 1’ini yanlış sınıflandırmıştır. Buna göre; Model 3 için Decision Tree algoritması accuracy (doğruluk) değeri 0.82, precision (kesinlik) değeri 0.85, recall (duyarlılık) değeri 0.82, f1-score değeri 0.83 olarak hesaplanmıştır. Decision Tree algoritmasının Model 3’ün 15 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.82; kesinlik-duyarlılık (f1-score) başarısı ise 0.83’tür. Bu değerler 1’e yakın olarak gözlendiğinden Decision Tree algoritmasının Model 3 veri seti için başarılı bir tahmin edici olduğu söylenebilir.




Şekil 4.29. Model 3 İçin Random Forest Algoritması Test Performansı

Şekil 4.29’da Model 3 için Random Forest algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 4’ünde sapma olduğu söylenebilir.

Çizelge 4.10. Model 3 İçin Random Forest Algoritması Karışıklık Matrisi

[[17 2]					
[2 7]]					
		precision	recall	f1- score	support
	0	0.89	0.89	0.89	19
	1	0.78	0.78	0.78	9
	accuracy			0.86	28
	macro avg	0.84	0.84	0.84	28
	weighted avg	0.86	0.86	0.86	28

Çizelge 4.10’da Model 3 için Random Forest algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 19 test verisinin 17’sini doğru ve 2’sini yanlış sınıflandırmıştır. 1 sınıfına ait 9 test verisinin 7’sini doğru ve 2’sini yanlış sınıflandırmıştır. Buna göre; Model 3 için Random Forest algoritması accuracy (doğruluk) değeri 0.86, precision (kesinlik) değeri 0.86, recall (duyarlılık) değeri 0.86, f1-score değeri 0.86 olarak hesaplanmıştır. Random Forest algoritmasının Model 3’ün 15 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) ve kesinlik-duyarlılık (f1-score) başarısı ise 0.86’dır. Bu değerler 1’e yakın olarak gözlendiğinden Random Forest algoritmasının Model 3 veri seti için başarılı bir tahmin edici olduğu söylenebilir.




Şekil 4.30. Model 3 İçin XGBoost Algoritması Test Performansı

Şekil 4.30’da Model 3 için XGBoost algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 3’ünde sapma olduğu söylenebilir.

Çizelge 4.11. Model 3 İçin XGBoost Algoritması Karışıklık Matrisi

[[16 3]					
[0 9]]					
		precision	recall	f1- score	support
	0	1.00	0.84	0.91	19
	1	0.75	1.00	0.86	9
	accuracy			0.89	28
	macro avg	0.88	0.92	0.89	28
	weighted avg	0.92	0.89	0.90	28

Çizelge 4.11’de Model 3 için XGBoost algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 19 test verisinin 16’sını doğru 3’ünü yanlış sınıflandırmıştır. 1 sınıfına ait 9 test verisinin tamamını doğru sınıflandırmıştır. Buna göre; Model 3 için XGBoost algoritması accuracy (doğruluk) değeri 0.89, precision (kesinlik) değeri 0.92, recall (duyarlılık) değeri 0.89, f1-score değeri 0.90 olarak hesaplanmıştır. XGBoost algoritmasının Model 3’ün 15 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.89; kesinlik-duyarlılık (f1-score) başarısı ise 0.90’dır. Bu değerler 1’e yakın olarak gözlemlendiğinden XGBoost algoritmasının Model 3 veri seti için başarılı bir tahmin edici olduğu söylenebilir.



Şekil 4.31. Model 3 İçin MLP Algoritması Test Performansı

Şekil 4.31’de Model 3 için MLP algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 9’unda sapma olduğu söylenebilir.


Çizelge 4.12. Model 3 İçin MLP Algoritması Karışıklık Matrisi

[[14 5]					
[4 5]]					
		precision	recall	f1- score	support
0		0.78	0.74	0.76	19
1		0.50	0.56	0.53	9
accuracy				0.68	28
macro avg		0.64	0.65	0.64	28
weighted avg		0.69	0.68	0.68	28

Çizelge 4.12’de Model 3 için MLP algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 19 test verisinin 14’ünü doğru ve 5’ini yanlış sınıflandırmıştır. 1 sınıfına ait 9 test verisinin 5’ini doğru ve 4’ünü yanlış sınıflandırmıştır. Buna göre; Model 3 için MLP algoritması accuracy

(doğruluk) değeri 0.68, precision (kesinlik) değeri 0.69, recall (duyarlılık) değeri 0.68, f1-score değeri 0.68 olarak hesaplanmıştır. MLP algoritmasının Model 3'ün 15 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı (accuracy) ve kesinlik-duyarlılık (f1-score) başarısı 0.68'dir. Bu değerler 1'e yakın olarak gözlemlendiğinden MLP algoritmasının Model 3 veri seti için başarılı bir tahmin edici olduğu, ancak kullanılan diğer algoritmalara göre daha kötü bir tahmin edici olduğu söylenebilir.

4.2.4. Model 4 İçin Algoritma Tahminleri




Şekil 4.32. Model 4 İçin Decision Tree Algoritması Test Performansı

Şekil 4.32'de Model 4 için Decision Tree algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 2'sinde sapma olduğu söylenebilir.

Çizelge 4.13. Model 4 İçin Decision Tree Algoritması Karışıklık Matrisi

[[24 0]					
[2 2]]					
		precision	recall	f1- score	support
0		0.92	1.00	0.96	24
1		1.00	0.50	0.67	4
accuracy				0.93	28
macro avg		0.96	0.75	0.81	28
weighted avg		0.93	0.93	0.92	28

Çizelge 4.13'te Model 4 için Decision Tree algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 24 test verisinin tamamını doğru sınıflandırmıştır. 1 sınıfına ait 4 test verisinin 2'sini doğru ve 2'sini yanlış sınıflandırmıştır. Buna göre; Model 4 için Decision Tree algoritması accuracy (doğruluk) değeri 0.93, precision (kesinlik) değeri 0.93, recall (duyarlılık) değeri 0.93, f1-score değeri 0.92 olarak hesaplanmıştır. Decision Tree algoritmasının Model 4'ün 15 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.93; kesinlik-duyarlılık (f1-score) başarısı ise 0.92'dir. Bu değerler 1'e yakın olarak gözlendiğinden Decision Tree algoritmasının Model 4 veri seti için başarılı bir tahmin edici olduğu söylenebilir.




Şekil 4.33. Model 4 İçin Random Forest Algoritması Test Performansı

Şekil 4.33'te Model 4 için Random Forest algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 2'sinde sapma olduğu söylenebilir.

Çizelge 4.14. Model 4 İçin Random Forest Algoritması Karışıklık Matrisi

[[24 0]					
[2 2]]					
		precision	recall	f1- score	support
	0	0.92	1.00	0.96	24
	1	1.00	0.50	0.67	4
	accuracy			0.93	28
	macro avg	0.96	0.75	0.81	28
	weighted avg	0.93	0.93	0.92	28

Çizelge 4.14’te Model 4 için Random Forest algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 24 test verisinin tamamını doğru sınıflandırmıştır. 1 sınıfına ait 4 test verisinin 2’sini doğru ve 2’sini yanlış sınıflandırmıştır. Buna göre; Model 4 için Random Forest algoritması accuracy (doğruluk) değeri 0.93, precision (kesinlik) değeri 0.93, recall (duyarlılık) değeri 0.93, f1-score değeri 0.92 olarak hesaplanmıştır. Random Forest algoritmasının Model 4’ün 15 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.93; kesinlik-duyarlılık (f1-score) başarısı ise 0.92’dir. Bu değerler 1’e yakın olarak gözlemlendiğinden Random Forest algoritmasının Model 4 veri seti için başarılı bir tahmin edici olduğu söylenebilir.




Şekil 4.34. Model 4 İçin XGBoost Algoritması Test Performansı

Şekil 4.34’te Model 4 için XGBoost algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 4’ünde sapma olduğu söylenebilir.

Çizelge 4.15. Model 4 İçin XGBoost Algoritması Karışıklık Matrisi

[[22 2]					
[2 2]]					
		precision	recall	f1- score	support
	0	0.92	0.92	0.92	24
	1	0.50	0.50	0.50	4
	accuracy			0.86	28
	macro avg	0.71	0.71	0.71	28
	weighted avg	0.86	0.86	0.86	28

Çizelge 4.15'te Model 4 için XGBoost algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 24 test verisinin 22'sini doğru ve 2'sini yanlış sınıflandırmıştır. 1 sınıfına ait 4 test verisinin 2'sini doğru ve 2'sini yanlış sınıflandırmıştır. Buna göre; Model 4 için XGBoost algoritması accuracy (doğruluk) değeri 0.86, precision (kesinlik) değeri 0.86, recall (duyarlılık) değeri 0.86, f1-score değeri 0.86 olarak hesaplanmıştır. XGBoost algoritmasının Model 4'ün 15 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) ve kesinlik-duyarlılık f1-score) başarısı 0.86'dır. Bu değerler 1'e yakın olarak gözlemlendiğinden XGBoost algoritmasının Model 4 veri seti için başarılı bir tahmin edici olduğu söylenebilir.



Şekil 4.35. Model 4 İçin MLP Algoritması Test Performansı

Şekil 4.35'te Model 4 için MLP algoritmasının tahmin değerlerinin test veri setine ait gerçek değerlerle karşılaştırması grafiksel olarak sunulmuştur. Buna göre 82 kişilik veri setinden rastgele seçilen 28 test verisi için algoritma tahminlerinin 12'sinde sapma olduğu söylenebilir.

Çizelge 4.16. Model 4 İçin MLP Algoritması Karışıklık Matrisi

[[12 12]					
[0 4]]					
		precision	recall	f1- score	support
	0	1.00	0.50	0.67	24
	1	0.25	1.00	0.40	4
	accuracy			0.57	28
	macro avg	0.62	0.75	0.53	28
	weighted avg	0.89	0.57	0.63	28


Çizelge 4.16'da Model 4 için MLP algoritmasının karışıklık matrisi görülmektedir. Tabloya göre algoritma 0 sınıfına ait 24 test verisinin 12'sini doğru ve 12'sini yanlış sınıflandırmıştır. 1 sınıfına ait 4 test verisinin ise tamamını doğru sınıflandırmıştır. Buna göre; Model 4 için MLP algoritması accuracy (doğruluk)

değeri 0.57, precision (kesinlik) değeri 0.89, recall (duyarlılık) değeri 0.57, f1-score değeri 0.63 olarak hesaplanmıştır. MLP algoritmasının Model 4'ün 15 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı (accuracy) 0.57; kesinlik-duyarlılık (f1-score) başarısı ise 0.63'tür. Bu değerler 1'e yakın olarak gözleendiğinden MLP algoritmasının Model 4 veri seti için başarılı bir tahmin edici olduğu, ancak kullanılan diğer algoritmalarla göre daha kötü bir tahmin edici olduğu söylenebilir.

4.3. Algoritma Tahmin Başarıları Karşılaştırmaları

Yapılan çalışma kapsamında oluşturulan 4 farklı model için kullanılan 4 farklı algoritmaya ilişkin karşılaştırmalı sonuçlar ve model karşılaştırmaları aşağıda grafiksel ve açıklamalı olarak sunulmuştur.


4.3.1. Model 1 İçin Karşılaştırma



Şekil 4.36. Model 1 Algoritma Accuracy Değerleri

Şekil 4.36'da Model 1 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının accuracy (doğruluk) değerleri sırasıyla 0.82, 0.79, 0.79 ve 0.57 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek accuracy (doğruluk) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 1'in 5 bağımsız değişkenine göre dinlediğini öğrenme


durumunu doğru tahmin etme başarısı en yüksek olan algoritmanın Decision Tree algoritması olduğu söylenebilir.



Şekil 4.37. Model 1 Algoritma F1-Score Değerleri


Şekil 4.37’de Model 1 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının F1-score (kesinlik-duyarlılık) değerleri sırasıyla 0.81, 0.77, 0.79 ve 0.49 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek F1-score (kesinlik-duyarlılık) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 1’in 5 bağımsız değişkenine göre dinlediğini öğrenme durumunu tespit etmede kesinlik-duyarlılık başarısı en yüksek olan algoritmanın Decision Tree algoritması olduğu söylenebilir.

4.3.2. Model 2 İçin Karşılaştırma



Şekil 4.38. Model 2 Algoritma Accuracy Değerleri


Şekil 4.38’de Model 2 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının accuracy (doğruluk) değerleri sırasıyla 0.93, 0.89, 0.86 ve 0.18 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek accuracy (doğruluk) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 2’nin 4 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı en yüksek olan algoritmanın Decision Tree algoritması olduğu söylenebilir.



Şekil 4.39. Model 2 Algoritma F1-Score Değerleri


Şekil 4.39’da Model 2 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının F1-score (kesinlik-duyarlılık) değerleri sırasıyla 0.92, 0.89, 0.86 ve 0.05 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek F1-score (kesinlik-duyarlılık) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 2’nin 4 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu tespit etmede kesinlik-duyarlılık başarısı en yüksek olan algoritmanın Decision Tree algoritması olduğu söylenebilir.

4.3.3. Model 3 İçin Karşılaştırma



Şekil 4.40. Model 3 Algoritma Accuracy Değerleri

Şekil 4.40'ta Model 3 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının accuracy (doğruluk) değerleri sırasıyla 0.82, 0.86, 0.89 ve 0.68 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek accuracy (doğruluk) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 3'ün 15 bağımsız değişkenine göre dinlediğini öğrenme durumunu doğru tahmin etme başarısı en yüksek olan algoritmanın XGBoost algoritması olduğu söylenebilir.




Şekil 4.41. Model 3 Algoritma F1-Score Değerleri

Şekil 4.41'de Model 3 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının F1-score (kesinlik-duyarlılık) değerleri sırasıyla 0.83, 0.86, 0.90 ve 0.68 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek F1-score (kesinlik-duyarlılık) değerlerine


ulaşıldığı gözlenmiştir. Sonuç olarak, Model 3'ün 15 bağımsız değişkenine göre dinlediğini öğrenme durumunu tespit etmede kesinlik-duyarlılık başarısı en yüksek olan algoritmanın XGBoost algoritması olduğu söylenebilir.

4.3.4. Model 4 İçin Karşılaştırma



Şekil 4.42. Model 4 Algoritma Accuracy Değerleri

Şekil 4.42'de Model 4 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının accuracy (doğruluk) değerleri sırasıyla 0.93, 0.93, 0.86 ve 0.57 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek accuracy (doğruluk) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 4'ün 15 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu doğru tahmin etme başarısı en yüksek olan algoritmaların Decision Tree ve Random Forest algoritmaları olduğu söylenebilir.



Şekil 4.43. Model 4 Algoritma F1-Score Değerleri

Şekil 4.43'te Model 4 için Decision Tree, Random Forest, XGBoost ve MLP algoritmalarının F1-score (kesinlik-duyarlılık) değerleri sırasıyla 0.92, 0.92, 0.86 ve 0.63 olarak görülmektedir. Buna göre; Decision Tree, Random Forest ve XGBoost algoritmaları için yüksek F1-score (kesinlik-duyarlılık) değerlerine ulaşıldığı gözlenmiştir. Sonuç olarak, Model 4'ün 15 bağımsız değişkenine göre GAMS kodlamasını öğrenme durumunu tespit etmede kesinlik-duyarlılık başarısı en yüksek olan algoritmaların Decision Tree ve Random Forest algoritmaları olduğu söylenebilir.

4.4. Model Karşılaştırmaları

Model 1 ve Model 3 karşılaştırıldığında Model 3 ile daha yüksek sınıflandırma başarısı değerlerine ulaşıldığı gözlenmiştir. Bu noktada ders anında öğrenmenin gerçekleştiğinin tespitinde bilginin anlaşılması (KBF3) faktörünün yanı sıra öğrencinin kendi öğrenme yollarına ilişkin farkındalığı (KBF1), dikkat/motivasyon/isteklilik (KBF2), öğrencinin tepkisi/memnuniyeti (KBF4) ve dersin kazanımlarının sağlanması (KBF5) faktörlerinin de önemli olduğu söylenebilir.

Model 2 ve Model 4 karşılaştırıldığında ders sonrasında öğrenmenin gerçekleştiğinin tespitinde en önemli faktörün dersin kazanımlarının sağlanması (KBF5) olduğu söylenebilir.

Tüm modeller karşılaştırıldığında ders sonrasında öğrenmenin tespitinin nispeten daha başarılı şekilde gerçekleştirildiği söylenebilir.

5. SONUÇLAR VE ÖNERİLER

Yapılan tez çalışmasının amaçları aşağıdaki gibi belirlenmiştir:

- Öğrenmenin gerçekleştiğini ders anında, ve sonrasında tespit edecek bir yapay zeka sistemi önermek,
- Öğrencilere öğrenme düzeylerine göre tekrar/ek ders içerikleri önerilmesini sağlamak,
- Öğrenciye özgü içerik oluşturulmasına girdi sağlamak,
- Yapay zeka veya çok kriterli karar verme gibi akıllı karar verme yöntemleriyle farklı eğitim programlarına uygulanabilecek adaptif bir sistem tasarlamaktır.

Bu çalışmada öncelikli olarak bir dersin öğrenilme durumunu ders anında ve sonrasında tespit edecek yapay zeka temelli bir sistem önerilmesi amaçlanmıştır. Yukarıda verilen bu ve benzeri amaçlar doğrultusunda çalışmanın yönteminde aşağıdaki adımlar izlenmiştir:

1. Öğrenme süreçleri analiz edilerek öğrenmeyi etkileyen kritik başarı faktörleri belirlenmiştir.
2. Bir ders seçilerek (GAMS optimizasyon yazılımına giriş) belirlenen faktörler doğrultusunda sorular hazırlanmıştır.
3. Seçilen derse ilişkin konu anlatım videosu oluşturulmuştur.
4. Sorular ve konu anlatım videosunun katılımcılara çevrimiçi olarak sunulabilmesi için bir veri toplama yazılımı (E-Öğrenme Analiz Programı) geliştirilmiştir.
5. Veri toplama yazılımı ile mühendislik öğrencilerinden etik prosedürlere uygun olarak veri toplanmıştır.

6. Toplanan veriler için uygun algoritmalar seçilerek dört farklı sınıflandırma modeli oluşturulmuştur.
7. Her bir model için algoritma sonuçları seçilen başarı metrikleriyle karşılaştırmalı olarak değerlendirilmiştir.

Yapılan çalışmada öğrenmenin gerçekleştiğini ders anında ve sonrasında tespit eden bir yapay zeka sistemi geliştirilmiş olup bu amaca ilişkin aşağıdaki sonuçlara ulaşılmıştır:

- Ders anında öğrenmeyi tespit etmeye yönelik “dinlediğini öğrenme” bağımlı değişkenini tahminleyen Model 1 ve Model 3 için sırasıyla 0.82 ve 0.89 accuracy (doğruluk); 0.81 ve 0.90 F1-score (kesinlik-duyarlılık) değerleriyle öğrenmenin yüksek doğruluk, kesinlik ve duyarlılıkla tahmini gerçekleştirilmiştir.
- Ders sonrasında öğrenmeyi tespit etmeye yönelik “GAMS kodlamasını öğrenme” bağımlı değişkenini tahminleyen Model 2 ve Model 4’ün her ikisi için de 0.93 accuracy (doğruluk) ve 0.92 F1-score (kesinlik-duyarlılık) değerleriyle öğrenmenin yüksek doğruluk, kesinlik ve duyarlılıkla tahmini gerçekleştirilmiştir.
- Öğrenme durumlarının tahminlerinde Decision Tree, Random Forest, XGBoost ve MLP algoritmaları kullanılmış olup genel olarak Decision Tree, Random Forest ve XGBoost algoritmaları ile başarılı tahminleme sağlanmıştır. Bu sonuç öğrenme süreçlerinin iyileştirilmesinde öğrenmenin tespitinde yapay zeka tekniklerinin kullanılmasının başarısını ortaya koymaktadır.
- Ders anında öğrenmenin gerçekleştiğinin tespit edilmesinde öğrencinin kendi öğrenme yollarına ilişkin farkındalığı (KBF1), dikkat/motivasyon/isteklilik (KBF2), öğrencinin tepkisi/memnuniyeti

(KBF4) ve dersin kazanımlarının sağlanması (KBF5) faktörlerinin bilginin anlaşılması (KBF3) kadar önemli gözlenmiştir.

- Ders sonrasında öğrenmenin gerçekleştiğinin tespiti nispeten daha başarılı gerçekleştirilmekle birlikte ders sonrasında öğrenmenin tespitinde en önemli faktörün dersin kazanımlarının sağlanması (KBF5) olduğu sonucuna ulaşılmıştır.

Ders anında ve sonrasında öğrenmenin tespit edilmesi öğrenci için kişiselleştirilmiş eğitim programı sağlanması, öğrenmeyi geliştirecek içeriklerin sunumu, öğrencinin akademik performansı ve kariyeri açısından erken önlemlerin gerçekleştirilmesi, akademisyenlere öğrencilerini daha iyi tanıma ve eğitimlerine katkıda bulunma imkanı tanınması gibi yönleriyle önem taşımaktadır. Bu çalışmada öğrenme tespiti yapılmış ancak çalışmanın ikinci amacı olan öğrencilerin öğrenme düzeylerine göre ders içeriği/önerisi sağlama gerçekleştirilmemiştir. Daha sonra yapılacak çalışmalarda bu konu kapsamlı bir şekilde değerlendirilebilir.

Öğrenciye özgü içerik oluşturulmasına girdi sağlamak amacı ise bu hususta öncelik arz eden öğrencinin öğrenmesinin sağlanıp sağlanmadığının tespiti ile gerçekleştirilmiştir.

Yapılan çalışma ile yapay zeka yöntemleriyle farklı eğitim programlarına uygulanabilecek adaptif bir sistem tasarlamak amacının gerçekleştirildiği söylenebilir. Bu noktada dersin öğrenilmesini tespitite kullanılan sorular ilişkili oldukları kritik başarı faktörleri çerçevesinde farklı bir ders ve eğitim programı için uyarlanarak öğrenme tespiti gerçekleştirilebilir.

Bu çalışmanın özgün katkılarından biri de hazırlanan “E-Oğrenme Analiz Programı” veri toplama yazılımıdır.



KAYNAKLAR

- Aghalarova, S., ve Bozkurt Keser, S., 2021. Önerilen Yapay Sinir Ağı Algoritması ile Ortaokul Öğrencilerin Akademik Performansının Tahmini. Veri Bilimi, 4(2): 19-32.
- Agrawal, H., and Mavani, H., 2015. Student Performance Prediction Using Machine Learning. International Journal of Engineering Research and Technology, 4(03): 111-113.
- Almohammadi, K., Hagra, H., Alhazzawi, D., and Aldabbagh, G., 2017. A Survey of Artificial Intelligence Techniques Employed for Adaptive Educational Systems within E-Learning Platforms. Journal of Artificial Intelligence and Soft Computing Research, 7(1): 47-64.
- Askari, M., and Keynia, F., 2020. Mid-Term Electricity Load Forecasting by a New Composite Method Based on Optimal Learning MLP Algorithm. IET Generation, Transmission & Distribution, 14(5): 845-852.
- Aydoğan, M., ve Karcı, A., 2018. Meslek Yüksekokulu Öğrencilerinin Başarı Performanslarının Makine Öğrenmesi Yöntemleri ile Analizi. In International Symposium on Multidisciplinary Studies and Innovative Technologies, 1-6.
- Bañeres, D., Rodríguez, M. E., Guerrero-Roldán, A. E., and Karadeniz, A., 2020. An early warning system to detect at-risk students in online higher education. Applied Sciences, 10(13): 1-28.
- Bekmanova, G., Ongarbayev, Y., Somzhurek, B., and Mukatayev, N., 2021. Personalized Training Model for Organizing Blended and Lifelong Distance Learning Courses and Its Effectiveness in Higher Education. Journal of Computing in Higher Education, 33(3): 668-683.

- Berding, F., Riebenbauer, E., Stütz, S., Jahncke, H., Slopinski, A., and Rebmann, K., 2022. Performance and Configuration of Artificial Intelligence in Educational Settings. Introducing a New Reliability Concept Based on Content Analysis. In *Frontiers in Education* (p. 325). Frontiers.
- Bhutto, E. S., Siddiqui, I. F., Arain, Q. A., and Anwar, M., 2020. Predicting Students' Academic Performance Through Supervised Machine Learning. In *2020 International Conference on Information Science and Communication Technology (ICISCT)* (pp. 1-6). IEEE.
- Bojorque, R., and Pesántez-Avilés, F., 2019. Academic Quality Management System Audit Using Artificial Intelligence Techniques. In *International Conference on Applied Human Factors and Ergonomics* (pp. 275-283). Springer, Cham.
- Buenaño-Fernández, D., Gil, D., and Luján-Mora, S., 2019. Application of Machine Learning in Predicting Performance for Computer Engineering Students: A Case Study. *Sustainability*, 11(10): 1-18.
- Chassignol, M., Khoroshavin, A., Klimova, A., and Bilyatdinova, A., 2018. Artificial Intelligence Trends in Education: A Narrative Overview. *Procedia Computer Science*, 136: 16-24.
- Chen, L., Chen, P., and Lin, Z., 2020. Artificial Intelligence in Education: A Review. *Ieee Access*, 8, 75264-75278.
- Chen, T., and Guestrin, C., 2016. Xgboost: A Scalable Tree Boosting System. In *Proceedings Of The 22nd Acm Sigkdd International Conference On Knowledge Discovery and Data Mining* (pp. 785-794).
- Chen, Z., Zhang, J., Jiang, X., Hu, Z., Han, X., Xu, M., V, S., and Vivekananda, G. N., 2020. Education 4.0 Using Artificial Intelligence for Students Performance Analysis. *Inteligencia Artificial*, 23(66): 124-137.

- Ciolacu, M. I., Svasta, P., Hartl, D., and Görzen, S., 2020. Education 4.0: Smart Blended Learning Assisted by Artificial Intelligence, Biofeedback and Sensors. In 2020 International Symposium on Electronics and Telecommunications (ISETC) (pp. 1-4). IEEE.
- Ciolacu, M., Svasta, P. M., Berg, W., and Popp, H., 2017. Education 4.0 for Tall Thin Engineer in a Data Driven Society. In 2017 IEEE 23rd International Symposium for Design and Technology in Electronic Packaging (SIITME) (pp. 432-437). IEEE.
- Ciolacu, M., Tehrani, A. F., Binder, L., and Svasta, P. M., 2018. 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) (pp. 23-30). IEEE.
- Cruz-Jesus, F., Castelli, M., Oliveira, T., Mendes, R., Nunes, C., Sa-Velho, M., and Rosa-Louro, A., 2020. Using Artificial Intelligence Methods to Assess Academic Achievement in Public High Schools of a European Union Country. *Heliyon*, 6(6): 1-11.
- Çakır, Ö., Mete, F., ve Kantos, Z. E., 2019. Kişiselleştirilmiş Öğretimin 5N1K Tekniğinde Başarıya Etkisi. *Adıyaman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (33): 125-147.
- Deo, R. C., Yaseen, Z. M., Al-Ansari, N., Nguyen-Huy, T., Langlands, T. A. M., and Galligan, L., 2020. Modern Artificial Intelligence Model Development for Undergraduate Student Performance Prediction: An Investigation on Engineering Mathematics Courses. *IEEE Access*, 8: 136697-136724.
- Duygu, B., ve Arıcı, N., 2019. Karar Ağacı Algoritmalarıyla Öğrencilerin Akademik Performans Verilerinin Sınıflandırılması. *SETSCI Conference Proceedings*, 4(1): 434-444.

- ElSayed, A. A., Caeiro-Rodríguez, M., MikicFonte, F. A., and Llamas-Nistal, M., 2019. Research in Learning Analytics and Educational Data Mining to Measure Self-Regulated Learning: A Systematic Review. In World Conference On Mobile And Contextual Learning (pp. 46-53).
- Gaobin, Huan Nan, C., and Zhen Zhong, L., 2020. An Artificial Intelligence Fuzzy System for Improvement of Physical Education Teaching Method. Journal of Intelligent & Fuzzy Systems, (Preprint), 1-10.
- Géron, A., 2019. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, United States of America, 482s.
- Gök, M., 2017. Makine Öğrenmesi Yöntemleri İle Akademik Başarının Tahmin Edilmesi. Gazi University Journal of Science Part C: Design and Technology, 5(3): 139-148.
- Görmez, Y., Okumuş Dağdeler, K. ve Kavuklu, M., 2022. Kişiselleştirilmiş Yabancı Dil Öğrenimi İçin Makine Öğrenmesi Yöntemleriyle İlgili Alanı Tahmini. Yükseköğretim ve Bilim Dergisi, 12(1): 111-121.
- Graham, R., 2018. The Global State of the Art in Engineering Education. Massachusetts Institute of Technology (MIT) Report, Massachusetts, USA.
- Güner, N., ve Çomak, E., 2011. Mühendislik Öğrencilerinin Matematik I Derslerindeki Başarısının Destek Vektör Makineleri Kullanılarak Tahmin Edilmesi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 17(2): 87-96.
- Hassan, H., Anuar, S., and Ahmad, N. B., 2019. Students' Performance Prediction Model Using Meta-Classifer Approach. In International Conference on Engineering Applications of Neural Networks (pp. 221-231). Springer, Cham.

- Hussain, M., Zhu, W., Zhang, W., and Abidi, S. M. R., 2018. Student Engagement Predictions in an e-Learning System and Their Impact on Student Course Assessment Scores. *Computational Intelligence and Neuroscience*, 2018: 1-21.
- Jani, K. H., Jones, K. A., Jones, G. W., Amiel, J., Barron, B., and Elhadad, N., 2020. Machine Learning to Extract Communication and History-Taking Skills in OSCE Transcripts. *Medical Education*, 54(12): 1159-1170.
- Janikow, C. Z., 1998. Fuzzy Decision Trees: Issues and Methods. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 28(1): 1-29.
- Jijo, B. T., and Abdulazeez, A. M., 2021. Classification Based on Decision Tree Algorithm for Machine Learning. *Journal of Applied Science and Technology Trends*, 2(01): 20-28.
- Jokhan, A., Chand, A. A., Singh, V., and Mamun, K. A., 2022. Increased Digital Resource Consumption in Higher Educational Institutions and The Artificial Intelligence Role in Informing Decisions Related to Student Performance. *Sustainability*, 14(4): 1-17.
- Kaplan, A., and 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.
- Kardaş, K., ve Güvenir, A., 2020. Kısa Sınavların, Ödevlerin ve Projelerin Dönem Sonu Sınavına Olan Etkilerinin Farklı Makine Öğrenmesi Teknikleri ile Araştırılması. *EMO Bilimsel Dergi*, 10(1): 22-29.
- Kayalı, S., ve Buyrukoğlu, S., 2022. Makine Öğrenmesi Yöntemleriyle Öğrencilerin Akademik Performanslarının Sınıflandırılması. In 2nd International Conference on Educational Technology and Online Learning- Icetol 2022 (pp. 330-336).

- Khan, I., Ahmad, A. R., Jabeur, N., and Mahdi, M. N., 2021. An Artificial Intelligence Approach to Monitor Student Performance and Devise Preventive Measures. *Smart Learning Environments*, 8(1): 1-18.
- Kim, Y., Soyata, T., and Behnagh, R. F., 2018. Towards Emotionally Aware AI Smart Classroom: Current Issues and Directions for Engineering and Education. *IEEE Access*, 6: 5308-5331.
- Koutina, M., and Kermanidis, K. L., 2011. Predicting Postgraduate Students' Performance Using Machine Learning Techniques. In *Artificial Intelligence Applications and Innovations* (Pp. 159-168). Springer, Berlin, Heidelberg.
- Lee, C. S., Tsai, Y. L., Wang, M. H., Huang, S. H., Reformat, M., and Kubota, N., 2021. Adaptive Fuzzy Neural Agent for Human and Machine Co-learning. *International Journal of Fuzzy Systems*, 1-21.
- Li, M., and Su, Y., 2020. Evaluation of Online Teaching Quality of Basic Education Based on Artificial Intelligence. *International Journal of Emerging Technologies in Learning (iJET)*, 15(16): 147-161.
- Liu, Y., Wang, Y., and Zhang, J., 2012. New Machine Learning Algorithm: Random Forest. In *International Conference on Information Computing and Applications* (pp. 246-252). Springer, Berlin, Heidelberg.
- Ma, W., Zhao, X., and Guo, Y., 2021. Improving the Effectiveness of Traditional Education Based on Computer Artificial Intelligence and Neural Network System. *Journal Of Intelligent & Fuzzy Systems*, (Preprint): 1-11.
- Mahesh, B., 2020. Machine Learning Algorithms-A Review. *International Journal of Science and Research (IJSR)*. [Internet], 9: 381-386.
- Navada, A., Ansari, A. N., Patil, S., and Sonkamble, B. A., 2011. Overview of Use of Decision Tree Algorithms In Machine Learning. In *2011 IEEE Control and System Graduate Research Colloquium* (pp. 37-42). IEEE.

- Özkan, Y., Koçoğlu, F. Ö., ve Erol, Ç. S. (2018). Prediction of Student Performance By Deep Learning Algorithm Öğrenci Performansının Yapay Zeka Derin Öğrenme Algoritması İle Öngörülmesi. 7th International Conference on “Innovations in Learning for the Future”: Digital Transformation in Education, 136-144.
- Rai, S., Shastri, K. A., Pratap, S., Kishore, S., Mishra, P., and Sanjay, H. A., 2021. Machine Learning Approach for Student Academic Performance Prediction. In *Evolution in Computational Intelligence* (pp. 611-618). Springer, Singapore.
- Rao, K. P., Sekhara, M. V. P. C., and Ramesh, B., 2016. Predicting Learning Behavior of Students Using Classification Techniques. *International Journal of Computer Applications*, 139(7): 15-19.
- Rimi, A. A., Bayat, O., Ibrahim, A. A., 2020. Developing Classifier for the Prediction of Students' Performance Using Data Mining Classification Techniques. *AURUM Journal of Engineering Systems and Architecture*, 4(1): 73-91.
- Rincón-Flores, E. G., López-Camacho, E., Mena, J., and López, O. O., 2020. Predicting Academic Performance with Artificial Intelligence (AI), A New Tool for Teachers and Students. In *2020 IEEE Global Engineering Education Conference (EDUCON)*, 1049-1054.
- Santhanam, R., Uzir, N., Raman, S., and Banerjee, S., 2016. Experimenting XGBoost Algorithm for Prediction and Classification of Different Datasets. *International Journal of Control Theory and Applications*, 9(40): 651-662.
- Sekeroglu, B., Dimililer, K., and Tuncal, K., 2019. Artificial Intelligence in Education: Application in Student Performance Evaluation. *Dilemas Contemporáneos: Educación, Política Y Valores*, 7(1): 1-21.
- Sezer, B., 2015. Kişiselleştirilmiş Matematik Problemlerinin Akademik Başarıya Etkisi. *Eğitim Teknolojisi Kuram ve Uygulama*, 5(2): 71-88.

- Sharma, K., Papamitsiou, Z., and Giannakos, M., 2019. Building Pipelines for Educational Data Using AI and Multimodal Analytics: A “Grey-Box” Approach. *British Journal of Educational Technology*, 50(6): 3004-3031.
- Siemens, G., and Baker, R. S. D., 2012. Learning Analytics and Educational Data Mining: Towards Communication and Collaboration. In *Proceedings of the 2nd international conference on learning analytics and knowledge* (pp. 252-254).
- Song, K., Yan, F., Ding, T., Gao, L., and Lu, S., 2020. A Steel Property Optimization Model Based on the XGBoost Algorithm and Improved PSO. *Computational Materials Science*, 174, 1-13.
- Tekin, C., Braun, J., and van der Schaar, M., 2015. etutor: Online Learning for Personalized Education. In *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (Pp. 5545-5549). IEEE.
- Ting, F. F., and Sim, K. S., 2017. Self-regulated Multilayer Perceptron Neural Network for Breast Cancer Classification. In *2017 International Conference on Robotics, Automation and Sciences (ICORAS)* (pp. 1-5). IEEE.
- Tosunoğlu, E., Yılmaz, R., Özeren, E., ve Sağlam, Z., 2021. Eğitimde Makine Öğrenmesi: Araştırmalardaki Güncel Eğilimler Üzerine İnceleme. *Ahmet Keleşoğlu Eğitim Fakültesi Dergisi*, 3(2): 178-199.
- Villegas-Ch, W., Sánchez-Viteri, S., and Román-Cañizares, M., 2021. Academic Activities Recommendation System for Sustainable Education in the Age of COVID-19. In *Informatics*, 8(2):1-18.
- Xiao, M., and Yi, H., 2020. A Practical and Efficient Multi-Assessment System for Vocational Teaching Based on Machine Learning. *The International Journal of Electrical Engineering & Education*, 0(0): 1-13.

Xiao, M., and Yi, H., 2021. Building an Efficient Artificial Intelligence Model for Personalized Training in Colleges and Universities. *Computer Applications in Engineering Education*, 29(2): 350-358.

Yavuzarslan, M., ve Erol, Ç. S., 2022. Öğrenme Yönetim Sistemi Log Kayıtlarının Akademik Başarı Tahmininde Kullanılması. *Bilişim Teknolojileri Dergisi*, 15(2): 199-207.





ÖZGEÇMİŞ

Betül ÇETİN, ilköğrenimini Adana Tabipler Odası İlköğretim Okulu'nda tamamladıktan sonra lise eğitimine Adana Piri Reis Anadolu Lisesi'nde devam etmiştir. 2014 yılında başladığı Çukurova Üniversitesi Endüstri Mühendisliği Bölümü'nden 2018 yılında mezun olmuştur. 2019 yılında Çukurova Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı'nda tezli yüksek lisans eğitimine başlamıştır.

