

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME ALGORİTMALARI KULLANARAK
ÖĞRENCİ AKADEMİK PERFORMANSININ ERKEN TAHMİNİ

DOKTORA TEZİ

Ahmet KALA

Endüstri Mühendisliği Anabilim Dalı

MAYIS 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME ALGORİTMALARI KULLANARAK
ÖĞRENCİ AKADEMİK PERFORMANSININ ERKEN TAHMİNİ

DOKTORA TEZİ

Ahmet KALA

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Orhan TORKUL

Ortak Danışman: Dr. Öğr. Üyesi Tuğba TUNACAN YILDIZ

MAYIS 2025

Ahmet KALA tarafından hazırlanan “DERİN ÖĞRENME ALGORİTMALARI KULLANARAK ÖĞRENCİ AKADEMİK PERFORMANSININ ERKEN TAHMİNİ” adlı tez çalışması 29.05.2025 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Alpaslan FIĞLALI Kocaeli Üniversitesi	
Jüri Üyesi :	Prof. Dr. Orhan TORKUL (Danışman) Sakarya Üniversitesi	
Jüri Üyesi :	Prof. Dr. Selim ZAİM İbn Haldun Üniversitesi	
Jüri Üyesi :	Prof.Dr. Harun Reşit YAZĞAN Sakarya Üniversitesi	
Jüri Üyesi :	Dr.Öğr.Üyesi Tuğrul TAŞCI Sakarya Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “DERİN ÖĞRENME ALGORİTMALARI KULLANARAK ÖĞRENCİ AKADEMİK PERFORMANSININ ERKEN TAHMİNİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(29/05/2025).

Ahmet KALA





Eşime ve çocuklarıma



TEŞEKKÜR

Bu çalışmanın ortaya çıkmasında yol gösterici olan ve katkılarını esirgemeyen, konu seçiminden araştırmanın yürütülmesine dek beni sınırlamayıp özgür bırakan, fikir ve görüşlerinden her zaman istifade ettiğim danışmanım Prof. Dr. Orhan TORKUL'a, ikinci danışmanım Dr. Tuğba TUNACAN YILDIZ'a ve her ihtiyaç duyduğumda bilgi ve tecrübelerini benden esirgemeyerek bana destek olan değerli hocam Prof. Dr. İhsan Hakan SELVİ'ye teşekkürlerimi sunarım.

Değerli görüşleriyle araştırmanın şekillenmesini sağlayan, dikkat etmem gereken noktalarla ilgili bilgi ve tecrübelerinden faydalandığım tez izleme jürimde yer alan Prof. Dr. Harun Reşit YAZĞAN ve Dr. Tuğrul TAŞÇI hocalarıma çok teşekkür ederim.

Tez çalışmam boyunca sahip olduğu bilgi ve deneyimiyle beni yönlendiren, cesaretlendiren ve destekleyen pek değerli dostum ve eski daire başkanım Doç. Dr. Süleyman UZUN'a çok teşekkür ederim. Doktora sürecinin başlamasına vesile olan, bu süreçte beni cesaretlendiren ve destekleyen eski daire başkanlarım Murat FİDAN, Sezer KUYUCU ve Akif TETİK'e, eski çalışma arkadaşlarım Öğr. Gör. Musa TURKAN, Mühendis Yavuz BİÇİCİ ve Öğr. Gör. Uğur TALAŞ'a ve yüksek lisans danışmanım rahmetli Prof. Dr. Birol AKYÜZ'e çok teşekkür ederim.

Son olarak bu zorlu süreçte her zaman destekçim olan sevgili eşim Züleyha KALA'ya, hayattaki en büyük motivasyon kaynaklarım biricik oğlum Eymen' e ve kızım Erva'ya ve tüm hayatım boyunca her zaman arkamda olan, beni sürekli destekleyen ve bugünlere gelmemde en büyük emeğe sahip olan canım anne ve babama çok teşekkür ederim.

Ahmet KALA



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xv
SİMGELER	xvii
TABLO LİSTESİ	xix
ŞEKİL LİSTESİ	xxi
ÖZET	xxiii
SUMMARY	xxvii
1. GİRİŞ	1
2. EĞİTSEL VERİ MADENCİLİĞİ	5
2.1. Giriş	5
2.1.1. EVM süreci	7
2.1.2. EVM kullanıcıları/paydaşları	8
2.1.3. EVM uygulama alanları ve görevleri	10
2.1.4. EVM yöntemleri	11
2.2. Öğrenci Akademik Performansın Tahmini	14
2.3. Öğrenci Akademik Performansının Tahmininde Kullanılan Yöntemler	16
2.3.1. İstatistiksel veri analiz yöntemleri	16
2.3.1.1. İstatistiksel veri analiz temel amaçları	16
2.3.1.2. İstatistiksel veri analiz yöntem çeşitleri	17
2.3.2. Özellik seçimi yöntemleri	20
2.3.3. Makine öğrenme yöntemleri	21
2.3.3.1. Makine öğrenmesi uygulamaları	23
2.3.3.2. Makine öğrenmesi süreci	24
2.3.3.3. Makine öğrenmesi türleri	26
2.3.3.4. Kullanılan makine öğrenmesi algoritmaları	28
2.3.4. Derin öğrenme	37
2.3.4.1. Derin öğrenme mimarileri	39
2.3.4.2. Derin öğrenme programları ve kütüphaneleri	49
3. LİTERATÜR TARAMASI	51
3.1. Giriş	51
3.2. Literatür İnceleme Metodolojisi	53
3.2.1. Sistematik inceleme	53
3.3. Arama Sonuçları	55
3.4. EVM Kapsamında Derin Öğrenme ile Erken Performans Tahmini	56
3.4.1. AS1: Yayınların zaman ve tür dağılımı	56
3.4.2. AS2: Kullanılan veri setleri ve öznitelikler	62
3.4.3. AS3: Tahmin modelleri ve performans kriterleri	66
3.4.4. AS4: Öğrenci performansının erken tahmini	72
3.4.5. AS5: Açıklanabilir yapay zeka (XAI) kullanımı ve açıklanabilirlik	73

3.4.6. AS6: Çalışmaların sınırlılıkları, katkıları ve gelecek araştırma önerileri.	74
3.4.6.1. Çalışmaların sınırlılıkları.....	74
3.4.6.2. Çalışmaların katkıları	74
3.4.6.3. Çalışmalardan gelecek araştırmalar için öneriler	75
3.5. Literatür Sonucu	75
3.6. Genel Değerlendirme ve Gelecek Fırsatlar	77
4. METODOLOJİ	79
4.1. Giriş	79
4.2. Kavramsal Model	80
4.2.1. Veri toplama.....	81
4.2.2. Veri işleme ve ön işleme	83
4.2.3. Özellik seçimi.....	84
4.2.4. Lojistik regresyon analizi	85
4.2.5. Veri bölme.....	86
4.3. Model geliştirme.....	86
4.3.1. Önerilen hibrid derin öğrenme modeli	87
4.3.1.1. Parçacık sürü optimizasyonu (PSO).....	87
4.3.1.2. Derin sinir ağı (DNN)	88
4.3.1.3. PSO-DNN hibrit derin öğrenme modeli.....	88
4.3.2. Karşılaştırılan makine öğrenme modelleri	91
4.4. Değerlendirme	92
4.4.1. Karşıtlık matrisi.....	92
4.4.2. Doğruluk.....	93
4.4.3. Kesinlik	94
4.4.4. Geri çağırma veya duyarlılık.....	94
4.4.5. F1-skoru	94
4.4.6. Yanlış pozitif oranı.....	94
4.4.7. Alıcı çalışma karakteristiği eğrisi.....	95
4.4.8. Eğri altındaki alan	95
4.5. Model Açıklaması	96
4.5.1. SHAP (SHapley katkı açıklamaları)	96
4.5.2. LIME (Yerel yorumlanabilir model-agnostik açıklamalar)	96
4.6. Duyarlılık Analizi	97
4.6.1.1. ANOVA testi.....	97
4.6.1.2. T-testi	97
5. MODEL UYGULAMASI VE SONUÇLAR.....	99
5.1. Giriş	99
5.2. Veri Analizi	99
5.2.1. Verinin toplaması süreci.....	99
5.2.2. Verinin temizlenmesi süreci.....	104
5.2.3. Özellik seçimi.....	105
5.2.4. Lojistik regresyon sonuçları	107
5.3. Model Uygulama ve Değerlendirme	108
5.3.1. Önerilen hibrit PSO-DNN erken tahmin sonuçları	110
5.3.2. Veri kombinasyonlarına göre erken tahmin sonuçları	114
5.3.3. Değişken akademik performans verileriyle erken tahmin sonuçları	116
5.3.4. Önerilen hibrit PSO-DNN uygulanabilirlik ve genellenebilirlik sonuçları	118
5.4. Önerilen Hibrit PSO-DNN Açıklanabilirlik Sonuçları.....	120
5.4.1. SHAP küresel açıklama sonucu	120

5.4.2. SHAP yerel açıklama sonuçları	121
5.4.3. LIME yerel açıklama sonuçları	124
5.5. Duyarlılık Anaizi Sonuçları	125
5.5.1. SHAP ve LIME açıklama sonuçları	126
5.5.2. T-testi sonuçları	126
5.5.3. ANOVA testi sonuçları	126
5.5.4. Duyarlılık analizi	132
6. SONUÇLAR VE ÖNERİLER	135
KAYNAKLAR	139
EKLER	155
ÖZGEÇMİŞ	157





KISALTMALAR

ANN	: Yapay Sinir Ağları
AUC	: Eğri Altındaki Alan (Area Under The Curve)
AYT	: Alan Yeterlilik Testi
DİL	: Dil
DT	: Karar Ağaçları (Decision Trees)
EA	: Eşit Ağırlık
EVM	: Eğitimsel Veri Madenciliği
GPA	: Genel Not Ortalaması
KNN	: k-En Yakın Komşu Algoritması (k-Nearest Neighbors)
LIME	: Local Interpretable Model-agnostic Explanations
LinR	: Lineer (Doğrusal) Regresyon
LR	: Lojistik Regresyon (Logistic Regression)
MÖ	: Makine Öğrenme
OULAD	: Open University Learning Analytics Dataset
RF	: Rastgele Ormanlar (Random Forests)
ROC	: Receiver Operating Characteristic
SAY	: Sayısal
SHAP	: SHapley Additive exPlanations
SOZ	: Sözel
SUBÜ	: Sakarya Uygulamalı Bilimler Üniversitesi
SVM	: Destek Vektör Makineleri (Support Vector Machines)
TYT	: Temel Yeterlilik Testi
XAI	: Açıklanabilir Yapay Zeka
YDT	: Yabancı Dil Testi



SİMGELER

α	: Sürüdeki parçacık sayısı
c_1	: Bireysel öğrenme katsayısı
c_2	: Global öğrenme katsayısı
$gbest$	: Küresel en iyi değer
$gfit$	: DNN tarafından hesaplanan başlangıç küresel en iyi uygunluk değeri
P	: Çift gizli katmanlı düğümlerin başlangıç konumu
$pfit$	: Bireysel en iyi uygunluk değerinin başlangıç durumu
$pibest$	: Bireysel en iyi değer
V	: Başlangıç hızı
w	: Atalet ağırlığı



TABLO LİSTESİ

Sayfa

Tablo 2.1. EVM kullanıcıları.	9
Tablo 3.1. Seçilen çalışmaların kritik detayları.	58
Tablo 3.2. En sık karşılaşılan anahtar kelimeler.	61
Tablo 3.3. Seçilen çalışmalarda kullanılan veri setleri, öznitelikler ve tahmin edilen nitelikler.	63
Tablo 3.4. Seçilen çalışmalarda kullanılan önerilen modeller, karşılaştırılan modeller ve performans değerlendirme yöntemleri.	67
Tablo 3.5. Ders uzunluğu, tahmin sıklığı ve erken tahmin süreleri.	73
Tablo 4.1. TYT, AYT ve YDT oturumları, ders alanları ve soru dağılımları.	82
Tablo 4.2. Erken tahmin.	86
Tablo 4.3. PSO-DNN parametreleri.	90
Tablo 4.4. Karşılaştırılan model parametreleri.	92
Tablo 5.1. SUBÜ veri seti nitelikleri.	101
Tablo 5.2. Programlama dersi ders içeriği.	103
Tablo 5.3. xAPI-Edu-Data genel veri seti nitelikleri.	104
Tablo 5.4. PSO-DNN gizli katman sayısı bazında en iyi model parametreleri.	110
Tablo 5.5. Veri grubu kombinasyonuna dayalı sınıflandırma göstergesi sonuçları.	115
Tablo 5.6. Erken tahmin sınıflandırma gösterge değerleri.	117
Tablo 5.7. xAPI-Edu-Data veri seti PSO-DNN sonuçları.	119
Tablo 5.8. xAPI-Edu-Data doğruluk sonuçları.	119



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. EVM ile ilişkili alanlar, Romero ve Ventura (2013)'ten uyarlanmıştır.....	6
Şekil 2.2. Eğitimsel veri madenciliğinde veri madenciliği uygulama süreci, Romero ve Ventura (2013)'ten uyarlanmıştır.	7
Şekil 2.3. Eğitimde veri madenciliği uygulama döngüsü, Romero ve Ventura (2007)'den uyarlanmıştır.....	8
Şekil 2.4. İstatistiksel veri analiz yöntemleri.	17
Şekil 2.5. Özellik seçimi yöntemleri.....	20
Şekil 2.6. Makine öğrenmesinin çok disiplinli gruplaması, Kühl (2019)'dan uyarlanmıştır.	22
Şekil 2.7. Makine öğrenmesi projesi için temel iş akışı, Zhang (2020)'den uyarlanmıştır.	24
Şekil 2.8. Kategorilerine göre makine öğrenme türleri, Deperlioğlu ve Köse (2024)'ten uyarlanmıştır.	26
Şekil 2.9. Makine öğrenme türleri ve görevleri, Deperlioğlu ve Köse (2024)'ten uyarlanmıştır.	27
Şekil 2.10. k-En yakın komşu (k-NN) sınıflandırması.	29
Şekil 2.11. Lojistik regresyonun sınıflandırması.	30
Şekil 2.12. Destek vektör makineleri sınıflandırması.	31
Şekil 2.13. Rastgele ormanlar ile sınıflandırma.....	32
Şekil 2.14. Karar ağaçları ile sınıflandırma.	33
Şekil 2.15. Yapay sinir ağı yapısı.	36
Şekil 2.16. MLP'nin yapısı.	37
Şekil 2.17. İleri beslemeli sinir ağı'nın (FNN) yapısal diyagramı, Guo (2020)'den uyarlanmıştır.	40
Şekil 2.18. CNN katmanları, Kouzehgar (2019)'dan uyarlanmıştır.	41
Şekil 2.19. RNN yapısı, Olah (2015)'den uyarlanmıştır.	43
Şekil 2.20. LSTM yapısı, Olah (2015)'den uyarlanmıştır.	44
Şekil 2.21. DCGAN mimarisi, Hayashi (2019)'den uyarlanmıştır.....	46
Şekil 2.22. Temel oto-kodlayıcı yapısı, Michelucci (2022)'den uyarlanmıştır.	47
Şekil 3.1. Sistematik literatür incelemesi makale seçim iş akışı (Prizma Flowchart).	56
Şekil 3.2. Yıllara göre makale sayıları.	57
Şekil 3.3. En fazla yayına sahip kaynaklar.	60
Şekil 3.4. Anahtar kelimeler için ortak görünüm ağ haritaları.	61
Şekil 3.5. Eğitim türleri.....	62
Şekil 3.6. Eğitim seviyeleri.....	62
Şekil 3.7. Veri seti türleri.....	65
Şekil 3.8. Veri seti kaynakları.....	65
Şekil 3.9. Önerilen DL modelleri.....	69
Şekil 3.10. Karşılaştırılan ML modelleri.	71
Şekil 3.11. Sınıflandırma türleri.....	71

Şekil 3.12. Sınıflandırma değerlendirme yöntemleri.	72
Şekil 4.1. Metodoloji iş akışı.	81
Şekil 4.2. Önerilen PSO-DNN modeli.	89
Şekil 4.3. Karşıtlık matrisi.	93
Şekil 4.4. ROC eğrisi.	95
Şekil 5.1. Yüksek korelasyon değerlerine sahip özelliklerin korelasyon matrisi. ...	106
Şekil 5.2. GPA ile yüksek korelasyona sahip özelliklere ait korelasyon matrisi.	106
Şekil 5.3. Lojistik regresyon sınıflandırma tablosu.	107
Şekil 5.4. Bağımsız değişkenlerin anlamlılık düzeyleri.	108
Şekil 5.5. Dersin yıllara göre geçme ve kalma durumu.	109
Şekil 5.6. Dönem başı model tahmin sonuçları.	111
Şekil 5.7. PSO-DNN karışıklık matrisi.	112
Şekil 5.8. RF karışıklık matrisi.	112
Şekil 5.9. PSO-DNN modelinin ROC Eğrisi.	113
Şekil 5.10. PSO-DNN modelinin kesinlik-hatırlama Eğrisi.	113
Şekil 5.11. Veri grubu kombinasyonlarına göre doğruluk değerleri.	116
Şekil 5.12. Erken tahmin doğruluk değerleri.	118
Şekil 5.13. SHAP küresel bar grafiği.	121
Şekil 5.14. İlk öğrencinin SHAP karar grafiği.	122
Şekil 5.15. İlk öğrencinin SHAP kuvvet grafiği.	123
Şekil 5.16. İkinci öğrencinin SHAP karar grafiği.	123
Şekil 5.17. İkinci öğrencinin SHAP kuvvet grafiği.	124
Şekil 5.18. İlk öğrencinin LIME grafiği.	124
Şekil 5.19. İkinci öğrencinin LIME grafiği.	125
Şekil 5.20. “Cinsiyet” ve “Engellilik Durumu” t_testi sonuçları.	126
Şekil 5.21. “Hazırlık Programında Geçirilen Dönem Sayısı” varyans sonuçları.	127
Şekil 5.22. “Hazırlık Programında Geçirilen Dönem Sayısı” post hoc testi sonuçları.	128
Şekil 5.23. “Hazırlık Programında Geçirilen Dönem Sayısı” Scheffe sonuçları.	128
Şekil 5.24. “Alınan Ders Sayısı” post hoc testi sonuçları.	129
Şekil 5.25. “Ders Tekrarı Sayısı” post hoc testi sonuçları.	129
Şekil 5.26. “Dersi Alan Öğrenci Sayısı” post hoc testi sonuçları.	130
Şekil 5.27. “Fizik Doğru Sayısı” post hoc testi sonuçları.	131
Şekil 5.28. “Matematik Yanlış Sayısı” Soru Sayısı post hoc testi sonuçları.	132

DERİN ÖĞRENME ALGORİTMALARI KULLANARAK ÖĞRENCİ AKADEMİK PERFORMANSININ ERKEN TAHMİNİ

ÖZET

Eğitim, bireylerin yaşam kalitesini artıran ve sosyo-ekonomik kalkınmayı destekleyen temel bir süreçtir. Ancak akademik başarısızlık, yalnızca öğrencilerin mezuniyet süreçlerini geciktirmekle kalmaz, aynı zamanda bireysel ve kurumsal düzeyde verimlilik kaybına yol açar. Bu durum, özellikle risk altındaki öğrencilerin erken dönemde tespit edilmesini kritik bir gereklilik haline getirmektedir. Araştırmalar, bir sınıfın genel akademik başarısının, en çok düşük performans gösteren öğrencilerin durumundan etkilendiğini ortaya koymaktadır. Dolayısıyla, bu öğrencilerin gelişimi, eğitim süreçlerinin etkinliğinin değerlendirilmesinde önemli bir gösterge olarak kabul edilir. Bununla birlikte, yüksek başarısızlık oranları ve sonucunda ortaya çıkan ders tekrarı gereksinimi, öğrenci motivasyonunu olumsuz etkilemekte ve eğitim kaynaklarının verimsiz kullanımına neden olmaktadır. Bu nedenle, veriye dayalı proaktif stratejilerin geliştirilmesi hem eğitim kalitesinin yükseltilmesi hem de toplumsal kalkınmanın sağlanması açısından büyük önem taşımaktadır.

Bu çalışma, akademik dönem başında öğrenci başarısını tahmin ederek potansiyel risk grubundaki bireyleri belirlemeyi ve eğitimcilere erken müdahale imkânı sunmayı amaçlayan yenilikçi bir hibrit model önermektedir. Modelin geliştirilmesinde, Derin Sinir Ağları (DNN) ile Parçacık Sürüsü Optimizasyonu (PSO) algoritması entegre edilmiştir. Derin sinir ağları, karmaşık ve çok boyutlu veri setlerinde yüksek doğruluklu öğrenme sağlayabilen güçlü bir yöntem olmakla birlikte, performansları hiperparametre optimizasyonunun etkinliğine bağlıdır. Bu noktada, PSO algoritması etkili bir optimizasyon aracı olarak devreye girmekte ve modelin tahmin başarısını önemli ölçüde artırmaktadır.

Araştırma, bir devlet üniversitesinin mühendislik fakültesinde öğrenim gören 1268 öğrencinin verileri üzerinde gerçekleştirilmiştir. Veri seti, demografik özellikler, akademik performans göstergeleri ve lise ile yükseköğretim giriş sınavı sonuçları olmak üzere üç ana kategoride toplanmıştır. Toplamda 12 öngörücü değişken üniversite performansını yansıtırken, 50 değişken lise dönemindeki akademik becerileri temsil etmektedir. Başarı durumu, öğrencilerin belirli bir dersi geçme veya kalma durumuna göre “geçti” ve “kaldı” olarak sınıflandırılmıştır. Ayrıca çalışma öğrencilerin lise ve yükseköğretim giriş sınavı sonucu performanslarına dayalı olarak akademik başarılarını tahmin etmeyi, dönem içi performans verilerinin etkisini incelemeyi ve en etkili öznitelikleri belirlemeyi de amaçlamaktadır.

Bu çalışmada, öğrencilerin akademik başarılarının erken dönemde tahmin edilebilmesi amacıyla sekiz temel aşamada çalışma gerçekleştirilmiştir. İlk aşamada, model eğitimi öncesinde veri setinde yer alan gereksiz, düşük bilgi değerine sahip veya yüksek derecede birbirleriyle ilişkili değişkenlerin elenmesi amacıyla korelasyon temelli bir özellik seçimi yöntemi olan Pearson korelasyon analizi uygulanmıştır. Belirlenen 0.95 eşik değeri doğrultusunda birbirleriyle yüksek korelasyona sahip özellik çiftleri tespit edilmiş ve GPA ile düşük korelasyon gösteren bir özellik gereksiz olarak

değerlendirilmiş ve veri setinden çıkarılarak özellik seçimi gerçekleştirilmiştir. Bu kapsamda, “Diploma Notu”, “Yerleştirme Puanı”, “TYT Puanı”, “SAY Puanı”, “TYT Başarı Sıralama Yüzdesi” ve “SAY Başarı Sıralama Yüzdesi” özellikleri analiz dışı bırakılmıştır.

İkinci aşamada, bağımsız değişkenlerin GPA üzerindeki etkilerini değerlendirmek ve en yüksek tahmin gücüne sahip değişkenleri belirlemek amacıyla lojistik regresyon analizi uygulanmıştır. Bu analizle, modelin açıklayıcı gücünü en çok artıran öznitelikler istatistiksel olarak değerlendirilmiştir. GPA en güçlü etkiye sahip değişkenin, -0,811 B katsayısıyla negatif yönde etkili olan “Ders Tekrarı Sayısı” olduğu tespit edilmiştir. Bunun yanı sıra, “Hazırlık Programında Geçirilen Dönem Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Lise Başarı Puanı” ve “Fizik Doğru Sayısı” gibi öznitelikler %5 anlamlılık düzeyinde modelde istatistiksel olarak anlamlı bulunmuştur.

Üçüncü analizde, DPH verileri (demografik bilgiler + akademik performans + lise ve yükseköğretim giriş sınavı sonuçları) kullanılarak, geliştirilen hibrit PSO-DNN modeli, geleneksel makine öğrenmesi ve klasik DNN yöntemleriyle dönem başında karşılaştırılmıştır. Yapılan deneyler, PSO-DNN modelinin en yüksek doğruluk (%63,3), F1 skoru (%56,1), kesinlik (%63,8) ve duyarlılık (%63,3) değerlerine ulaştığını göstermiştir. Özellikle “Kaldı” sınıfının tahmininde PSO-DNN modeli, daha yüksek doğruluk ve duyarlılık değerleri elde etmiştir. Sonuç olarak, PSO-DNN modeli, dönem başında öğrenci başarısını tahmin etmede genel performans açısından güçlü ve etkili bir yöntem olarak öne çıkmaktadır.

Dördüncü aşamada, dönem başında veri gruplarının ayrı ayrı ve birlikte kullanıldığı veri kombinasyonlarının, öğrenci başarısını tahmin etme etkinliği incelenmiştir. En yüksek doğruluk değeri %65,4 ile önerilen PSO-DNN modeli ve P (akademik) veri grubunda elde edilmiştir. Önerilen model, DPH kombinasyonu ile %63,3 doğruluk, %56,1 F1 skoru, %63,8 kesinlik ve %63,3 duyarlılık değerleri elde etmiştir. Bu değerler, özellikle lise başarı puanları ve üniversiteye giriş sınav sonuçlarının tahmin gücünü artırdığını göstermektedir. Genel olarak PSO-DNN modeli, doğruluk açısından diğer modellerden daha iyi performans göstermiştir. Karşılaştırmalı olarak en yakın sonuçları Rasgele Orman modeli vermiştir; Karar Ağaçları ise en düşük başarıyı göstermiştir. Bu sonuçlar, karmaşık yapıları modellerin daha fazla değişkenle daha başarılı tahminler yapabildiğini göstermektedir.

Beşinci analizde, ara sınav, kısa sınav, ödev ve proje çalışması gibi dönem içi değişkenler modele eklenerek, tahminlerin dönem başı, ara sınav öncesi ve final öncesi olmak üzere farklı zaman dilimlerinde değerlendirilmesi sağlanmıştır. En yüksek başarıyı dönem başında ve ara sınav öncesinde PSO-DNN modeli, final öncesinde ise RF modeli gerçekleştirmiştir. Final öncesinde tüm modellerin doğruluk, F1 skoru, kesinlik ve hatırlama değerlerinde önemli iyileşmeler kaydedilmiş, bu da daha fazla verinin tahmin performansını artırdığını göstermiştir.

Altıncı analizde, modelin genelleştirilebilirliğini test etmek amacıyla, yaygın kullanılan xAPI-Edu-Data veri seti kullanılmıştır. Bu veri seti ile yapılan testlerde önerilen PSO-DNN modeli sürü boyutu, maksimum iterasyon ve gizli katman sayısı gibi belirli sınırlamalara rağmen en yüksek performans gösteren iki modele yakın diğer modellerden ise daha iyi doğruluk değeri elde etmiştir.

Yedinci analizde ise SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi açıklanabilir yapay zeka (XAI) teknikleri uygulanarak modelin karar mekanizması şeffaflaştırılmıştır. Bu analizler,

modelin tahminlerinde en etkili olan öznitelikleri ortaya koymuş; “Dersi Alan Öğrenci Sayısı”, “Lise Başarı Puanı”, “Ders Tekrar Sayısı” ve “TYT Yerleştirme Puanı” gibi değişkenlerin etkili olduğu anlaşılmıştır.

Son aşama olan duyarlılık analizinde XAI bulguları, t-testi ve ANOVA sonuçlarıyla karşılaştırılmış ve yüksek derecede tutarlılık göstererek modelin istatistiksel açıdan güvenilirliğini desteklemiştir. Yapılan analizler, modelin belirli özelliklere karşı yüksek duyarlılık gösterdiğini ortaya koymuştur. Özellikle sınıf mevcudunun az olmasının başarı üzerinde olumlu etki yarattığı, dengeli dağıtılmış ders yükünün akademik performansı artırdığı, hazırlık eğitiminin istatistiksel açıdan anlamlı faydalar sağladığı ve STEM alanlarındaki başarının genel akademik sonuçlara önemli katkı sunduğu gözlemlenmiştir.

Çalışmanın sınırlılıkları arasında, tek bir üniversite ve dersle sınırlı olması, hiperparametre optimizasyonunda teknik kısıtlamalar ve hesaplama maliyetleri yer almaktadır. Gelecek çalışmalar için, modelin farklı eğitim kurumları ve disiplinlerde test edilmesi, optimizasyon tekniklerinin çeşitlendirilmesi, XAI yöntemlerinin derinleştirilmesi ve bulut tabanlı uygulamalarla yaygınlaştırılması önerilmektedir. Ayrıca, veri güvenliği ve gizliliğinin sağlanmasına yönelik çalışmaların artırılması, modelin pratik uygulamalarda daha etkin kullanılmasını sağlayacaktır.

Sonuç olarak, bu çalışma, eğitim alanında veriye dayalı karar alma süreçlerine önemli katkılar sunmaktadır. Geliştirilen PSO-DNN modeli, öğrencilerin akademik performanslarını erken dönemde tahmin ederek, eğitimcilere ve politika yapıcılara rehberlik etme potansiyeli taşımaktadır. Modelin açıklanabilirliği ve şeffaflığı, eğitim ortamlarında yapay zekâ tabanlı sistemlere olan güveni artırabilir. Gelecekte, bu tür modellerin yaygınlaşmasıyla, kişiselleştirilmiş eğitim stratejilerinin geliştirilmesi ve öğrenci başarısının küresel ölçekte artırılması mümkün olacaktır.



EARLY PREDICTION OF STUDENT ACADEMIC PERFORMANCE USING DEEP LEARNING ALGORITHMS

SUMMARY

Education is a fundamental process that enhances individuals' quality of life and supports socio-economic development. However, academic failure not only delays students' graduation but also leads to productivity losses at both individual and institutional levels. This situation makes it critically necessary to identify at-risk students at an early stage. Research shows that the overall academic success of a class is most affected by the performance of low-achieving students. Therefore, the progress of these students is considered a key indicator in evaluating the effectiveness of educational processes. Moreover, high failure rates and the resulting need for course repetition negatively impact student motivation and lead to inefficient use of educational resources. For this reason, developing data-driven proactive strategies is of great importance in terms of improving educational quality and ensuring societal development.

This study proposes an innovative hybrid model aimed at predicting student success at the beginning of the academic term and identifying individuals in potential risk groups, thereby offering educators the opportunity for early intervention. The model integrates Deep Neural Networks (DNN) with the Particle Swarm Optimization (PSO) algorithm. While DNNs are powerful methods capable of high-accuracy learning in complex and multidimensional datasets, their performance highly depends on effective hyperparameter optimization. At this point, the PSO algorithm serves as an efficient optimization tool and significantly enhances the model's predictive performance.

The research was conducted using data from 1,268 students enrolled in the engineering faculty of a public university. The dataset is categorized into three main groups: demographic characteristics, academic performance indicators, and results from high school and higher education entrance exams. A total of 12 predictor variables represents university performance, while 50 variables reflect academic skills acquired during high school. Success status was classified as "pass" or "fail" based on students' ability to pass a specific course. Additionally, the study aims to predict academic success based on high school and entrance exam performance, evaluate the impact of in-term performance data, and identify the most influential attributes.

The study was conducted in eight main stages to enable early prediction of students' academic performance. In the first stage, Pearson correlation analysis was applied as a correlation-based feature selection method to eliminate redundant, low-information, or highly interrelated variables from the dataset before model training. Based on a threshold of 0.95, highly correlated variable pairs were identified, and variables with low correlation to GPA were considered unnecessary and removed. Accordingly, "Diploma Grade", "Placement Score", "TYT Score", "SAY Score", "TYT Success Ranking Percentage", and "SAY Success Ranking Percentage" were excluded from the analysis.

In the second stage, logistic regression analysis was conducted to assess the impact of independent variables on GPA and to identify the most powerful predictors. Through this analysis, features that significantly increased the explanatory power of the model were evaluated statistically. The variable with the strongest impact on GPA was identified as “Number of Course Repeats”, which had a negative effect with a B coefficient of -0.811. Additionally, variables such as “Number of Semesters in Preparatory Program”, “Number of Students Taking the Course”, “Number of Course Repeats”, “High School Achievement Score”, and “Physics Correct” were found to be statistically significant at the 5% level.

In the third analysis, using the DPH dataset (demographics + academic performance + entrance exam results), the proposed hybrid PSO-DNN model was compared with traditional machine learning and classic DNN methods at the beginning of the term. Experiments showed that the PSO-DNN model achieved the highest accuracy (63.3%), F1 score (56.1%), precision (63.8%), and recall (63.3%). Especially for the “fail” class, the PSO-DNN model yielded higher accuracy and recall. Thus, the PSO-DNN model stands out as a robust and effective approach for early prediction of student performance.

In the fourth stage, the effectiveness of different data combinations—used separately and together—on predicting student success at the beginning of the term was examined. The highest accuracy of 65.4% was achieved using the academic (P) data group with the proposed PSO-DNN model. Using the full DPH combination, the model reached 63.3% accuracy, 56.1% F1 score, 63.8% precision, and 63.3% recall. These results indicate that high school grades and entrance exam scores significantly improve prediction accuracy. Overall, the PSO-DNN model outperformed other models in terms of accuracy. The closest results came from the Random Forest model, while Decision Trees showed the lowest performance. These findings highlight that complex model can make better predictions when using more variables.

In the fifth analysis, in-term variables such as midterms, quizzes, assignments, and projects were added to the model to evaluate predictions at different times: start of term, before midterms, and before finals. The PSO-DNN model performed best at the start of term and before midterms, while the RF model performed best before finals. Notably, all models showed significant improvements in accuracy, F1 score, precision, and recall before finals, demonstrating that more data improves prediction performance.

In the sixth analysis, the model’s generalizability was tested using the widely used xAPI-Edu-Data dataset. Despite certain limitations such as swarm size, maximum iterations, and number of hidden layers, the PSO-DNN model achieved performance close to the top two models and better than others in terms of accuracy.

In the seventh analysis, explainable artificial intelligence (XAI) techniques such as SHAP (SHapley Additive exPlanations) and LIME (Local Interpretable Model-agnostic Explanations) were applied to make the model’s decision-making process transparent. These analyses identified the most influential features in predictions, including “Number of Students Taking the Course”, “High School Achievement Score”, “Number of Course Repeats”, and “TYT Placement Score”.

In the final stage, a sensitivity analysis was conducted by comparing XAI findings with t-test and ANOVA results, which showed high consistency, supporting the model’s statistical reliability. The analysis revealed that the model is highly sensitive to certain features. Specifically, smaller class sizes had a positive effect on success, a

balanced course load improved academic performance, preparatory education had statistically significant benefits, and success in STEM subjects contributed significantly to overall academic outcomes.

The study's limitations include being limited to one university and one course, technical constraints in hyperparameter optimization, and computational costs. For future work, testing the model in different institutions and disciplines, diversifying optimization techniques, deepening the use of XAI methods, and expanding with cloud-based applications are recommended. Additionally, enhancing data security and privacy will allow for more effective use of the model in practical applications.

In conclusion, this study provides significant contributions to data-driven decision-making processes in education. The developed PSO-DNN model has the potential to guide educators and policymakers by predicting students' academic performance at an early stage. Its explainability and transparency can enhance trust in AI-based systems in educational environments. In the future, the widespread adoption of such models may enable the development of personalized education strategies and globally improve student success.



1. GİRİŞ

Eğitim, bireylerin belirli alanlarda gelişimlerini desteklemek ve toplumun yaratıcılığı ile verimliliğini artırmak amacıyla kullanılan temel bir araçtır. Öğretim ise, okullarda nitelikli ve profesyonel bir şekilde, planlı ve programlı olarak verilen bir eğitim sürecidir. Eğitim sürecine dâhil olan bireyler için, öğrenme içeriği, yöntemleri, süreleri ve hedefleri önceden planlanır ve bu plan, süreç boyunca minimal değişikliklerle uygulanır. Alınan eğitim ve öğretimin kalitesi, bireyin eğitim sürecindeki aşamasına bağlı olarak farklı ölçütlerle değerlendirilebilir. Türkiye’de özellikle lise ve yükseköğretim düzeyleri arasında kayda değer farklar bulunmakta olup, bu farklar çeşitli sınavlarla ölçümlenmektedir. Örneğin, 4+4+4 eğitim sistemi sonrasında, öğrencilerin ilkökul ve ortaokul süreçlerindeki başarıları, lise yerleştirme sınavı sonuçlarına yansımakta; fen liseleri, Anadolu liseleri ve diğer lise türlerine yerleşim oranları bu etkinliğin bir göstergesi olarak kullanılmaktadır. Benzer şekilde, lise eğitiminin kalitesi ise yükseköğretim giriş sınavı sonuçları üzerinden değerlendirilmekte ve bu sınavdaki sayısal, sözel ve eşit ağırlık gibi puan türlerinde elde edilen başarı oranları temel alınmaktadır.

Yükseköğretimde ise eğitimin etkinliği ve öğretim planlarının başarısı, mezun olan öğrencilerin sayısı ve bu mezunların iş gücüne katılım oranlarıyla ilişkilendirilmektedir. Ancak, yalnızca mezun sayısı gibi genel göstergelere odaklanmak, eğitim süreçlerinin bütünsel bir değerlendirmesini yapmada yetersiz kalabilir. Bunun yerine, ilgili programların içeriğindeki derslerin performansını ölçmek ve öğrencilerin akademik gelişimini daha erken aşamalarda değerlendirmek, daha anlamlı sonuçlar ortaya koyabilir. Bu bağlamda, öğrencilerin akademik performanslarının erken dönemde tahmin edilmesi, öğrenme sürecine uyum sağlamakta zorluk çeken bireylere zamanında müdahale etme imkânı sunar ve eğitimin etkinliğini artırabilir.

Özellikle yükseköğretim düzeyinde, öğrencilerin akademik performansları bireysel ihtiyaçlarına ve önceki eğitim süreçlerinde kazandıkları bilgi ve becerilere göre farklılık göstermektedir. Örneğin, mühendislik öğrencilerinin akademik başarılarını

tahmin ederken, lise düzeyindeki matematik, fizik ve kimya gibi derslerdeki başarıları önemli bir gösterge olarak değerlendirilebilir. Çünkü mühendislik eğitimi, bu derslerde kazanılan temel bilgi ve beceriler üzerine inşa edilmektedir. Ancak, öğrencilerin lise diplomaları veya yükseköğretim giriş sınavı sonuçları gibi geleneksel ölçütler, literatürde akademik performansın erken tahmininde yeterince kullanılmamıştır. Dahası, öğrencilerin yüz yüze eğitim bağlamındaki akademik performanslarını tahmin etmeye yönelik çalışmalar oldukça sınırlıdır. Literatürdeki mevcut çalışmaların büyük bir kısmı çevrimiçi eğitim ortamlarına odaklanmış olup, öğrencilerin performansını ders esnasındaki öğrenme süreçlerinden ziyade ders dışındaki faaliyetlerine dayalı olarak değerlendirmiştir. Bu durum, yüz yüze eğitimde kullanılan tahmin modellerinin geliştirilmesi için daha fazla araştırma yapılması gerektiğini göstermektedir.

Son dönemde derin öğrenme modelleri, karmaşık eğitim verilerindeki desenleri belirlemede büyük bir potansiyel sergilemiş, ancak bu modellerin etkinliği kullanılan veri miktarı, veri kalitesi ve hiperparametre ayarlarına bağlı olarak değişiklik göstermiştir. Derin öğrenme yöntemlerinin bu karmaşıklığı, eğitimciler arasında güven oluşturma konusunda zorluklara neden olabilir. Model tahminlerinin açıklanabilirliği ve şeffaflık düzeyi düşük olduğunda, bu yöntemlerin eğitim ortamlarında benimsenmesi sınırlı kalabilmektedir.

Bu bağlamda, bu çalışma, üniversitelerde yüz yüze eğitim alan öğrencilerin akademik performanslarının erken dönemde tahmin edilmesini amaçlamaktadır. Amacımızı yerine getirmek için parçacık sürüsü optimizasyonu (PSO) ve derin sinir ağları (DNN) kombinasyonunu içeren hibrit bir tahmin modeli önerilmektedir. Tahmin modelinin girdileri lise düzeyinde kazanılan akademik beceriler, yükseköğretim giriş sınavı sonuçları, üniversite akademik verileri ve demografik özellikler gibi çok çeşitli değişkenleri içerirken çıktı değişkeni öğrencilerin bir ders kapsamında geçme veya kalma durumudur. Çalışma, yükseköğretim giriş sınavı sonuçlarının önemini vurguladığından, yalnızca mühendislik programı ve tek bir kurum ile sınırlandırılmıştır. Bu bağlamda, farklı öğretim üyeleri tarafından verilen ve düşük başarı oranlarına sahip olan “Programlama” dersi seçilmiş; bu ders, modelin genel uygulanabilirliğini test etmek amacıyla analiz edilmiştir.

Ayrıca, modelin etkinliği xAPI-Edu-Data veri seti kullanılarak değerlendirilmiş ve önerilen hibrit modelin sonuçları literatürdeki diğer beş çalışma ile karşılaştırılmıştır.

Önerilen modelin üstün performansını açıklamak ve elde edilen sonuçları daha iyi anlamlandırmak için SHAP ve LIME gibi açıklanabilir yapay zeka (XAI) yöntemleri kullanılmıştır.

Bu tez şu şekilde düzenlenmiştir: Bölüm 2 eğitsel veri madenciliği, öğrenci performans tahmini, makine öğrenmesi, derin öğrenme ve açıklanabilir yapay zeka (XAI) ile ilgili kavramsal bilgiler içermektedir. Bölüm 3 literatür taramasına ayrılmış olup, literatürde eğitsel veri madenciliği ve derin öğrenme modelleri ile ilgili sistematik ve bibliyometrik analizler sunulmuştur. Bölüm 4, önerilen hibrit derin öğrenme modeline ilişkin metodolojiyi ele almakta olup, kavramsal model, veri toplama ve işleme süreçleri, model geliştirme adımları, eğitim ve değerlendirme yöntemleri detaylı bir şekilde açıklanmıştır. Bölüm 5 modelin uygulanması ve sonuçları ile ilgilidir. Bu bölümde, önerilen modelin performansı istatistiksel analizlerle ve karşılaştırmalı değerlendirmelerle incelenmiş, SHAP ve LIME gibi açıklanabilir yapay zeka yöntemleri kullanılarak model sonuçları detaylandırılmıştır. Son olarak, Bölüm 6, çalışmanın ana bulgularını özetlemekte, sınırlılıklarını tartışmakta ve gelecekteki araştırmalar için öneriler sunmaktadır.



2. EĞİTSEL VERİ MADENCİLİĞİ


2.1. Giriş

Eğitimsel Veri Madenciliği (EVM), eğitim alanında ortaya çıkan verilerin analiz edilerek öğrenme süreçlerinin ve eğitim ortamlarının daha iyi anlaşılmasını amaçlayan bir disiplindir. Baker ve Eğitimsel Veri Madenciliği Dergisi, EVM'yi, eğitimsel bağlamlardan elde edilen özgün veri türlerini incelemek için yöntemler geliştiren ve bu yöntemler aracılığıyla öğrenciler ile öğrenme ortamları hakkında daha derin bir kavrayış sağlamaya çalışan bir alan olarak tanımlamaktadır [1, 2]. Bu tanım, veri madenciliği kavramını doğrudan kullanmasa da, eğitimle ilgili veriler üzerinde çeşitli analitik yaklaşımların uygulanabileceğini ima etmektedir [3].

Bununla birlikte, bazı kaynaklar EVM'yi daha net bir şekilde veri madenciliği tekniklerinin eğitimsel verilere uygulanması olarak ele almaktadır. EVM hem bir öğrenme bilimi hem de artan eğitimsel veri kaynakları sayesinde veri madenciliği için geniş bir uygulama alanı sunmaktadır [4]. Bu alan, mevcut eğitim uygulamalarını ve öğrenme materyallerini geliştirmek amacıyla veriye dayalı karar alma süreçlerini desteklemektedir.

Romero ve Ventura ise EVM'yi, eğitim ortamlarından elde edilen belirli veri kümelerine veri madenciliği tekniklerinin uygulanması ve bu sayede eğitimle ilgili önemli sorulara yanıt aranması olarak açıklamaktadır. Bu tanımlar, detaylarda farklılık gösterse de, ortak noktaları eğitimsel verilerden yararlanarak bilgi keşfetmek ve eğitim sistemlerini iyileştirmektir [5, 6].

EVM, üç ana alanın birleşimi olarak tanımlanabilir (Şekil 2.1): bilgisayar bilimi, eğitim ve istatistik. Bu üç alanın kesişimi, aynı zamanda öğrenme analitiği, bilgisayar tabanlı öğrenme ortamları, veri madenciliği ve makine öğrenmesi (MÖ) gibi EVM ile doğrudan ilişkili alt disiplinleri de ortaya çıkarmaktadır [6].




Şekil 2.1. EVM ile ilişkili alanlar, Romero ve Ventura (2013)’ten uyarlanmıştır.

Disiplinler arası bir alan olarak EVM, istatistik, makine öğrenmesi, veri madenciliği, bilgi erişimi, öneri sistemleri, psiko-pedagoji, bilişsel psikoloji, psikometri vb. alanlardan yöntemler kullanır ve teknikler uygular. Hangi yöntem veya tekniğin kullanılacağı, ele alınan eğitimsel soruna bağlı olarak değişiklik gösterir.

EVM, farklı öğrenme ortamlarından elde edilen verileri kullanarak eğitimsel sorunların çözümüne katkıda bulunmayı hedefler. Geleneksel yüz yüze eğitim, bilgisayar destekli eğitim ve karma öğrenme ortamları, her biri farklı türde veri kaynakları sunmaktadır [7]. İnternet teknolojilerindeki ilerlemeler ve bu teknolojilerin geniş kitlelere ulaşması, çevrimiçi öğrenme platformlarının eğitim alanında önemli bir yer edinmesine yol açmıştır. Bu ortamlar arasında Öğrenme Yönetim Sistemleri (LMS), Sanal Sınıf Uygulamaları, Kitlese Açık Çevrimiçi Dersler (MOOCs), Çevrimiçi İşbirlikçi Öğrenme Platformları, Zeki Öğretim Sistemleri, Uyarlanabilir ve Zeki Hipermedya Sistemleri, Test ve Sınav Sistemleri ve E-Öğrenme Portalları gibi elektronik platformlar yer almaktadır [8]. EVM’de kullanılan veriler, yalnızca öğrencilerin bireysel olarak eğitim ortamlarındaki etkileşim verileri (örneğin, sistemdeki gezinti bilgileri, sınav sonuçları ve alıştırma performansları) ile sınırlı değildir. Aynı zamanda, grup çalışmaları sırasında öğrenciler tarafından üretilen veriler (örneğin, yazılı sohbet kayıtları), idari veriler (örneğin, okul, okul bölgesi ve öğretmen bilgileri) ve demografik veriler (örneğin, yaş, cinsiyet, akademik notlar) de EVM’de kullanılmaktadır [9]. Tüm bu veri kaynakları ile birlikte işleyen eğitsel veri madenciliği süreci, uygulamaları, yöntemleri alt bölümlerde açıklanmaktadır.

2.1.1. EVM süreci


EVM sürecinde, eğitim ortamlarından elde edilen işlenmemiş veriler, eğitimle ilgili çalışmalar ve uygulamalar üzerinde önemli sonuçlar doğurabilecek faydalı bilgiler haline getirilmektedir. Bu süreç, Veri Madenciliği'nin iş, genetik, tıp gibi diğer alanlardaki uygulamalarından çok farklı değildir, çünkü genel Veri Madenciliği yaklaşımıyla aynı temel adımları içermektedir [5]. EVM sürecinde izlenen veri madenciliği uygulama süreci Şekil 2.2'de gösterilmiştir.



Şekil 2.2. Eğitimsel veri madenciliğinde veri madenciliği uygulama süreci, Romero ve Ventura (2013)'ten uyarlanmıştır.

Bu süreç, eğitim ortamından incelenecek verilerin toplanması veya seçilmesiyle başlar. Elde edilen ham veriler, EVM sürecinin en kritik ve önemli aşaması olan veri ön işleme adımıyla madencilik süreci için uygun bir formata dönüştürülmektedir. Sonraki aşamada, hazırlanan verilere Veri Madenciliği teknikleri uygulanır. EVM’de, sınıflandırma, görselleştirme, birliktelik analizi ve kümeleme gibi geleneksel Veri Madenciliği teknikleri başarıyla kullanılmaktadır. Bu teknikler, “EVM Yöntemleri”

başlığı altında detaylı olarak açıklanmaktadır. Eğitim sistemlerinde Veri Madenciliği uygulama döngüsü Şekil 2.3'te gösterilmiştir. Şekil 2.3'te gösterildiği gibi, eğitim sistemlerinin tasarımı, planlaması, kurulumu ve sürdürülmesi eğitimciler ve akademisyenler tarafından gerçekleştirilir. Öğrenciler ise bu sistemleri kullanır ve onlarla etkileşime girer. Dersler, öğrenci profilleri, sistem kullanımı ve etkileşim verileri gibi mevcut tüm bilgilerden yararlanılarak, e-öğrenme sürecini geliştirmeye yönelik faydalı bilgiler ortaya çıkarılmak üzere çeşitli veri madenciliği teknikleri uygulanabilir. Bu bilgiler, hem eğitimciler hem de öğrenciler tarafından kullanılabilir.



Şekil 2.3. Eğitimde veri madenciliği uygulama döngüsü, Romero ve Ventura (2007)'den uyarlanmıştır.

Eğitsel veri madenciliği sürecinin son aşaması, elde edilen sonuçların analiz edilerek yorumlanması ve değerlendirilmesidir. Eğitim verilerinin çeşitliliği bu süreci karmaşık hale getirebilir. Bu nedenle, istatistiksel analizler, makine öğrenmesi algoritmaları ve veri görselleştirme gibi araçlar kullanılarak veriler anlamlandırılır. Elde edilen bulgular, müfredat tasarımı, öğretim yöntemleri ve öğrenci destek sistemleri gibi alanlarda iyileştirmeler yapmak için kullanılır. Bu aşamada, verilerin eğitimsel amaçlara uygun şekilde değerlendirilmesi ve etik-gizlilik konularının dikkate alınması kritik öneme sahiptir.

2.1.2. EVM kullanıcıları/paydaşları

Eğitimde Veri Madenciliği (EVM), farklı kullanıcı grupları ve paydaşlar için çeşitli amaçlara hizmet eden geniş bir alandır. İlk bakışta EVM'nin yalnızca öğrenciler ve öğretmenler gibi iki temel gruba hitap ettiği düşünülebilir, ancak Tablo 2.1'de görüleceği üzere bu alan, daha geniş bir kullanıcı yelpazesine sahiptir [5].

Tablo 2.1. EVM kullanıcıları.

Kullanıcılar / Aktörler	Veri Madenciliği Kullanım Amaçları
Öğrenenler / Öğrenciler	E-öğrenmeyi kişiselleştirmek; öğrencilere öğrenmelerini daha da geliştirebilecek aktiviteler, kaynaklar ve öğrenme görevleri önermek; ilginç öğrenme deneyimleri önermek; yol kısaltma veya takip edilecek bağlantılar önermek; uyarlanabilir ipuçları oluşturmak; kurslar, ilgili tartışmalar vb. önermek.
Eğitimciler / Öğretmenler / Eğitimciler / Öğreticiler	Öğretim hakkında objektif geri bildirim almak; öğrencilerin öğrenme ve davranışlarını analiz etmek; desteğe ihtiyacı olan öğrencileri tespit etmek; öğrenci performansını tahmin etmek; öğrencileri gruplara ayırmak; öğrencinin düzenli ve düzensiz kalıplarını bulmak; en çok yapılan hataları tespit etmek; en etkili aktiviteler belirlemek; kursların uyarlanmasını ve özelleştirilmesini iyileştirmek vb.
Kurs Geliştiricileri / Eğitim Araştırmacıları	Kurs materyalini değerlendirmek ve sürdürmek; öğrenci öğrenimini iyileştirmek; kurs içeriğinin yapısını ve öğrenme sürecindeki etkinliğini değerlendirmek; otomatik olarak öğrenci modelleri ve öğretici modelleri oluşturmak; veri madenciliği tekniklerini karşılaştırarak her görev için en kullanışlı olanı önermek; eğitim amaçlı özel veri madenciliği araçları geliştirmek vb.
Kuruluşlar / Öğrenme Sağlayıcıları / Üniversiteler / Özel Eğitim Şirketleri	Yüksek öğrenim kurumlarında karar süreçlerini geliştirmek; karar verme sürecinde verimliliği artırmak; belirli hedeflere ulaşmak; her öğrenci sınıfı için değerli olabilecek belirli kurslar önermek; retansiyon ve notları iyileştirmenin en uygun maliyetli yolunu bulmak; mezuniyet için en nitelikli adayları seçmek; üniversitede başarılı olacak öğrencileri kabul etmeye yardımcı olmak vb.
Yöneticiler / Okul Bölgesi Yöneticileri / Ağ Yöneticileri / Sistem Yöneticileri	Kurumsal kaynakları (insan ve malzeme) ve eğitim tekliflerini en iyi şekilde organize etmek; mevcut kaynakları daha etkili kullanmak; eğitim programı tekliflerini geliştirmek ve uzaktan eğitim yaklaşımının etkinliğini belirlemek; öğretmen ve müfredatı değerlendirmek; web sitesi verimliliğini artırmak ve kullanıcılara uyarlamak için parametreler belirlemek (optimal sunucu boyutu, ağ trafiği dağılımı vb.).

2.1.3. EVM uygulama alanları ve görevleri

Eğitim ortamlarında veri madenciliği teknikleri, birçok problemin çözümüne katkı sağlayabilecek geniş bir uygulama yelpazesine sahiptir. Araştırmacılar, bu alanda yapılan çalışmaları analiz ederek EVM'nin kullanım alanlarını ve işlevlerini kategorize etmişlerdir. Bu alandaki öncü çalışmalardan birini Castro, Vellido, Nebot ve Mugica (2007) tarafından gerçekleştirilmiştir. Bu çalışmada, EVM'nin görev ve konu alanları şu şekilde sınıflandırılmıştır: öğrenci performansının değerlendirilmesi, öğrenme davranışına dayalı ders uyarlamaları, öğrenme materyallerinin değerlendirilmesi, web tabanlı e-öğrenme kurslarında geri bildirim sağlama ve atipik öğrenci davranışlarının tespiti [10].

Baker ve Yacef (2009), EVM'nin dört temel uygulama alanını öne sürmüştür: öğrenci modellerinin iyileştirilmesi, alan bilgisi modellerinin geliştirilmesi, etkili pedagojik destek sağlama ve öğrenme teorilerini destekleyen deneysel çalışmalar [11].

Peña-Ayala, Domínguez ve Medel (2009), 91 araştırmayı inceleyerek EVM'nin uygulama alanlarını dört ana kategoriye ayırmıştır: öğrenci modelleme, öğretim, içerik ve değerlendirme [12].

Romero ve Ventura (2010) ise EVM'nin uygulama alanlarını daha detaylı bir şekilde ele alarak aşağıdaki başlıklarda sınıflandırmıştır [5]:

- **Veri Analizi ve Görselleştirme:** Bu alan, eğitimciler ve yöneticiler için öğrenci etkinliklerini analiz etme ve karar verme süreçlerini destekleme amacıyla kullanılır. İstatistiksel analizler ve veri görselleştirme teknikleri bu görevde sıkça kullanılan yöntemlerdir.
- **Eğitimcilere Geri Bildirim Sağlama:** Bu görev, eğitimcilere öğrencilerin öğrenme süreçlerini iyileştirme ve kaynakları daha etkili kullanma konusunda rehberlik etmeyi amaçlar. Birlikte kuralları gibi VM teknikleri bu alanda yaygın olarak kullanılır.
- **Öğrencilere Kişiselleştirilmiş Öneriler Sunma:** Bu alan, öğrencilerin bireysel ihtiyaçlarına uygun öğrenme materyalleri, görevler ve bağlantılar önermeyi hedefler. Birlikte kuralı madenciliği, kümeleme ve sıralı örüntü madenciliği bu görevde sıkça kullanılan tekniklerdir.

- Öğrenci Performansının Modellenmesi: Bu görev, öğrencilerin performansını tahmin etmeye yöneliktir. Regresyon analizi, yapay sinir ağları ve Bayes ağları gibi teknikler bu alanda kullanılır.
- İstenmeyen Öğrenci Davranışlarının Tespiti: Bu alan, hile, düşük motivasyon veya akademik başarısızlık gibi atipik davranışları tespit etmeyi hedefler. Sınıflandırma ve kümeleme teknikleri bu görevde kullanılır.
- Öğrencilerin Gruplandırılması: Öğrencileri benzer özelliklerine göre gruplara ayırarak kişiselleştirilmiş öğrenme deneyimleri sunmayı amaçlar. Kümeleme ve sınıflandırma teknikleri bu alanda kullanılır.
- Sosyal Ağ Analizi: Öğrenciler arasındaki sosyal ilişkileri inceleyerek iş birliği ve bilgi paylaşımını analiz etmeyi hedefler. İşbirlikli filtreleme bu alanda sıkça kullanılan bir tekniktir.
- Kavram Haritaları Geliştirme: Eğitimcilere otomatik kavram haritaları oluşturma konusunda yardımcı olmayı amaçlar. Birliktelik kuralları ve metin madenciliği teknikleri bu görevde kullanılır.
- Ders Yazılımlarının Yapılandırılması: Öğrenme materyallerinin otomatik olarak yapılandırılmasını ve yeniden kullanılabilirliğini sağlamayı hedefler. Kümeleme ve Naive Bayes teknikleri bu alanda kullanılır.
- Planlama ve Zamanlama: Kurs planlama, kaynak yönetimi ve müfredat geliştirme gibi süreçleri desteklemeyi amaçlar. Birliktelik kuralları ve karar ağaçları bu görevde kullanılan tekniklerdir.

Peña-Ayala (2014), 2010-2013 yılları arasında yayınlanan 240 çalışmayı analiz ederek EVM uygulamalarını altı temel kategori altında sınıflandırmıştır. Bu kategoriler şunlardır: öğrenci davranışlarını modelleme, öğrenci performansını modelleme, değerlendirme, öğrenci modelleme, öğrenci destek/geri bildirim ve müfredat, alan bilgisi, sıralama ve öğretmen desteği [13].

2.1.4. EVM yöntemleri

Eğitimde Veri Madenciliği (EVM), hem teorik (örneğin, öğrenme hipotezlerini incelemek) hem de pratik (örneğin, öğrenme araçları geliştirmek) amaçlarla eğitimsel verilere ve sorunlara odaklanan bir disiplindir. EVM, eğitim alanında kullanılmak üzere veri madenciliği teknikleri geliştirerek ve bu teknikleri araştırarak metodolojik katkılar sunmaktadır [9]. EVM yöntemleri, veri madenciliği ve makine öğrenmesi,

psikometri, istatistik, bilgi görselleştirme ve hesaplamalı modelleme gibi çeşitli alanlardan beslenen tekniklerden oluşmaktadır [11].

EVM yöntemlerini sınıflandırmaya yönelik ilk çalışmalardan birini Romero ve Ventura (2007) gerçekleştirmiştir. Bu çalışmada, 1995-2005 yılları arasında yayımlanan makaleler incelenmiş ve EVM yöntemleri iki ana kategoriye ayrılmıştır: istatistik ve görselleştirme ile web madenciliği. Web madenciliği ise kendi içinde kümeleme, sınıflandırma ve aykırı değer tespiti, birliktelik kuralı madenciliği, ardışık örüntü madenciliği ve metin madenciliği olarak alt kategorilere ayrılmıştır [7]. Romero ve Ventura (2010), en sık kullanılan EVM yöntemlerinin regresyon, kümeleme, sınıflandırma ve birliktelik kuralı madenciliği olduğunu, en popüler tekniklerin ise karar ağaçları, yapay sinir ağları ve Bayes ağları olduğunu belirtmiştir [5]. Geleneksel veri madenciliği tekniklerinin (sınıflandırma, kümeleme, birliktelik analizi gibi) eğitim alanında başarıyla uygulandığı bilinmektedir. Ancak, eğitim sistemleri bazı özel özelliklere sahiptir ve bu nedenle öğrenme süreçleri ve öğrenenlerle ilgili verileri analiz etmek için özelleştirilmiş veri madenciliği tekniklerine ihtiyaç duyulmaktadır [14]. Bu doğrultuda, Romero ve Ventura 2007, 2013 ve 2010 yıllarında yaptıkları çalışmaları güncelleyerek EVM alanında kullanılan yöntemleri detaylı bir şekilde sınıflandırmıştır. Bu sınıflandırmada tahmin, kümeleme, aykırılık tespiti, ilişki madenciliği, sosyal ağ analizi, süreç madenciliği, metin madenciliği, verilerin damıtılması, modellerle keşif, bilgi takibi ve negatif olmayan matris ayrışımı gibi yöntemler yer almaktadır [5–7].

Bousbia ve Belamri (2014), Romero ve Ventura'nın (2007, 2010, 2013) çalışmalarından yola çıkarak EVM yöntemlerini yeniden ele almış ve şu şekilde sınıflandırmıştır [15]:

- Tahmin: Bu yöntem, verinin belirli bir yönünü diğer yönlerinden hareketle ortaya çıkaran bir model geliştirmeyi amaçlar. Tahmin yöntemleri arasında sınıflandırma (kategorik değişkenlerin tahmini), regresyon (sürekli verilerin tahmini) ve yoğunluk tahmini (olasılık yoğunluk fonksiyonlarının tahmini) bulunur. EVM'de öğrencilerin akademik başarılarının veya davranışlarının tahmin edilmesi amacıyla kullanılır.
- Kümeleme: Bu yöntem, doğal olarak bir araya gelen grupları belirlemek ve veri setini kategorilere ayırmak için kullanılır. Örnekler arasındaki benzerlik,

uzaklık ölçümleriyle değerlendirilir. EVM'de benzer öğrenme stillerine veya bilişsel stratejilere sahip öğrencilerin gruplandırılmasında kullanılır.

- **İlişki Madenciliği:** Veri setindeki değişkenler arasındaki ilişkileri keşfetmek ve bu ilişkileri kurallar halinde ifade etmek için kullanılır. Birliktelik kuralları gibi teknikler bu kapsamdadır. EVM'de öğrencilerin çevrimiçi aktiviteleri ile final notları arasındaki ilişkilerin analizinde kullanılır.
- **Verilerin Damıtılması:** Bu teknik, verilerin insanlar tarafından hızlı bir şekilde anlaşılmasını ve sınıflandırılmasını sağlayacak şekilde sunulmasını içerir. Özetleme, görselleştirme ve etkileşimli ara yüzler bu yöntemin temel unsurlarıdır. EVM'de öğrenci aktivitelerinin görselleştirilmesi, öğrenme süreçlerinin anlaşılmasına yardımcı olur.
- **Modellerle Keşif:** Bu yöntem, tahmin veya ilişki madenciliği gibi analizlerde kullanılmak üzere onaylanmış modellerin geliştirilmesini amaçlar. Örneğin, öğrenci davranışları ile özellikleri arasındaki ilişkilerin modellenmesinde kullanılır.
- **Aykırlık Tespiti:** Bu yöntem, veri setindeki diğer verilerden anlamlı şekilde farklı olan veri noktalarını belirlemeyi hedefler. EVM'de öğrenci veya öğretmen davranışlarındaki sapmaların tespitinde kullanılır.
- **Sosyal Ağ Analizi:** Bireyler arasındaki ilişkileri incelemeyi amaçlayan bu yöntem, EVM'de işbirlikli öğrenme süreçlerinin analizinde kullanılır.
- **Süreç Madenciliği:** Bu yöntem, bir bilgi sistemi tarafından kaydedilen olay kayıtlarından süreçle ilgili bilgi çıkarılmasını ve görselleştirilmesini hedefler. EVM'de öğrencilerin ders akışları ve davranışlarının analizinde kullanılır.
- **Metin Madenciliği:** Metinlerden yüksek kaliteli bilgi çıkarılmasını amaçlayan bu yöntem, metin kategorizasyonu, kümelenme, duyarlılık analizi ve belge özetleme gibi görevleri içerir. EVM'de tartışma forumları ve çevrimiçi içeriklerin analizinde kullanılır.
- **Bilgi Takibi:** Bu yöntem, öğrencilerin becerilerini ve davranışlarını süreç içinde izleyerek tahmin etmeyi amaçlar.
- **Negatif Olmayan Matris Ayırışımı:** Bu teknik, bir matrisin iki veya daha fazla matrisin çarpımı şeklinde ayrıştırılmasını içerir. Örneğin, öğrenci test sonuçlarının analizinde kullanılabilir.

2.2. Öğrenci Akademik Performansın Tahmini

Eğitsel Veri Madenciliği (EVM), öğrenci öğrenme çıktılarının iyileştirilmesi amacıyla eğitim verilerinden anlamlı bilgi çıkarımına odaklanan önemli bir araştırma alanı olarak ortaya çıkmıştır. EDM'nin temel amacı, eğitim verilerine veri madenciliği tekniklerini uygulayarak öğrenci performansını doğru bir şekilde tahmin etmektir. Bu tahmin yeteneği, akademik başarısızlık riski taşıyan öğrencileri belirlemeye olanak tanıyarak, zamanında müdahalelerin gerçekleştirilmesini ve eğitim stratejilerinin iyileştirilmesini sağlar. Güncel literatürde, öğrenci performansını tahmin etmede etkili bir şekilde kullanılan çeşitli makine öğrenimi teknikleri vurgulanmakta olup, bu yöntemler modern veri odaklı eğitim yaklaşımlarıyla uyum göstermektedir [16, 17].

Öğrenci performansının erken tahmini, hem öğrenci öğrenme çıktılarının iyileştirilmesi hem de eğitim kurumları için kaynak tahsisinin optimize edilmesi açısından büyük önem taşımaktadır. Risk altındaki öğrencilerin erken tespiti, akademik katılım ve başarıyı artırmaya yönelik hedeflenmiş müdahalelerin tasarlanmasına olanak tanır [18]. Örneğin, çalışmalar, kişiselleştirilmiş öğretim stratejilerinin okul terk oranlarını önemli ölçüde azaltabileceğini ve akademik başarıyı artırabileceğini göstermektedir [19, 20].

Güçlü bir tahmin modeli, öğrenci performansını etkileyen çeşitli faktörlere dayanır. Bu faktörler arasında demografik veriler, geçmiş akademik performans, davranışsal metrikler ve öğrenme ortamındaki katılım düzeyleri yer almaktadır [21, 22]. Örneğin, önceki derslerden başarısız olma sayısı ile gelecekteki akademik performans arasında negatif bir korelasyon olduğu belirlenmiştir; bu da geçmiş akademik kayıtların önemli birer tahmin göstergesi olduğunu göstermektedir [23]. Ayrıca, çevrimiçi tartışmalara katılım oranları veya ödev tamamlama gibi etkileşim metrikleri de akademik başarıyı öngörmede kritik değişkenler arasındadır [18]. Bu çok yönlü değişkenler, öğrenci performansının geniş bir perspektiften ele alınmasını ve akademik başarıyı etkileyen çeşitli faktörlerin bütüncül bir yaklaşımla analiz edilmesini gerektirmektedir [24].

Lise ve üniversite giriş sınavı sonuçlarının yükseköğretim başarısı üzerindeki etkilerini araştırmak, karmaşık bir ilişkiyi ortaya koymaktadır. Daha önce yapılan çalışmalar, lise not ortalaması ile üniversite başarısı arasında bir korelasyon olduğunu göstermekte ve önceki akademik ölçütlerin gelecekteki başarıyı öngören göstergeler olduğunu vurgulamaktadır [25, 26]. Ayrıca, standartlaştırılmış giriş sınavları yalnızca doğrudan akademik performans değil, aynı zamanda öğrencilerin yükseköğretim ortamına

uyum sağlama ve eğitimlerini sürdürme eğilimlerini de öngörebilmektedir [27, 28]. Bu durum, akademik geçmiş verilerinden yararlanarak eğitimsel yolculukları tahmin etmenin önemini ortaya koymakta ve erken uyarı mekanizmalarında güçlü değerlendirme sistemlerinin kritik rolünü pekiştirmektedir [29, 30].

Makine öğrenimi yöntemleri, EDM kapsamında öğrenci performansının erken tahmininde önemli bir rol oynamaktadır. Karar ağaçları, yapay sinir ağları, destek vektör makineleri (SVM) ve topluluk yöntemleri gibi çeşitli algoritmalar bu amaçla kullanılmaktadır [31–33]. Örneğin, yapay sinir ağları, öğrenci verilerindeki karmaşık örüntüleri modelleyebilme kapasitesiyle dikkat çekerken, topluluk yöntemleri birden fazla tahmin modelini bir araya getirerek doğruluğu artırmaktadır [34]. Ayrıca, birden fazla algoritmayı birleştiren hibrit yaklaşımlar, geleneksel yöntemlere kıyasla daha üstün sonuçlar sunarak eğitim alanındaki tahmin kapasitesini artırmaktadır [35–37].

Derin öğrenme metodolojilerinin erken tahmin sistemlerine entegrasyonu, bu modellerin otomatik olarak veri temsilleri keşfetme yeteneği sayesinde giderek daha fazla ilgi görmektedir. Özellikle, Evrişimsel Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) ağlarını kullanan derin öğrenme modelleri, eğitim ortamlarında bulunan büyük ve karmaşık veri kümelerini yönetme konusunda avantaj sağlamaktadır [37–40]. Bu modeller, öğrenci öğrenme davranışlarına ilişkin ayrıntılı örüntüleri yakalayarak, geleneksel modeller tarafından gözden kaçabilecek içgörüler sunmaktadır.

Derin öğrenme gibi yüksek doğruluk sağlayan tahmin modelleri, çoğunlukla “kara kutu” olarak işlev görerek karar verme süreçlerinin anlaşılmasını sınırlamaktadır. Bu nedenle son dönem çalışmalarda, eğitimde erken tahmin süreçlerinde Açıklanabilir Yapay Zekâ'nın (XAI) önemi giderek daha fazla vurgulanmaktadır. XAI, bu süreçleri açıklayarak farklı özelliklerin tahminler üzerindeki etkilerini anlamaya yardımcı olur ve eğitimciler ile paydaşlar arasında güven oluşturur [38, 41].

EDM alanındaki ilerlemelere rağmen, özellikle üniversite giriş sınavı sonuçları gibi kapsamlı veri setlerini kullanarak öğrenci performansını tahmin etmek için hibrit derin öğrenme modelleri ile XAI tekniklerinin entegrasyonu konusunda önemli boşluklar bulunmaktadır. Mevcut literatür genellikle geleneksel tahmin yöntemlerine veya tekil algoritmik yaklaşımlara odaklanmakta, birden fazla etkileyen faktörün etkileşimini bütüncül olarak değerlendirmeyi ihmal etmektedir [17, 18]. Bu durum, eğitim amaçlı

tahmin analitiklerini optimize etme konusunda kritik bir zorluk teşkil etmekte ve bu çok yönlü ilişkileri ele alan bütünleşik çalışmalara olan ihtiyacı vurgulamaktadır.

Çalışmamızda, üniversite giriş sınavı sonuçlarını içeren kapsamlı bir veri setine odaklanarak XAI destekli hibrit derin öğrenme yaklaşımını kullanmayı amaçlıyoruz. Bu yöntem sayesinde yalnızca eğitsel veri madenciliğinin tahmin kapasitesine katkı sağlamakla kalmayıp, aynı zamanda bulgularımızın eğitimciler ve paydaşlar için erişilebilir ve yorumlanabilir olmasını sağlayarak akademik başarısızlık riski taşıyan öğrenciler için en iyi sonuçları elde etmeyi hedeflemekteyiz.

2.3. Öğrenci Akademik Performansının Tahmininde Kullanılan Yöntemler

Bu çalışmada, öğrenci performansının erken tahmini amacıyla istatistiksel veri analizi, özellik seçimi, makine öğrenmesi ve derin öğrenme kullanılmıştır. Kullanılan yöntemler aşağıda maddeler halinde açıklanmıştır.

2.3.1. İstatistiksel veri analiz yöntemleri

İstatistiksel veri analiz yöntemleri, günümüzde eğitimden sağlığa, ekonomiden sosyal bilimlere kadar birçok disiplinde yaygın bir şekilde kullanılmaktadır. Bu yöntemler, ham verilerin anlamlandırılması, verilerdeki eğilimlerin ortaya konulması, değişkenler arasındaki ilişkilerin belirlenmesi ve geleceğe yönelik tahminlerde bulunulması gibi amaçlarla uygulanır. Özellikle eğitim bilimleri alanında, öğrencilerin akademik performanslarını etkileyen faktörlerin belirlenmesi, bu faktörler arasındaki ilişkilerin analiz edilmesi ve etkili tahmin modellerinin geliştirilmesi süreçlerinde istatistiksel yöntemler kritik bir rol oynar.

2.3.1.1. İstatistiksel veri analiz temel amaçları


İstatistiksel veri analizinin temel amaçları şu şekilde sıralanabilir:

1. Verileri Anlamlandırma: Ham verilerin işlenerek bilgiye dönüştürülmesi ve karmaşık ilişkilerin daha anlaşılır hale getirilmesi. Bu süreç, verilerin özetlenmesi ve görselleştirilmesi yoluyla gerçekleştirilir.
2. Eğilimlerin Belirlenmesi: Veri setlerindeki genel eğilimlerin, kalıpların ve trendlerin tespit edilmesi. Bu, özellikle zaman serisi analizlerinde ve büyük veri setlerinin incelenmesinde önemlidir.

3. Hipotez Testi: Araştırmacılar tarafından ortaya atılan hipotezlerin geçerliliğinin istatistiksel yöntemlerle test edilmesi. Bu süreç, özellikle bilimsel araştırmalarda teorik varsayımların doğrulanması için kullanılır.
4. Tahmin ve Modelleme: Mevcut verilerden yola çıkarak geleceğe yönelik tahminler yapmak ve veriye dayalı modeller geliştirmek. Bu, özellikle makine öğrenmesi ve yapay zeka uygulamalarında sıklıkla kullanılan bir yaklaşımdır.
5. İlişkileri Ortaya Çıkarmak: Değişkenler arasındaki ilişkilerin analiz edilerek, bağımlı ve bağımsız değişkenler arasındaki bağlantıların belirlenmesi. Bu, nedensellik ilişkilerinin anlaşılmasına yardımcı olur.

2.3.1.2. İstatistiksel veri analiz yöntem çeşitleri

İstatistiksel veri analiz yöntemleri, genel olarak betimleyici (descriptive) ve çıkarımsal (inferential) istatistikler olarak iki ana kategoriye ayrılır. Şekil 2.4’de istatistiksel veri analiz yöntem çeşitleri ve en yaygın kullanılan teknikler gösterilmiştir. Bu çalışmada, çıkarımsal parametrik istatistik analiz tekniklerinden yararlanılmıştır. İkili karşılaştırmalar için bağımsız örneklem t-testi, birden fazla grup içeren analizler için ise ANOVA testi kullanılmıştır. Ayrıca, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi incelemek amacıyla lojistik regresyon analizi tercih edilmiştir.



Şekil 2.4. İstatistiksel veri analiz yöntemleri.

Betitleyici istatistikler

Betitleyici istatistikler (Descriptive Statistics), verileri  zetleyen ve y netilebilir bir bi imde sunan y ntemleri kapsar. Bu y ntemler, genellikle ortalama, medyan, mod, standart sapma ve frekans daėılımları gibi hesaplanabilir metrikler aracılıėıyla bir veri k mesinin temel  zelliklerini tanımlamaya odaklanır. Mishra ve arkadaşlarının vurguladıėı gibi, betimsel istatistikler veri k mesi hakkında ilk i g r ler sunarak istatistiksel analiz i in bir temel oluřturur ve b ylece desenlerin, eėilimlerin ve olası aykırı deėerlerin belirlenmesine yardımcı olur [42]. Ayrıca, Alabi ve Bukola, betimsel istatistiklerin yalnızca arařtırmacılara verilerinin  zellikleri hakkında bilgi vermekle kalmayıp, aynı zamanda  rneklem  zerinden bir pop lasyon hakkında  ıkarım yapılmasını saėlayan  ıkarımsal istatistikler i in kritik bir zemin hazırladıėını belirtmektedir [43].

Betimsel istatistiklerin kullanımı, saėlık ve eėitim gibi bir ok alanda yaygındır ve arařtırmacılara  l  lebilir klinik sonu lar ve eėitim performans g stergelerini tanımlamada yardımcı olur [44, 45]. Ayrıca, bařarılı bir betimsel analiz genellikle uygun istatistiksel yazılımların kullanılmasını gerektirir; SPSS ve R gibi ara lar bu hesaplamaları kolaylařtırmak i in yaygın olarak kullanılmaktadır [44].

 ıkarımsal istatistikler

 ıkarımsal istatistikler (Inferential Statistics),  rnekleme dayalı veriler ile pop lasyon parametreleri hakkında genellemeler yapmayı hedefleyen istatistiksel y ntemlerdir. Bu baėlamda, hipotez testleri, grupları karřılařtırma testleri, regresyon analizi ve g ven aralıkları gibi temel uygulamalar bulunur. Hipotez testleri, belirli bir pop lasyon parametresinin doėru olup olmadıėını test etmede kritik bir rol oynar. Bu testler, sıfır hipotezi (H_0) ve alternatif hipotez (H_1) olmak  zere iki ana hipoteze dayanır [46, 47]. H_0 , genellikle bir etki veya farkın olmadıėı varsayımını ifade ederken, H_1 , bir farkın var olduėunu belirtir. Bu  er evede, p-deėeri, g zlemlenen sonu ların sıfır hipotezinin doėru olduėu varsayımı altında ne kadar olası olduėunu ifade eder ve bu deėer, anlamlılık d zeyine (α) karřılařtırılarak karar verme s recinde kullanılır [46, 47].

Grupları karřılařtırma testleri, iki veya daha fazla grubun ortalamaları veya daėılımları arasında anlamlı bir fark olup olmadıėını belirlemek amacıyla kullanılır. T-testleri, iki grubun ortalamalarının karřılařtırılması i in yaygın bir y ntemdir.  zellikle baėımsız ve eřleřtirilmiř  rneklemeler i in ayrı versiyonları bulunmaktadır. ANOVA,    veya

daha fazla grubun ortalamalarının karşılaştırılması için kullanılan bir diğer önemli tekniktir [47, 48]. Ayrıca, kategorik verilerin ilişkilerini test etmek için kullanılan ki-kare testi de gruplar arası geliştirilmiş bir başka istatistiksel yöntemdir [47, 49].

Regresyon analizi, bağımlı bir değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi incelemek ve modellemek için kullanılan istatistiksel bir yöntemdir [47, 50]. Doğrusal regresyon, bu ilişkilerin doğrusal olarak modellenmesi için kullanılırken, lojistik regresyon belirli bir olayın olasılığını tahmin etmek için kullanılır ve bağımlı değişkenin kategorik olduğu durumlarda tercih edilir [46, 47]. Veri tahmininde kullanılan bu analizler, veri seti içindeki ilişkileri açıklamada ve gelecekteki sonuçları öngörmede etkili bir araçtır [51]. Ayrıca, regresyon analizi, istatistiksel anlamda belirli bir model oluşturulmasını sağlayarak, değişkenler arasındaki ilişkilerin net bir şekilde ortaya konmasına yardımcı olur.

Güven aralıkları, belirli bir güven düzeyiyle bir popülasyon parametresinin muhtemel değer aralığını temsil eder. Bir örneğin güven aralığı, popülasyonun gerçek değerinin bu aralıkta olma ihtimalini belirtir. Örneğin, %95 güven aralığı, parametrenin %95 ihtimalle bu aralıkta olduğunu ifade eder [46, 47]. Güven aralıkları, hipotez testlerinin sonuçlarını desteklemek veya sorgulamak üzere ek bilgiler sunabilir. Bunun yanı sıra, örneklem büyüklüğü gibi faktörler, güven aralıklarının genişliğini etkileyebilir. Küçük örneklem boyutları, güven aralıklarının çok geniş olmasına yol açabilir ve bu durum, çıkarımsal istatistiklerin sonuçlarını yorumlamayı zorlaştırır [49].


Parametrik olmayan testler, verilerin belli bir dağılıma uymadığı durumlar için geliştirilmiş alternatif testlerdir. Bu testler, parametrik testlere göre daha esnek ancak genellikle daha az güçlüdürler. Örneğin, Mann-Whitney U testi ve Kruskal-Wallis testi gibi parametrik olmayan testler kullanılabilir. Bu tür testlerin kullanılması, verilerin yapısına uygun yöntemlerin seçilmesine olanak sağlar ve daha güvenilir sonuçlar elde edilmesine yardımcı olur [46, 47].

Çıkarımsal istatistikler, örneklem dağılımlarının doğru bir şekilde anlaşılmasını gerektirir. Örneklem dağılımları, büyük örneklem için merkezi limit teoremi gereğince, örneklem istatistiklerinin normal dağılıma yaklaşmasına neden olur [49]. Bu dağılımlar, hipotez testlerinin ve güven aralıklarının temeli olan bir yapıdır. Güven aralıklarının sağlam olması, araştırmacıların popülasyon hakkında sağlıklı uygulamalarda bulunmasını kolaylaştırır [46, 51].

2.3.2. Özellik seçimi yöntemleri

Özellik seçimi, makine öğrenmesi ve veri madenciliği uygulamalarında, model performansını artırmanın yanı sıra hesaplama yükünü azaltma amacı gütmektedir. Bu teknikle, model içindeki gereksiz veya fazla bilgi kaldırılarak daha anlamlı ve bilgilendirici özelliklerin kullanılması sağlanır. Özellik seçiminin dört temel yararı bulunmaktadır: biri, alakasız veya zayıf ilgili özelliklerin kaldırılması, aşırı uyum (overfitting) veya yetersiz uyum (underfitting) problemlerini azaltmaktadır; ikincisi, özelliklerin daha iyi yorumlanabilir hale gelmesini sağlamaktadır; üçüncüsü, daha az veriyle daha hızlı algoritmaların çalışmasını mümkün kılar, bu da eğitim süresinin kısılmasına yol açar; son olarak, yanıltıcı bilgilerin azalması sonucunda modelin doğruluğu artar [52–54].

Özellik seçimi için kullanılan yöntemler, modelin türüne göre değişiklik gösterir ve genellikle üç ana gruba ayrılır: filtre yöntemleri, sarmalayıcı yöntemler ve gömülü yöntemler [52, 54, 55]. Şekil 2.5'te özellik seçimi yöntem çeşitleri gösterilmiştir. Bu çalışmada denetimli filtre yöntemi olan Pearson korelasyon filtre yöntemi kullanılmıştır.



Şekil 2.5. Özellik seçimi yöntemleri.

Filtre yöntemleri, özellikleri seçerken bağımsız bir yaklaşım sergiler ve genellikle istatistiksel testlere dayanır. Bu yöntemler, model eğitim aşamasından bağımsız çalışarak hesaplama süresini azaltır ve aşırı uyum sorununu en aza indirmeye yardımcı

olur [54, 56]. Örnek olarak bilgi kazanımı, ki-kare testi, Fisher skoru, korelasyon analizi ve ANOVA gibi teknikler bu grupta yer almaktadır. Örneğin, bilgi kazanımı tekniği, veri kümesindeki her bir değişkenin hedef değişken ile olan ilişkisini analiz ederek özelliklerin önemini belirler [52, 54]. Benzer şekilde, ki-kare testi kategorik değişkenler arasındaki ilişkiyi değerlendirirken, Fisher skoru özelliklerin sıralanmasını sağlamaktadır [54, 55].

Sarmalayıcı yöntemler ise, model performansını en üst düzeye çıkarmak amacıyla özellik silme veya ekleme işlemlerini adım adım gerçekleştirir. İleri seçim, geriye doğru eleme, kapsamlı özellik seçimi ve özyinelemeli özellik eleme gibi teknikler bu grupta yer alır. İleri seçim tekniği, başlangıçta boş bir özellik kümesiyle başlayarak her adımda bir özellik eklerken, geriye doğru eleme tüm özelliklerle başlar ve her seferinde en az önemli olanı çıkarır. Kapsamlı özellik seçimi ise tüm olası özellik kombinasyonlarının değerlendirildiği bir süreçtir; ancak hesaplama açısından maliyetli olabilir [54, 55].

Gömülü yöntemler, özellik seçimi sürecini öğrenme algoritmasının içinde entegre edilmiş biçimde gerçekleştirir. Bu yöntemler, öğrenme sürecini optimizasyon hedefleriyle belirleyerek en iyi sonuçları veren özellikleri otomatik olarak seçerler. Düzenleştirme modelleri, regresyon ve sınıflandırma problemlerinde parametreleri ceza terimleriyle kontrol ederek, bu sayede gereksiz özelliklerin sıfırlanarak daha optimize edilmiş setler elde edilmesini sağlar. Örneğin L1 düzenlemesi (kement) ve esnek ağlar bu grup içerisinde sıklıkla kullanılan tekniklerdir [54, 55].


2.3.3. Makine öğrenme yöntemleri

Makine öğrenmesi kavramı, Arthur Samuel tarafından 1959 yılında ortaya atılmıştır. Samuel, bilgisayarların deneyimlerden öğrenebilmesini sağlamak amacıyla oyun ve örüntü tanıma algoritmalarına yapay zekâ unsurlarını entegre etmiştir. Makine öğrenmesinin temel amacı, verilerden elde edilen bilgiler doğrultusunda tahminlerde bulunmak veya kararlar almaktır. Bu yöntem, karmaşık problemlerin modellenmesinde etkili bir araç haline gelmiştir [57].

İnsanları bilgisayarlardan ayıran en temel özelliklerden biri, geçmişteki deneyimlerden öğrenme becerisine sahip olmalarıdır. Bilgisayarlar, önceden belirlenmiş talimatları takip eder ve programlandıkları şekilde çalışır. Ancak günümüzde makine öğrenmesi sayesinde bilgisayarlar da deneyimlerden öğrenebilmektedir. Bu bağlamda,

bilgisayarlar için deneyimler veri olarak ifade edilir ve makine öğrenmesi, bu verilerden anlamlı bilgiler çıkarmayı hedefler [58].

Makine öğrenmesinin çok disiplinli bir alan olduğunu gösteren bilimsel bir gruplandırma Şekil 2.6’da sunulmaktadır. Bu şekil, makine öğrenmesinin yapay zeka, veri madenciliği, derin öğrenme ve istatistiksel öğrenme ile ilişkili olduğunu göstermektedir. Bu terimler genellikle aynı bağlamda kullanılsa da, farklı disiplinlerde anlamları ve kullanım alanları değişkenlik göstermektedir [59].



Şekil 2.6. Makine öğrenmesinin çok disiplinli gruplaması, Kühl (2019)’dan uyarlanmıştır.

İstatistik perspektifinden bakıldığında, makine öğrenmesi, veri setlerinden bilgi edinmeyi, tahmin yapmayı ve karar vermeyi amaçlayan istatistiksel öğrenmenin bir uygulaması olarak değerlendirilebilir. Bilgisayar biliminde ise makine öğrenmesi, hesaplama gücünü kullanarak verimli algoritmalar geliştirmeye odaklanır. Makine öğrenmesi, istatistiksel yaklaşımları içermekle birlikte, istatistik alanından bağımsız yöntemler de barındırmaktadır. Son yıllarda derin öğrenme yöntemleri büyük ilgi görmüş olup, bu modeller birden fazla katmandan oluşarak veri temsillerini farklı soyutlama seviyelerinde öğrenebilmektedir. Derin öğrenme, makine öğrenmesini önemli ölçüde ileri taşımıştır. Veri madenciliği ise, veriden içgörü elde etmeye yönelik analitik yöntemlerin uygulanma sürecini ifade eder. Makine öğrenmesi, veri madenciliği için temel bir unsur olup, veri madenciliği sürecinde anlamlı modeller

üretmeyi hedefler. Öte yandan yapay zeka, makine öğrenmesi ve istatistiksel öğrenme gibi çeşitli teknikleri bünyesinde barındırmaktadır [59].


2.3.3.1. Makine öğrenmesi uygulamaları

Makine öğrenmesi, günümüzde hızla gelişen ve birçok sektörde önemli bir rol oynayan bir teknolojidir. Makine öğrenmesinin öne çıkan bazı kullanım alanları şunlardır:

- **Veri Madenciliği ve Analiz:** Büyük veri kümelerinden anlamlı bilgiler çıkararak iş stratejilerini iyileştirmek için kullanılır.
- **Tahmine Dayalı Analitik:** Gelecekteki eğilimleri ve müşteri davranışlarını öngörerek işletmelerin daha bilinçli kararlar almasını sağlar.
- **Dolandırıcılık Tespiti ve Güvenlik:** Finansal işlemlerde hileli aktiviteleri belirleyerek sistem güvenliğini artırır.
- **Müşteri Segmentasyonu ve Pazarlama:** Müşteri gruplarını belirleyerek hedefe yönelik pazarlama stratejileri oluşturur.
- **Web Optimizasyonu:** Arama motoru sıralamalarını iyileştirerek kullanıcı deneyimini geliştirir.
- **Öneri Sistemleri:** Kullanıcı geçmişine dayalı olarak kişiselleştirilmiş ürün ve hizmet önerileri sunar.
- **Finansal Tahminler ve Risk Analizi:** Yatırım kararlarını destekleyerek risk yönetimini güçlendirir.
- **Sağlık Sektörü:** Hastalık teşhisi ve kişiselleştirilmiş tedavi yöntemleri geliştirmede kullanılır.
- **Eğitim:** Öğrenciye özel öğrenme yöntemleri sunarak eğitim kalitesini artırır.
- **Perakende ve Tedarik Zinciri Yönetimi:** Stok yönetimi ve fiyatlandırma stratejilerinde etkin rol oynar.
- **Ulaşım ve Lojistik:** Trafik tahmini ve rota optimizasyonu ile zaman ve maliyet tasarrufu sağlar.
- **İnsan Kaynakları:** Çalışan performans analizleri ve işe alım süreçlerini iyileştirir.
- **Görüntü ve Ses Tanıma:** Yüz tanıma, konuşma algılama ve el yazısı analizinde yaygın olarak kullanılır.

2.3.3.2. Makine öğrenmesi süreci

Makine öğrenmesi süreci, bir dizi kapsamlı ve sistematik adımı içeren karmaşık bir süreçtir. Bu adımlar, veri toplama ve ön işleme ile başlayarak, öznitelik mühendisliği, model seçimi ve eğitimi, model doğrulama ve sonuçların üretilmesi gibi aşamaları kapsar. Bu süreç, veri bilimi ve yapay zeka uygulamalarının temelini oluşturur ve etkili bir şekilde yönetilmesi, başarılı modellerin geliştirilmesi için kritik öneme sahiptir. Şekil 2.7'de, makine öğrenmesi yaklaşımlarını uygulamak için izlenmesi gereken temel prosedürler detaylı bir şekilde gösterilmiştir [60].



Şekil 2.7. Makine öğrenmesi projesi için temel iş akışı, Zhang (2020)'den uyarlanmıştır.

Veri toplama ve ön işleme

Makine öğrenmesi sürecinin ilk ve en önemli aşamalarından biri, veri toplama ve ön işlemedir. Bu aşama, modelin performansını doğrudan etkileyen veri kalitesini artırmaya yönelik işlemleri içerir. Veri toplama sürecinde, ilgili problem alanına uygun veri setleri belirlenir ve toplanır. Ancak, ham veriler genellikle eksik değerler, aykırı değerler ve gürültü içerebilir. Bu nedenle, veri ön işleme adımları, veri setinin temizlenmesi ve analize hazır hale getirilmesi için gereklidir.

- Eksik Değerlerin Düzeltilmesi: Veri setindeki eksik değerler, ortalama, medyan veya mod gibi istatistiksel yöntemlerle doldurulabilir. Alternatif olarak, eksik değerlerin bulunduğu satırlar veya sütunlar veri setinden çıkarılabilir.
- Aykırı Değerlerin Tespiti ve Giderilmesi: Aykırı değerler, veri setindeki diğer değerlerden önemli ölçüde farklı olan ve modelin performansını olumsuz etkileyebilecek değerlerdir. Aykırı değerler, kutu grafikleri veya Z-skoru gibi yöntemlerle tespit edilerek giderilebilir.
- Gürültünün Azaltılması: Gürültü, veri setindeki rastgele hatalar veya tutarsızlıklardır. Gürültünün azaltılması, veri setinin daha tutarlı ve güvenilir hale getirilmesini sağlar.

Öznitelik mühendisliği

Öznitelik mühendisliği, makine öğrenmesi modellerinin performansını artırmak için veri setindeki özniteliklerin (özelliklerin) seçilmesi, dönüştürülmesi ve optimize edilmesi sürecidir. Bu aşama, gereksiz veya ilgisiz özniteliklerin elenmesini ve veri setinin daha etkili bir şekilde temsil edilmesini sağlar. Öznitelik mühendisliği, aşağıdaki adımları içerebilir:

- **Öznitelik Seçimi:** Veri setindeki en önemli özniteliklerin belirlenmesi ve gereksiz özniteliklerin çıkarılması. Bu işlem, modelin karmaşıklığını azaltır ve eğitim süresini kısaltır.
- **Öznitelik Dönüştürme:** Özniteliklerin, makine öğrenmesi algoritmalarının daha iyi çalışması için uygun bir forma dönüştürülmesi. Örneğin, kategorik verilerin sayısal değerlere dönüştürülmesi veya özniteliklerin normalleştirilmesi.
- **Öznitelik Çıkarımı:** Mevcut özniteliklerden yeni öznitelikler türetilmesi. Bu işlem, veri setindeki bilgi içeriğini artırabilir ve modelin performansını iyileştirebilir.

Model seçimi ve eğitimi

Veri ön işleme ve öznitelik mühendisliği aşamaları tamamlandıktan sonra, uygun makine öğrenmesi modeli seçilir ve eğitilir. Model seçimi, problemin doğasına ve veri setinin özelliklerine bağlıdır. Örneğin, sınıflandırma problemleri için destek vektör makineleri (SVM) veya karar ağaçları (DT) kullanılabilirken, regresyon problemleri için doğrusal regresyon (LinR) veya rastgele orman (RF) modelleri tercih edilebilir.

Model eğitimi sırasında, veri seti genellikle eğitim ve test setleri olarak ikiye ayrılır. Eğitim seti, bir modelin verilerden öğrenmesini sağlamak amacıyla kullanılırken, test seti ise modelin performansını ölçmek ve değerlendirmek için ayrılmış verilerden oluşur. Model eğitimi, genellikle bir optimizasyon süreci içerir ve bu süreçte modelin parametreleri, veri setine en iyi şekilde uyacak şekilde ayarlanır.

Model doğrulama ve değerlendirme

Model eğitimi tamamlandıktan sonra, modelin performansı doğrulanır ve değerlendirilir. Bu aşama, modelin genelleme yeteneğini test etmek ve aşırı uyum (overfitting) gibi sorunları tespit etmek için kritik öneme sahiptir.


Model değerlendirme, doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skoru gibi metrikler kullanılarak yapılır. Bu metrikler, modelin sınıflandırma veya regresyon performansını ölçmek için kullanılır.

Sonuçların üretilmesi ve raporlama

Makine öğrenmesi sürecinin son aşaması, modelin tahminlerinin veya sınıflandırmalarının üretilmesi ve bu sonuçların raporlanmasıdır. Bu aşamada, modelin performansı ve elde edilen sonuçlar, ilgili paydaşlara sunulur. Raporlama, modelin nasıl çalıştığı, hangi özelliklerin önemli olduğu ve modelin sınırlılıkları gibi bilgileri içermelidir.


2.3.3.3. Makine öğrenmesi türleri

Makine öğrenmesi alanında birçok farklı teknik bulunmaktadır. Bu teknikler, genel olarak üç ana kategoriye ayrılabilir. Bu kategoriler Şekil 2.8'de gösterilmektedir.



Şekil 2.8. Kategorilerine göre makine öğrenme türleri, Deperlioğlu ve Köse (2024)'ten uyarlanmıştır.

Öğrenme sürecinde insan denetiminin miktarına göre, en yaygın yöntemler dört ana kategoriye ayrılır: denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme. Bu yöntemlerin gerçekleştirdikleri temel görevler Şekil 2.9'da detaylı olarak gösterilmiştir [61].



Şekil 2.9. Makine öğrenme türleri ve görevleri, Deperlioğlu ve Köse (2024)’ten uyarlanmıştır.

1. Denetimli öğrenme, belirli bir veri kümesindeki özniteliklerden yola çıkarak hedef değişkeni (veya etiketi) tahmin etmeyi amaçlayan bir yöntemdir [62]. Sınıflandırma ve regresyon makine öğrenmesi görevleri için kullanılır. Yaygın olarak kullanılan denetimli öğrenme sınıflandırma algoritmaları arasında destek vektör makineleri, lojistik regresyon, sinir ağları, rastgele ormanlar, K en yakın komşular ve karar ağaçları bulunmaktadır. Regresyon algoritmaları arasında ise doğrusal regresyon, destek vektör regresyonu, karar ağaçları tabanlı regresyon modelleri, rastgele orman regresyonu ve yapay sinir ağları gibi yöntemler yer almaktadır.
2. Denetimsiz öğrenme, hedef değişkenin (veya etiketin) bulunmadığı veri kümelerinde, benzer özelliklere sahip veri noktalarını gruplamaya veya veri yapısını keşfetmeye yönelik bir yaklaşımdır [62]. Denetimsiz öğrenme görevleri arasında kümeleme, ilişkilendirme ve boyut indirgeme yer almaktadır.
3. Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme yöntemlerinin sınırlılıklarını aşmak için hem etiketli hem de etiketsiz verilerin bir arada kullanıldığı bir yaklaşımdır [58].
4. Pekiştirmeli öğrenme, belirsizlik altında optimal kararlar almayı öğrenmeye yönelik bir yöntemdir [63]. Bu yöntem, belirli eylemlerin diğerlerine göre daha iyi sonuçlar ürettiği problemlerde kullanılır. Analist, algoritmaya bir veri seti, bir hedef ve eylemler için ödül veya ceza mekanizmaları sağlar. Algoritmanın görevi,

belirlenen hedefe ulaşmak için en uygun eylem kombinasyonunu bulmaktır. Bunu gerçekleştirmek için, algoritma farklı eylem kombinasyonlarını değerlendirir ve ödülleri en üst düzeye çıkaran modelleri belirler [64].

2.3.3.4. Kullanılan makine öğrenmesi algoritmaları


Bu çalışmada, önerilen hibrit derin öğrenme modelinin performansı, geleneksel makine öğrenmesi modelleri ile karşılaştırılmıştır. Karşılaştırma kapsamında, yaygın olarak kullanılan ve farklı özelliklere sahip olan aşağıdaki makine öğrenmesi algoritmaları değerlendirilmiştir:

- k-En Yakın Komşu Algoritması (k-Nearest Neighbors, KNN),
- Lojistik Regresyon (Logistic Regression, LR),
- Destek Vektör Makineleri (Support Vector Machines, SVM),
- Rastgele Ormanlar (Random Forests, RF),
- Karar Ağaçları (Decision Trees, DT),
- Yapay Sinir Ağları (Artificial Neural Networks, ANN).

Bu algoritmalar, önerilen hibrit modelin performansını kapsamlı bir şekilde değerlendirmek amacıyla seçilmiştir. Her bir algoritmanın çalışma prensibi, avantajları ve kullanılan parametreler, bir sonraki bölümde detaylı olarak açıklanmaktadır.

k-En yakın komşu algoritması

k-En Yakın Komşu (k-Nearest Neighbors, KNN) algoritması, makine öğrenimi ve istatistik alanlarında temel bir yaklaşım olup, sınıflandırma ve regresyon görevlerindeki basitliği ve etkinliğiyle yaygın olarak tanınmaktadır. k-En Yakın Komşu (KNN) algoritması, makine öğrenimi ve veri madenciliğinde yaygın olarak bilinen parametrik olmayan bir sınıflandırma yöntemidir. İlk olarak 1950'lerde kavramsallaştırılmış olup, temel çalışmalar Cover ve Hart'a atfedilmiş ve onlar tarafından sınıflandırma görevleri için en yakın komşu kuralı üzerine öncü bir makalede resmileştirilmiştir [65]. k-NN algoritması, benzer veri noktalarının genellikle birbirine yakın olduğu ilkesine dayanarak, Şekil 2.10'da görüldüğü gibi yeni örnekleri en yakın komşularının çoğunluk etiketiyle sınıflandırır [66].



Şekil 2.10. k-En yakın komşu (k-NN) sınıflandırması.


Yapısal olarak k-NN, etiketlenmiş giriş örneklerinden oluşan bir veri kümesini kaydederek çalışır. Yeni bir veri noktasının sınıflandırılması gerektiğinde, bu noktanın veri kümesindeki diğer noktalarla olan mesafesi hesaplanır ve belirlenen k en yakın komşu tespit edilir. Genellikle Öklid veya Manhattan mesafe metrikleri kullanılır [67, 68]. Sınıflandırma doğruluğunu artırmak için, komşuların mesafeye göre ağırlıklandırıldığı ağırlıklı k-NN gibi çeşitli iyileştirme ve uyarlamalar önerilmiştir. Bu tür yöntemler özellikle kapalı alan konum belirleme gibi uygulamalarda etkili olmaktadır [69]. k-NN'nin temel parametreleri arasında k değeri, mesafe metriği ve olası ağırlıklandırma yöntemleri yer alır [68]. k değerinin seçimi kritik bir faktördür—küçük k değerleri gürültüye duyarlılığı artırabilirken, büyük k değerleri sınıflar arasındaki farkları azaltarak genelleme yapabilir [70].

k-NN, tıbbi tanı sistemlerinden belge sınıflandırmaya kadar çeşitli alanlarda yaygın olarak kullanılmaktadır. Örneğin, tıbbi veri kümelerinde hastalıkların sınıflandırılması için kullanılarak, daha karmaşık sınıflandırıcılarla karşılaştırılabilecek bir temel model işlevi görmektedir [67]. Eğitim alanında ise öğrenci başarısını tahmin etme veya çeşitli değerlendirme sonuçlarını analiz etme gibi görevlerde kullanılabilir; yorumlanabilirliği ve kolay uygulanabilirliği nedeniyle tercih edilmektedir [71]. Daha ileri düzey uygulamalarda, topluluk yöntemleri ve hibrit yaklaşımlar ile k-NN diğer algoritmalarla birleştirilerek belirli görevlerde performansı artırmak için kullanılmaktadır. Örneğin, ağ saldırı tespiti gibi alanlarda bu tür hibrit yöntemler yaygın olarak uygulanmaktadır [72].

Lojistik regresyon

Lojistik regresyon (Logistic Regression, LR), bir veya daha fazla bağımsız değişkene dayalı olarak ikili bir sonucun olasılığını modellemek için yaygın olarak kullanılan bir istatistiksel yöntemdir. Bu yöntem, 1958 yılında David Cox tarafından tanıtılmış olup, tıbbi araştırmalar, sosyal bilimler ve eğitim veri madenciliği gibi birçok alanda önemli bir yer edinmiştir [73]. Doğrusal regresyondan farklı olarak, bağımlı değişkenin herhangi bir değeri alabileceği durumlar yerine, lojistik regresyon lojistik fonksiyon kullanarak çıktıyı 0 ile 1 arasındaki bir aralığa sınırlar ve bağımsız değişkenleri belirli bir sınıf veya olayın olasılığıyla ilişkilendirir [74].

Lojistik regresyonun yapısı, Şekil 2.11’de görüldüğü gibi logit dönüşümüne dayanır. Bu dönüşümde, sonucun olasılığının log-olasılık değeri, açıklayıcı değişkenlerin doğrusal bir kombinasyonu olarak modellenir [74].



Şekil 2.11. Lojistik regresyonun sınıflandırması.


Lojistik regresyonun temel hiperparametreleri, modelin karmaşıklığını kontrol eden düzenlileştirme (regularization) terimleri üzerine yoğunlaşmaktadır. En yaygın türler L1 (Lasso) ve L2 (Ridge) düzenlileştirmeleridir [75]. Bu parametrelerin seçimi, özellikle yüksek boyutlu veri kümelerinde aşırı öğrenme (overfitting) riskini azaltma açısından modelin performansını önemli ölçüde etkileyebilir [76].

Lojistik regresyon, sağlıktan finansa çeşitli alanlarda geniş uygulama alanına sahiptir. [77–79]. Eğitim veri madenciliğinde ise lojistik regresyon, öğrenci başarısını ve okul terk oranlarını etkileyen faktörleri ortaya çıkarmak amacıyla tahmine dayalı analizlerde kullanılmaktadır [80].

Destek vektör makineleri

Destek Vektör Makineleri (Support Vector Machines, SVM), sınıflandırma ve regresyon görevleri için temel olan, iyi bilinen bir denetimli makine öğrenimi algoritmaları sınıfıdır. Bu yöntem, 1990'lı yılların başında Vladimir Vapnik tarafından görüntü sınıflandırma problemlerini çözmek amacıyla geliştirilmiştir. SVM, farklı sınıfları ayıran en uygun hiper düzlemi belirleyerek ve her sınıfın en yakın noktaları (destek vektörleri) arasındaki marjı maksimize ederek çalışır. Bu geometrik yaklaşım, istatistiksel öğrenme teorisine dayanır ve yapısal risk minimizasyonu ilkesini esas alarak yüksek boyutlu uzaylarda bile güçlü genelleştirme yetenekleri sergiler [81, 82].

SVM'nin mimarisi büyük ölçüde model performansını önemli ölçüde etkileyen hiperparametreler tarafından belirlenir. Temel hiperparametreler arasında, düşük eğitim hatası ile düşük test hatası arasındaki dengeyi yöneten düzenleme parametresi (C), kullanılan çekirdek türü (doğrusal, polinom, radyal tabanlı fonksiyon vb.) ve belirli çekirdeklerle ilişkili parametreler, örneğin RBF çekirdeğindeki gamma parametresi yer alır. Gamma, bireysel eğitim örneklerinin etkisini belirler [81]. Şekil 2.12 de SVM sınıflandırma yapısı gösterilmiştir



Şekil 2.12. Destek vektör makineleri sınıflandırması.


SVM'nin uygulama alanları oldukça geniş olup biyoenformatik, e-posta sınıflandırma ve el yazısı rakam tanıma gibi çeşitli disiplinleri kapsar. Ayrıca, eğitim veri madenciliği bağlamında, öğrenci performansını tahmin etme, olası okul terklerini

belirleme ve öğrenme çıktılarını iyileştirmek için özelleştirilmiş eğitim içerikleri sunma gibi konularda umut vadeden sonuçlar elde edilmiştir.

Rastgele ormanlar

Rastgele Ormanlar (Random Forests, RF), bir topluluk öğrenme tekniği olarak 2001 yılında Leo Breiman tarafından tanıtılmış ve o zamandan beri veri bilimi ve makine öğreniminin çeşitli alanlarında önemli bir yer edinmiştir. RF, birden fazla karar ağacı oluşturarak ve bunların sonuçlarını birleştirerek tahmin doğruluğunu artırır, böylece tek ağaç modellerinde yaygın olarak görülen aşırı öğrenme problemini azaltır [83].

RF'nin mimari yapısı, tahmin performansını önemli ölçüde etkileyen çeşitli hiperparametreleri içerir. Temel hiperparametreler arasında, ormandaki ağaç sayısı, her ağacın maksimum derinliği, bir iç düğümün bölünmesi için gereken minimum örnek sayısı ve her düğümde en iyi bölme için dikkate alınacak özellik sayısı bulunur [84]. Şekil 2.13'de RF sınıflandırma yapısı gösterilmiştir




Şekil 2.13. Rastgele ormanlar ile sınıflandırma.

RF, sağlık, çevre bilimi, finans ve eğitim gibi birçok alanda geniş uygulama alanına sahiptir. Eğitim veri madenciliğinde, RF öğrenci performansını sınıflandırmak ve tahmin etmek amacıyla kullanılarak, risk altındaki öğrencileri belirlemeye ve uygun müdahaleleri planlamaya yardımcı olmaktadır [85].

Karar ağaçları

Karar Ağaçlarının (Decision Trees, DT) geliştirilmesi, çeşitli istatistik ve makine öğrenimi kuramcılarına dayandırılabilir; özellikle Ross Quinlan'ın 1986'da yayımladığı ID3 algoritması ve bunu 1993'te geliştirdiği C4.5 algoritması önemli katkılar sağlamıştır [86]. Bu algoritmalar, karar ağaçlarının düğümler ve dallardan oluşan yapılandırılmış formatı sayesinde sezgisel olarak yorumlanmasını mümkün kılmıştır. Düğümler, özellik değerlerine dayalı kararları temsil ederken, dallar bu kararların sonuçlarını ifade eder. Karar ağaçlarının yapısı, anlaşılabilirliği ve görselleştirme kolaylığı sağlaması nedeniyle eğitim veri madenciliği, tıbbi teşhis ve finansal modelleme gibi çeşitli alanlarda değerli araçlar haline gelmiştir [87].

Bir karar ağacının mimarisi, kök düğüm, dallar ve yaprak düğümlerden oluşur. Kök düğüm, kararların alındığı başlangıç koşulunu temsil ederken, yaprak düğümler nihai sonuçları veya sınıflandırmaları gösterir. Ara düğümler ise veri kümesine uygulanan koşulları ifade ederek, hedef değişkene göre giderek daha homojen alt kümelere ayrılmasını sağlar [88, 89]. Bu düğümlerde alınan kararlar, genellikle veri bölme kriterlerine dayanır ve GINI safsızlığı veya bilgi kazancı gibi ölçütler kullanılarak alt kümelerdeki homojenliği en üst düzeye çıkarmayı amaçlar [89]. Şekil 2.14'te bir karar ağacı yapısı verilmiştir.



Şekil 2.14. Karar ağaçları ile sınıflandırma.

Karar ağaçlarının performansını optimize etmek için hiperparametreler kritik bir rol oynar. Temel hiperparametreler arasında ağacın maksimum derinliği (ağacın aşırı öğrenmesini önlemek için büyüme sınırı), bir düğümün bölünmesi için gerekli minimum örnek sayısı ve bölme kalitesini ölçmek için kullanılan kriter (örneğin, GINI indeksi veya entropi) bulunur [90, 91].

Eğitim Veri Madenciliği (EDM) alanında, karar ağaçları öğrenci başarısını tahmin etme, müfredat geliştirme ve risk altındaki öğrencileri belirleme gibi çeşitli uygulamalarda kullanılmaktadır. Karar ağaçlarının doğrudan yorumlanabilir yapısı, eğitimcilerin ve araştırmacıların karmaşık eğitim verilerinden anlamlı çıkarımlar yapmasını sağlayarak öğretim stratejilerinin ve eğitim sonuçlarının iyileştirilmesine katkıda bulunmaktadır [91, 92]. Ayrıca, karar ağaçları öğrenme kalıplarını ve davranışlarını analiz etmek için kritik bir araç olup, veri odaklı pedagojik kararların alınmasını destekleyerek öğrenci katılımını artırmakta ve öğrenme verimliliğini yükseltmektedir [88].

Yapay sinir ağları

Yapay sinir ağları, insan beyninin öğrenme, bilgi üretme ve keşfetme gibi yeteneklerini taklit ederek, herhangi bir insan müdahalesi olmadan otomatik olarak bu süreçleri gerçekleştirebilen bilgisayar sistemleridir. Bu sistemler, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik çıkarma ve optimizasyon gibi karmaşık görevlerde oldukça başarılıdır. Yapay sinir ağları, sağlık sektörü başta olmak üzere otomotiv, elektronik, enerji, uzay bilimleri, bankacılık, finans ve askeri alanlar gibi birçok farklı sektörde yaygın olarak kullanılmaktadır [93].

Yapay Sinir Ağları (ANN), temel olarak bilgisayarlara öğrenme yetisi kazandıran ve klasik programlama yöntemlerinden farklı çalışan hesaplamalı modellerdir. Bilgiler, ağın yapısında saklanır ve doğrudan yorumlanması zordur. ANN'lar, örnek verilerle öğrenerek yeni ve daha önce karşılaşılmamış durumlar hakkında tahminler yapabilir. Algılama, sınıflandırma ve örüntü tamamlama gibi görevlerde başarılı olan bu sistemler, belirsiz ve eksik bilgileri işleyebilme yeteneğine sahiptir. Ayrıca hata toleransı sayesinde, kısmi veri kaybı yaşandığında bile çalışmaya devam edebilirler [93].


Ancak ANN'ların bazı dezavantajları da bulunmaktadır. Öncelikle, donanım bağımlı olmaları ve uygun ağ yapısının genellikle deneme-yanılma yöntemiyle belirlenmesi, geliştirme sürecini zorlaştırmaktadır. Öğrenme katsayısı, hücre sayısı ve katman sayısı

gibi parametrelerin belirlenmesi için standart bir kural bulunmamaktadır. Ayrıca, eğitim sürecinin ne zaman tamamlanacağına dair kesin bir yöntem olmadığı gibi, ağıın ürettiğı çözümlerin nasıl elde edildiğini açıklamak da güçtür. Bu durum, ANN'ların güvenilirliğini sorgulayan bir unsur olarak değerlendirilmektedir [93].

ANN'lar, birçok farklı fonksiyonu yerine getirebilir. Bunlar arasında probabilistik fonksiyon kestirimi, sınıflandırma, örüntü eşleştirme, zaman serileri analizi, sinyal filtreleme, veri sıkıştırma ve optimizasyon gibi işlemler yer almaktadır. Ayrıca, doğrusal olmayan sinyal işleme ve sistem modelleme gibi karmaşık hesaplamalarda kullanılabilen ANN'lar, yapay zeka tabanlı kontrol sistemlerinde de önemli bir rol oynamaktadır. Bu geniş kullanım alanı, ANN'ları makine öğrenimi ve yapay zeka çalışmalarında vazgeçilmez bir araç haline getirmiştir [93].

ANN biyolojik sinir ağı temel elemanı olan nöron hücrelerinin ve bu hücrelerin birbirleri ile arasında kurduğu bağıın dijital olarak modellenmesidir. Nöronda dendrit, hücre çekirdeğı, hücre gövdesi, akson, miyelin kılıf, ranvier boğumu, shwann hücresi ve akson uçları bölümleri bulunmaktadır [94]. ANN, temel olarak girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücre çıktısı gibi bileşenlerden oluşur. Ağırlıklar, hücreye gelen bilginin önemini ve hücre üzerindeki etkisini belirler. Toplama fonksiyonu, hücreye gelen net girdiyi hesaplamak için kullanılırken, aktivasyon fonksiyonu bu net girdiyi işleyerek hücrenin üreteceğı çıktıyı belirler. Yapay sinir ağıları genellikle girdi katmanı, ara (gizli) katmanlar ve çıktı katmanı olmak üzere üç temel yapıdan oluşur. ANN'nın öğrenme yeteneğı ve zekası, ağıdaki bağlantıların sahip olduğı ağırlık değerlerinde saklıdır. Bu ağırlıklar, eğitim süreci boyunca optimize edilerek modelin doğru tahminler yapması sağlanır. Şekil 2.15'de bir yapay sinir ağı yapısı verilmiştir.


bir nöronun gelen akson



Şekil 2.15. Yapay sinir ağı yapısı.

Yapay Sinir Ağları içinde en yaygın kullanılan modeller algılayıcılar, çok katmanlı algılayıcılar (MLP), vektör kuantizasyon modelleri (LVQ), kendi kendine organize olan model (SOM), adaptif rezonans teorisi modelleri (ART), Hopfield ağları, Neocognitron ağı, Boltzmann makinesi, probabilistik ağlar (PPN), Elman ağı ve radyal temelli ağlar (RBN) olarak sıralanabilir [95]. Bu çalışmada Çok Katmanlı Algılayıcı (MLP) kullanılmıştır.

MLP'nin yapısı, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur (Şekil 2.16.). Her katman, giriş verilerini işleyen ve doğrusal olmayan aktivasyon fonksiyonları aracılığıyla veri içindeki karmaşık ilişkileri modelleyen düğümlerden veya nöronlardan meydana gelir [94]. MLP performansını belirleyen temel hiperparametreler arasında gizli katman sayısı, her katmandaki nöron sayısı, öğrenme oranı, aktivasyon fonksiyonlarının seçimi ve eğitimde kullanılan optimizasyon algoritması bulunur [96].



Şekil 2.16. MLP'nin yapısı.

MLP'ler, enerji tahmininde, geçmiş yük verilerini analizinden üretim sektöründe, kalite tahmini için üretim süreçlerinin optimize edilmesine kadar çeşitli alanlarda başarıyla uygulanmaktadır [97–100]. Eğitim veri madenciliği alanında, öğrenci davranışlarını analiz etmek ve akademik başarıyı tahmin etmek için kullanılan MLP modelleri, kişiselleştirilmiş öğrenme ortamlarının oluşturulmasını desteklemektedir.

2.3.4. Derin öğrenme

Derin öğrenme, insan beyninin karmaşık problemleri çözme süreçlerini taklit eden bir makine öğrenmesi yöntemidir. Bu yöntem, gözlemlene, analiz etme, öğrenme ve karar verme gibi yetenekleri kullanarak, büyük miktarlardaki verilerden özellik çıkarma, dönüştürme ve sınıflandırma gibi işlemleri gerçekleştirebilir. Derin öğrenme, denetimli veya denetimsiz olarak uygulanabilir [101]. Geleneksel makine öğrenmesi yöntemlerinden farklı olarak, derin öğrenme, önceden tanımlanmış kurallar yerine, resim, video, ses ve metin gibi veri türlerinin özelliklerini otomatik olarak öğrenebilir. Bu süreç, örnekler üzerinden öğrenme yoluyla gerçekleştirilir [102].

Derin öğrenme alanındaki önemli gelişmeler ve kilometre taşları aşağıdaki gibi sıralanabilir [103]:

- 1986: R. Dechter tarafından bir makalede “Derin Öğrenme” terimi ilk kez kullanıldı.
- 1980: Kunihiko Fukushima, Evrişimli Sinir Ağlarının öncülü olan Neocognitron'u tanıttı.
- 1985: Hilton ve Sejnowski, Boltzmann Makinesini geliştirdi.

- 1986: Smolensky, daha sonra Kısıtlanmış Boltzmann Makinesi olarak da bilinen Harmonium'u tanıttı. Aynı yıl, Jordan Tekrarlayan Sinir Ağını tanımladı.
- 1990: Yann LeCun ve diğerleri, LeNet adlı ağı tanıtarak Derin Sinir Ağlarının ilk pratik uygulamasını gösterdi.
- 1997: Schuster ve Paliwal, Çift Yönlü Tekrarlayan Sinir Ağını tanıttı.
- 2006: Hinton, Derin İnanç Ağlarını tanıttı.
- 2009 ve Sonrası: Deng ve Hinton gibi bilim insanları tarafından düzenlenen NIPS Çalıştayları ve 2010'dan itibaren düzenlenen ImageNet yarışmaları, Derin Öğrenmenin yaygınlaşmasına ve bugünkü düzeye ulaşmasına büyük katkı sağladı.

Derin öğrenme, sınıflandırma, tanımlama, tahmin, teşhis ve görüntü işleme gibi çeşitli alanlarda kullanılmaktadır. Bu yöntemler, veri toplanabilen hemen hemen her alanda uygulanabilir. Derin öğrenmenin kullanıldığı başlıca alanlar şunlardır:

Bilgisayarlı Görü ve Desen Tanıma:

- Ünlü kişilerin seslerinin farklı görüntülerle eşleştirilmesi,
- Resim ve videolarda renk restorasyonu,
- Düşük çözünürlüklü görüntülerin iyileştirilmesi,
- Gerçek zamanlı çoklu insan hareketlerinin tahmini,
- Resimlerdeki nesnelerin metne dönüştürülmesi,
- Videolardaki davranışların gerçek zamanlı analizi,
- Fotoğraflardan yeni nesnelerin oluşturulması,
- Resimlerdeki yazıların farklı dillere çevrilmesi,
- Nesli tükenmekte olan hayvanların tespiti ve korunması,
- Mevcut görüntülerden yeni modellerin elde edilmesi,
- Fotoğraf ve videolardaki metinlerin okunması,
- Güneş enerjisi potansiyelinin tahmini.

Bilgisayar Oyunları, Robotlar ve Otonom Araçlar:

- Bilgisayar oyunlarının otomatik olarak oynanması,
- Kendi kendine hareket edebilen araçlar,
- Robotik sistemler,

- Bilgisayar oyunlarının kurallarını otomatik öğrenen sistemler.

Ses İşleme:

- Sesli asistanlar,
- Beste yapabilen bilgisayarlar,
- Videolardan dudak okuma teknolojileri.

Sanat ve Yaratıcılık:

- Ünlü ressamların stillerinin başka resimlere uygulanması,
- Matematiksel ifadeler, bilgisayar kodları, Wikipedia makaleleri ve hatta Shakespeare tarzında romanlar yazan bilgisayarlar,
- El yazısının bilgisayar metinlerine dönüştürülmesi.

Tahmin ve Analiz:

- Seçim sonuçlarının tahmini,
- Deprem tahminleri.


2.3.4.1. Derin öğrenme mimarileri

Derin öğrenme, yapay sinir ağlarının çok katmanlı yapılar kullanarak karmaşık veri modellerini öğrenmesini sağlayan bir makine öğrenmesi alanıdır. Bu alanda, farklı problem türlerine uygun çeşitli mimariler kullanılmaktadır. En yaygın derin öğrenme mimarileri şunlardır: İleri Beslemeli Sinir Ağları (Feedforward Neural Networks - FNN), Evrişimli Sinir Ağları (Convolutional Neural Networks - CNN), Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN), Uzun Kısa Süreli Bellek Ağları (Long Short-Term Memory - LSTM), Otokodlayıcılar (Autoencoders), Generatif Çekişmeli Ağlar (Generative Adversarial Networks - GAN) ve Dönüştürücüler (Transformers). Bu çalışmada, İleri Beslemeli Sinir Ağları (FNN) içeren Derin Yapay Sinir Ağları (Deep Artificial Neural Networks - Deep ANN) kullanılmıştır.

İleri beslemeli sinir ağları

İleri Beslemeli Sinir Ağları (Feedforward Neural Networks - FNN), yapay sinir ağlarının en temel ve yaygın kullanılan türlerinden biridir. Bu ağlar, verilerin tek yönlü olarak ileri doğru iletilmesi prensibiyle çalışır ve genellikle sınıflandırma, regresyon ve modelleme gibi görevlerde kullanılır. FNN'ler, katmanlı bir yapıya sahiptir ve bu katmanlar Şekil 2.17'de gösterildiği gibi girdi katmanı (input layer), gizli katmanlar (hidden layers) ve çıktı katmanı (output layer) olarak sınıflandırılır. Girdi katmanı,

modelin dış dünyadan aldığı verileri temsil ederken, gizli katmanlar veriler üzerinde doğrusal olmayan dönüşümler gerçekleştirir. Çıktı katmanı ise modelin nihai tahminlerini üretir [104].



Şekil 2.17. İleri beslemeli sinir ağının (FNN) yapısal diyagramı, Guo (2020)'den uyarlanmıştır.


FNN'lerin avantajları arasında doğrusal olmayan ilişkileri modelleme yeteneği ve geniş bir uygulama yelpazesine sahip olmaları sayılabilir. Özellikle görüntü işleme, doğal dil işleme ve finansal tahminler gibi alanlarda sıklıkla kullanılırlar [105]. Ancak, FNN'lerin bazı sınırlamaları da bulunmaktadır. Örneğin, çok sayıda gizli katman ve nöron içeren modeller, aşırı uyum (overfitting) sorunu yaşayabilir. Ayrıca, eğitim süreci büyük veri setleri ve karmaşık modeller için hesaplama açısından maliyetli olabilir. Zamansal bağımlılıkları olan verileri modellemede ise RNN veya LSTM gibi modeller daha uygundur [104].

Konvolüsyonel sinir ağları

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks - CNN), özellikle görüntü işleme ve bilgisayarlı görü alanında devrim yaratan bir derin öğrenme modelidir. Geleneksel sinir ağlarından farklı olarak, CNN'ler görüntülerdeki uzamsal yapıları ve yerel özellikleri otomatik olarak öğrenebilme yeteneği ile öne çıkar. Bu özellik, onları nesne tanıma, yüz tanıma, tıbbi görüntü analizi ve benzeri görevlerde oldukça etkili kılar [106]. CNN'ler, özellikle büyük ölçekli görüntü veri setleri üzerinde yüksek doğruluk oranları elde etmek için tasarlanmıştır ve bu alanda birçok başarılı uygulama örneği bulunmaktadır.

CNN'lerin temel yapısı, konvolüsyonel katmanlar, pooling katmanları ve tam bağlantılı katmanlar olmak üzere üç ana bileşenden oluşur. Konvolüsyonel katmanlar, görüntü üzerinde filtreler (kernels) kullanarak yerel özellik haritaları çıkarır. Bu

filtreler, görüntünün farklı bölgelerinde kaydırılarak uygulanır ve kenarlar, dokular veya diğer önemli özellikler tespit edilir. Bu işlem, parametre paylaşımı sayesinde hesaplama açısından verimlidir ve modelin boyutunu büyük ölçüde azaltır [104]. Pooling katmanları ise özellik haritalarının boyutunu küçültmek ve modelin ölçek değişimlerine karşı daha dayanıklı olmasını sağlamak için kullanılır. En yaygın kullanılan pooling yöntemi, maksimum pooling (max pooling) olup, bu yöntem belirli bir bölgedeki en büyük değeri alarak özelliklerin korunmasını sağlar [106]. Tam bağlantılı katmanlar ise, önceki katmanlardan gelen özellikleri birleştirerek nihai sınıflandırma veya regresyon görevini gerçekleştirir. Şekil 2.18'de, ReLU aktivasyon fonksiyonuna sahip iki evrışimsel katman, iki adet maksimum havuzlama katmanı ve SoftMax aktivasyonlu bir tam bağlantılı katman içeren bir CNN mimarisinin şematik gösterimi yer almaktadır.



Şekil 2.18. CNN katmanları, Kouzehgar (2019)'dan uyarlanmıştır.

CNN'lerde, konvolüsyonel katmanların çıktılarına doğrusal olmayan bir dönüşüm uygulamak için aktivasyon fonksiyonları kullanılır. Bunlar arasında en yaygın olanı, ReLU (Rectified Linear Unit) aktivasyon fonksiyonudur. ReLU, negatif değerleri sıfıra eşitlerken pozitif değerleri olduğu gibi bırakır. Bu, modelin eğitim sürecini hızlandırır ve gradyan kaybolması (vanishing gradient) gibi sorunları hafifletir [107]. Ayrıca, CNN'lerin eğitimi sırasında geri yayılım (backpropagation) ve gradyan inişi (gradient descent) gibi optimizasyon yöntemleri kullanılır. Bu süreç, modelin tahminleri ile gerçek değerler arasındaki hatayı minimize etmeyi amaçlar.


CNN'lerin en önemli avantajlarından biri, görüntülerdeki hiyerarşik özellikleri otomatik olarak öğrenebilmesidir. Bu, geleneksel yöntemlerde manuel olarak özellik çıkarımı yapma gereksinimini ortadan kaldırır. Ayrıca, parametre paylaşımı ve pooling

işlemleri sayesinde hesaplama açısından verimlidir. Ancak, CNN'lerin bazı sınırlamaları da bulunmaktadır. Özellikle büyük modellerde aşırı uyum (overfitting) sorunu ortaya çıkabilir. Bu sorun, düzenlileştirme (regularization) teknikleri veya veri artırma (data augmentation) yöntemleri ile hafifletilebilir. Ayrıca, CNN'ler zamansal veriler veya sıralı veriler gibi uzamsal olmayan veri türlerinde sınırlı performans gösterir [106].

Tekrarlayan sinir ağları

Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN) özellikle zaman serisi verileri, metin verileri ve sıralı veriler gibi zamansal bağımlılıkları olan veri türlerini modellemek için kullanılan bir sinir ağı türüdür. RNN'ler, geleneksel ileri beslemeli sinir ağlarından (FNN) farklı olarak, bir dizi içindeki öğeler arasındaki bağlantıları öğrenebilme yeteneğine sahiptir. Bu özellik, RNN'leri doğal dil işleme (NLP), konuşma tanıma, zaman serisi tahmini ve benzeri görevlerde oldukça etkili kılar [104]. RNN'ler, bir dizi içindeki her bir adımda (time step) girdi alır ve bu girdiyi önceki adımlardan gelen bilgilerle birleştirerek çıktı üretir. Bu, RNN'lerin geçmiş bilgileri “hatırlama” yeteneği olarak da adlandırılır.

RNN yapısı Şekil 2.19 ile gösterilmiştir [108] . Bu görsel, bir Tekrarlayan Sinir Ağı (RNN) modelinin yapısını göstermektedir. RNN'ler, önceki zaman adımlarındaki bilgiyi saklayarak ve güncelleyerek sıralı verileri işler. Şekilde, sol tarafta tek bir RNN hücresi, sağ tarafta ise ağın zamana yayılmış (unrolled) hali gösterilmiştir. Modelin temel bileşenleri girdi katmanı (X), gizli durum (h) ve tekrarlayan ağ bloğu (A) şeklindedir. Her zaman adımında bir giriş (X_t) ve önceki gizli durum (h_{t-1}) kullanılarak yeni bir gizli durum (h_t) hesaplanır. Bu süreç, ağın geçmiş bilgileri dikkate alarak tahminler yapmasını sağlar. Bu sayede, RNN'ler bir dizi içindeki uzun vadeli bağımlılıkları öğrenebilir. Ancak, klasik RNN'ler pratikte uzun dizilerdeki bağımlılıkları öğrenmekte zorlanır. Bu sorun, gradyan kaybolması (vanishing gradient) veya gradyan patlaması (exploding gradient) olarak bilinen problemlerden kaynaklanır. Bu problemler, RNN'lerin uzun dizilerdeki bağımlılıkları etkili bir şekilde öğrenmesini engeller [109]. RNN'lerin bu sınırlamalarını aşmak için, Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ve Kapılı Tekrarlayan Birimler (Gated Recurrent Units - GRU) gibi gelişmiş mimariler önerilmiştir.



Şekil 2.19. RNN yapısı, Olah (2015)'den uyarlanmıştır.


RNN'lerin avantajları arasında, sıralı verilerdeki zamansal bağımlılıkları modelleme yeteneği ve esnek yapısı sayılabilir. Ancak, RNN'lerin bazı sınırlamaları da bulunmaktadır. Özellikle uzun dizilerde performans düşüklüğü ve eğitim sürecinin hesaplama açısından yoğun olması, bu modellerin kullanımını zorlaştırabilir. Bu nedenle, LSTM ve GRU gibi gelişmiş mimariler, RNN'lerin bu sınırlamalarını hafifletmek için yaygın olarak tercih edilir [109].

Uzun kısa vadeli hafıza ağları

Uzun Kısa Süreli Bellek Ağları (Long Short-Term Memory - LSTM), Tekrarlayan Sinir Ağları (RNN) mimarisinin bir uzantısı olarak, özellikle uzun vadeli bağımlılıkları öğrenme konusunda geleneksel RNN'lerin yaşadığı sınırlamaları aşmak için geliştirilmiş bir modeldir. LSTM, ilk olarak Hochreiter ve Schmidhuber (1997) tarafından önerilmiş ve zaman serisi analizi, doğal dil işleme (NLP), konuşma tanıma gibi alanlarda yaygın olarak kullanılmıştır. LSTM'nin temel avantajı, uzun dizilerdeki bilgileri koruyabilme ve geçmiş bilgilere erişebilme yeteneğidir. Bu özellik, LSTM'yi özellikle sıralı verilerdeki karmaşık bağımlılıkları modellemede oldukça etkili kılar.

LSTM'nin temel yapısı, hücre durumu (cell state) ve kapı mekanizmaları (gates) kavramlarına dayanır. Hücre durumu, bilgileri uzun süre boyunca taşıyan bir yapıdır ve bu yapı sayesinde LSTM, geçmiş bilgileri koruyabilir. Kapı mekanizmaları ise bilgi akışını kontrol eder ve bu mekanizmalar sayesinde LSTM, hangi bilgilerin unutulacağını, hangi bilgilerin saklanacağını ve hangi bilgilerin çıktıya aktarılacağını dinamik olarak belirler. Yapısında unutma kapısı, giriş kapısı, hücre durumu ve çıkış kapısı olmak üzere dört temel bileşen bulunur. Unutma kapısı (forget gate), önceki hücre durumunun (C_{t-1}) ne kadarının korunacağını belirler. Giriş kapısı (input gate), yeni bilgilerin ne kadarının mevcut hücre durumuna (C_t) ekleneceğini kontrol eder. Hücre durumu (cell state), uzun süreli belleği saklayan ana bileşendir ve doğrusal bir bağlantı sayesinde bilgiyi uzun vadede taşıyabilir. Çıkış kapısı (output gate) ise hücre

durumundan elde edilen bilgiyi işleyerek yeni gizli durumu (h_t) oluşturur. Bu kapılar sigmoid (σ) ve tanh aktivasyon fonksiyonları ile çalışarak, ağıın hangi bilgileri unuttuğunu, hangi bilgileri eklediğini ve çıktıya nasıl dönüştürdüğünü düzenler. LSTM ile ilgili yapı Şekil 2.20 ile gösterilmektedir.



Şekil 2.20. LSTM yapısı, Olah (2015)'den uyarlanmıştır.

LSTM'nin en önemli avantajı, gradyan kaybolması (vanishing gradient) sorununu büyük ölçüde hafifletmesidir. Geleneksel RNN'ler, uzun dizilerdeki bağımlılıkları öğrenirken gradyanların zaman içinde küçülmesi nedeniyle etkili bir şekilde eğitilemez. LSTM ise hücre durumu ve kapı mekanizmaları sayesinde bu sorunu minimize eder ve uzun vadeli bağımlılıkları daha iyi öğrenebilir [104]. Bu özellik, LSTM'yi özellikle metin tamamlama, makine çevirisi, konuşma tanıma ve zaman serisi tahmini gibi görevlerde oldukça başarılı kılar. LSTM'nin bazı sınırlamaları da bulunmaktadır. Özellikle, modelin karmaşık yapısı ve çok sayıda parametre içermesi, eğitim sürecini hesaplama açısından maliyetli hale getirebilir. Ayrıca, LSTM'nin performansı, hiperparametrelerin (örneğin, öğrenme oranı, kapı başlangıç değerleri) doğru ayarlanmasına büyük ölçüde bağlıdır. Bu sınırlamaları aşmak için, Kapılı Tekrarlayan Birimler (Gated Recurrent Units - GRU) gibi daha basit alternatifler önerilmiştir. GRU, LSTM'ye benzer bir performans sunarken daha az parametreye sahip olduğu için hesaplama açısından daha verimlidir [110].

Generatif ekiřmeli aęlar


Generatif ekiřmeli Aęlar (Generative Adversarial Networks - GAN), 2014 yılında Ian Goodfellow ve arkadaşları tarafından onerilen ve yapay zeka alanında devrim nitelięi taşıyan bir derin renme modelidir. GAN'lar, iki ayrı sinir aęının birbirine karřı rekabet etmesi prensibi zerine kuruludur: retici (generator) ve ayırt edici (discriminator). retici aę, gerek verilere benzeyen yeni veri rnekleri retmeye alıřırken, ayırt edici aę ise bu rneklerin gerek mi yoksa sahte mi olduęunu belirlemeye alıřır. Bu iki aę, birbirlerini srekli olarak geliřtiren bir ekiřme iinde eęitilir. Bu sre, GAN'ların son derece gereki veriler (rneęin, grntler, sesler, metinler) retmesini saęlar [111].

GAN'ların temel alıřma prensibi, bir oyun teorisi senaryosuna benzer. retici aę, ayırt edici aęı kandırmaya alıřırken, ayırt edici aę da reticinin rettięi sahte rnekleri tespit etmeye alıřır. Bu sre, bir denge noktasına (Nash dengesi) ulařana kadar devam eder. Bu denge noktasında, retici aę o kadar iyi hale gelir ki, ayırt edici aę artık gerek ve sahte rnekleri ayırt edemez. GAN'ların bu dinamik yapısı, onları zellikle grnt sentezi, veri artırma (data augmentation) ve sanatsal ierik retimi gibi alanlarda olduka popler hale getirmiřtir [111].

GAN'ların en nemli avantajı, rettikleri verilerin kalitesi ve eřitlilięidir. zellikle Deep Convolutional GAN (DCGAN), Conditional GAN (cGAN) ve CycleGAN gibi geliřmiř mimariler, GAN'ların farklı uygulama alanlarında kullanılmasını saęlamıřtır. rneęin, CycleGAN, bir grnt alanını bařka bir grnt alanına dnřtrme (rneęin, atları zebraalara dnřtrme) gibi grevlerde olduka bařarılıdır [112]. Ancak, GAN'ların eęitimi olduka zorlu olabilir. zellikle, mod kmesi (mode collapse) ve eęitim dengesizlięi (training instability) gibi sorunlar, GAN'ların performansını olumsuz etkileyebilir. Mod kmesi, retici aęın sınırlı sayıda rnek retmesine ve eřitlilięini kaybetmesine neden olurken, eęitim dengesizlięi, retici ve ayırt edici aęların birbirini geersiz kılmasına yol aabilir [111].

GAN'ların uygulama alanları olduka geniřtir. zellikle grnt iřleme alanında, gereki yzler, manzaralar ve sanatsal eserler retmek iin kullanılırlar. Ayrıca, tıbbi grntleme, veri artırma ve anomali tespiti gibi alanlarda da bařarılı sonular vermektedir. rneęin, tıbbi grntlerin kalitesini artırmak veya eksik verileri tamamlamak iin GAN'lar kullanılabilir [113]. Bununla birlikte, GAN'ların etik ve gvenlik aısından da bazı riskleri bulunmaktadır. zellikle, sahte grntler veya

videolar (deepfake) üretmek için kötüye kullanılma potansiyeli, GAN'ların etkilerini tartışmalı hale getirmiştir. Deep Convolutional GAN (DCGAN) mimarisi Şekil 2.21'de gösterilmiştir.




Şekil 2.21. DCGAN mimarisi, Hayashi (2019)'dan uyarlanmıştır.

Oto-kodlayıcılar

Otokodlayıcılar (Autoencoders), denetimsiz öğrenme (unsupervised learning) yöntemlerinden biri olarak, verilerin etkili bir şekilde temsil edilmesini sağlayan sinir ağı modelleridir. Temel olarak, otokodlayıcılar girdi verilerini daha düşük boyutlu bir özellik uzayına sıkıştırarak (encoding) ve bu sıkıştırılmış temsilden orijinal veriyi yeniden oluşturmayı (decoding) öğrenir. Bu süreç, otokodlayıcıların verilerdeki önemli özellikleri çıkarmasını ve gereksiz bilgileri filtrelemesini sağlar. Otokodlayıcılar, özellikle boyut indirgeme (dimensionality reduction), gürültü giderme (denoising) ve anomali tespiti (anomaly detection) gibi görevlerde yaygın olarak kullanılır [104].

Otokodlayıcıların temel yapısı, kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki ana bileşenden oluşur. Kodlayıcı, girdi verilerini daha düşük boyutlu bir özellik uzayına eşlerken, kod çözücü bu sıkıştırılmış temsilden orijinal veriyi yeniden oluşturmaya çalışır. Bu süreç, otokodlayıcıların verilerin temel yapısını öğrenmesini sağlar. Temel Oto-Kodlayıcı yapısı Şekil 2.22 ile gösterilmiştir.



Şekil 2.22. Temel oto-kodlayıcı yapısı, Michelucci (2022)’den uyarlanmıştır.

Otokodlayıcıların avantajları arasında, verilerin etkili bir şekilde temsil edilmesi ve boyut indirgeme yeteneği sayılabilir. Bu özellik, özellikle büyük ve karmaşık veri setleri üzerinde çalışırken büyük bir avantaj sağlar. Ancak, otokodlayıcıların bazı sınırlamaları da bulunmaktadır. Örneğin, otokodlayıcıların performansı, modelin mimarisi ve hiperparametrelerin (örneğin, öğrenme oranı, gizli katman boyutu) doğru ayarlanmasına bağlıdır. Ayrıca, otokodlayıcıların yeniden oluşturma hatası, her zaman verilerin anlamlı bir temsiliyi garanti etmez.

Dönüştürücüler

Dönüştürücüler (Transformers), 2017 yılında Vaswani ve arkadaşları tarafından önerilen ve doğal dil işleme (NLP) alanında devrim yaratan bir derin öğrenme mimarisidir. Transformers, geleneksel Tekrarlayan Sinir Ağları (RNN) ve Uzun Kısa

Süreli Bellek Ağları (LSTM) gibi modellerin aksine, sıralı verileri işlemek için özyineleme (recurrence) yerine dikkat mekanizmaları (attention mechanisms) kullanır. Bu yaklaşım, Transformers'ın uzun mesafeli bağımlılıkları daha etkili bir şekilde öğrenmesini sağlar ve paralel hesaplama imkanı sunarak eğitim sürecini hızlandırır [114]. Transformers, özellikle makine çevirisi, metin özetleme, soru-cevap sistemleri ve metin sınıflandırma gibi görevlerde olağanüstü başarılar elde etmiştir.

Transformers mimarisinin temel bileşeni, öz-dikkat (self-attention) mekanizmasıdır. Öz-dikkat, bir dizideki her bir ögenin diğer tüm öğelerle olan ilişkisini hesaplar ve bu ilişkileri kullanarak her bir ögenin temsilini günceller. Bu sayede, Transformers bir metin içindeki kelimeler arasındaki bağlamı daha iyi yakalayabilir. Öz-dikkat mekanizması, özellikle uzun metinlerdeki bağımlılıkları modellemede RNN ve LSTM gibi modellerden daha etkilidir [114]. Transformers mimarisi, bu mekanizmayı birden fazla katmanda tekrarlayarak (multi-head attention) daha zengin ve çok boyutlu temsiller elde eder.

Transformers'ın en önemli avantajlarından biri, paralel hesaplama yeteneğidir. Geleneksel RNN ve LSTM modelleri, sıralı verileri adım adım işlemek zorunda olduğu için eğitim süreci yavaş ve hesaplama açısından maliyetlidir. Transformers ise tüm diziyi aynı anda işleyebilir ve bu sayede eğitim sürecini önemli ölçüde hızlandırır. Ayrıca, Transformers'ın esnek yapısı, farklı veri türlerine (örneğin, metin, görüntü, ses) uyarlanabilmesini sağlar [114]. Transformers mimarisi, BERT (Bidirectional Encoder Representations from Transformers), GPT (Generative Pre-trained Transformer) ve T5 (Text-to-Text Transfer Transformer) gibi modern dil modellerinin temelini oluşturur. Örneğin, BERT, metinlerdeki bağlamı iki yönlü (bidirectional) olarak anlamayı sağlarken, GPT metin üretme görevlerinde oldukça başarılıdır. Bu modeller, önceden eğitilmiş (pre-trained) dil modelleri olarak kullanılır ve belirli görevlere ince ayar (fine-tuning) yapılarak uyarlanır [115]. Bu yaklaşım, NLP alanında büyük bir atılım sağlamış ve birçok yeni uygulamanın önünü açmıştır. Transformers'ın bazı sınırlamaları da bulunmaktadır. Özellikle, büyük ölçekli modellerin eğitimi, önemli miktarda hesaplama kaynağı ve enerji gerektirir. Ayrıca, öz-dikkat mekanizması, dizinin uzunluğunun karesiyle orantılı bir hesaplama karmaşıklığına sahiptir, bu da çok uzun dizilerde performans sorunlarına yol açabilir. Bu sorunları hafifletmek için, Longformer, Reformer ve Performer gibi daha verimli mimariler önerilmiştir [116, 117].

2.3.4.2. Derin öğrenme programları ve kütüphaneleri

Derin öğrenme alanında, farklı ihtiyaçlara ve kullanım senaryolarına uygun çeşitli programlama kütüphaneleri geliştirilmiştir. Bu kütüphaneler, derin öğrenme modellerinin tasarlanması, eğitilmesi ve uygulanması süreçlerini kolaylaştırmaktadır. En yaygın kullanılan derin öğrenme kütüphaneleri arasında Caffe, Keras, TensorFlow, Theano ve Torch bulunmaktadır. Bu kütüphaneler, farklı özellikleri ve kullanım kolaylıkları ile öne çıkmaktadır.

- Caffe: Python programlama dili kullanılarak Berkeley Vision and Learning Center (BVLC) tarafından geliştirilmiş açık kaynaklı bir derin öğrenme kütüphanesidir. Özellikle görüntü işleme ve bilgisayarlı görü alanlarında yaygın olarak kullanılmaktadır. Caffe, CPU ve GPU arasında geçiş yaparak hızlı ve optimize edilmiş hesaplamalar yapabilme özelliği ile dikkat çeker. Ayrıca, içerisinde önceden eğitilmiş modeller bulundurması, kullanıcıların bu modelleri kendi projelerine kolayca entegre etmelerine olanak tanır [118].
- Keras: Python tabanlı, modüler bir derin öğrenme kütüphanesidir. TensorFlow ve Theano gibi diğer derin öğrenme kütüphaneleri üzerine inşa edilmiştir. Kullanıcı dostu arayüzü ve basit yapısı ile özellikle yeni başlayanlar için idealdir. Keras, katmanlar, aktivasyon fonksiyonları ve optimizasyon algoritmaları gibi bileşenleri kolayca birleştirerek yeni modeller oluşturmayı sağlar. Ayrıca, Python ile uyumlu olması ve herhangi bir ek kurulum gerektirmemesi, kullanımını daha da kolaylaştırmaktadır [119].
- TensorFlow: Google'ın Google Brain ekibi tarafından geliştirilen açık kaynaklı bir derin öğrenme kütüphanesidir. Veri akış grafikleri kullanarak hesaplamalar gerçekleştirir. Bu grafiklerde, düğümler matematiksel işlemleri temsil ederken, kenarlar ise çok boyutlu veri dizileri (tensörler) üzerinde işlem yapar. TensorFlow, esnek mimarisi sayesinde hesaplamaları tek bir API ile masaüstü, sunucu veya mobil cihazlardaki CPU veya GPU'lara dağıtabilme özelliğine sahiptir. Bu özellik, TensorFlow'u hem araştırmacılar hem de endüstriyel uygulamalar için popüler bir seçenek haline getirmektedir [118].
- Theano: Python programlama dili ile Montreal Üniversitesi'ndeki MILA Lab tarafından geliştirilmiş bir derin öğrenme kütüphanesidir. Çok boyutlu dizileri kullanarak matematiksel ifadeleri etkili bir şekilde tanımlama ve değerlendirme yeteneği sunar. Theano, CPU ve GPU arasında geçiş yapabilme

özelliđi ile hızlı optimizasyonlar gerçekleştirir. Ayrıca, kapsamlı birim testleri yapma imkanı sunması ve yeni kullanıcılar için anlaşılır eğitim kaynaklarına sahip olması, Theano'yu öğrenme ve uygulama açısından avantajlı kılmaktadır [118].

- Torch: Lua programlama dili kullanılarak geliştirilmiş bir derin öğrenme kütüphanesidir. Çok boyutlu diziler üzerinde işlem yapma yeteneđi ile öne çıkar. Torch, makine öğrenmesi, sinyal işleme, paralel hesaplama ve ağ iletişimi gibi alanlarda kullanılabilcek hazır fonksiyonlar içerir. Ayrıca, GPU ve CPU arasında geçiş yapabilme özelliđi ile hızlı hesaplamalar yapmayı mümkün kılar. Torch, özellikle araştırmacılar tarafından yaygın olarak kullanılmaktadır [118].



3. LİTERATÜR TARAMASI

3.1. Giriş

Eğitimde Veri Madenciliği (EVM) alanında öğrenci performansını tahmin etme üzerine birçok çalışma yapılmıştır. Bu literatür çalışmaları, araştırmacılar tarafından farklı teknik ve konulara odaklanarak ele alınmıştır. Makine öğrenimi yöntemleri [16, 120–122], yapay sinir ağları [123], öğrenci okulu bırakma analizleri [124], öğrenme analitiği [125, 126], veri madenciliği yaklaşımları [126–128] ve öğrenci performansı tahmini [129–131] gibi çalışmalar öne çıkmaktadır. Bunun yanı sıra, e-öğrenme sistemleri [132], bilgisayar tabanlı öğrenme ortamları [15], bilgisayar destekli işbirlikçi öğrenme [133], öğrenci devamlılığı [134], özellik seçimi [135], performansı etkileyen faktörler [136], sınıf içi öğrenme [137], akademik başarı tahmini [138], erken tahmin sistemleri [139, 140] ve büyük veri uygulamaları [141, 142] gibi konular da geniş bir yelpazede araştırılmıştır. Ancak, derin öğrenme (DL) teknikleri kullanılarak yapılan erken tahmine özgü çalışmalar oldukça sınırlıdır. Özellikle, yalnızca DL teknikleri veya erken tahmin üzerine odaklanan kapsamlı literatür çalışmaları neredeyse bulunmamaktadır.

Erken tahmin üzerine yapılan önemli çalışmalardan biri, Zambrano ve ark. (2021) tarafından gerçekleştirilmiştir. Bu çalışmada, Google Scholar, Web of Science ve Scopus veri tabanlarından elde edilen 82 yayın incelenmiş ve bu yayınlar; eğitim sistemi türü, uygulanan veri madenciliği teknikleri, kullanılan özellikler ve erken doğru tahminin uygulanabilirliği açısından kategorize edilmiştir. Sonuçlar, çevrimiçi ve yüz yüze öğrenme çalışmalarının yaygın olduğunu göstermiştir. En sık kullanılan algoritmalar arasında Karar Ağacı (DT), Rastgele Orman (RF), Destek Vektör Makinesi (SVM), Naive Bayes (NB), Lojistik Regresyon (LR) ve Lineer Regresyon (LinR) yer almaktadır. Çalışmada, öğrenci değerlendirmesi, Öğrenme Yönetim Sistemleri (LMS) ve öğrenci etkileşimlerinden elde edilen verilerin, erken tahmin için temel faktörler olduğu belirlenmiştir. Ancak çalışmada, seçilen modellerin hiperparametreleri, tahmin modeli prosedürlerinin ayrıntılı analizi, sınırlamaların

raporlanması ve gelecekteki araştırma fırsatlarının belirlenmesi gibi alanlarda eksiklikler tespit edilmiştir [140].

Erken tahmin üzerine yapılan bir diğer çalışma, Alatawi ve ark. (2022) tarafından gerçekleştirilmiştir. Bu çalışmada, tahmin modelleri, modellerde kullanılan desenler, tahmin yöntemlerindeki zayıflıklar ve tahmin tekniklerinin uygulanmasını sınırlayan zorluklar ele alınmıştır. Ancak çalışmanın sınırlılığı, kullanılan özellikler, çalışma prosedürleri, tahmin edilen değişkenler, model değerlendirme yöntemleri ve erken tahminin zaman boyutu hakkında yeterli detaylı bilginin sunulmamış olmasıdır [139].

EVM kapsamında derin öğrenme (DL) tekniklerine açıkça odaklanan literatür çalışmalarına bakıldığında, yalnızca bir kapsamlı çalışma tespit edilmiştir. Bu çalışma, Hernández-Blanco ve ark. (2019) tarafından gerçekleştirilmiştir. Çalışmanın amacı, önceden belirlenmiş 13 EVM görevi sınıflandırmasına dayalı olarak DL kullanılarak EVM’de gerçekleştirilen görevleri belirlemektir. ACM Digital Library, Google Scholar ve IEEE Xplore veri tabanlarında yürütülen sistematik bir inceleme sonucunda, bu alanda 41 çalışma tespit edilmiştir. Bulgular, DL tekniklerinin öğrenci performansını tahmin etme, istenmeyen öğrenci davranışlarını tespit etme ve öneriler ile değerlendirmeler oluşturma gibi görevler için yaygın olarak kullanıldığını göstermiştir. Ayrıca bu çalışmaların %67’sinde, DL yöntemlerinin geleneksel makine öğrenimi (ML) yöntemlerinden daha iyi performans gösterdiği bildirilmiştir [143].

Önceki literatür çalışmaları, DL yöntemlerinin öğrenci performansının erken tahmini üzerindeki etkisini inceleyen kapsamlı bir çalışmanın eksikliğini vurgulamaktadır. Bu literatür çalışmasında, derin öğrenme ve erken tahmin alanlarını kapsayan bir inceleme yapılması amaçlanmaktadır. Bu literatür incelemesinin katkıları şunlardır:

- Öğrenci performansının erken tahmininde DL teknikleri ve algoritmalarının genel bir görünümünü sunar.
- DL'nin öğrenci performansının erken tahmininde mevcut kullanımını sistematik bir literatür incelemesi yoluyla belirler.
- Literatürdeki boşlukları tespit eder ve DL ile erken tahmini geliştirmek için gelecekteki araştırma alanlarını vurgular.

3.2. Literatür İnceleme Metodolojisi

Bu literatür incelemesi, sistematik bir inceleme olup inceleme adımlarının ayrıntıları aşağıdaki alt bölümlerde sunulmaktadır.

3.2.1. Sistematik inceleme

Bu çalışma, Kitchenham tarafından yazılım mühendisliği araştırmacılarına önerilen yönergeler doğrultusunda sistematik bir literatür inceleme yaklaşımını benimsemektedir [144]. Temel hedef, öğrencilerin performansının erken tahmini için derin öğrenme (DL) teknikleri ve algoritmalarına ilişkin mevcut durumu analiz ederek, mevcut çalışmalara dair bilgiler sağlamak ve gelecekteki araştırmalar için boşlukları belirlemektir.

Sistematik literatür inceleme prosedürü şu şekilde özetlenmiştir:

1. Araştırma Soruları

Bu çalışma aşağıdaki araştırma sorularını (AS'ler) ele almaktadır:

- AS1: Çalışmaların yayın yılı, yayın türü, eğitim türü ve seviyesi bakımından dağılımı nedir?
- AS2: Erken tahmin için hangi veri setleri, özellikler ve tahmin edilen değişkenler kullanılmaktadır?
- AS3: Erken tahmin için hangi DL modelleri ve teknikleri kullanılmakta ve performans değerlendirme yöntemleri nelerdir?
- AS4: Erken tahmin modellerinde açıklanabilir yapay zeka (XAI) teknikleri nasıl kullanılmakta ve bu tekniklerin model açıklanabilirliği üzerindeki etkisi nedir?
- AS5: Öğrenci akademik performansı ne kadar erken ve kabul edilebilir bir doğruluk seviyesiyle tahmin edilebilmektedir?
- AS6: Önceki çalışmalarda belirlenen ana zorluklar, sınırlamalar ve araştırma fırsatları nelerdir?

2. Arama Süreci

Sistematik analiz, 30 Kasım 2023 tarihine kadar Scopus ve Web of Science veri tabanlarındaki çalışmaları kapsamaktadır. Arama, sekiz anahtar terim kullanılarak gerçekleştirilmiştir: “educational data mining”, “data mining”, “machine learning”, “deep learning”, “neural network”, “performance”,

“student” ve “early”. Arama terimleri, Scopus ve Web of Science veri tabanlarına uygun şekilde yapılandırılmıştır. Kullanılan arama sorguları şu şekildedir:

Scopus: TITLE-ABS-KEY ((“educational data mining” OR “data mining” OR “machine learning” OR “deep”) AND (“deep learning” OR (“deep” AND “neural network”))) AND student AND performance AND early)

Web of Science: (ALL= (((“educational data mining” OR “data mining” OR “machine learning” OR “deep”)))) AND AB= (((“deep learning” OR (“deep” AND “neural network”))) AND student AND performance AND early))

3. Dahil Etme ve Hariç Tutma Kriterleri

Bu inceleme, 30 Kasım 2023 tarihine kadar öğrencilerin performansının erken tahmini için DL tekniklerini ve algoritmalarını ele alan çalışmaları kapsamaktadır. Öğrenci performansının erken tahmini veya DL ile doğrudan ilişkili olmayan çalışmalar, uygun özet veya anahtar kelimelere sahip olmayanlar, İngilizce yazılmamış olanlar ve tam metinlerine erişilemeyen yayınlar hariç tutulmuştur.

4. Kalite Değerlendirmesi

Çalışmaya dahil edilen araştırma makaleleri, belirtilen veri tabanlarındaki aktif akademik dergilerden alınmış ve yeterli kaliteye sahip kabul edilmiştir. Diğer veri tabanlarından elde edilen çalışmalar ise inceleme dışı bırakılmıştır.

5. Veri Toplama

Seçilen makalelere ait ilgili veriler elektronik bir tabloya organize edilmiştir. Bu veriler arasında; makale detayları, eğitim türü ve seviyesi, kullanılan veri setleri ve özellikler, DL/ML modelleri, değerlendirme yöntemleri, erken tahmin durumları, çalışmanın sınırlamaları, katkıları ve gelecekteki araştırma önerileri yer almaktadır.


6. Veri Analizi

Toplanan veriler, tanımlanan araştırma sorularına göre analiz edilmiştir. Elde edilen analiz sonuçları sentezlenmiş, her bir araştırma sorusuna yönelik bulgular karşılaştırılmış ve ortak temalar belirlenmiştir.

3.3. Arama Sonuçları

Bu çalışmada, makale seçim sürecini sistematik bir şekilde raporlamak amacıyla PRISMA (The Preferred Reporting Items for Systematic Reviews and Meta-Analysis) akış şeması kullanılmıştır. PRISMA akış şeması, tespit etme, tarama, uygunluk ve dahil etme olmak üzere dört aşamadan oluşmaktadır. Çalışmanın makale seçim aşamaları, Şekil 3.1’de PRISMA akış şeması ile görselleştirilmiştir.

Web of Science ve Scopus veri tabanlarında yapılan arama süreci sonucunda, 20 Aralık 2024 tarihine kadar yayımlanmış toplam 278 makale elde edilmiştir. Bu makaleler arasından 69’unun her iki veri tabanında da yer alan kopyalar olduğu belirlenmiş ve bir makale analiz dışında tutulmuştur. Böylece, 209 özgün makaleden oluşan bir veri seti oluşturulmuştur. Makalelerin türlerine göre dağılımı ise şu şekildedir: 113 dergi makalesi, 61 uluslararası konferans makalesi, 21 konferans değerlendirme yazısı ve 13’ü kitap, kitap bölümü, toplantı yazıları, bildiri makaleleri ve değerlendirme yazıları gibi farklı türlerden oluşmaktadır. Tüm makalelerin özetleri titizlikle incelenmiş ve bu süreçte 142 makale çalışma kapsamı dışında bırakılmıştır. Hariç tutulan makalelerin 116’sının öğrenci performansı tahmini veya derin öğrenme ile ilgili olmadığı, 24’ünün ücretsiz erişim ve tam metin sağlanamaması nedeniyle elendiği ve 2 makalenin İngilizce olmadığı tespit edilmiştir. Geriye kalan makalelere tam metin incelemesi uygulanmış, bu aşamada da konu dışı olduğu belirlenen 28 makale daha çalışma dışında bırakılmıştır. Sonuç olarak, 39 makale seçilmiş ve bu makaleler, beş temel araştırma sorusuna yanıt bulmak amacıyla kullanılmıştır.



Şekil 3.1. Sistematik literatür incelemesi makale seçim iş akışı (Prizma Flowchart).


3.4. EVM Kapsamında Derin Öğrenme ile Erken Performans Tahmini

Bu bölümde, sistematik literatür incelemesi kapsamında belirlenen araştırma sorularına verilen yanıtlar doğrultusunda elde edilen bulgular tartışılmıştır.

3.4.1. AS1: Yayınların zaman ve tür dağılımı

Tablo 3.1, seçilen 39 çalışmanın önemli detaylarını içermektedir. Bu çalışmalar, 2017 ile 30 Kasım 2023 tarihleri arasında yayımlanmıştır. Çalışmaların tamamı dergi ve

konferans yayınlarından oluşmakta olup, dergi yayınları toplamın %65'ini (24 çalışma) kapsamaktadır. Web of Science ve Scopus veri veritabanından elde edilen 39 makalenin yıllık bazda makale sayılarının dağılımı Şekil 3.2'de gösterilmektedir.



Şekil 3.2. Yıllara göre makale sayıları.

Şekil 3.2'deki veriler incelendiğinde, yıllar içinde makale sayısında bir artış eğiliminin olduğu görülmektedir. İlk çalışmaların yalnızca 2017 ve 2018 yıllarında konferans bildirisi formatında yayımlandığı anlaşılmaktadır. Ancak, 2019 yılı itibarıyla makale sayılarında belirgin bir artış gözlemlenmiştir. Özellikle 2021 yılında bu artış dikkat çekici bir boyuta ulaşmış ve toplamda 11 eser yayımlanmıştır; bunların 10'u makale olarak yayınlanmıştır. Bu durum, konuya olan ilginin giderek arttığını göstermektedir ve bu çerçevede giderek daha fazla araştırmacının bu alana yöneldiği söylenebilir.

Tablo 3.1. Seçilen çalışmaların kritik detayları.


Referanslar	Türü	Atıf Sayısı	WoS	Kaynak Adı	Yayınlayan	Eğitim Türü				Eğitim Seviyesi	
						Y	H	E	O	Ü	Tümü
(Xiaoyong Li ve ark, 2022) [40]	M	8	✓	Complex and Intelligent Systems	Springer	✓				✓	
(Venkatachalam ve ark, 2023) [37]	M	1		Revue d'Intelligence Artificielle	IIETA	✓			✓		
(Almahdi ve ark, 2023) [145]	K	1		ITIKD 2023	IEEE Inc.			✓		✓	
(Wen ve ark, 2023) [146]	M	0	✓	Applied Sciences	MDPI			✓		✓	
(Anjali ve ark, 2022) [147]	K	1		IC3SIS 2022	IEEE Inc.			✓			✓
(Waheed ve ark, 2023) [33]	M	5		Expert Systems with App.	Elsevier Ltd			✓		✓	
(Sayed ve ark, 2022) [36]	M	1		SN Computer Science	Springer	✓				✓	
(Leelaluk ve ark, 2022) [148]	K	0		TALE 2022	IEEE Inc.			✓		✓	
(Al-azazi ve ark, 2023) [149]	M	2		Heliyon	Elsevier Ltd			✓		✓	
(Wan ve ark, 2023) [150]	K	0	✓	COMPSAC	IEEE Com. Society	✓				✓	
(Qin ve ark, 2023) [151]	M	1		IEEE Access	IEEE Inc.		✓			✓	
(Kusumawardani ve ark, 2023) [152]	M	1	✓	IEEE Access	IEEE Inc.		✓			✓	
(Chen ve ark, 2022) [38]	M	6	✓	Applied Sciences	MDPI			✓		✓	
(Pereira ve ark, 2021) [153]	M	20		IEEE Access	IEEE Inc.		✓			✓	
(Tanuar ve ark, 2018) [154]	K	14		INAPR 2018	IEEE Inc.	✓				✓	
(Waheed ve ark, 2020) [155]	M	242	✓	Computers in Human Behavior	Elsevier Ltd			✓		✓	
(Aljohani ve ark, 2019) [156]	M	45		Sustainability	MDPI			✓		✓	
(Yu ve ark, 2021) [157]	M	2		Sustainability	MDPI			✓		✓	
(Aljuid, 2021) [158]	M	1		JATIT	Little Lion Sci.	✓			✓		
(Mao ve ark, 2020) [159]	K	8		EVM 2020	IEVMS			✓			✓
(Mi ve ark, 2022) [31]	M	6	✓	iJET	IAOE			✓			✓

Table 3.1. (Devamı) Seçilen çalışmaların kritik detayları.

Referanslar	Türü	Atıf Sayısı	WoS	Kaynak Adı	Yayınlayan	Eğitim Türü				Eğitim Seviyesi	
						Y	H	E	O	Ü	Tümü
(Aslam ve ark, 2021) [160]	M	16	✓	iJET	IAOE	✓					✓
(Kim ve ark, 2018) [161]	K	29		EVM 2018	IEVMS			✓			✓
(Wang ve ark, 2019) [162]	M	17		Computing	Springer			✓			✓
(Li ve ark, 2020) [39]	K	12	✓	Lecture Notes in Com.Science	Springer			✓		✓	
(Ojajuni ve ark, 2021) [32]	K	8	✓	Lecture Notes in Com. Sci.	Springer	✓			✓		
(Raga ve ark, 2019) [163]	K	33	✓	ISSET 2019	IEEE Inc.		✓			✓	
(Surenthiran ve ark, 2021) [164]	M	4	✓	Optical Memory and Neural Net.	Pleiades journals			✓			✓
(Karimi ve ark, 2020) [165]	K	25		EVM 2020	IEVMS			✓		✓	
(Chen ve ark, 2020) [166]	M	51	✓	Journal of Learning Analytics	UTS ePRESS			✓		✓	
(Hu ve ark, 2019) [167]	K	23	✓	ICPS	ACM	✓				✓	
(Hassan ve ark, 2019) [168]	M	53		International Journal of Intelligent Systems	John Wiley and Sons Ltd			✓		✓	
(Wang ve ark, t.y.) [169]	K	65		EVM 2017	IEVMS			✓			✓
(Du ve ark, 2020) [170]	M	18	✓	IEEE Access	IEEE Inc.			✓	✓		
(Uliyan ve ark, 2021) [171]	M	9	✓	IEEE Access	IEEE Inc.	✓				✓	
(Park ve ark, 2021) [172]	M	10		JOIV	Politeknik Negeri Padang			✓		✓	
(Nabil ve ark, 2021) [35]	M	41	✓	IEEE Access	IEEE Inc.	✓				✓	
(Adnan ve ark, 2021) [173]	M	70	✓	IEEE Access	IEEE Inc.			✓		✓	
(Yousafzai ve ark, 2021) [34]	M	48	✓	Sustainability	MDPI	✓			✓		

Y: Yüz yüze eğitim, H: Hibrit eğitim, E: E-Öğrenme, O: Ortaöğretim, Ü: Üniversite

Şekil 3.3'te en fazla yayına sahip kaynaklar listelenmiştir. Toplam çalışmaların yaklaşık yarısını oluşturan 23 makale, altı farklı kaynakta yayımlanmıştır. Bu kaynaklar arasında öne çıkanlar ise IEEE Access (7 makale), International Conference on Educational Data Mining (ICEVM) (4 makale), Sustainability (3 makale), Applied Sciences (2 makale), The International Journal of Engineering Technologies (IJET) (2 makale) ve Lecture Notes in Computer Science (LNCS) (2 makale) olarak sıralanmaktadır.




Şekil 3.3. En fazla yayına sahip kaynaklar.

Tablo 3.2, VOSviewer programı ile analiz edilen çalışmalarda en az 3 kez geçen yazar anahtar kelimelerine ait “Yazar Anahtar Kelimelerinin Görülme Sıklığı” ve “Toplam Bağlantı Gücü” değerlerini göstermektedir. “Yazar Anahtar Kelimelerinin Görülme Sıklığı”, belirli bir anahtar kelimenin çalışmalarda kaç kez geçtiğini ifade ederken, “Toplam Bağlantı Gücü” ise iki anahtar kelimenin birlikte görülme sıklığını ve bu ilişkinin gücünü ortaya koymaktadır. Tablo 3.2’de belirtildiği üzere, derin öğrenme, en sık kullanılan ve en yüksek toplam bağlantı gücüne sahip anahtar kelime olarak öne çıkmaktadır. Bu durum, minimum anahtar kelime görülme sıklığı 3 olan ilk on anahtar kelimeye göre değerlendirilmiştir. Öne çıkan diğer önemli anahtar kelimeler arasında “makine öğrenmesi”, “eğitim verisi madenciliği”, “erken tahmin” ve “öğrenme analitiği” yer almaktadır. VOSviewer tarafından oluşturulan görsel analiz, Şekil 3.4’de gösterildiği gibi, anahtar kelimelerin popülerliği ile bu kelimeler arasındaki bağlantıları anlamaya olanak sağlamaktadır. Bu görsel analizler, literatürdeki eğilimleri ve konular arasındaki ilişkileri daha iyi kavramak için değerli bir araçtır.


Tablo 3.2. En sık karşılaşılan anahtar kelimeler.

Sıra	Anahtar Kelime (İngilizce)	Anahtar Kelime (Türkçe)	Görülme Sayısı	Toplam Bağlantı Gücü
1	deep learning	derin öğrenme	16	22
2	machine learning	makine öğrenimi	12	18
	educational data	eğitimde veri		
3	mining	madenciliği	8	11
4	early prediction	erken tahmin	6	10
5	learning analytics	öğrenme analitiği	7	10
	long short-term	uzun kısa vadeli		
6	memory (LSTM)	bellek (LSTM)	3	8
	virtual learning	sanal öğrenme		
7	environment (VLE)	ortamı (VLE)	3	8
	student performance	öğrenci performansı		
8	prediction	tahmini	5	6
9	deep neural networks	derin sinir ağları	4	5




Şekil 3.4. Anahtar kelimeler için ortak görünüm ağ haritaları.

Çalışmalar, eğitim sistemi türü ve eğitim seviyesine göre sınıflandırıldığında Şekil 3.5'de gösterildiği gibi, çalışmaların %59'u e-öğrenme (23 çalışma), %31'i geleneksel yüz yüze eğitim (12 çalışma) ve %10'u hibrit (karma) eğitim (4 çalışma) türlerinde yer almaktadır.



Şekil 3.5. Eğitim türleri.

Bu çalışmaların analizi sonucunda, Şekil 3.6'da görüldüğü gibi, 39 çalışmanın %67'si (26 çalışma) üniversite öğrencileriyle, %13'ü (5 çalışma) ortaokul öğrencileriyle ve %21'i (8 çalışma) tüm eğitim seviyelerini kapsayan e-öğrenme kursları üzerinde gerçekleştirilmiştir. Çoğunlukla üniversite düzeyinde çalışmalar yapılmasının temel nedenleri arasında veri erişiminin kolaylığı, veri toplama süreçlerinin daha pratik olması ve bilgisayar destekli eğitimin yaygınlığı öne çıkmaktadır. Ayrıca, yükseköğretime yönelik çalışmaların büyük çoğunluğunun lisans düzeyinde olduğu, yüksek lisans, doktora veya ilkökul seviyelerinde herhangi bir çalışmanın gerçekleştirilmediği tespit edilmiştir.



Şekil 3.6. Eğitim seviyeleri.

3.4.2. AS2: Kullanılan veri setleri ve öznitelikler

Öğrenci performansının erken tahminine yönelik kullanılan veri setlerinin dağılımı Tablo 3.3'te gösterilmiştir.


Tablo 3.3. Seçilen çalışmalarda kullanılan veri setleri, öz nitelikler ve tahmin edilen nitelikler.

Referanslar	Genel/Özel	Türü	Veri Seti	Nitelikler										Tahmin Edilen Nitelikler			
				Demografik	Akademik	Etkinlik	Değerlendirme	Davranışsal	Log Dosyaları	Diğer	Final Notları	Final Puanları	Not Ortalamaları	Okulu Bırakma	Mezuniyet	Öğrenme Puanları	Diğer
(Xiaoyong Li ve ark, 2022) [40]	Ö	Diğer	Pekin üniversite veri setleri	✓				✓					✓				
(Venkatachalam ve ark, 2023) [37]	Ö	Diğer	Devlet ve mühendislik kolejleri veri seti	✓	✓		✓						✓				
(Adnan ve ark, 2021; Al-azazi ve ark, 2023; Aljohani ve ark, 2019; Almahdi ve ark, 2023; Hassan ve ark, 2019; Karimi ve ark, 2020; Kusumawardani ve ark, 2023; Waheed ve ark, 2020, 2023; Wen ve ark, 2023) [33, 145, 146, 149, 152, 155, 156, 165, 168, 173]	G	VLE	OULAD	✓	✓	✓	✓				✓						
(Anjali ve ark, 2022) [147]	Ö	MOOCs	MITx ve Harvard X dersleri							✓				✓			
(Sayed ve ark, 2022) [36]	Ö	Diğer	Halka açık erişilebilir veri kaynağı		✓	✓	✓										✓
(Leelaluk ve ark, 2022) [148]	Ö	Diğer	M2B Öğrenme sistemleri verisi							✓	✓						
(Wan ve ark, 2023) [150]	Ö	LMS	Mühendislik Fakültesi veri seti			✓	✓		✓			✓					
(Qin ve ark, 2023) [151]	Ö	Diğer	Üniversite veri seti	✓	✓	✓	✓	✓				✓					
(Chen ve ark, 2022) [38]	Ö	LMS	Moodle LMS			✓				✓		✓					✓
(Pereira ve ark, 2021) [153]	Ö	Diğer	Amazonas Federal Üniversitesi CS1 dersi			✓					✓						
(Tanuar ve ark, 2018) [154]	Ö	Diğer	Bina Nusantara Üniversite verisi				✓						✓				
(Yu ve ark, 2021) [157]	Ö	LMS	Kuzey Tayvan üniversite veri seti			✓	✓		✓			✓					

Table 3.3. (Devamı) Seçilen çalışmalarda kullanılan veri setleri, öznitelikler ve tahmin edilen nitelikler.


Referanslar	Genel/Özel	Türü	Veri Seti	Nitelikler										Tahmin Edilen Nitelikler				
				Demografik	Akademik	Etkinlik	Değerlendirme	Davranışsal	Log Dosyaları	Diğer	Final Notları	Final Puanları	Not Ortalamaları	Okulu Bırakma	Mezuniyet	Öğrenme Puanları	Diğer	
(Aljuid, 2021; Karimi ve ark, 2020; Ojajuni ve ark, 2021; Yousafzai ve ark, 2021) [32, 34, 158, 165]	G	ITSs	UCI Makine Öğrenimi Deposu	✓	✓		✓	✓				✓						
(Mao ve ark, 2020) [159]	Ö	ITSs ve Diğer	Pyrenees ve iSnap									✓					✓	
(Mi ve ark, 2022) [31]	G	MOOCs	edX açık veri seti									✓				✓		
(Aslam ve ark, 2021) [160]	Ö	Diğer	Matematik ve Portekizce veri seti	✓	✓	✓	✓					✓						
(Kim ve ark, 2018) [161]	G	MOOCs	Udacity Veri Seti			✓									✓			
(Wang ve ark, 2019) [162]	Ö	Diğer	İki e-öğrenme sistemi veri seti	✓	✓	✓	✓	✓	✓			✓						
(Li ve ark, 2020) [39]	Ö	Diğer	505 üniversite öğrenci veri seti			✓		✓					✓					
(Raga ve ark, 2019) [163]	Ö	LMS	Moodle LMS			✓		✓				✓						
(Chen ve ark, 2020) [166]	Ö	LMS	Moodle LMS			✓	✓		✓			✓						
(Hu ve ark, 2019) [167]	Ö	Diğer	Üniversite X'ten bir veri seti				✓							✓				
(Wang ve ark, t.y.) [169]	Ö	MOOCs	Code.org									✓					✓	
(Du ve ark, 2020) [170]	Ö	LMS	Blackboard LMS			✓	✓	✓	✓			✓						
(Uliyan ve ark, 2021) [171]	Ö	Diğer	Üniversite veri seti				✓							✓				
(Park ve ark, 2021) [172]	Ö	LMS	Siber Üniversite LMS sistemi	✓	✓	✓			✓					✓				
(Nabil ve ark, 2021) [35]	Ö	Diğer	Öğrenci notları				✓										✓	
(Adnan ve ark, 2021) [173]	G	LMS	xAPI-Edu-Data	✓	✓	✓						✓	✓					

Tablo 3.3'ün incelenmesiyle, Şekil 3.7'de görüldüğü gibi, çalışmaların %63'ünün (25 çalışma) Massive Open Online Courses (MOOCs), Virtual Learning Environments (VLEs), Learning Management Systems (LMSs) ve Intelligent Teaching Systems (ITSs) gibi sistemlerle bağlantılı olduğu tespit edilmiştir. Bu veri setleri arasında VLE'ler dikkat çekmektedir. Ayrıca çalışmaların %25'inde (10 çalışma) genel açık veri setlerinin kullanıldığı belirlenmiş olup, bu veri setleri içinde öğrencilerin haftalık VLE etkinlik bilgilerini içeren Open University Learning Analytics Dataset (OULAD) 10 çalışmada yer almıştır.



Şekil 3.7. Veri seti türleri.

Şekil 3.8'de gösterildiği gibi, incelenen çalışmaların üçte biri genel veri setlerini kullanmaktadır. Bu veri setleri arasında OULAD (10 çalışma), edX açık veri seti (1 çalışma), Udacity verisi (1 çalışma), xAPI-Edu-Data (1 çalışma) ve UCI Machine Learning Repository (4 çalışma) yer almaktadır.



Şekil 3.8. Veri seti kaynakları

Öğrenci performansının erken tahmininde kullanılan özniteliklerin ve hedeflenen çıktıların sınıflandırması Tablo 3.3’de ayrıntılı olarak verilmiştir. Buna göre, en sık kullanılan öznitelikler arasında öğrenci demografik bilgileri (yaş, cinsiyet, bölge, adres, aile büyüklüğü, anne ve baba eğitimi, anne ve baba mesleği, sağlık durumu vb.), değerlendirme sonuçları, etkinlik verileri, LMS günlük kayıtları ve davranışsal bilgiler yer almaktadır. Ayrıca öne çıkan diğer öznitelikler arasında öğrenci notları, not ortalamaları, test sonuçları, öğrenme çıktıları ve anlık veriler bulunmaktadır.

Yapılan araştırmalar incelendiğinde, çalışmaların %67’sinin (26 çalışma) nihai notları ve puanları tahmin etmeye odaklandığı tespit edilmiştir. Diğer hedeflenen çıktılar arasında not ortalamaları (GPA), öğrenme çıktısı puanları, uygulama performans puanları, sınav performansı, öğrenme davranışları, ders notları, devamsızlık verileri ve anlık notlar yer almaktadır.

3.4.3. AS3: Tahmin modelleri ve performans kriterleri

Önerilen modeller, karşılaştırılan modeller ile sınıflandırma ve değerlendirme yöntemlerinin dağılımı Tablo 3.4’de gösterilmiştir.


Tablo 3.4. Seçilen çalışmalarda kullanılan önerilen modeller, karşılaştırılan modeller ve performans değerlendirme yöntemleri.

Referanslar	R / S	Sınıflandırma	Önerilen Modeller								Karşılaştırılan Modeller										Değerlendirme Yöntemleri						
			LSTM	Deep ANN	CNN	DFNN	RNN	DBN	BLSTM	Hibrit	SVM	RF	LR	DT	KNN	NB	ANN	GBM	AdaBoost	Others	Doğruluk	F1 Skoru	Kesinlik	Duyarlılık	ROC-AUC	RMSE	Diğer
(Li ve ark, 2022) [40]	S	3							✓		✓	✓	✓					✓	✓	✓	✓	✓	✓				
(Venkatachalam ve ark, 2023) [37]	S	4	✓	✓					✓	✓	✓						✓		✓	✓	✓	✓	✓		✓		
(Almahdi ve ark, 2023) [145]	S	2		✓						✓						✓	✓		✓	✓							
(Wen ve ark, 2023) [146]	S	4				✓				✓	✓	✓				✓				✓	✓	✓	✓				
(Anjali ve ark, 2022) [147]	S	2		✓							✓	✓			✓	✓			✓	✓		✓					
(Waheed ve ark, 2023) [33]	S	2	✓							✓		✓	✓	✓		✓			✓	✓	✓	✓	✓	✓		✓	
(Sayed ve ark, 2022) [36]	S	2		✓	✓		✓	✓	✓						✓					✓			✓			✓	
(Leelaluk ve ark, 2022) [148]	S	2	✓								✓				✓	✓		✓			✓	✓	✓				
(Al-azazi ve ark, 2023) [149]	S	4	✓			✓	✓		✓										✓	✓	✓	✓	✓				
(Wan ve ark, 2023) [150]	S	2						✓												✓				✓			
(Qin ve ark, 2023) [151]	S	3		✓	✓					✓			✓	✓					✓	✓	✓		✓				
(Kusumawardani ve ark, 2023) [152]	S	2	✓																✓	✓	✓					✓	
(Chen ve ark, 2022) [38]	S	2	✓						✓	✓		✓								✓	✓	✓	✓				
(Pereira ve ark, 2021) [153]	S	2		✓							✓								✓	✓	✓	✓	✓	✓			
(Tanuar ve ark, 2018) [154]	R,S	2		✓								✓	✓							✓					✓		
(Waheed ve ark, 2020) [155]	S	2		✓						✓		✓								✓		✓	✓			✓	
(Aljohani ve ark, 2019) [156]	S	2	✓							✓		✓				✓				✓		✓	✓			✓	
(Yu ve ark, 2021) [157]	S	2	✓		✓		✓												✓	✓	✓	✓	✓				
(Aljuid, 2021) [158]	S	2		✓							✓						✓		✓	✓			✓			✓	

Table 3.4. (Devamı) Seçilen çalışmalarda kullanılan önerilen modeller, karşılaştırılan modeller ve performans değerlendirme yöntemleri.

Referanslar	R / S	Sınıflandırma	Önerilen Modeller										Karşılaştırılan Modeller										Değerlendirme Yöntemleri						
			LSTM	Deep ANN	CNN	DFNN	RNN	DBN	BLSTM	Hibrit	SVM	RF	LR	DT	KNN	NB	ANN	GBM	AdaBoost	Others	Doğruluk	F1 Skoru	Kesinlik	Duyarlılık	ROC-AUC	RMSE	Diğer		
(Mao ve ark, 2020) [159]	S	2	✓									✓							✓	✓	✓	✓	✓	✓					
(Mi ve ark, 2022) [31]	S	5		✓						✓		✓	✓		✓						✓	✓	✓						
(Aslam ve ark, 2021) [160]	S	2		✓						✓	✓									✓	✓	✓	✓						
(Kim ve ark, 2018) [161]	S	2						✓											✓					✓					
(Wang ve ark, 2019) [162]	S	2	✓	✓			✓			✓	✓								✓	✓	✓								
(Li ve ark, 2020) [39]	S	2						✓	✓		✓	✓	✓		✓					✓	✓			✓					
(Ojajuni ve ark, 2021) [32]	S	5			✓					✓	✓	✓	✓					✓	✓	✓									
(Raga ve ark, 2019) [163]	S	2				✓														✓				✓					
(Surenthiran ve ark, 2021) [164]	S	3							✓	✓				✓		✓					✓	✓				✓			
(Karimi ve ark, 2020) [165]	S	4	✓							✓		✓									✓		✓						
(Chen ve ark, 2020) [166]	S	2	✓							✓	✓	✓	✓	✓	✓	✓	✓							✓					
(Hu ve ark, 2019) [167]	R, S	2	✓																✓	✓	✓					✓			
(Hassan ve ark, 2019) [168]	S	2	✓									✓				✓				✓		✓	✓			✓			
(Wang ve ark, t.y.) [169]	S	2	✓									✓									✓	✓	✓						
(Du ve ark, 2020) [170]	S	2		✓					✓				✓					✓		✓	✓	✓	✓			✓			
(Uliyan ve ark, 2021) [171]	S	2						✓	✓	✓	✓	✓	✓		✓	✓				✓	✓	✓	✓						
(Park ve ark, 2021) [172]	S	2		✓						✓	✓		✓							✓	✓	✓	✓	✓					
(Nabil ve ark, 2021) [35]	S	2		✓						✓	✓	✓	✓	✓	✓		✓			✓	✓					✓			
(Adnan ve ark, 2021) [173]	S	4				✓				✓	✓			✓		✓	✓	✓	✓	✓	✓	✓							
(Yousafzai ve ark, 2021) [34]	S	6	✓		✓		✓		✓	✓	✓	✓		✓	✓					✓	✓	✓	✓						

Şekil 3.9, incelenen makalelerde önerilen derin öğrenme (DL) modellerinin çeşitliliğini göstermektedir. Bu modeller arasında Long Short-Term Memory (LSTM), Deep Feed Forward Neural Networks (DFFNN), Bidirectional LSTM (BLSTM), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Deep Belief Network (DBNN), Deep Neural Networks (DNN) ve hibrit DL yaklaşımları yer almaktadır. Modeller arasında LSTM'nin daha sık tercih edildiği dikkati çekmektedir.



Şekil 3.9. Önerilen DL modelleri.

Hibrit DL tekniklerinin dokuz farklı çalışmada kullanıldığı belirlenmiştir. Bu teknikler arasında şunlar bulunmaktadır:

- CNN-LSTM [37–40],
- Levy Flight Rock Hyraxes Swarm Optimization (LFRHSO)-RNN [36],
- Atom Search Optimization (ASO)-DBN [164],
- BLSTM + Conditional Random Field (CRF) [171],
- Latent Variational Autoencoder (LVAEPre)-DNN [174],
- LSTM-ANNs [149].

Bu çalışmalar arasında, Chen ve ark. (2022), VLE'deki veri dağılımı ve tahmin edilebilirlik sorunlarını çözmek amacıyla CNN ve LSTM modellerini birleştiren hibrid bir yapay zeka çerçevesi geliştirmiştir [38]. Li ve ark. (2020), üniversite kampüs ağından toplanan çevrimiçi öğrenme kayıtları ve blog verilerini kullanarak öğrencilerin 13 haftalık ders performansını tahmin etmeye yönelik Sequential


Prediction Based on Deep Network (SPDN) adlı modeli tanıtmış ve bu modelde CNN ile LSTM DL tekniklerini entegre etmiştir [39].

Li ve ark. (2022) ise, öğrencilerin dört günlük davranış verilerinden otomatik özellik çıkarımı yapmak amacıyla CNN ve LSTM modellerini birleştiren uçtan uca bir hibrit DL modeli önermiştir [40]. Venkatachalam ve Sivanraju (2023), LSTM, CNN ve Çok Katmanlı Algılayıcı (MLP) modüllerini içeren hibrit bir çerçeve olan Student Achievement Prediction Model Using the Distinctive Deep Learning (SADDL) modelini geliştirmiştir. SADDL, öğrencilerin fizyolojik, akademik ve demografik verilerini kullanarak diğer makine öğrenimi modellerine kıyasla üstün performans sergilemiştir [37].

Sayed ve ark. (2022), öğrenci, yönetici ve öğretmen verilerini içeren geniş bir veri seti ile öğrenci performansını tahmin etmek için LFRHSO-RNN adlı hibrit modeli sunmuş ve bu modeli Grey Wolf Optimizer (GWO)-RNN, Firefly Algorithm (FFA)-RNN, Bat Algorithm (BAT)-RNN ve Particle Swarm Optimization (PSO)-RNN gibi diğer hibrit modellerle karşılaştırmıştır [36]. Surenthiran ve ark. (2021), öğrencilerin geçmiş performanslarına dayalı sınıflandırılması için Atom Search Optimization (ASO) destekli DBNN tabanlı hibrit bir model önermiştir [164].


Uliyan ve ark. (2021), öğrencilerin ders bırakma durumlarını analiz etmek için BLSTM ve CRF modellerini birleştiren bir hibrit DL yöntemi sunmuş ve yüksek doğruluk oranı raporlamıştır [171]. Du ve ark. (2020), veri setindeki dengesizliği gidermek ve risk altındaki öğrenciler için erken uyarılar sağlamak amacıyla LVAE tabanlı LVAEPre adlı entegre bir çerçeve geliştirmiştir [174]. Al-azazi ve Ghurab (2023) ise öğrencilerin günlük çok sınıflı performanslarını tahmin etmek için ANN ve LSTM modellerini birleştiren hibrit bir ANN-LSTM modeli tasarlamıştır [149].

Önerilen DL modellerinin, Lojistik Regresyon (LR), Destek Vektör Makineleri (SVM), Karar Ağacı (DT), Rastgele Orman (RF), k-En Yakın Komşu (KNN), Yapay Sinir Ağı (ANN), Gradient Boosting Machine (GBM), Adaptive Boosting (AdaBoost) ve Naive Bayes (NB) gibi temel makine öğrenimi modelleriyle karşılaştırıldığı görülmüştür (Şekil 3.10). Ayrıca bazı çalışmalarda, önerilen modeller LSTM, CNN, RNN ve DNN gibi DL teknikleriyle de karşılaştırılmıştır. Sonuçlar, önerilen DL modellerinin ML ve DL tekniklerine kıyasla eşdeğer veya üstün performans gösterdiğini ortaya koymuştur.



Şekil 3.10. Karşılaştırılan ML modelleri.


Şekil 3.11, seçilen makalelerde ele alınan sınıflandırma türlerini göstermektedir. Tanuar ve ark. (2018) [154] ile Hu ve Rangwala (2019) [167] dışında, çalışmalar sınıflandırma üzerine yoğunlaşmıştır. Sınıflandırılan tüm çalışmaların sonuçlarına göre, %72'si ikili sınıflandırma olarak gerçekleştirilmiştir. Geriye kalan %28'lik kısım ise üç sınıf, dört sınıf, beş sınıf ve altı sınıf olarak tahmin edilmiştir. İkili sınıflandırmaya örnek olarak geçti-kaldı, doğru-yanlış, başarılı-başarısız ve risk altında-değil gibi durumlar verilebilir.



Şekil 3.11. Sınıflandırma türleri.

Birden fazla model oluşturulduğu durumlarda, en iyi performans gösteren modeli değerlendirmek ve seçmek oldukça önemlidir. Şekil 3.12, seçilen makalelerde kullanılan performans değerlendirme yöntemlerini göstermektedir. Regresyon

çalışmaları için Kök Ortalama Karesel Hata (Root Mean Square Error , RMSE) tercih edilirken, sınıflandırma çalışmaları doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall), F1 skoru ve Eğri Altındaki Alan (AUC) gibi performans metrikleriyle değerlendirilmiştir.



Şekil 3.12. Sınıflandırma değerlendirme yöntemleri.

3.4.4. AS4: Öğrenci performansının erken tahmini

Öğrenci performansının erken tahminine yönelik seçilen çalışmalar incelendiğinde, erken tahmin sürelerinin derslerin uzunluğuna bağlı olarak değişiklik gösterdiği belirlenmiştir. Ancak bazı çalışmalarda eğitim sürecinin uzunluğu hakkında bilgi verilmediği görülmüştür [31, 32, 34, 36, 37, 151, 153, 154, 158, 160, 162, 164, 167, 171, 172, 174]. Ders uzunluğu, tahmin sıklığı ve erken tahmin süreleri Tablo 3.5'de özetlenmiştir.

Tablo 3.5 incelendiğinde, öğrenci performansının genellikle tahmin aralığının ilk çeyreğinde veya ortasında tahmin edildiği görülmektedir. Bu tahmin aralıklarının 20 dakikadan [159] 14 akademik yıla [35] kadar geniş bir yelpazede değiştiği gözlemlenmiştir. Ayrıca, tahmin süresi uzadıkça öğrenci performans tahminlerinin doğruluğunda bir iyileşme olduğu tespit edilmiştir. En başarılı tahmin sonuçlarının genellikle tahmin aralığının sonunda elde edildiği belirtilmiştir.

Tablo 3.5. Ders uzunluğu, tahmin sıklığı ve erken tahmin süreleri.

Referans	Süre	Tahmin Frekansı	Erken Tahmin
(Anjali ve ark, 2022) [147]	5 Hafta	1-5. Haftalar	1. Hafta
(Leelaluk ve ark, 2022) [148]	7 Hafta	1-7. Haftalar	7. Hafta
(Kim ve ark, 2018) [161]	8 Hafta	1-8. Haftalar	3. Hafta
(Li ve ark, 2020) [39]	13 Hafta	1-13. Haftalar	7. Hafta
(Chen ve ark, 2020) [166]	16 Hafta	(6, 8, 10, 12, 16). Haftalar	6. Hafta
(Yu ve ark, 2021) [157]	17 Hafta	(3, 6, 9, 12, 18). Haftalar	9. Hafta
(Wan ve ark, 2023) [150]	21 Hafta	1-12. Haftalar	8. Hafta
(Wen ve ark, 2023) [146] ve (Adnan ve ark, 2021) [173]	40 Hafta	Sekans uzunluğu (10-100)	%20'sinde
(Aljohani ve ark, 2019) [156]	40 Hafta	(5, 10, 20, 30, 40). Haftalar	10. Hafta
(Hassan ve ark, 2019) [168]	40 Hafta	(5, 10, 15, 20, 25, 30, 35, 40). Haftalar	10. Hafta
(Waheed ve ark, 2020) [155]	40 Hafta	1-4. Çeyrekler	1. Çeyrek
(Waheed ve ark, 2023) [33]	40 Hafta	(5, 10, 20, 30, 38). Haftalar	20. Hafta
(Karimi ve ark, 2020) [165]	40 Hafta	(5, 10, 15, 20). Haftalar	20. Hafta
(Al-azazi ve ark, 2023) [149]	40 Hafta	Günler (0 ve 270)	İlk 90 gün
(Almahdi ve ark, 2023) [145]	40 Hafta	Günler (0, 7, 14, 30, 45, 60)	İlk 0 gün
(Kusumawardani ve ark, 2023) [152]	40 Hafta	Günler (0, 20, 40, 60, 80, 100, 120, 140)	İlk 140 gün
(Li ve ark, 2022) [40]	145 Gün	Sekans uzunluğu (5, 10, 15, 20)	%20'sinde
(Chen ve ark, 2020) [166]	70 Gün	Günler (28, 42, 56, 70)	İlk 28 gün
(Mi ve ark, 2022) [31]	48000 Birim	Veri hacmi (8000, 16000, 32000, 40000, 48000)	8000 Birim
(Nabil ve ark, 2021) [35]	14 Yıl	Akademik Yıllar	İlk 2 yıl
(Mao ve ark, 2020) [159]	20 Dakika	Dakikalar (2, 4, 6, 8, 10, 15, 20)	İlk 10 dakika
(Raga ve ark, 2019) [163]	3 Ay	Ara sınav ve final	İlk ay
(Hassan ve ark, 2019) [168]	12 Adım	Zaman Adımları 1-12	5. Adımda

3.4.5. AS5: Açıklanabilir yapay zeka (XAI) kullanımı ve açıklanabilirlik

Eğitim Veri Madenciliği (EVM) alanında, Açıklanabilir Yapay Zeka (XAI) uygulamaları, karmaşık modellerin karar mekanizmalarını anlamaya yönelik sunduğu olanaklar sayesinde özellikle öğrenci performansını tahmin etme bağlamında büyük ilgi görmektedir. Eğitim ortamlarında kullanılan prediktif modellerin şeffaflığını ve

yorumlanabilirliğini artırmak için XAI'nin faydalarını ele alan iki çalışma bulunmaktadır.

Pereira ve ark. (2021), bireysel ve grup halinde programlama yapan öğrencilerin davranışlarını analiz etmek amacıyla, bir siyah kutu prediktif modelini yorumlamaya yönelik bir yöntem geliştirmiştir. Çalışmada, istatistiksel analizler yardımıyla öğrenci performansını etkileyen faktörler incelenmiştir [153]. Chen ve ark. (2022), sanal öğrenme ortamlarında öğrenci performansı tahmini için açıklanabilir yapay zeka tekniklerini kullanan bir çerçeve sunmuştur. Bu çalışma, öğrencilerin akademik başarılarını etkileyen unsurların daha iyi anlaşılmasını sağlayarak derin XAI yaklaşımlarını eğitim süreçlerine entegre etmiştir [38].

Sonuç olarak, Açıklanabilir Yapay Zeka'nın EVM ile entegrasyonu, öğrenci performansını öngören prediktif modellerin şeffaflığını ve yorumlanabilirliğini artırarak eğitimcilere değerli içgörüler sunmaktadır. Bu sayede, eğitim süreçlerinde daha etkin müdahalelerde bulunmak ve sonuçları iyileştirmek mümkün hale gelmektedir.

3.4.6. AS6: Çalışmaların sınırlılıkları, katkıları ve gelecek araştırma önerileri

3.4.6.1. Çalışmaların sınırlılıkları

Çalışmaların sınırlılıkları genellikle veri setleriyle ilgili sorunlar olarak rapor edilmiştir. Bu sınırlılıklar şu şekilde özetlenebilir: veri setindeki dengesiz dağılım [33, 35, 145–147, 149, 152, 155–157, 160, 165, 166, 168, 173], küçük örneklem boyutu [159, 166], yapısız veri [159], veri setinin sınırlı olması [36, 37, 150, 174], kısa eğitim süresi [159], genel veri setlerinin kullanımı [31, 32, 145, 146, 149, 152, 155, 155, 156, 161, 165, 168, 173], yalnızca temel özelliklerin dikkate alınması [34], düşük katılım oranı [156] ve aynı türdeki verilerin kullanılması [35, 148, 154, 167, 171].

3.4.6.2. Çalışmaların katkıları

Seçilen çalışmalar incelendiğinde, aşağıdaki konuları ele almak amacıyla yeni algoritmalar geliştirerek literatüre katkı sağladıkları görülmüştür: davranışsal verilerin analizi [32, 39, 40, 153, 162, 173, 174], öğrenme sonuçlarının tahmin edilmesi [31, 159], veri setlerindeki dengesiz dağılımın ele alınması [38, 145–147, 160, 166], tahmin sonuçlarının yorumlanabilirliğinin artırılması [38, 149], özellik seçiminin entegre edilmesi [31, 34] ve zaman serisi sıralı sınıflandırma problemlerinin çözülmesi [33, 39, 40, 148, 150, 156, 161, 165, 166, 168]. Ayrıca, çalışmaların ele aldığı diğer önemli

konular arasında çok adımlı sınıflandırma problemleri [159, 169], karma öğrenme ortamlarında tahmin yapılması [163], terk etme oranlarının tahmin edilmesi [147] ve mezuniyet tahminleri [161] yer almaktadır.

3.4.6.3. Çalışmalardan gelecek araştırmalar için öneriler

İncelenen çalışmaların geleceğe yönelik araştırma önerileri, veri ve modeller olmak üzere iki ana kategoriye ayrılmıştır. Veri ile ilgili olarak, gelecekte çözülmesi gereken konular arasında veri dengesizliği probleminin giderilmesi [33, 35, 145, 165, 166], veri seyrekliği sorunlarının analiz edilmesi [165, 173] ve veri setlerinin genişletilmesi [33–40, 148, 151, 156–158, 160, 161, 168, 174] gibi başlıklar yer almaktadır.

Model geliştirme açısından ise, zaman duyarlı modellerin araştırılması [149, 159], farklı model türlerinin incelenmesi [37, 172], önerilen modellerin iyileştirilmesi [146, 146, 171], doğal dil işleme tekniklerinin entegrasyonu [155, 156, 170, 173] ve derin öğrenme modellerinin yorumlanabilirliğinin dinamik olarak tahmin edilmesi [40] gibi konuların daha fazla çalışılması önerilmektedir.

3.5. Literatür Sonucu

Bu sistematik literatür taraması, eğitim verisi madenciliği (EVM) bağlamında derin öğrenme (DL) kullanılarak öğrenci performansının erken tahmini üzerine yapılan 39 çalışmayı sentezleyip analiz etmiştir. İnceleme; yayınların özellikleri, çalışmaların dağılımı, kullanılan veri setleri ve öznitelikler, önerilen modeller ve performans değerlendirme yöntemleri gibi çeşitli yönleri kapsamlı bir şekilde ele almıştır. Bunun yanı sıra, araştırmaların sınırlamaları, katkıları ve gelecekteki çalışmalar için sunulan öneriler detaylı olarak incelenmiştir.

İncelemeden elde edilen başlıca bulgular şu şekilde özetlenmiştir:

1. Yayın Trendleri ve Dağılımı:

- Web of Science ve Scopus veritabanlarından başlangıçta 278 makale elde edilmiş, bunlardan 209’u benzersiz makale olarak detaylı analize dahil edilmiştir.
- Çalışmaların %65’i dergilerde yayımlanmış olup, en verimli kaynaklar arasında IEEE Access, EVM, Sustainability, Applied Sciences, IJET ve LNCS bulunmaktadır.

- Çalışmalar genellikle e-öğrenme (%59) ve geleneksel yüz yüze eğitim (%31) bağlamında yürütülmüş ve ağırlıklı olarak üniversite düzeyindeki öğrencilere (%67) odaklanmıştır.
- DL, en sık karşılaşılan anahtar kelime olarak öne çıkarken, bunu makine öğrenmesi, eğitim verisi madenciliği, erken tahmin ve öğrenme analitiği takip etmiştir.

2. Veri Seti ve Öznitelik Analizi:

- MOOCs, VLE'ler, LMS'ler ve ITS'ler, erken tahmin çalışmalarında en yaygın kullanılan veri setleri arasındadır.
- Öğrenci demografik bilgileri, değerlendirme sonuçları, etkinlik verileri, LMS günlük verileri ve davranışsal bilgiler, tahmin için kullanılan temel özniteliklerdendir.
- Çalışmaların %67'sinde tahmin edilen temel çıktılar nihai puanlar ve notlar olmuştur.

3. Model ve Performans Analizi:

- Erken tahmin amacıyla kullanılan DL teknikleri arasında LSTM, DFFNN, BLSTM, CNN, RNN, DBN ve hibrit DL modelleri bulunmaktadır.
- Özellikle CNN ve LSTM modellerinin birleştirilmesiyle elde edilen hibrit DL teknikleri, istikrarsız veri dağılımları ve tahmin edilebilirlik sorunlarına karşı etkili sonuçlar sunmuştur.
- Önerilen DL modelleri, temel ML modelleri ve diğer DL teknikleriyle kıyaslandığında üstün veya benzer performans göstermiştir.
- Değerlendirme yöntemleri arasında doğruluk, hassasiyet, hatırlama, F1 skoru, AUC ve regresyon modelleri için RMSE kullanılmıştır.

4. Erken Tahmin Süresi Analizi:

- Erken tahmin süreleri, dersin süresine bağlı olarak 20 dakikadan 14 akademik yıla kadar değişiklik göstermiştir.
- Tahmin süresi sonlarında daha iyi sonuçların elde edildiği gözlemlenmiştir.

5. Erken Tahmin Modellerinde Açıklanabilir Yapay Zeka (XAI) Tekniklerinin Kullanımı:

- XAI teknikleri, EVM bağlamında öğrenci performansını tahmin eden modellerin şeffaflığını artırarak akademik başarıyı etkileyen faktörlerin

daha iyi anlaşılmasını sağlamaktadır. Bu sayede, eğitim süreçlerinde daha etkin müdahaleler mümkün hale gelmektedir.

6. Sınırlamalar, Katkılar ve Gelecek Araştırmalar:

- Çalışmalarda sıkça karşılaşılan sınırlamalar, veri setiyle ilgili sorunlara odaklanmaktadır; bunlar arasında istikrarsız veriler, küçük örneklem boyutları ve veri kıtlığı öne çıkmaktadır.
- Çalışmaların katkıları arasında davranışsal veri analizi, öğrenme çıktılarının tahmini ve istikrarsız veriyle başa çıkmak için yeni algoritmalar geliştirilmesi bulunmaktadır.
- Gelecekteki araştırma önerileri, veri sınırlamalarını aşma yöntemlerinin geliştirilmesi, zaman duyarlı modellerin keşfi, doğal dil işleme tekniklerinin entegrasyonu ve DL modellerinin yorumlanabilirliğinin dinamik tahmini gibi konuları kapsamaktadır.

3.6. Genel Değerlendirme ve Gelecek Fırsatlar

Bu sistematik literatür taraması, EVM bağlamında DL yöntemleriyle öğrenci performansının erken tahminine ilişkin mevcut araştırmalar hakkında kapsamlı bir genel bakış sunmaktadır. Elde edilen bulgular, araştırmacılar, eğitimciler ve politika yapıcılar için önemli bilgiler sağlamanın yanı sıra, bu dinamik ve etkili alanı geliştirmek için gelecekteki çalışmalara rehberlik edebilecek temel veriler sunmaktadır.

Bununla birlikte, bu incelemenin belirli sınırlamaları da bulunmaktadır. Öncelikle, veritabanı seçimi ve sorgu stratejisi nedeniyle bazı çalışmalar gözden kaçmış olabilir. Anahtar kelime ve özet bazlı sınırlamalar, içerik açısından uygun olabilecek bazı çalışmaların dışlanmasına yol açmış olabilir. Ayrıca, tam metin erişim kısıtlamaları ve kullanılan modellerle ilgili hiperparametre bilgisi eksiklikleri de dikkate alınması gereken diğer sınırlamalardır.

Gelecekteki Araştırma Fırsatları:

- Öğrenci performansı tahmini için mevcut hibrit DL modellerinin geliştirilmesi veya yeni modellerin tasarımı,
- Büyük veri ve IoT altyapıları kullanılarak gerçek zamanlı veri analizi yapılması,

- Eğitim türüne uygun özniteliklerin seçimi,
- Risk altındaki öğrenciler için erken uyarı sistemlerinin oluşturulması ve bu sistemler aracılığıyla gerçek zamanlı müdahalelerin uygulanması,
- Bu müdahalelerin etkinliğinin ölçülmesi,
- Açıklanabilir yapay zeka modellerinin geliştirilmesi.



4. METODOLOJİ

4.1. Giriş

Bu çalışma, yüz yüze eğitim ortamlarında öğrencilerin akademik performansını erken tahmin etmeyi hedeflemektedir. Özellikle lise verileri ve yükseköğretim kurumları sınavı (HEIE) verilerinin, öğrencilerin akademik başarılarını önceden tahmin etme konusundaki etkilerini belirlemek için beş ana analiz gerçekleştirilmiştir. Bu analizler, öğrencilerin başarılarını tahmin etme sürecinde kullanılan verilerin türünü, bu verilerin modellerle entegrasyonunu ve tahmin modellerinin etkinliğini kapsamaktadır.

İlk olarak, Pearson korelasyon filtre yöntemi ile özellikler arasındaki doğrusal ilişkiler belirlenmiş ve yüksek derecede benzer olan özellikler tespit edilmiştir. Yüksek korelasyona sahip özellik çiftleri, belirlenen eşik değeri (0.95) kullanılarak seçilmiştir.

İkinci analizde, bağımsız değişkenlerin Genel Not Ortalaması (GPA) üzerindeki etkilerini değerlendirmek ve en yüksek tahmin gücüne sahip değişkenleri belirlemek amacıyla lojistik regresyon analizi yapılmıştır.

Üçüncü analizde, dönemin başında öğrenci akademik performansının erken tahmin edilmesi amaçlanmıştır. Bu amaçla, demografik bilgiler, akademik performans verileri, lise ve HEIE sonuçları kullanılarak önerilen hibrit derin öğrenme modeli olan Parçacık Sürü Optimizasyonu tabanlı Derin Sinir Ağı modeli (PSO-DNN), geleneksel makine öğrenimi ve derin sinir ağları (DNN-DL) modelleriyle karşılaştırılmıştır.

Dördüncü analizde ise, toplanan özniteliklerin öğrenci performansının erken tahminine olan katkıları hesaplanmıştır. Bu öznitelikler demografik (D), akademik (P) ve lise ile HEIE verilerini (H) içeren üç ana gruba ayrılmıştır.


Beşinci analizde, öğrencilerin performanslarını tahmin etmede daha fazla veri kullanılmıştır. Dönem içinde değişmeyen veriler ile ara sınav, quiz, ödev ve proje tasarımı gibi değişken veriler eklenerek modeller geliştirilmiştir. Bu modellerin performansı, dönem başı, ara sınav öncesi ve final sınavı öncesi gibi farklı zaman dilimlerinde ölçülmüş ve sınavların tahmin sürecine katkıları belirlenmiştir.

Altıncı analizde, önerilen PSO-DNN modelinin genelleştirilebilirliği değerlendirilmiş ve xAPI-Edu-Data veri seti ile modelin performansı test edilmiştir. Bu veri seti, öğrencilerin notlarını üç kategoriye ayıran ve akademik araştırmalarda yaygın olarak kullanılan bir genel veri setidir. Modelin doğruluk sonuçları, literatürdeki diğer erken tahmin çalışmalarının sonuçlarıyla karşılaştırılarak değerlendirilen modelin başarısı ortaya konmuştur.

Son olarak, önerilen hibrit PSO-DNN modelinin tahmin performansını daha iyi anlamak amacıyla, SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi açıklanabilir yapay zeka (XAI - Explainable Artificial Intelligence) yöntemleri uygulanmıştır. XAI yöntemleri ile elde edilen sonuçlar, modelin tahmin performansını daha iyi anlamak amacıyla istatistiksel duyarlılık analizi ile karşılaştırılmıştır. XAI yöntemleri, modelin tahminleri üzerindeki en etkili özelliklerin belirlenmesini sağlarken, t-testi ve ANOVA (Analysis of Variance) gibi istatistiksel testlerle bu özelliklerin istatistiksel olarak anlamlı olup olmadığı değerlendirilmiştir. İstatistiksel duyarlılık analizi, özellikle modelin hangi özelliklere daha duyarlı olduğunu ve bu özelliklerin tahminler üzerindeki etkilerinin kayda değer olup olmadığını ortaya koymayı amaçlamaktadır. Bu karşılaştırma, XAI sonuçlarının güvenilirliğini ve geçerliliğini destekleyerek, modelin tahminlerine olan etkilerinin daha derinlemesine anlaşılmasını sağlamaktadır.

4.2. Kavramsal Model

Bu bölüm, Eğitim Veri Madenciliği (EVM) alanında açıklanabilir yapay zekâ entegrasyonu ile hibrit bir derin öğrenme modelini kullanarak yüz yüze eğitim ortamlarında öğrenci performansını erken tahmin etmeye yönelik yenilikçi bir yaklaşımı ele almaktadır. Şekil 4.1, bu çalışmada kullanılan iş akışını görsel olarak sunmaktadır. Metodoloji; veri toplama, veri ön işleme, özellik seçimi, veri bölme, model geliştirme, değerlendirme, model açıklama ve duyarlılık analizi temel aşamalarından oluşmaktadır. Bu aşamaların her biri, ilerleyen bölümlerde detaylı bir şekilde açıklanacaktır.



Şekil 4.1. Metodoloji iş akışı.

4.2.1. Veri toplama

Türkiye'de Yükseköğretim Kurulu (YÖK) tarafından tanınan 200'den fazla üniversite bulunmaktadır ve bu üniversiteler farklı akademik alanlar ve programlar sunmaktadır. Üniversiter devlet, vakıf, meslek yüksekokulları ve özel üniversite olarak çeşitlenmektedir. Devlet üniversiteleri yaklaşık %60'ını oluşturmaktadır.

Türkiye'de üniversiteye giriş süreci, 2018 yılından itibaren uygulamaya konulan Yükseköğretim Kurumları Sınavı (YKS) çerçevesinde gerçekleştirilmektedir. Ölçme, Seçme ve Yerleştirme Merkezi (ÖSYM) tarafından her yıl düzenlenen bu ulusal sınav sistemi, adayların lise boyunca edindikleri akademik bilgi, genel yetenek ve muhakeme becerilerinin ölçülmesini amaçlamaktadır. YKS, üç temel oturumdan oluşmaktadır: Temel Yeterlilik Testi (TYT), Alan Yeterlilik Testi (AYT) ve Yabancı Dil Testi (YDT). Bu yapı, adayların genel yeteneklerinin yanı sıra alanlara özgü bilgi düzeylerini de ortaya koymayı hedeflemektedir. Tablo 4.1'de TYT, AYT ve YDT oturumları, ders alanları ve soru dağılımları verilmiştir [175].

Tablo 4.1. TYT, AYT ve YDT oturumları, ders alanları ve soru dağılımları.

Oturum	Ders/Test Alanı	Soru Sayısı	Testlerin Kapsamı
TYT	Türkçe	40	Türkçe Testi
	Temel Matematik	40	Temel Matematik Testi
	Sosyal Bilimler	20	Tarih (5), Coğrafya (5), Felsefe (5), Din Kültürü ve Ahlak Bilgisi (veya ilave Felsefe soruları) (5)
	Fen Bilimleri	20	Fizik (7), Kimya (7), Biyoloji (6)
	Türk Dili ve Edebiyatı	40	Türk Dili ve Edebiyatı (24), Tarih-1 (10) ve Coğrafya-1 (6)
AYT	Sosyal Bilimler-1	40	Tarih-2 (11), Coğrafya-2 (11), Felsefe Grubu (12) ve Din Kültürü ve Ahlak Bilgisi (veya ilave Felsefe Grubu soruları) (6)
	Sosyal Bilimler-2	40	
	Matematik	40	Matematik Testi
YDT	Fen Bilimleri	40	Fizik (14), Kimya (13) ve Biyoloji (13)
	Yabancı Dil	80	Yabancı Dil Testi

YKS sonuçları, adayların farklı disiplinlerdeki başarılarına göre sayısal, sözel, eşit ağırlık ve dil olarak kategorize edilmektedir. TYT’de elde edilen puanlar, ön lisans ve bazı lisans programlarına erişimde esas alınırken, AYT ve YDT puanları ise lisans programlarına yerleştirme sürecinde daha ayrıntılı değerlendirme imkanı sağlamaktadır [175].

Bu sınav sonuçları ÖSYM tarafından üniversitelere web servisleri ile sunulmaktadır. Web serviste öğrencinin sınavın değerlendirilmesi için kullanılan lise bilgileri (lise başarı puanı, okulu, okul türü, okul alanı ... vb.), tercih sırası, doğru ve yanlış sayıları,

sınav puanları ve başarı sıralaması, sınav yerleştirme puanları ve başarı sıralaması ve sınav puan türleri ile ilgili veriler sunulmaktadır.

Web servisleri ile üniversitelere sunulan diğer bir veri kaynağı ise Türkiye Cumhuriyeti vatandaşlarının kimlik ve nüfus bilgilerinin dijital ortamda tutulmasını sağlayan Merkezî Nüfus İdaresi Sistemi (MERNİS)'dir.

Web servislerin yanı sıra Türkiye'deki yükseköğretim sisteminde en önemli eğitim veri kaynağı öğrenme yönetim sistemleri (Learning Management Systems - LMS)'dir. Öğrenim Yönetim Sistemi (ÖYS) üzerinden elde edilen veriler, öğrencilerin akademik performanslarını ve öğrenme süreçlerini analiz etmek için çeşitli kategorilere ayrılmaktadır. Akademik performans verileri arasında sınav sonuçları, ödev ve proje notları ile ders katılım notları yer almaktadır. Bunun yanı sıra, öğrencinin ÖYS'ye giriş-çıkış kayıtları, ders materyallerine erişim sıklığı ve süresi, forumlarda yaptığı etkileşimler gibi ders etkileşim verileri de önemli bir yer tutmaktadır. ÖYS ayrıca, öğrencinin test çözümleri, video izleme süresi ve canlı derslere katılım durumunu da kaydederek çevrimiçi öğrenme etkinlikleri hakkında veri sağlamaktadır.

4.2.2. Veri işleme ve ön işleme

Bu aşama veri birleştirme, veri temizleme ve veri dönüşümü olmak üzere üç ana adımdan oluşmaktadır. Bu kapsamda ilk olarak, Öğrenci Bilgi Yönetim Sistemi (BYS) tarafından sağlanan yükseköğretim akademik performans verileri, ÖSYM web servisi üzerinden üniversitelere sunulan lise ve Yükseköğretim Kurumları Sınavı (YKS) sonuç verileriyle birleştirildi. Ardından veri temizleme adımında, analiz ve modelleme sürecini olumsuz etkileyebilecek sorunlu verilerin tespit edilip düzeltilmesi veya çıkarılması sağlanmıştır. Bu kapsamda:

- Veri setinde yer alan ancak yalnızca tek bir değeri içeren sütunlar analiz ve modelleme için herhangi bir anlam taşımadığı için veri setinden çıkarılmıştır.
- Tüm değerleri eksik olan ya da %80'den fazla eksik veri içeren sütunlar veri setine katkıda bulunamayacakları gerekçesiyle temizlenmiştir.
- Veri setinde kalan eksik değerler belirlenmiş ve modelleme sürecinin doğruluğunu korumak adına bu eksik veriler sütunların ortalama değerleri ile doldurulmuştur.

Böylece, veri seti eksiksiz ve tutarlı bir hale getirilerek makine öğrenimi modellerine uygun bir formata dönüştürülmüştür.

Son adım olan veri dönüşümü adımı, makine öğrenimi modellerinin yalnızca sayısal verilerle çalışabilmesi nedeniyle, veri setindeki kategorik değişkenler uygun bir biçime dönüştürülmüştür. Bu dönüşüm için, kategorik veriler her bir kategoriye benzersiz bir sayısal değer atanmasını sağlayan LabelEncoder yöntemi kullanılarak sayısal değerlere dönüştürülmüştür. LabelEncoder, kategorik değişkenlerde yer alan sınıfları alfabetik sıraya göre sıralar ve her sınıfa bir tam sayı atar. Örneğin, bir “Cinsiyet” değişkeni “Erkek” ve “Kadın” kategorilerini içeriyorsa, “Erkek” kategorisi 0, “Kadın” kategorisi 1 olarak kodlanır. Bu işlem, özellikle ağaç tabanlı algoritmalar gibi kategorik değişkenlerle doğrudan çalışabilen modeller için etkili bir ön işleme adımıdır.

Sayısal veriler ise modelleme sürecinde farklı ölçeklerdeki değişkenlerin adil bir şekilde değerlendirilmesi ve ağırlıklandırılması için normalize edilmiştir. Bu işlemde, veriler ortalama ve standart sapma değerleri kullanılarak standardize edilmiş, böylece her bir özelliğin ortalaması 0, standart sapması ise 1 olacak şekilde yeniden ölçeklendirilmiştir. Normalizasyon, verilerin daha iyi bir dağılıma kavuşmasını ve bazı algoritmaların (örneğin, lojistik regresyon, SVM gibi mesafe tabanlı yöntemlerin) daha iyi performans göstermesini sağlar.

Standardizasyon işleminden sonra, verilerin belirli bir aralığa getirilmesi amacıyla Min-Max ölçekleme yöntemi uygulanmıştır. Bu yöntem, her bir veriyi minimum değer 0 ve maksimum değer 1 arasında olacak şekilde ölçeklendirir. Min-Max ölçekleme, verilerin tüm özelliklerinin aynı aralıkta olmasını sağladığı için özellikle derin öğrenme modelleri gibi gradyan tabanlı algoritmaların daha hızlı ve kararlı öğrenmesine yardımcı olur. Bu adımların tümü, veri setinin makine öğrenimi modellerine uygun hale getirilmesi ve model performansını artırmak için kritik bir ön işleme sürecini oluşturur.

4.2.3. Özellik seçimi

Özellik seçimi, model eğitimi öncesinde veri setindeki gereksiz, düşük bilgiye sahip veya birbiriyle yüksek derecede ilişkili özelliklerin elenerek, yalnızca modelin başarısı için anlamlı olan temel özelliklerin belirlenmesini içeren önemli bir adımdır. Bu

çalışmada, özellik seçimi sürecinde Pearson korelasyon filtre yöntemi kullanılmıştır. Bu yöntemle, özellikler arasındaki doğrusal ilişkiler analiz edilerek birbirine yüksek derecede benzer bilgi taşıyan veya model için anlamlı katkı sağlamayan özellikler tespit edilmiştir. Pearson korelasyon katsayısı, iki değişken arasındaki doğrusal ilişkinin yönünü ve gücünü ölçen bir metriktir ve -1 ile +1 arasında bir değer alır. Katsayı +1'e yaklaştığında pozitif doğrusal ilişki, -1'e yaklaştığında negatif doğrusal ilişki, 0'a yakın olduğunda ise ilişkisizlik anlamına gelir.

Bu süreçte, yüksek korelasyona sahip özellik çiftleri (örneğin, korelasyon katsayısı 0.95 eşik değerinden büyük olanlar) tespit edilmiştir. Yüksek korelasyon, bu özelliklerin model üzerinde aynı bilgiyi taşıyabileceğini ve bir özelliğin diğerini temsil edebileceğini gösterir. Bu durumda, modelin aşırı yüklenmesini önlemek ve daha etkili bir öğrenme süreci sağlamak amacıyla, bu çiftlerden yalnızca daha bilgilendirici olanı veri setinde tutulmuş, diğerleri çıkarılmıştır. Özelliklerin bu şekilde elenmesi, modelin karmaşıklığını azaltarak eğitim sürecini hızlandırır, daha genel sonuçlar elde edilmesini sağlar ve aşırı uyum (overfitting) riskini önemli ölçüde düşürür.

4.2.4. Lojistik regresyon analizi

Lojistik regresyon, bir ya da birden fazla bağımsız değişkenin, kategorik yapıda olan bir bağımlı değişken üzerindeki etkisini incelemek amacıyla kullanılan istatistiksel bir modelleme tekniğidir. Özellikle, bağımlı değişkenin iki veya daha fazla kategoriye ayrıldığı durumlarda kullanılır. Bu analiz, bağımlı değişkenin belirli bir kategoriye ait olma olasılığını tahmin etmek için uygundur. Örneğin, öğrencilerin GPA düzeylerinin “Geçti” veya “Kaldı” olarak sınıflandırılmasında etkili faktörleri anlamak için kullanılabilir.

Bu çalışmada, lojistik regresyon analizi, bağımsız değişkenlerin GPA üzerindeki etkilerini değerlendirmek ve en yüksek tahmin gücüne sahip değişkenleri belirlemek amacıyla uygulanmıştır. Analiz sürecinde, bağımsız değişkenleri adım adım modele dahil eden stepwise yöntem tercih edilmiştir. Stepwise yöntem, yalnızca en anlamlı katkıyı sağlayan değişkenleri modele ekleyerek daha basit ve etkili bir model elde edilmesini sağlar.

4.2.5. Veri bölme

Veri seti, makine öğrenimi modeli oluşturma sürecinde iki alt kümeye ayrılmıştır: eğitim ve test kümeleri. Eğitim kümesi, veri setinin %70'ini içerir ve modelin, verilerdeki desenleri ve ilişkileri öğrenmesi için kullanılmıştır. Test kümesi ise verilerin %30'unu içerir ve modelin, daha önce görülmemiş veriler üzerindeki performansını değerlendirmek için ayrılmıştır. Bu yöntem, modelin yeni verilere nasıl genelleme yapabildiğini değerlendirme açısından kritik öneme sahiptir. Eğitim ve test kümelerinin ayrılması, aşırı uyum (overfitting) veya yetersiz uyum (underfitting) gibi olası problemleri tespit etmeye olanak tanır.

Veri kombinasyonu çalışmasında, bağımsız öznitelikler üç ana gruba ayrılmıştır: Demografik (D), Akademik (P) ve HEİE (H). Bu grupların ve özniteliklerin detaylı dağılımı Tablo 5.1'de verilmiştir.

Erken tahmin çalışması kapsamında, dönem boyunca değişen akademik performans verileri (Kısa Sınav 1, Kısa Sınav 2, Kısa Sınav 3, Arasınava, Ödev 1, Ödev 2 ve Proje Tasarımı sınav notları), tüm statik öznitelikleri içeren veri setine sırasıyla eklenmiştir. Bu işlemin amacı, farklı zaman noktalarında tahminler yaparak performansı analiz etmektir. Tahminler, dönemin başlangıcında, arasınava sınavından önce ve final sınavından önce olmak üzere üç farklı aşamada gerçekleştirilmiştir. Akademik performans verilerinin dinamik olarak veri setine dahil edilme süreci Tablo 4.2'de detaylı bir şekilde sunulmuştur.

Tablo 4.2. Erken tahmin.

Tahmin Zamanı	D	P	H	Q1	A1	Q2	MD	A2	Q3	PR
Dönem başlangıcı	✓	✓	✓							
Arasınava sınavından önce	✓	✓	✓	✓	✓	✓				
Final sınavından önce	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓

Q: Kısa Sınav, A: Ödev, MD: Arasınava, PR: Proje Tasarımı

4.3. Model geliştirme

Bu bölümde, önerilen hibrit derin öğrenme modelinin geliştirilme süreci ve performans değerlendirmesi ayrıntılı olarak ele alınmaktadır. İlk olarak, PSO-DNN

hibrit modelinin mimarisi, hiperparametre optimizasyon süreci ve uygulama adımları detaylandırılmıştır. Ardından, modelin performansını değerlendirmek amacıyla kullanılan geleneksel makine öğrenme algoritmalarının mimarisi ve hiperparametreleri hakkında bilgi verilmiştir.

4.3.1. Önerilen hibrid derin öğrenme modeli

Önerilen Hibrid Derin Öğrenme Modeli, DNN'lerin veri içerisindeki karmaşık ilişkileri öğrenme yeteneği ile Parçacık Sürü Optimizasyonu (PSO) algoritmasının hiperparametre ayarlama ve global arama kabiliyetlerini bir araya getirmektedir. Geleneksel DNN yapılarında hiperparametre seçimi, çoğunlukla deneme-yanılma yöntemlerine bağlı olarak zaman alıcı ve hesaplama maliyetlerinin yüksek olduğu bir süreç iken, PSO algoritması bu süreci otomatik hale getirerek modelin yapısal ve eğitsel parametrelerini daha verimli bir şekilde optimize etmektedir. Bu hibrit yaklaşım, hem PSO'nun global minimuma yakın-optimal çözümler üretebilme kapasitesini hem de DNN'in karmaşık veri temsil yeteneğini kullanarak, özellikle yüksek boyutlu ve heterojen veri kümelerinde performansı artırmayı hedeflemektedir. Böylece, önerilen PSO-DNN modeli, hiperparametre optimizasyonunda karşılaşılan belirsizlik ve hesaplama maliyetlerini minimize ederken, model doğruluğu ve genel başarı oranında da belirgin iyileştirmeler sağlamaktadır. Öncelikle PSO'nun temel prensipleri, ardından DNN'in yapısal özellikleri ele alınacak, son olarak ise önerilen PSO-DNN modeli detaylandırılacaktır.

4.3.1.1. Parçacık sürü optimizasyonu (PSO)

Parçacık Sürü Optimizasyonu (PSO), bir hedef fonksiyonun global minimumunu veya maksimumunu bulmak için ajanların (parçacıkların) bir arama alanında hareket ettiği, doğadan esinlenen popüler bir optimizasyon yöntemidir [176, 177]. PSO, özellikle karmaşık problemlerin çözümünde etkili bir araçtır ve birçok farklı alanda başarıyla uygulanmaktadır. Bu yöntem, biyolojik sistemlerden, özellikle kuş sürüleri ve balık sürülerinin koordineli hareketlerinden ilham alarak geliştirilmiştir. PSO'nun temel amacı, parçacıkların arama alanında bilgi paylaşarak en uygun çözümü bulmasını sağlamaktır.

PSO, özellikle sinir ağlarının hiperparametre optimizasyonunda etkili bir şekilde kullanılmaktadır. Bu yöntem, sinir ağı modellerinde öğrenme oranı, katman sayısı, nöron sayısı gibi hiperparametrelerin optimize edilmesi için uygundur. Bu çalışmada

olduğu gibi, Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM) ve Multi-Layer Perceptron (MLP) gibi çeşitli sinir ağı mimarilerinin performansını artırmak için PSO yaygın bir şekilde tercih edilmiştir [178–180]. Bu çalışmada da derin sinir ağı modelinin hiperparametrelerini optimize etmek amacıyla uygulanmıştır.

4.3.1.2. Derin sinir ağı (DNN)

Derin Sinir Ağı (DNN), giriş ve çıkış katmanları arasında birden fazla gizli katman içeren bir Yapay Sinir Ağı (ANN) türüdür. Bu gizli katmanlar, DNN'lerin verilerden hiyerarşik temsiller öğrenmesine olanak tanır. Bu özellik, DNN'leri özellikle görsel tanıma, konuşma tanıma, doğal dil işleme gibi karmaşık görevlerde güçlü ve etkili araçlar haline getirir. DNN'lerin başarısında, eğitim sürecini doğrudan etkileyen ve modelin davranışını kontrol eden hiperparametrelerin doğru bir şekilde seçimi kritik bir öneme sahiptir. Hiperparametreler, modelin öğrenme süreci başlamadan önce belirlenir ve modelin performansı üzerinde büyük bir etkisi vardır. Derin öğrenmede en önemli hiperparametreler arasında öğrenme hızı, sinir ağının katman sayısı, her bir katmanda bulunan nöron sayısı, aktivasyon fonksiyonları, batch boyutu, regularizasyon teknikleri, dropout oranı, batch normalizasyonu, optimizasyon algoritmaları ve öğrenme hızı planlamaları yer almaktadır [178]. Bu hiperparametreler, ağın eğitimi sırasında bilgi akışını ve öğrenme sürecini düzenleyerek modelin başarımını optimize etmeye yardımcı olur.


Özellikle DNN'lerde, gizli katmanların sayısı ve her bir katmandaki nöron sayısı, modelin karmaşıklığını ve öğrenme kapasitesini belirler. Aktivasyon fonksiyonları ise modelin doğrusal olmayan ilişkileri öğrenmesini sağlar. Dropout ve batch normalizasyonu gibi regularizasyon yöntemleri ise aşırı öğrenme (overfitting) problemini azaltırken, optimizasyon algoritmaları modelin ağırlıklarının güncellenme sürecini düzenler. Tüm bu hiperparametrelerin doğru seçimi, DNN'lerin farklı problem türlerinde yüksek performans göstermesini mümkün kılar.

4.3.1.3. PSO-DNN hibrit derin öğrenme modeli

Önerilen Parçacık Sürü Optimizasyonu tabanlı Derin Sinir Ağı modeli (PSO-DNN), derin sinir ağlarının eğitim sürecini iyileştirmek amacıyla PSO'nun yinelemeli optimizasyon kabiliyetlerinden faydalanmaktadır. Bu yöntem, modelin yapısını, ağırlıklarını ve hiperparametrelerini optimize ederek, karmaşık optimizasyon

problemleri için PSO'nun yakın-optimal çözümler bulma yeteneğini kullanır. Önerilen PSO-DNN modelinin mimarisi, derin sinir ağı (DNN) modelindeki katmanları ve nöron sayılarını detaylı şekilde sunan Şekil 4.3'de gösterilmiştir.

Bu model, geleneksel Derin Sinir Ağları'na (DNN) kıyasla hiperparametrelerini otomatik olarak optimize etme özelliğine sahiptir. Geleneksel DNN'ler genellikle sabit mimariler ve hiperparametreler ile eğitilir ve bu parametrelerin belirlenmesi çoğunlukla zaman alıcı bir deneme-yanılma sürecini gerektirir. Mevcut PSO ve DNN uygulamalarının büyük bir kısmı, gizli katman sayısı veya katman başına nöron gibi yapısal parametreleri optimize etmeye odaklanmaktadır. Ancak, önerilen modelimiz, yalnızca bu yapısal parametreleri değil, aynı zamanda aktivasyon fonksiyonları, optimizasyon algoritmaları, öğrenme oranları, eğitim dönemi sayıları ve batch boyutu gibi önemli hiperparametreleri de otomatik olarak optimize etmektedir.



Şekil 4.2. Önerilen PSO-DNN modeli.

Bu otomatik hiperparametre ayarlama süreci, derin öğrenme modelleriyle sıkça ilişkilendirilen karmaşıklık ve yüksek hesaplama maliyetini önemli ölçüde

azaltmaktadır. Önerilen modelde, global-en-iyi parçacık sürüsü optimizasyon algoritması, PySwarms Python kütüphanesi kullanılarak uygulanmıştır [181]. Modelin optimizasyon sırasında kullandığı parametreler, Tablo 4.3'de detaylı bir şekilde sunulmuştur.

Tablo 4.3. PSO-DNN parametreleri.

Sembol	Parametre	Değer
α	Sürüdeki parçacık sayısı	[10, 25]
maxiter	Maksimum iterasyon sayısı	[10, 25]
w	Başlangıç ağırlığı	0.5
c1	Bireysel öğrenme katsayısı	2
c2	Global öğrenme katsayısı	2
num_layers	Gizli katman sayısı	[2, 3, 4, 5]
neurons_min	Katman başına min. nöron sayısı	4
neurons_max	Katman başına maksimum nöron sayısı	64
epochs_min	Minimum epoch sayısı	10
epochs_max	Maksimum epoch sayısı	200
batch_min	Minimum batch boyutu	2
batch_max	Maksimum batch boyutu	256
cost	Maliyet fonksiyonu	Doğruluk (Accuracy)
activation	Aktivasyon fonksiyonları	['Relu', 'Tanh']
optimizer	Optimizasyon algoritması	['SGD', 'Adam', 'RMSprop']
learning_rate	Öğrenme oranı	[0.001, 0.01, 0.1]

Ayrıca, DNN'yi optimize etmek için kullanılan PSO yöntemi, Algoritma 1'de detaylı olarak verilmiştir.

Algoritma 1: DNN'in Optimizasyonu için PSO Süreci

Girdi:

- α : Sürüdeki parçacık sayısı
- c : Bilişsel katsayılar
- w : Atalet ağırlığı
- V : Başlangıç hızı
- P : Çift gizli katmanlı düğümlerin başlangıç konumu
- $pfit$: Bireysel en iyi uygunluk değerinin başlangıç durumu
- $pibest$: Bireysel en iyi değer

- *gfit*: DNN tarafından hesaplanan başlangıç küresel en iyi uygunluk değeri
- *gbest*: Küresel en iyi değer

Adımlar:

while *gfit* > 0 **do**

for *i* = 1 to α **do**

 Hızı güncelle: $V_i \leftarrow wV_{i-1} + c_1\text{rand}_1(pibest - P_{i-1}) + c_2\text{rand}_2(gbest - P_{i-1})$

 Konumu güncelle: $P_i \leftarrow P_{i-1} + V_i$

 DNN kullanarak P_i ile *pfit*(*i*) 'i hesapla

if *pfit*(*i*) < *pfit*(*i* - 1) **then**

 Küresel en iyi değeri güncelle: $pibest \leftarrow P_i$

if *pfit*(*i*) < *gfit* **then**

 Küresel en iyi uygunluk değerini güncelle: $gfit \leftarrow pfit(i)$

 Küresel en iyi değeri güncelle: $gbest \leftarrow pibest$

end if

end if

end for

end while

return *gfit*, *gbest*

4.3.2. Karşılaştırılan makine öğrenme modelleri

Bu çalışmada önerilen hibrit derin öğrenme modeli, DNN ile geleneksel makine öğrenimi modellerinin performansını karşılaştırmıştır. Karşılaştırılan modeller arasında k-En Yakın Komşu Algoritması (KNN), Lojistik Regresyon (LR), Destek Vektör Makineleri (SVM), Rastgele Ormanlar (RF), Karar Ağaçları (DT) ve Yapay Sinir Ağları (ANN) bulunmaktadır. Bu modellerin optimizasyonunda kullanılan parametreler, Tablo 4.4'de detaylı şekilde verilmiştir.

Tablo 4.4. Karşılaştırılan model parametreleri.

Model	Parametreler
Derin Sinir Ağı (DNN)	Aktivasyon Fonksiyonu: ReLU, Çözümleyici: Adam, Öğrenme Oranı: 0.001, Epok Sayısı: 100, Mini Toplu İşlem Boyutu: 2, Gizli Katman Nöron Sayıları: [64, 32], Kayıp Fonksiyonu: Sparse Categorical Crossentropy, Başarı Metriği: Doğruluk (Accuracy), Çıkış Katmanı Aktivasyon Fonksiyonu: Sigmoid
Yapay Sinir Ağı (ANN)	Gizli Katman Boyutları: (100,), Aktivasyon Fonksiyonu: ReLU, Çözümleyici: Adam, Mini Toplu İşlem Boyutu: Otomatik (Auto), Başlangıç Öğrenme Oranı: 0.001, Rastgele Durum: 42
Karar Ağacı (DT)	Kriter: Gini, Ayırıcı: En İyi (Best), Rastgele Durum: 42
k-En Yakın Komşu Algoritması (KNN)	Komşu Sayısı: 5, Ağırlık Yöntemi: Uniform, Algoritma: Otomatik (Auto), Yaprak Boyutu: 30, p Değeri: 2, Metrik: Minkowski
Lojistik Regresyon (LR)	Ceza Fonksiyonu: L2, C Değeri: 1.0, Çözümleyici: LBFGS, Rastgele Durum: 42
Rastgele Orman (RF)	Ağaç Sayısı: 100, Kriter: Gini, Rastgele Durum: 42
Destek Vektör Makineleri (SVM)	C Değeri: 1.0, Çekirdek: RBF (Radial Basis Function), Derece: 3, Gamma: Ölçeklendirilmiş (Scale), Rastgele Durum: 42

4.4. Değerlendirme


Derin öğrenme modellerinin performansını doğru bir şekilde değerlendirmek, çeşitli sınıflandırma metriklerinin kullanılmasını gerektirir. Bu metrikler, modelin tahmin yeteneğini farklı açılardan inceleyerek kapsamlı bir değerlendirme yapılmasını sağlar. Bu çalışmada, yaygın olarak kullanılan sınıflandırma metrikleri kullanılmıştır:

4.4.1. Karşıtlık matrisi

Karşıtlık Matrisi (Confusion Matrix), bir sınıflandırma modelinin tahmin performansını detaylı bir şekilde gösteren, sınıflandırma hatalarını ve başarılarını özetleyen bir tablodur [105]. Matriste şu dört temel bileşen bulunur (Şekil 4.3.):

- Doğru Pozitif (True Positive, TP): Doğru bir şekilde “Geçti” olarak sınıflandırılan örnekler.
- Doğru Negatif (True Negative, TN): Doğru bir şekilde “Kaldı” olarak sınıflandırılan örnekler.
- Yanlış Pozitif (False Positive, FP): Yanlış bir şekilde “Geçti” olarak sınıflandırılan örnekler (Tip I Hatası).
- Yanlış Negatif (False Negative, FN): Yanlış bir şekilde “Kaldı” olarak sınıflandırılan örnekler (Tip II Hatası).

Bu matrisi kullanarak modelin güçlü ve zayıf yönleri kolayca analiz edilebilir. Örneğin, hangi sınıflar arasındaki karışıklığın fazla olduğu veya modelin belirli bir sınıfta neden başarısız olduğu gibi bilgileri çıkarabilirsiniz [182].



Şekil 4.3. Karşılıklı matrisi.

4.4.2. Doğruluk

Doğruluk (Accuracy), modelin doğru tahmin ettiği örneklerin toplam örnek sayısına oranını ifade eder:

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN)$$

Doğruluk, genel performansı hızlıca anlamak için basit ve etkili bir metriktir. Ancak, dengesiz veri setlerinde (örneğin, bir sınıfın çok fazla, diğerinin çok az olduğu durumlar) yetersiz kalabilir çünkü azınlık sınıflarındaki hatalar gözden kaçabilir [183].

4.4.3. Kesinlik

Kesinlik (Precision), pozitif olarak tahmin edilen örnekler arasında gerçekten pozitif olanların oranını ölçer:

$$\text{Kesinlik} = \text{TP} / (\text{TP} + \text{FP})$$

Bu metrik, pozitif tahminlerin doğruluğunu vurgular ve özellikle yanlış pozitiflerin maliyetli olduğu durumlarda önemlidir. Örneğin, hastalık teşhisi modellerinde, sağlıklı bir kişiyi hasta olarak yanlış tahmin etmenin önüne geçmek için hassasiyet yüksek tutulmalıdır [183].

4.4.4. Geri çağırma veya duyarlılık

Geri Çağırma veya Duyarlılık (Recall, Sensitivity), gerçek pozitif örneklerin ne kadarının doğru şekilde pozitif olarak sınıflandırıldığını ölçer:

$$\text{Duyarlılık} = \text{Doğru Pozitif Oranı (TPR)} = \text{TP} / (\text{TP} + \text{FN})$$

Bu metrik, modelin pozitif sınıfları tanıma yeteneğini değerlendirir ve özellikle pozitif vakaların gözden kaçmasının maliyetli olduğu durumlarda (örneğin, kanser taraması gibi) önem taşır [184].

4.4.5. F1-skoru

F1-Skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır ve şu şekilde hesaplanır:

$$\text{F1-Skoru} = (2 * \text{Duyarlılık} * \text{Kesinlik}) / (\text{Duyarlılık} + \text{Kesinlik})$$

Bu metrik, hassasiyet ve duyarlılık arasında bir denge sağlayarak özellikle dengesiz veri setlerinde daha anlamlı bir performans değerlendirmesi sunar [184]. Eğer bir model hem yüksek hassasiyete hem de yüksek duyarlılığa sahipse, F1-Skoru da yüksek olur.

4.4.6. Yanlış pozitif oranı


Yanlış pozitif oranı (False Positive Rate, FPR), gerçek negatiflerin yanlış bir şekilde pozitif olarak sınıflandırılma oranını ifade eder. Yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda bu oran büyük önem taşır. Örneğin bu çalışmada, “Kaldı” olarak sınıflandırılması gereken öğrencilerin “Geçti” olarak sınıflandırılması istenmeyen bir durumdur ve ciddi sonuçlar doğurabilir. Ancak, veri setinde çok az negatif örnek bulunduğu durumlarda bu ölçüt daha az kullanışlı hale gelir.

$$\text{FPR} = \text{FP} / (\text{FP} + \text{TN})$$

4.4.7. Alıcı çalışma karakteristiği eğrisi

Şekil 4.4’de gösterilen Alıcı Çalışma Karakteristiği Eğrisi (Receiver Operating Characteristic Curve, ROC) eğrisi, bir modelin pozitif sınıfları doğru tahmin etme oranını (True Positive Rate, TPR) yanlış pozitif oranı (False Positive Rate, FPR) karşısında, tüm olası sınıflandırma eşiklerinde görsel olarak temsil eder. ROC eğrisi, farklı eşiklerde TPR ve FPR değerleri hesaplanarak çizilir. Grafiğin x-ekseni FPR’yi, y-ekseni ise TPR’yi temsil eder.

Mükemmel bir modelin ROC eğrisi, bir eşikte (0, 1) noktasından geçer, bu da TPR’nin 1 ve FPR’nin 0 olduğu anlamına gelir.



Şekil 4.4. ROC eğrisi.

4.4.8. Eğri altındaki alan

Eğri Altındaki Alan (Area Under The Curve, AUC) , modelin sınıflar arasında ayrım yapabilme yeteneğini ölçer ve ROC (Receiver Operating Characteristic) eğrisi altında kalan alanı ifade eder (Şekil 4.4). AUC değeri, modelin pozitif sınıfları negatif sınıflardan ne kadar iyi ayırabildiğini gösterir. AUC değeri 1'e yaklaştıkça modelin performansı artar. Özellikle ikili sınıflandırma problemlerinde, AUC yüksek bir ayrım gücünün göstergesidir [185].

4.5. Model Açıklaması

Modelin eğitim ve test aşamalarının tamamlanmasının ardından, model tahminlerinin daha iyi yorumlanabilirliği ve şeffaflığı için yaygın olarak kullanılan açıklanabilir yapay zeka (XAI) tekniklerinden faydalanılmıştır. Bu çalışmada, özellikle SHAP (Shapley Additive Explanations) ve LIME (Local Interpretable Model-Agnostic Explanations) yöntemleri kullanılmıştır.

4.5.1. SHAP (SHapley katkı açıklamaları)

SHAP, oyun teorisinden türetilmiş bir XAI yöntemidir ve Shapley değerlerini kullanarak karmaşık modellerin tahminlerini açıklamaya yardımcı olur. Bu teknik, her bir özelliğin model tahminine olan katkısını hesaplar ve her özelliğin çıktıyı nasıl etkilediğini sayısal olarak ifade eder. SHAP değerleri, modelin çıktısını oluşturan özelliklerin ağırlıklarını belirler ve tahminlerde hangi özelliklerin daha etkili olduğunu ortaya koyar. SHAP'ın temel avantajı, bireysel özelliklerin model üzerindeki etkisini detaylı bir şekilde görselleştirerek, modelin işleyişi hakkında kapsamlı bir içgörü sunmasıdır [186, 187].

Bu çalışmada, önerilen hibrit derin öğrenme modelinin yorumlanması için SHAP Python paketindeki DeepExplainer aracı kullanılmıştır. DeepExplainer, derin sinir ağlarında SHAP değerlerini tahmin etmek ve modelin tahminlerini açıklamak için özel olarak tasarlanmıştır. Özellikle karmaşık derin öğrenme modellerinin analizinde SHAP değerlerinin kümülatif etkisini değerlendirmek, tahmin süreçlerini daha anlaşılır hale getirmiştir [188].

4.5.2. LIME (Yerel yorumlanabilir model-agnostik açıklamalar)

LIME, karmaşık modellerin belirli örnekler üzerindeki karar mekanizmalarını açıklamak için kullanılan modelden bağımsız bir XAI yöntemidir. Bu teknik, herhangi bir model türüne uygulanabilir olmasıyla dikkat çeker ve hem sınıflandırma hem de regresyon problemlerinde etkili bir şekilde kullanılabilir. LIME, bir modelin tahminini çevresel verilere dayanarak basitleştirilmiş ve anlaşılır bir açıklama sunar. Bu sayede, karmaşık ve çoğunlukla bir kara kutu olarak görülen modellerin karar verme süreçlerini kullanıcılar için şeffaf hale getirir. LIME'in bu özelliği, modelin tahminlerini daha geniş bir kitle için erişilebilir ve yorumlanabilir kılar [186, 189].

Bu çalışmada, LIME tekniklerini uygulamak için lime Python paketi kullanılmıştır. Lime Python kütüphanesi, bireysel örnekler üzerinde yerel açıklamalar üretmek için

oldukça kullanışlıdır ve tahmin süreçlerini anlaşılır bir şekilde görselleştirerek, modelin güvenilirliğini artırmıştır.

4.6. Duyarlılık Analizi

Bu bölümde, çalışma kapsamında geliştirilen hibrit PSO-DNN modelinin tahmin performansına en çok katkı sağlayan değişkenlerin belirlenmesi ve modelin hangi faktörlere daha duyarlı olduğunun incelenmesi amaçlanmaktadır. Bu doğrultuda, SHAP ve LIME gibi açıklanabilir yapay zeka (XAI) yöntemlerinin çıktılarının istatistiksel olarak anlamlı olup olmadığını değerlendirmek için istatistiksel duyarlılık analizi gerçekleştirilmiştir.

Modelin tahminlerindeki önemli değişkenleri istatistiksel olarak test etmek için t-testi ve ANOVA (Analysis of Variance) uygulanmıştır. Bu testler, modelin tahminlerinde belirleyici olan değişkenlerin istatistiksel olarak anlamlı olup olmadığını ortaya koymaktadır. Analizlerde, faktör olarak Genel Not Ortalaması (GPA) değişkeni seçilmiş ve bu değişken ile diğer değişkenler arasındaki ilişkiler incelenmiştir. İkili karşılaştırmalar için bağımsız t-testleri, birden fazla grup içeren analizler için ise ANOVA testleri tercih edilmiştir.

4.6.1.1. ANOVA testi

Tek yönlü ANOVA (Varyans Analizi), bağımsız gruplar arasındaki ortalamalar arasında istatistiksel olarak anlamlı bir fark olup olmadığını belirlemek için kullanılan bir yöntemdir. Bu analizde, gruplar arasında varyansların homojen olup olmadığını kontrol etmek amacıyla Levene testi (varyansların homojenliği testi) uygulanmıştır. Levene testi sonucunda varyansların homojen olduğu durumlarda Scheffe testi, homojen olmadığı durumlarda ise Tamhane testi gibi post-hoc testler kullanılmıştır.

Post-hoc testler, ANOVA'nın hangi gruplar arasında anlamlı farklılık olduğunu belirleyememesi nedeniyle, gruplar arasındaki spesifik farklılıkları tespit etmek için kullanılır. Scheffe testi, hata oranını kontrol etmek için oldukça katı bir yaklaşım sunarak hata oranını minimize ederken, Tamhane testi varyansların eşit olmadığı durumlarda güvenilir sonuçlar sağlar.

4.6.1.2. T-testi

T-testi, iki bağımsız grubun ortalamaları arasında anlamlı bir fark olup olmadığını değerlendirmek için kullanılan temel bir istatistiksel yöntemdir. Bu çalışmada, not

ortalaması (GPA) üzerindeki deęiřkenlerin ikili karřılařtırmaları iin baęımsız t-testleri uygulanmıřtır. rneęin, erkek ve kadın ęrencilerin GPA deęerleri arasında istatistiksel olarak anlamlı bir fark olup olmadıęını deęerlendirmek iin kullanılabilir.

T-testi, normal daęılıma sahip gruplar iin geerlidir ve grupların varyanslarının eřit olup olmadıęı Levene testi ile kontrol edilebilir. Bu yntem, eęitim ve sosyal bilimlerde sıka kullanılan basit ama etkili bir aratır.



5. MODEL UYGULAMASI VE SONUÇLAR

5.1. Giriş

Bu bölümde, önerilen hibrit PSO-DNN derin öğrenme modelinin ve diğer makine öğrenimi ile derin öğrenme modellerinin erken tahmin sonuçları detaylı bir şekilde sunulmaktadır. İlk olarak veri analizi kapsamında, verinin toplanma süreci, verinin içeriği, lojistik regresyon analizi ve özellik seçimi süreçleri ele alınacaktır. Ardından, makine öğrenimi ve derin öğrenme modelleri ile yapılan erken tahminlerin sonuçları karşılaştırılacak, önerilen hibrit modelin performansı değerlendirilecektir. Modelin uygulanabilirlik ve genellenebilirlik sonuçları da, farklı dersler ve veri setleri üzerinde test edilerek incelenecektir. Son olarak, modelin açıklanabilirlik sonuçları SHAP ve LIME yöntemleri ile detaylandırılacak, modelin tahminlerine farklı özelliklerin katkıları ve açıklanabilirliği üzerinde durulacaktır.

5.2. Veri Analizi

Bu bölümde, çalışmada kullanılan veri setlerinin analizi ve bu analizler doğrultusunda elde edilen bulgular sunulacaktır. İlk olarak, verinin toplanma ve temizleme süreci detaylandırılacak, ardından özellik seçimi süreci kapsamında veriler arasındaki ilişkiler incelenerek önemli değişkenler belirlenecektir. Daha sonra, lojistik regresyon analizi uygulanarak verilerdeki anlamlı ilişkiler ve modelin doğruluğu değerlendirilecektir. Bu analizler, çalışmanın ilerleyen aşamalarında kullanılacak makine öğrenimi ve derin öğrenme modellerinin temellendirilmesine katkı sağlayacaktır.

5.2.1. Verinin toplaması süreci

Bu çalışmada, önerilen yöntemlerin etkinliğini değerlendirmek ve büyük veri boyutlarında uygulanabilirliğini test etmek amacıyla en az 500 öğrenci verisinden oluşan bir veri seti oluşturulması hedeflenmiştir. Veri erişiminin daha kolay olması nedeniyle, Sakarya Uygulamalı Bilimler Üniversitesi (SUBÜ) çalışma kapsamında seçilmiştir. 1 enstitü, 6 fakülte, 1 yüksekokul ve 12 meslek yüksekokuluyla eğitim-öğretim faaliyetlerini sürdüren SUBÜ, 2025 yılı itibarıyla yaklaşık 30 bin öğrenciye

sahiptir. Üniversite, Öğrenci Bilgi Yönetim Sistemi (BYS) olarak adlandırılan bir LMS sistemi kullanmaktadır. Çalışmada kullanılan veriler, BYS ve ÖSYM'nin üniversitelere sunduğu ÖSYM Sınav Sonuç Açıklama Web Servisi aracılığıyla elde edilmiştir. Bu veri seti, lise performans verileri, YKS sonuçları ve yükseköğretim akademik başarı verilerini içermekte olup, Türkiye'deki yükseköğretim sistemine özgü yapısıyla çalışmanın özgüllüğünü artırmaktadır. Bu özel veri setinin seçilme nedeni, Türkiye'deki öğrencilerin akademik başarı tahminlerini daha doğru bir şekilde yapmak ve modelin yerel eğitim sistemine uygunluğunu sağlamaktır.

Özel veri seti, Türkiye'deki bir devlet üniversitesi olan Sakarya Uygulamalı Bilimler Üniversitesi Rektörlüğü'nden 10.10.2022 tarihli ve 62375 sayılı dilekçe ile talep edilmiş, 12.01.2023 tarihli ve E-83892146-713.01-72081 sayılı yazı (Şekil A.1.) ile izin alınarak elde edilmiştir. Teknoloji Fakültesi mühendislik bölümlerinde ortak zorunlu ders olan “Programlama” dersini 2019, 2021 ve 2022 yıllarında alan öğrencilerine aittir. Pandemi ve deprem gibi doğal afetler, eğitim-öğretim süreçlerinde aksamalara neden olmuş ve öğrenci performansına ilişkin verilerin toplanmasını zorlaştırmıştır. Bu nedenle, 2025 yılında yaklaşık 4000 öğrencisi bulunan ve en fazla öğrenciye sahip olan Teknoloji Fakültesi tez çalışması için seçilmiştir. Mühendislik bölümlerinin ortak zorunlu ders olarak yer aldığı bu fakültede, öğrenci performansının belirlenmesinde kritik bir rol oynayan ve ödev, kısa sınav ve proje gibi yoğun veri içeren “Programlama” dersi çalışmanın odak noktası olarak belirlenmiştir. Bu derse ait 2019, 2021 ve 2022 yıllarına ait veriler, geleneksel yüz yüze eğitim ortamında BYS ve ÖSYM Web Servisi'nden toplanmıştır. 2020 yılı ise pandemi nedeniyle uzaktan eğitimle gerçekleştirildiğinden, yüz yüze eğitim odaklı bu çalışma kapsamında değerlendirmeye alınmamıştır.

Bu veri setinde kullanılan performans değişkenleri diğer çalışmalarda kullanılan performans değişkenlerinden farklıdır. Bu sebeple önermiş olduğumuz modelde kullanacağımız yöntemlerin başarı performansını diğer çalışmalar ile karşılaştırabilmek amacıyla da gene bir veri seti ile de analiz gerçekleştirilmiştir.

Veri toplama sürecinin ardından gerçekleştirilen ön veri temizleme işlemleri sonucunda, veri seti toplam 63 özelliğe sahip hale getirilmiştir. Bu özelliklerden ikisi nominal, 59'u sayısal ve biri nominal çıktı değişkenidir. Özelliklerin detaylı açıklamaları Tablo 5.1'de sunulmuştur.

Tablo 5.1. SUBÜ veri seti nitelikleri.

Nitelikler (Türkçe)	Nitelikler (İngilizce)	Veri Türü
Demografik Bilgiler (D)		
Yaş	Age	Sayısal
Cinsiyet	Gender	Nominal
Engellilik Durumu	Disability Status	Nominal
Akademik Performans (P)		
Hazırlık Programında Geçirilen Dönem Sayısı	Number of Semesters in Preparatory Program	Sayısal
Dersi Alan Öğrenci Sayısı	Number of Students Taking the Course	Sayısal
Ders Tekrarı Sayısı	Number of Course Repeats	Sayısal
Alınan Ders Sayısı	Number of Courses Taken	Sayısal
Ara Sınav	Midterm	Sayısal
Kısa Sınav 1	Quiz 1	Sayısal
Kısa Sınav 2	Quiz 2	Sayısal
Kısa Sınav 3	Quiz 3	Sayısal
Ödev 1	Assignment 1	Sayısal
Ödev 2	Assignment 2	Sayısal
Proje Tasarımı	Project Design	Sayısal
Final	Final	Sayısal
Lise ve Üniversite Giriş Sınavları (H)		
Lise Başarı Puanı	High School Achievement Score	Sayısal
Diploma Notu	Diploma Grade	Sayısal
Tercih Sırası	Preference Order	Sayısal
Türkçe Doğru Sayısı	Turkish Correct	Sayısal
Türkçe Yanlış Sayısı	Turkish Incorrect	Sayısal
Sosyal Bilimler Doğru Sayısı	Social Sciences Correct	Sayısal
Sosyal Bilimler Yanlış Sayısı	Social Sciences Incorrect	Sayısal
Temel Matematik Doğru Sayısı	Basic Mathematics Correct	Sayısal
Temel Matematik Yanlış Sayısı	Basic Mathematics Incorrect	Sayısal
Fen Doğru Sayısı	Natural Sciences Correct	Sayısal
Fen Yanlış Sayısı	Natural Sciences Incorrect	Sayısal
Türk Dili ve Edebiyatı Doğru Sayısı	Turkish Language and Literature Correct	Sayısal
Türk Dili ve Edebiyatı Yanlış Sayısı	Turkish Language and Literature Incorrect	Sayısal
Tarih 1 Doğru Sayısı	History 1 Correct	Sayısal
Tarih 1 Yanlış Sayısı	History 1 Incorrect	Sayısal
Coğrafya 1 Doğru Sayısı	Geography 1 Correct	Sayısal
Coğrafya 1 Yanlış Sayısı	Geography 1 Incorrect	Sayısal
Tarih 2 Doğru Sayısı	History 2 Correct	Sayısal
Tarih 2 Yanlış Sayısı	History 2 Incorrect	Sayısal
Coğrafya 2 Doğru Sayısı	Geography 2 Correct	Sayısal
Coğrafya 2 Yanlış Sayısı	Geography 2 Incorrect	Sayısal

Tablo 5.1. (Devamı) Sakarya Uygulamalı Bilimler Üniversitesi veri seti nitelikleri.

Nitelikler (Türkçe)	Nitelikler (İngilizce)	Veri Türü
Felsefe Grubu Doğru Sayısı	Philosophy Group Correct	Sayısal
Felsefe Grubu Yanlış Sayısı	Philosophy Group Incorrect	Sayısal
Din Kültürü Doğru Sayısı	Religious Culture Correct	Sayısal
Din Kültürü Yanlış Sayısı	Religious Culture Incorrect	Sayısal
Matematik Doğru Sayısı	Mathematics Correct	Sayısal
Matematik Yanlış Sayısı	Mathematics Incorrect	Sayısal
Fizik Doğru Sayısı	Physics Correct	Sayısal
Fizik Yanlış Sayısı	Physics Incorrect	Sayısal
Kimya Doğru Sayısı	Chemistry Correct	Sayısal
Kimya Yanlış Sayısı	Chemistry Incorrect	Sayısal
Biyoloji Doğru Sayısı	Biology Correct	Sayısal
Biyoloji Yanlış Sayısı	Biology Incorrect	Sayısal
Yabancı Dil Doğru Sayısı	Foreign Language Correct	Sayısal
Yabancı Dil Yanlış Sayısı	Foreign Language Incorrect	Sayısal
Yerleşme Başarı Sırası	Placement Success Ranking	Sayısal
Yerleşme Puanı	Placement Score	Sayısal
TYT Puanı	TYT Score	Sayısal
SAY Puanı	SAY Score	Sayısal
EA Puanı	EA Score	Sayısal
TYT Yerleşme Puanı	TYT Placement Score	Sayısal
SAY Yerleşme Puanı	SAY Placement Score	Sayısal
TYT Başarı Sıralama Yüzdesi	TYT Success Ranking Percentage	Sayısal
SAY Başarı Sıralama Yüzdesi	SAY Success Ranking Percentage	Sayısal
EA Başarı Sıralama Yüzdesi	EA Success Ranking Percentage	Sayısal
TYT Yerleşme Başarı Sıralaması Yüzdesi	TYT Placement Success Ranking Percentage	Sayısal
SAY Yerleşme Başarı Sıralama Yüzdesi	SAY Placement Success Ranking Percentage	Sayısal
Performance Metrics		
Genel Not Ortalaması (GPA)	Grade Point Average	Nominal

Veri seti, üç farklı mühendislik programından, yedi öğretim görevlisi tarafından yürütülen derslere katılan toplam 1268 öğrenciden elde edilmiştir. Bu öğrencilerin %11,1'i kadın, %88,9'u erkek olup, %49,4'ü gündüz programında, %50,6'sı ise akşam programında eğitim görmektedir. Program dağılımlarına bakıldığında, öğrencilerin %50,5'i Mekatronik Mühendisliği, %30,4'ü Makine Mühendisliği ve %19,1'i Elektrik-Elektronik Mühendisliği programlarında öğrenim görmektedir.

Programlama dersi 15 haftalık ders içeriği Tablo 5.2’de verilmiştir.

Tablo 5.2. Programlama dersi ders içeriği.

Hafta	Konular
1	Algoritmalara Giriş
2	Python Programlama Temelleri
3	Veri Yapıları
4	Kontrol Yapıları ve Döngüler
5	Fonksiyonlar ve Modüller
6	Dosya İşlemleri ve Hata Ayıklama
7	Veri Bilimine Giriş
8	Temel Veri Analizi ve NumPy
9	Ara Sınav
10	Veri Görselleştirme ve Matplotlib
11	Pandas ile Veri Analizi
12	Makine Öğrenmesine Giriş
13	Denetimli Öğrenme Algoritmaları
14	Denetimsiz Öğrenme Algoritmaları
15	Derin Öğrenmeye Giriş

Genel veri seti, önerilen modelin farklı dersler ve eğitim kurumlarında uygulanabilirliğini değerlendirmek ve veri seti yanlılıklarını göz önünde bulundurmak amacıyla kullanılmıştır. Bu kapsamda, akademik araştırmalarda yaygın olarak kullanılan ve çeşitli dersleri kapsayan xAPI-Edu-Data genel veri seti tercih edilmiştir. Söz konusu veri seti, <https://www.kaggle.com/aljarah/xAPI-EDu-Data> adresinden temin edilmiş olup, dünya çapında kullanılan Kalboard 360 çevrimiçi Öğrenim Yönetim Sistemi'nden elde edilen eğitim verilerini içermektedir.

xAPI-Edu-Data, 480 veri örneği ve 16 özellikten oluşur. Özellikler, Demografik, Akademik ve Davranışsal olarak üç gruba ayrılmaktadır. Hedef değişken ise, öğrencilerin notlarının “Düşük”, “Orta” ve “Yüksek” olarak sınıflandırılabilceği “Class” özelliğidir. Tablo 5.3’te xAPI-Edu-Data veriseti nitelikleri ve açıklamaları verilmiştir.

Tablo 5.3. xAPI-Edu-Data genel veri seti nitelikleri.

Nitelik Adı	Grup	Açıklama	Tür
Gender	Demografik	Öğrencinin cinsiyeti	Kategorik
Nationality	Demografik	Öğrencinin uyruğu.	Kategorik
Place of Birth	Demografik	Öğrencinin doğum yeri.	Kategorik
Stage ID	Akademik	Öğrencinin eğitim aşaması	Kategorik
Grade Level	Akademik	Öğrencinin sınıf seviyesi.	Kategorik
Section ID	Akademik	Dersin veya sınıfın bölümü.	Kategorik
Topic	Akademik	Dersin konusu.	Kategorik
Semester	Akademik	Dönem bilgisi	Kategorik
Relation	Davranışsal	Öğrencinin ebeveyniyle olan ilişkisi (Anne veya Baba).	Kategorik
Raised Hands	Davranışsal	Öğrencinin derste parmak kaldırma (katılım) sayısı.	Sayısal
Visited Resources	Davranışsal	Öğrencinin çevrimiçi kaynakları ziyaret etme sayısı.	Sayısal
Announcements View	Davranışsal	Öğrencinin duyuruları görüntüleme sayısı.	Sayısal
Discussion Participation	Davranışsal	Öğrencinin çevrimiçi tartışmalara katılım düzeyi.	Sayısal
Parent Satisfaction	Davranışsal	Öğrenci velisinin memnuniyet düzeyi (Memnun/Memnun Değil).	Kategorik
Student Absence Days	Davranışsal	Öğrencinin devamsızlık durumu (Kısa Süreli/Uzun Süreli).	Kategorik
Class	Hedef Değişken	Öğrencinin not seviyesi (“Düşük”, “Orta”, “Yüksek”).	Kategorik

5.2.2. Verinin temizlenmesi süreci

Veri temizleme sürecinde, analiz ve modelleme aşamalarını olumsuz etkileyebilecek sorunlu veriler tespit edilerek düzeltilmiş veya çıkarılmıştır. Bu kapsamda:

- Anlamsız Sütunların Çıkarılması: Veri setinde yalnızca tek bir değeri içeren sütunlar (“TYT Engel Durumu”, “AYT Engel Durumu”, “YDT Engel Durumu”, “AYT Girme İsteği”, “YDT Girme İsteği” ve “Süre Ekstrapolasyon


Durumu”), analiz ve modelleme açısından herhangi bir katkı sağlamadığı için veri setinden çıkarılmıştır.

- Eksik Verilerin Temizlenmesi: Tüm değerleri eksik olan veya %80’den fazla eksik veri içeren sütunlar (“SOZ Puan”, “DIL Puanı”, “SOZ Yerleştirme Puanı”, “DIL Yerleştirme Puanı”, “TYT_EK Puanı”, “SOZ_EK Puanı”, “SAY_EK Puanı”, “EA_EK Puanı”, “DIL_EK Puanı”, “SOZ Başarı Sıralama Yüzdesi”, “DIL Başarı Sıralama Yüzdesi”, “TYT_EK Başarı Sıralama Yüzdesi”, “SOZ_EK Başarı Sıralama Yüzdesi”, “SAY_EK Başarı Sıralama Yüzdesi”, “EA_EK Başarı Sıralama Yüzdesi”, “DIL_EK Başarı Sıralama Yüzdesi”) veri setine katkıda bulunamayacağı için temizlenmiştir.
- Eksik Değerlerin Doldurulması: Veri setinde kalan eksik değerler (“EA Yerleştirme Puanı” ve “EA Başarı Sıralama Yüzdesi”) belirlenmiş ve modelleme sürecinin doğruluğunu korumak amacıyla sütunların ortalama değerleri ile doldurulmuştur.

Bu işlemler sonucunda veri seti eksiksiz ve tutarlı hale getirilerek makine öğrenimi modellerine uygun bir formata dönüştürülmüştür.


5.2.3. Özellik seçimi

Özellik seçimi sürecinde, yüksek korelasyona sahip olan özellikleri belirlemek için 0.95’lik bir eşik değeri kullanılmıştır. Bu süreçte, tüm özellikler ve hedef değişken olan GPA arasındaki korelasyon matrisi analiz edilmiş olup sonuçlar Şekil 5.1’de gösterilmiştir. “Diploma Notu”, “Lise Başarı Puanı”, “Yerleştirme Puanı”, “SAY Yerleştirme Puanı”, “SAY Yerleştirme Başarı Sıralama Yüzdesi”, “SAY Puanı”, “SAY Başarı Sıralama Yüzdesi”, “TYT Yerleştirme Puanı”, “TYT Yerleştirme Başarı Sıralama Yüzdesi”, “TYT Puanı” ve “TYT Başarı Sıralama Yüzdesi”, belirtilen eşik değeri doğrultusunda yüksek korelasyona sahip özellikler olarak tespit edilmiştir. Bu özellikler arasından “Diploma Notu”, “Yerleştirme Puanı”, “TYT Puanı”, “SAY Puanı”, “TYT Başarı Sıralama Yüzdesi” ve “SAY Başarı Sıralama Yüzdesi”, GPA ile düşük korelasyon göstermeleri sebebiyle gereksiz olarak değerlendirilmiş ve veri setinden çıkarılmıştır. Özellik seçimi işlemi tamamlandıktan sonra, veri setindeki özellik sayısı 54’ten 48’e düşürülerek daha optimize bir yapı elde edilmiştir.



Şekil 5.1. Yüksek korelasyon değerlerine sahip özelliklerin korelasyon matrisi.

GPA ile yüksek korelasyon değerlerine sahip özelliklere ait korelasyon matrisi Şekil 5.2'de sunulmuştur.



Şekil 5.2. GPA ile yüksek korelasyona sahip özelliklere ait korelasyon matrisi.

Şekil 5.2'ye göre GPA ile en yüksek korelasyona sahip öz nitelikler: “Hazırlık Programında Geçirilen Dönem Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Alınan Ders Sayısı”, “Arasınav”, “Kısa Sınav 1”, “Kısa Sınav 2”, “Kısa Sınav 3”, “Ödev 1”, “Ödev 2”, “Proje Tasarımı”, “Temel Matematik Doğru Sayısı”, “Kimya Doğru Sayısı” ve “Biyoloji Doğru Sayısı”dır.

5.2.4. Lojistik regresyon sonuçları

Bağımlı kategorik değişken ile bağımsız değişkenler arasındaki ilişkiyi incelemek amacıyla gerçekleştirilen lojistik regresyon analizi sonucunda, modelin başlangıçtaki doğruluk oranı %62,1 olarak hesaplanmıştır. “Kaldı (Fail)” olarak sınıflandırılan öğrenciler, %83,5 doğruluk oranıyla tahmin edilmiştir (Şekil 5.3).

Classification Table ^a					
Observed			Predicted		
			Grade Point Average	Percentage	
			Fail	Pass	Correct
Step 1	Grade Point Average	Fail	757	0	100,0
		Pass	511	0	,0
	Overall Percentage				59,7
Step 2	Grade Point Average	Fail	675	82	89,2
		Pass	396	115	22,5
	Overall Percentage				62,3
Step 3	Grade Point Average	Fail	640	117	84,5
		Pass	356	155	30,3
	Overall Percentage				62,7
Step 4	Grade Point Average	Fail	628	129	83,0
		Pass	353	158	30,9
	Overall Percentage				62,0
Step 5	Grade Point Average	Fail	632	125	83,5
		Pass	356	155	30,3
	Overall Percentage				62,1

a. The cut value is ,500

Şekil 5.3. Lojistik regresyon sınıflandırma tablosu.

Şekil 5.4'de bağımsız değişkenlerin anlamlılık düzeyleri gösterilmiştir. Tabloya göre, B değerleri her bir bağımsız değişkenin katsayılarını ifade etmektedir. “Ders Tekrarı Sayısı” değişkeni, -0.811 B değeriyle en yüksek katsayıya sahiptir. %5 anlamlılık düzeyine göre, “Hazırlık Programında Geçirilen Dönem Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Lise Başarı Puanı” ve “Fizik Doğru Sayısı” değişkenlerinin modele anlamlı katkıda bulunduğu görülmektedir. Exp(B) değeri, bağımsız değişkenlerdeki bir birimlik artışın oranlardaki değişimini temsil etmektedir.

Exp(B) değerinin 1'den büyük olması, bağımsız değişkenin bağımlı değişken üzerindeki olumlu etkisini göstermektedir. “Hazırlık Programında Geçirilen Dönem Sayısı” değişkeni, 1.220 Exp(B) değeriyle bağımlı değişken üzerinde güçlü bir etki yaratmaktadır.

Variables in the Equation									
		B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
								Lower	Upper
Step 1 ^a	Number of Course Repeats	-,940	,151	38,650	1	,000	,390	,290	,525
	Constant	-,225	,062	13,301	1	,000	,798		
Step 2 ^b	Number of Students	-,014	,004	16,505	1	,000	,986	,979	,993
	Number of Course Repeats	-,851	,152	31,187	1	,000	,427	,317	,576
	Constant	,759	,249	9,285	1	,002	2,137		
Step 3 ^c	Number of Students	-,016	,004	19,667	1	,000	,984	,977	,991
	Number of Course Repeats	-,865	,154	31,623	1	,000	,421	,311	,569
	Physics Correct	,097	,026	14,391	1	,000	1,102	1,048	1,159
	Constant	,408	,266	2,351	1	,125	1,504		
Step 4 ^d	Number of Students	-,017	,004	22,176	1	,000	,983	,976	,990
	Number of Course Repeats	-,833	,155	28,724	1	,000	,435	,320	,589
	High School Achievement Score	,005	,002	8,689	1	,003	1,005	1,002	1,008
	Physics Correct	,096	,026	13,896	1	,000	1,101	1,047	1,158
	Constant	-1,390	,665	4,367	1	,037	,249		
Step 5 ^e	Number_of_Semesters_in_Preparatory_Program	,199	,074	7,133	1	,008	1,220	1,054	1,412
	Number of Students	-,017	,004	21,598	1	,000	,983	,976	,990
	Number of Course Repeats	-,811	,156	27,071	1	,000	,445	,328	,603
	High School Achievement Score	,005	,002	9,724	1	,002	1,005	1,002	1,008
	Physics Correct	,088	,026	11,487	1	,001	1,092	1,038	1,149
	Constant	-1,572	,672	5,472	1	,019	,208		

a. Variable(s) entered on step 1: Number of Course Repeats.

b. Variable(s) entered on step 2: Number of Students.

c. Variable(s) entered on step 3: Physics Correct.

d. Variable(s) entered on step 4: High School Achievement Score.

e. Variable(s) entered on step 5: Number_of_Semesters_in_Preparatory_Program.


Şekil 5.4. Bağımsız değişkenlerin anlamlılık düzeyleri.

5.3. Model Uygulama ve Değerlendirme

Bu bölümde, önerilen hibrit PSO-DNN derin öğrenme modelinin uygulama süreci ve performans değerlendirmesi detaylı bir şekilde sunulacaktır. İlk olarak, veri setlerinde yer alan farklı grupların tüm kombinasyonları ile makine öğrenimi ve derin öğrenme modelleri kullanılarak yapılan tahmin sonuçları analiz edilecektir. Ardından, erken tahmin sonuçları üzerinden makine öğrenimi ve derin öğrenme modellerinin karşılaştırmalı değerlendirilmesi yapılacaktır. Önerilen hibrit PSO-DNN modelinin

erken tahmin performansı, geleneksel yöntemlerle karşılaştırılacak ve modelin etkinliği değerlendirilecektir. Son olarak, modelin genellenabilirliği ve uygulanabilirliği test edilerek, önerilen modelin farklı eğitim kurumları ve dersler için geçerliliği tartışılacaktır. Bu bölümde elde edilen sonuçlar, modelin doğruluğunu, etkinliğini ve potansiyel gelişim alanlarını ortaya koyacaktır.

Çalışmada, öğrencilerin başarı durumlarının “Geçti (Pass)” veya “Kaldı (Fail)” olarak tahmin edilmesi için makine öğrenimi (ML) ve derin öğrenme (DL) modelleri kullanılmıştır. İkili sınıflandırma sürecinde, başarısız öğrencileri tespit etmek amacıyla Not Ortalaması (GPA) üzerinden geçme eşiği 50 olarak belirlenmiştir. Bu eşiğe göre, toplam 1268 öğrencinin %60'ı (757 öğrenci) dersten başarısız olmuş, %40'ı (511 öğrenci) ise başarılı olarak dersi geçmiştir. Yıllara göre öğrencilerin geçme ve kalma durumlarının dağılımı Şekil 5.5'te görselleştirilmiştir.



Şekil 5.5. Dersin yıllara göre geçme ve kalma durumu.

Önerilen PSO-DNN modeli ve karşılaştırmalı diğer modeller, aşağıdaki özelliklere sahip bir bilgisayarda eğitilmiş ve test edilmiştir: 11. Nesil Intel® Core™ i5-11400H işlemci (2.70 GHz), Windows 11 Pro işletim sistemi, 16 GB RAM, NVIDIA GeForce GTX 1650 grafik kartı ve 64-bit mimari. Modeller, yalnızca CPU kaynakları kullanılarak çalıştırılmıştır.

Sınıflandırma modelleri, Python programlama dilinde Pandas, Keras ve NumPy kütüphaneleri kullanılarak, Anaconda Navigator platformu üzerinde geliştirilmiştir.

Modellerin eğitimi, önerilen Hibrit DL modeli ve karşılaştırmalı ML/DL modelleri için ayrılan eğitim veri seti ile gerçekleştirilmiştir. Daha sonra, tüm modellerin performansını değerlendirmek için ayrı bir test veri seti kullanılmıştır.


5.3.1. Önerilen hibrit PSO-DNN erken tahmin sonuçları

Bu çalışmada, yüz yüze eğitim ortamlarında öğrencilerin performansının erken tahmin edilmesi, demografik veriler, akademik performans, lise ve yükseköğretim giriş bilgileri kullanılarak derin öğrenme (DL) ve makine öğrenimi (ML) modelleriyle gerçekleştirilmiştir. Önerilen hibrit derin öğrenme modeli PSO-DNN, geleneksel makine öğrenimi ve DNN tabanlı derin öğrenme modelleriyle karşılaştırılmıştır. PSO-DNN modeline ait başlangıç parametreleri Tablo 2'de verilmiş olup, bu parametrelerle oluşturulan modellerin en iyi parametre kombinasyonları gizli katman sayısına göre Tablo 5.4'de gösterilmiştir. Tablo 5.4'de göre, en iyi doğruluk değeri, 3 gizli katmandan oluşan 2. modelle elde edilmiştir.

Tablo 5.4. PSO-DNN gizli katman sayısı bazında en iyi model parametreleri.

Parametreler	Model 1	Model 2	Model 3	Model 4
Sürünün Boyutu (Swarm Size)	10	25	10	10
Maksimum İterasyon Sayısı	25	10	25	25
Gizli Katman Sayısı	2	3	4	5
			37, 29,	43, 19,
Katman Başına Nöron Sayısı	64, 24	58, 41, 64	35, 25	28, 41, 3
Epok Sayısı	200	150	191	142
Batch Boyutu	256	2	103	4
Aktivasyon Fonksiyonları	relu	relu	relu	relu
Optimizasyon Algoritması	rmsprop	sgd	adam	sgd
Öğrenme Oranı (Learning Rate)	0.01	0.001	0.001	0.001
Kriter Değeri (Doğruluk - Accuracy)	0,606	0,633	0,598	0,601
Sıralama (Rank)	2	1	4	3


Önerilen PSO-DNN modeli ve diğer modeller, daha önce görülmeyen test verisi üzerinde test edilerek performansları değerlendirilmiştir. Her bir modelin sınıflandırma performansına ait metrikler Şekil 5.6'da sunulmuştur.




Şekil 5.6. Dönem başı model tahmin sonuçları.

Şekil 5.6'ya göre, PSO-DNN modeli en yüksek doğruluk (%63,3), F1 skoru (%56,1), kesinlik (%63,8) ve duyarlılık (%63,3) değerlerine ulaşmıştır. Bununla birlikte, AUC (%55,5) değeri orta seviyede kalmıştır. Bu durum, doğru sınıflamalar ile modelin genel uyumu açısından geliştirme alanı olduğunu göstermektedir. Random Forest (RF) modeli, PSO-DNN modelini takip ederek %62,7 doğruluk ve %57,2 AUC gibi güçlü performans değerleri sergilemiştir. Benzer şekilde, ANN modeli %62,2 doğruluk ve biraz daha yüksek bir AUC değeri (%58,6) ile dengeli bir tahmin performansı göstermiştir. Lojistik Regresyon (LR), KNN ve DNN modelleri, doğruluk açısından %56,2 ile %61,4 arasında değişen orta seviyede sonuçlar elde etmiş, ancak belirli metriklerde farklı güçlü yönler ortaya koymuştur. Buna karşın, Karar Ağaçları (DT) modeli, tüm metriklerde en düşük performansı sergileyerek %56,2 doğruluk değeri ile en zayıf model olarak dikkat çekmiştir.

PSO-DNN ve RF modellerinin performansına dair karışıklık matrisi Şekil 5.7 ve Şekil 5.8'de sunulmuştur. Karışıklık matrisi, iki modelin farklı sınıfları ne derece doğru tahmin edebildiğini değerlendirme açısından detaylı bilgi sağlamaktadır. Bu değerlendirme sonucunda PSO-DNN modelinin RF modeline kıyasla daha üstün bir performans sergilediği görülmüştür. Özellikle “Kaldı” sınıfının tahmininde PSO-DNN modeli, daha yüksek doğruluk ve duyarlılık değerleri sağlamıştır.




Şekil 5.7. PSO-DNN karışıklık matrisi.




Şekil 5.8. RF karışıklık matrisi.

Önerilen PSO-DNN modeli için Şekil 5.9 ve Şekil 5.10’da sunulan analizler, modelin sınıflandırma performansını farklı perspektiflerden değerlendirmektedir. Şekil 5.9, yanlış pozitifler ve yanlış negatifler arasındaki dengeyi ROC-AUC eğrisiyle gösterirken, Şekil 5.10 ise "Geçti" sınıfını tahmin etme konusunda doğruluk ve duyarlılık arasındaki dengeyi vurgulamaktadır. Bu iki eğri birlikte değerlendirildiğinde, PSO-DNN modelinin Precision-Recall eğrisinin (AUC-PR) ve ROC eğrisinin (AUC-ROC) altında yüksek bir alan elde ettiği görülmüştür. Bu durum, modelin nadir sınıfları doğru bir şekilde tahmin etme ve sınıflandırma problemini dengeli bir şekilde çözme konularında başarılı olduğunu göstermektedir. Sonuç olarak, önerilen PSO-DNN modeli genel performans açısından oldukça güçlü bir model olarak öne çıkmaktadır.



Şekil 5.9. PSO-DNN modelinin ROC Eğrisi.



Şekil 5.10. PSO-DNN modelinin kesinlik-hatırlama Eğrisi.

5.3.2. Veri kombinasyonlarına göre erken tahmin sonuçları

Bu çalışmada, dönem başında demografik (D), akademik (P) ve HEIE (H) verilerinin kombinasyonlarının, öğrenci başarısını tahmin etme etkinliği incelenmiştir. Farklı giriş veri setlerinin kullanıldığı durumlarda, modeller klasik sınıflandırma kriterleri ile değerlendirilmiştir. Tablo 5.1, her modelin veri grubu kombinasyonuna göre elde edilen sınıflandırma göstergesi sonuçlarını göstermektedir.

Tablo 5.5 ve Şekil 5.11’de farklı veri grubu kombinasyonları ve modeller kullanılarak yapılan sınıflandırma analizine ait sonuçlar yer almaktadır. Değerlendirme, doğruluk (accuracy), F1 skoru, kesinlik (precision) ve duyarlılık (recall) kriterlerine dayalı olarak gerçekleştirilmiştir. Elde edilen sonuçlara göre, en yüksek doğruluk değeri %65,4 ile önerilen PSO-DNN modeli ve P (akademik) veri grubunda elde edilmiştir. Bununla birlikte, DPH kombinasyonunda %63,3 doğruluk değeri ile diğer veri gruplarına kıyasla başarılı bir sonuç sergilemiştir. Genel olarak PSO-DNN modeli, doğruluk açısından diğer modellerden daha iyi performans göstermiştir.

F1 skoru açısından en yüksek değer %56,1 ile yine PSO-DNN modeli ve DPH veri grubu kombinasyonunda elde edilmiştir. PSO-DNN modeli, F1 skoru açısından diğer veri kombinasyonlarında da başarılı sonuçlar göstermiştir; örneğin, DP (%51,6) ve DH (%43,9) kombinasyonlarında yüksek performans sergilemiştir. SVM ve LR modellerinin F1 skorlarının ise diğer modellere göre oldukça düşük seviyelerde kaldığı görülmüştür.

Kesinlik (precision) açısından en yüksek değer %63,8 ile PSO-DNN modeli ve DPH kombinasyonunda kaydedilmiş, akademik verilerle (P) çalışan modellerin kesinlik değerleri genel olarak yüksek bulunmuştur. Örneğin, PSO-DNN ve ANN modelleri bu kombinasyonda %58,8 kesinlik değeriyle dikkat çekmiştir. Ancak, SVM modeli diğer kombinasyonlarda genellikle düşük kesinlik değerleri göstermiştir.


Duyarlılık (recall) açısından da en iyi sonuç %63,3 ile PSO-DNN modeli ve DPH veri grubu kombinasyonu ile elde edilmiştir. DPH kombinasyonu dışında, DP (%47,4) ve DH (%36,8) kombinasyonlarında da PSO-DNN modeli öne çıkmıştır. ANN ve DT modelleri duyarlılık açısından ortalama seviyede performans sergilerken, LR ve SVM modelleri duyarlılık değerlerinde oldukça düşük kalmıştır.

Tablo 5.5. Veri grubu kombinasyonuna dayalı sınıflandırma göstergesi sonuçları.

Kriter	Model	D	P	H	DH	DP	PH	DPH
Doğruluk	PSO-DNN	0,601	0,654	0,630	0,625	0,646	0,648	0,633
	ANN	0,601	0,640	0,617	0,609	0,630	0,638	0,606
	DT	0,614	0,635	0,556	0,554	0,591	0,570	0,559
	KNN	0,583	0,614	0,567	0,564	0,617	0,596	0,604
	LR	0,601	0,612	0,606	0,601	0,619	0,630	0,619
	RF	0,614	0,627	0,577	0,577	0,606	0,604	0,614
	SVM	0,601	0,606	0,588	0,588	0,596	0,612	0,612
F1 Skoru	PSO-DNN	0,000	0,504	0,350	0,439	0,516	0,427	0,561
	ANN	0,000	0,422	0,402	0,371	0,415	0,489	0,444
	DT	0,140	0,409	0,442	0,437	0,422	0,488	0,481
	KNN	0,502	0,414	0,400	0,385	0,455	0,442	0,439
	LR	0,000	0,282	0,318	0,315	0,300	0,429	0,418
	RF	0,150	0,437	0,353	0,348	0,476	0,373	0,352
	SVM	0,000	0,272	0,013	0,000	0,260	0,237	0,221
Kesinlik	PSO-DNN	0,000	0,588	0,585	0,544	0,567	0,610	0,638
	ANN	0,000	0,588	0,533	0,518	0,562	0,559	0,508
	DT	0,632	0,578	0,444	0,440	0,483	0,464	0,453
	KNN	0,479	0,525	0,447	0,441	0,526	0,492	0,504
	LR	0,000	0,537	0,515	0,500	0,564	0,558	0,536
	RF	0,619	0,550	0,454	0,453	0,507	0,506	0,533
	SVM	0,000	0,519	0,143	0,000	0,482	0,548	0,553
Duyarlılık	PSO-DNN	0,000	0,441	0,250	0,368	0,474	0,329	0,633
	ANN	0,000	0,329	0,322	0,289	0,329	0,434	0,395
	DT	0,079	0,316	0,441	0,434	0,375	0,513	0,513
	KNN	0,526	0,342	0,362	0,342	0,401	0,401	0,388
	LR	0,000	0,191	0,230	0,230	0,204	0,349	0,342
	RF	0,086	0,362	0,289	0,283	0,447	0,296	0,263
	SVM	0,000	0,184	0,007	0,000	0,178	0,151	0,138

Genel olarak, PSO-DNN modeli tüm veri grubu kombinasyonlarında diğer modellere kıyasla daha yüksek doğruluk, F1 skoru, kesinlik ve duyarlılık değerleri sağlamıştır. Özellikle DPH veri kombinasyonu, öğrenci başarısını tahmin etmede en iyi sonuçları

sunmuş, bu da demografik, akademik ve HEIE verilerinin birlikte kullanıldığında tahmin performansını artırdığını göstermiştir. Bu sonuçlar, erken dönem öğrenci başarısı tahmininde hem veri grubunun kapsamının hem de kullanılan modelin tahmin doğruluğu üzerinde kritik bir etkisi olduğunu ortaya koymaktadır.



Şekil 5.11. Veri grubu kombinasyonlarına göre doğruluk değerleri.

5.3.3. Değişken akademik performans verileriyle erken tahmin sonuçları

Bu analizde, değişken akademik performans verileriyle birlikte DL ve ML modellerinin etkinliği, sabit akademik performans verilerine (DPH) sırasıyla dönem başında, vize öncesinde ve final öncesinde eklenerek değerlendirilmiştir. Tablo 5.6, her model için erken tahmin sınıflandırma analizine ait sınıflandırma göstergesi değerlerini detaylı şekilde sunmaktadır.

Dönem başlangıcı verilerine göre, en yüksek doğruluk değeri %63,3 ile PSO-DNN modeli tarafından elde edilmiştir. PSO-DNN, bu dönemde F1 skoru (%56,1), kesinlik (%63,8) ve hatırlama (%63,3) açısından da diğer modellere kıyasla üstün bir performans göstermiştir. PSO-DNN'i takiben DT ve ANN modelleri orta seviyede performans sergilerken, SVM modeli bu dönemde en düşük F1 skoru (%22,1) ve hatırlama (%13,8) değeri ile zayıf bir sonuç ortaya koymuştur.


Tablo 5.6. Erken takmin sınıflandırma gösterge değerleri.

Değerlendirme Kriterleri	PSO-DNN	ANN	DT	KNN	LR	RF	SVM
Dönem Başlangıcı							
Doğruluk	0,633	0,606	0,559	0,604	0,619	0,614	0,612
F1 Skoru	0,561	0,444	0,481	0,439	0,418	0,352	0,221
Kesinlik	0,638	0,508	0,453	0,504	0,536	0,533	0,553
Hatırlama (Recall)	0,633	0,395	0,513	0,388	0,342	0,263	0,138
Ara Sınav Öncesi							
Doğruluk	0,824	0,798	0,748	0,769	0,798	0,822	0,798
F1 Skoru	0,790	0,744	0,686	0,714	0,748	0,775	0,752
Kesinlik	0,754	0,752	0,682	0,705	0,745	0,780	0,736
Hatırlama (Recall)	0,829	0,737	0,691	0,724	0,750	0,770	0,770
Final Öncesi							
Doğruluk	0,871	0,840	0,827	0,798	0,848	0,895	0,848
F1 Skoru	0,833	0,801	0,790	0,759	0,812	0,867	0,814
Kesinlik	0,865	0,794	0,765	0,725	0,801	0,878	0,794
Hatırlama (Recall)	0,803	0,809	0,816	0,796	0,822	0,855	0,836

Arasınav öncesi veriler incelendiğinde, doğruluk değerleri genel olarak önemli bir artış göstermiştir. Bu dönemde en yüksek doğruluk değerine sahip modeller %82,4 ile PSO-DNN ve %82,2 ile RF olmuştur. F1 skoru açısından PSO-DNN (%79,0), kesinlik açısından RF (%78,0) ve hatırlama açısından yine PSO-DNN (%82,9) modeli öne çıkmıştır. ANN, LR ve SVM modelleri de bu dönemde güçlü sonuçlar verirken, DT modeli diğer modellere göre daha düşük doğruluk (%74,8) ve F1 skoru (%68,6) ile nispeten daha zayıf kalmıştır.

Final öncesi dönemde, tahmin performansları en yüksek seviyeye ulaşmıştır. Bu dönemde doğruluk açısından en iyi sonuç %89,5 ile RF modelinden elde edilmiştir. RF'yi %87,1 doğruluk ile PSO-DNN ve %84,8 doğruluk ile SVM ve LR modelleri takip etmiştir. F1 skoru açısından da %86,7 ile RF, kesinlik açısından %87,8 ile yine RF modeli öne çıkmıştır. Hatırlama değerlerinde ise PSO-DNN modeli %80,3, RF modeli %85,5 ve ANN modeli %80,9 değerleri ile dikkat çekmiştir. Genel olarak, final öncesi dönemde tüm modellerin performansı belirgin şekilde iyileşmiş, özellikle RF ve PSO-DNN modelleri diğer modellere göre daha güçlü sonuçlar elde etmiştir.

Sonuç olarak zaman ilerledikçe modellerin tahmin performansının belirgin şekilde arttığı gözlemlenmiştir. Dönem başlangıcında PSO-DNN modeli genel olarak en iyi sonuçları verirken, ara sınav ve final öncesi dönemlerde RF modeli öne çıkmıştır. Final öncesinde tüm modellerin doğruluk, F1 skoru, kesinlik ve hatırlama değerlerinde önemli iyileşmeler kaydedilmiş, bu da daha fazla verinin tahmin performansını artırdığını göstermiştir. Bu bulgular, hem kullanılan modelin hem de veri toplama zamanlamasının tahmin başarısı üzerindeki kritik etkisini ortaya koymaktadır. Şekil 5.12'de, DL ve ML modellerinin doğruluk değerleri dönem başında, vize öncesi ve final öncesinde sunulmaktadır.



Şekil 5.12. Erken tahmin doğruluk değerleri

5.3.4. Önerilen hibrit PSO-DNN uygulanabilirlik ve genellenebilirlik sonuçları

Önerilen PSO-DNN modelinin genellenebilirliğini değerlendirmek için, öğrencilerin notlarını “Düşük”, “Orta” ve “Yüksek” olmak üzere üç kategoriye ayıran ve akademik araştırmalarda yaygın olarak kullanılan xAPI-Edu-Data genel veri seti kullanılmıştır. Önerilen modelin xAPI-Edu-Data veri setiyle gerçekleştirdiği üç sınıflı sınıflandırmaya ait gizli katman sayısına göre en iyi parametre kombinasyonu Tablo 5.7’de sunulmuştur. Bu sınıflandırmada, en yüksek doğruluk değeri (%80,6), üç gizli katmana sahip Model 2 tarafından elde edilmiştir. Önceki çalışmalarda, xAPI-Edu-Data veri seti ile yapılan üç sınıflı sınıflandırmada kullanılan modeller ve bunların doğruluk değerleri Tablo 5.8’de yer almaktadır. Tablo 5.8’e göre, en yüksek doğruluk oranı (%84,0), Vijayalakshmi (2019) tarafından DNN modeli ile elde edilmiştir [190]. Sürü boyutu, maksimum iterasyon ve gizli katman sayısı gibi belirli sınırlamalara rağmen, önerilen PSO-DNN modeli umut verici sonuçlar sergilemiştir. Model, en

yüksek performans gösteren iki modele yakın bir doğruluk oranı sağlamakta ve diğer modellerin üzerinde bir performans ortaya koymaktadır.

Tablo 5.7. xAPI-Edu-Data veri seti PSO-DNN sonuçları.

Parametreler	Model 1	Model 2	Model 3	Model 4
Sürünün Boyutu	10	10	25	25
Maksimum İterasyon Sayısı	10	10	10	10
Gizli Katman Sayısı	2	3	4	5
Katman Başına Nöron Sayısı	61, 28	59, 13, 60	56, 29, 53, 12	59, 19, 45, 51, 54
Epok Sayısı	172	190	143	170
Batch Boyutu	22	56	42	37
Aktivasyon Fonksiyonları	relu	relu	relu	relu
Optimizasyon Algoritması	adam	adam	sgd	adam
Öğrenme Oranı	0.01	0.001	0.01	0.001
Kriter Değeri (Doğruluk)	0,785	0,806	0,792	0,785
Sıralama (Rank)	3	1	2	3

Tablo 5.8. xAPI-Edu-Data doğruluk sonuçları.

Model	Vij. ve Ven. (2019) [190]	(Tuaha ve ark, 2019) [191]	(Abubakari ve ark, 2020) [192]	(Sixhaxa ve ark, 2022) [193]	(Pujianto ve ark, 2020) [194]	Mevcut Çalışma
NB	0,730	0,676	0,508	-	-	-
LR	-	0,742	-	-	-	-
ANN/MLP	-	0,781	-	-	-	-
RF	-	0,790	0,783	-	-	-
SVM	-	-	-	0,750	0,817	-
KNN	-	-	-	0,690	0,750	-
DT	-	-	0,690	0,711	0,716	-
DNN	0,840	-	-	0,768	-	-
PSO-DNN	-	-	-	-	-	0,806


5.4. Önerilen Hibrit PSO-DNN Açıklanabilirlik Sonuçları

Bu çalışmada, önerilen hibrit PSO-DNN modelinin sonuçlarını açıklamak ve neden diğer modellerden daha iyi performans gösterdiğini anlamak amacıyla SHAP ve LIME gibi XAI yöntemleri kullanılmıştır.

5.4.1. SHAP küresel açıklama sonucu

Şekil 5.13, PSO-DNN modelinin tüm test verileri için oluşturulan SHAP grafiğini sunmaktadır. Bu grafikte, model tahminlerinde en yüksek etkiye sahip ilk 20 özellik, etkilerinin büyüklüğüne göre sıralanmıştır. Bu sıralama, modelin hangi özelliklere daha fazla ağırlık verdiğini ve bu özelliklerin tahmin sonuçlarını nasıl etkilediğini anlamamıza olanak tanımaktadır.

Şekil 5.13 incelendiğinde, “Dersi Alan Öğrenci Sayısı” özelliğinin tahminler üzerinde en büyük etkiye sahip olduğu görülmektedir. İkinci sırada “Lise Başarı Puanı” yer alırken, “Ders Tekrarı Sayısı” üçüncü sırada en etkili özellik olarak öne çıkmaktadır. Dördüncü sırada ise “TYT Yerleştirme Puanı” bulunmaktadır. Bunun dışında önemli katkı sağlayan diğer özellikler şunlardır: “TYT Yerleştirme Başarı Sıralama Yüzdesi”, “Matematik Yanlış Sayısı”, “Sosyal Bilimler Yanlış Sayısı”, “SAY Yerleştirme Başarı Sıralama Yüzdesi”, “Alınan Ders Sayısı”, “EA Puanı”, “Kimya Doğru Sayısı”, “Fen Yanlış Sayısı”, “Coğrafya 1 Doğru Sayısı”, “SAY Yerleştirme Puanı”, “Fizik Yanlış Sayısı”, “Tercih Sırası”, “Tarih 1 Yanlış Sayısı”, “Biyoloji 1 Yanlış Sayısı”, “Matematik Doğru Sayısı” ve “Hazırlık Programında Geçirilen Dönem Sayısı”. Bu sonuçlar, modelin tahminlerinde hangi özelliklerin daha belirleyici olduğunu ortaya koymakta ve bu özelliklerin önem sırasını detaylı şekilde göstermektedir.




Şekil 5.13. SHAP küresel bar grafiği.

5.4.2. SHAP yerel açıklama sonuçları

SHAP, her öğrencinin sınıflandırması için yerel düzeyde açıklamalar sunmaktadır. Yerel açıklama için, “Kaldı (Fail)” sınıfına ait iki öğrenci seçilmiştir. Bu öğrencilerden birinin sınıflandırılmasında etkili olan özellikler, küresel açıklama sonuçlarıyla uyumlu iken, diğer öğrencininki uyumsuzluk göstermektedir.

Şekil 5.14, ilk öğrencinin “Kaldı” olarak sınıflandırılmasına ilişkin SHAP karar grafiğini göstermektedir. Yatay ekseninde her özelliğin tahmin üzerindeki etkisini temsil eden SHAP değerleri yer almakta, pozitif SHAP değerleri tahmini artırırken negatif değerler tahmini azaltmaktadır. Dikey ekseninde ise özellikler etkilerinin büyüklüğüne göre sıralanmıştır. Grafikte, parantez içindeki değerler analiz edilen veri noktası için


ilgili özelliğin değerini ifade etmektedir. Genel tahmin sonucu, tüm özelliklerin SHAP değerlerinin toplamıyla belirlenmektedir.



Şekil 5.14. İlk öğrencinin SHAP karar grafiği.


Bu analiz sonucunda, ilk öğrencinin “Kaldı” olarak sınıflandırılmasında en önemli katkıyı “Ders Tekrarı Sayısı”, “Dersi Alan Öğrenci Sayısı” ve “Alınan Ders Sayısı” özelliklerinin sağladığı görülmüştür. Buna karşılık, “TYT Yerleştirme Puanı” bu öğrencinin “Kaldı” olarak sınıflandırılmasına olumsuz bir etki yapmıştır.

Şekil 5.15, aynı öğrencinin sınıflandırılmasına ilişkin SHAP Kuvvet Grafiğini sunmaktadır. Bu grafik, Şekil 5.14’deki karar grafiğiyle aynı sonuçları göstermekte, ancak özelliklerin etkilerini görsel olarak daha net bir şekilde ayırt etmektedir. Grafikteki kırmızı alanlar, öğrencinin “Kaldı” olarak sınıflandırılmasına pozitif katkıda bulunan özellikleri, mavi alanlar ise olumsuz etkileri temsil etmektedir. Çubukların uzunluğu, her bir özelliğin tahmin üzerindeki etkisinin derecesini ifade etmektedir. Özellikle “Ders Tekrarı Sayısı”, “Dersi Alan Öğrenci Sayısı” ve “Alınan Ders Sayısı” çubuklarının daha uzun olması, bu özelliklerin sınıflandırmaya daha fazla etki ettiğini göstermektedir.




Şekil 5.15. İlk öğrencinin SHAP kuvvet grafiği.

Yerel açıklamalar, eğitimcilerin öğrencilere daha kişiselleştirilmiş geri bildirim ve eğitim sunmalarına olanak sağlamaktadır. Küresel açıklamalar doğrultusunda tüm “Kaldı” öğrenciler için aynı geri bildirimi sağlamak bazı durumlarda etkili olsa da, bu yaklaşım her öğrenci için yeterli sonuç vermeyebilir. Örneğin, ilk öğrenci için “Ders Tekrar Sayısı” ve “Dersi Alan Öğrenci Sayısı” özellikleri küresel açıklamalarla uyumlu şekilde en etkili özelliklerdir. Ancak, ikinci öğrenci için durum farklıdır. Şekil 5.16 ve Şekil 5.17’ye göre, ikinci öğrencinin “Kaldı” olarak sınıflandırılmasında en etkili özellikler “Fizik Yanlış Sayısı”, “EA Puanı” ve “Kimya Doğru Sayısı” olmuştur. Bu özellikler, küresel açıklamada en önemli üç özellik arasında yer almamaktadır. Ayrıca, “Ders Tekrar Sayısı” ve “Dersi Alan Öğrenci Sayısı” özellikleri küresel açıklamada en önemli özellikler arasında bulunmasına rağmen, bu öğrenci için tahmini olumsuz yönde etkilemiştir.



Şekil 5.16. İkinci öğrencinin SHAP karar grafiği.




Şekil 5.17. İkinci öğrencinin SHAP kuvvet grafiği.

Eğitimcilerin yalnızca küresel özelliklere dayanarak tüm “Kaldı” sınıf öğrencilerine yönelik müdahalelerde bulunması, ilk öğrenci için etkili sonuçlar verebilir. Ancak, bu yaklaşım ikinci öğrenci için başarıyı artırmada yeterince etkili olmayabilir.

Sonuç olarak, yerel açıklamalar, eğitimcilerin her öğrencinin bireysel ihtiyaçlarına yönelik daha kişiselleştirilmiş ve etkili geri bildirimler sunmasını sağlamaktadır. Bu yaklaşım, eğitim programlarının daha verimli bir şekilde düzenlenmesine olanak tanır. Böylece, küresel özelliklerle birlikte her öğrencinin bireysel performansı ve özellikleri de dikkate alınarak daha dengeli ve etkili bir eğitim stratejisi oluşturulabilir.


5.4.3. LIME yerel açıklama sonuçları

LIME yöntemi, test veri setinden belirli bir örnek seçilerek her sınıf için olasılık değerlerinin elde edilmesini sağlar. Bu yöntem, her sınıfa atanan olasılıkları grafiksel olarak açıklamak için kullanılmaktadır. Grafiğin sol tarafında her sınıfın olasılık değerleri, orta sütunda en etkili özellikler, sağ sütunda ise bu özelliklerin değerleri gösterilir. Turuncu renk, bir özelliğin pozitif etkisini ifade ederken, mavi renk negatif etkisini belirtmektedir. Şekil 5.18, LIME yöntemiyle analiz edilen ilk öğrenciye ilişkin sonuçları sunmaktadır. İlk öğrenci için sol tarafta yer alan olasılık değerlerine göre, “Kaldı” olarak sınıflandırılma olasılığı %93’tür. Bu sınıflandırmada en etkili özellikler “Ders Tekrar Sayısı”, “Dersi Alan Öğrenci Sayısı”, “TYT Yerleştirme Puanı”, “SAY Yerleştirme Başarı Sıralama Yüzdesi” ve “Matematik Yanlış Sayısı” olarak belirlenmiştir. Bu özellikler arasında “TYT Yerleştirme Puanı” turuncu renk ile pozitif bir etkiyi temsil ederken, diğer özellikler mavi renk ile negatif etkiyi göstermektedir.



Şekil 5.18. İlk öğrencinin LIME grafiği.

Şekil 5.19, LIME yöntemiyle analiz edilen ikinci öğrenciye ilişkin sonuçları göstermektedir. İkinci öğrenci için sol taraftaki olasılık değerlerine göre, “Kaldı” olarak sınıflandırılma olasılığı %74’tür. En etkili özellikler “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Tarih 1 Yanlış Sayısı”, “Coğrafya 1 Doğru Sayısı” ve “Alınan Ders Sayısı” olarak belirlenmiştir. Bu özelliklerden “Tarih 1 Yanlış Sayısı” ve “Coğrafya 1 Doğru Sayısı”, mavi renk ile negatif etkileri temsil etmektedir.



Şekil 5.19. İkinci öğrencinin LIME grafiği.

SHAP ve LIME grafiklerinin karşılaştırılması sonucunda, LIME tarafından belirtilen ilk 5 özelliğin, SHAP açıklamalarında yer alan ilk 20 özellik içinde bulunduğu gözlemlenmiştir. Ancak, özellikle ikinci öğrenci için LIME’ın 3., 4. ve 5. sırada önem verdiği özelliklerin, SHAP açıklamalarında 16., 19. ve 17. sıralarda yer aldığı görülmüştür.

SHAP ve LIME yöntemlerinin farklı sonuçlar üretmesi, bu yöntemlerin odak noktalarının ve yaklaşımlarının farklı olmasından kaynaklanmaktadır. SHAP, oyun teorisi tabanlı bir yaklaşım kullanarak modelin genel davranışını ve özellikler arasındaki etkileşimleri dikkate alarak küresel açıklamalar sağlar. LIME ise, belirli bir tahmin etrafında yerel bir model oluşturur ve bu yerel bölgede özelliklerin önemini değerlendirir. Bu yöntemsel farklılıklar, SHAP’ı daha kapsamlı ancak hesaplama açısından daha yoğun bir yöntem haline getirirken, LIME’ı daha hızlı ancak daha yerelleşmiş açıklamalar sunan bir yaklaşım yapmaktadır.

5.5. Duyarlılık Anaizi Sonuçları

Bu bölümde, hibrit PSO-DNN modelinin tahmin performansını etkileyen değişkenlerin istatistiksel anlamlılığı kapsamlı bir şekilde incelenmiştir. Çalışmada, SHAP ve LIME açıklanabilir yapay zeka (XAI) yöntemleriyle belirlenen kritik özelliklerin geçerliliği, istatistiksel testlerle desteklenmiş ve bu iki yaklaşımın sonuçları sentezlenmiştir. Analizlerde Genel Not Ortalaması (GPA) referans değişken

olarak alınmış, hem küresel hem de yerel düzeyde modelin hangi özelliklere karşı daha duyarlı olduğu sistematik olarak ortaya konulmuştur.

5.5.1. SHAP ve LIME açıklama sonuçları

Modelin SHAP küresel açıklama çıktıları, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Hazırlık Programında Geçirilen Dönem Sayısı” gibi özelliklerin model kararlarında belirleyici rol oynadığını göstermiştir. Bu bulgular, söz konusu özelliklerin SHAP değer sıralamasında üst basamaklarda yer almasıyla desteklenmiştir.

LIME yöntemiyle yapılan yerel analizler ise bireysel öğrenci profillerinde farklı özelliklerin öne çıktığını ortaya koymuştur. Örneğin, bazı öğrencilerde “Fizik Yanlış Sayısı”, “EA Puanı” ve “Kimya Doğru Sayısı” gibi özelliklerin SHAP’ın genel sıralamasından farklı şekilde etkili olduğu gözlemlenmiştir. Bu bulgu, modelin farklı veri noktalarında değişken duyarlılıklar sergilediğini göstermektedir.

5.5.2. T-testi sonuçları

İkili grup karşılaştırmalarında kullanılan bağımsız örneklem t-testleri, “Cinsiyet” ve “Engellilik Durumu” özelliklerinin varyans yapılarında istatistiksel olarak anlamlı farklılıklar olduğunu göstermiştir ($p < 0.05$, Şekil 5.20). Bu farklılıklar, modelin bu özniteliklere karşı duyarlılığını ve bu faktörlerin tahmin performansına etkisini doğrulamaktadır.

Group Statistics					
	Grade Point Average	N	Mean	Std. Deviation	Std. Error Mean
Gender	Fail	757	,8996	,30073	,01093
	Pass	511	,8728	,33353	,01475
Disability Status	Fail	757	,0000	,00000	,00000
	Pass	511	,0020	,04424	,00196

Independent Samples Test										
		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
Gender	Equal variances assumed	8,805	,003	1,489	1266	,137	,02681	,01800	-,00850	,06211
	Equal variances not assumed			1,460	1016,787	,145	,02681	,01836	-,00923	,06284
Disability Status	Equal variances assumed	5,951	,015	-1,217	1266	,224	-,00196	,00161	-,00511	,00120
	Equal variances not assumed			-1,000	510,000	,318	-,00196	,00196	-,00580	,00189

Şekil 5.20. “Cinsiyet” ve “Engellilik Durumu” t₂-testi sonuçları.

5.5.3. ANOVA testi sonuçları

Birden fazla grup içeren analizlerde ANOVA testi uygulanarak, “Alınan Ders Sayısı”, “Hazırlık Programında Geçirilen Dönem Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders

Tekrarı Sayısı”, “Arasınav”, “Kısa Sınav 1”, “Kısa Sınav 2”, “Kısa Sınav 3”, “Ödev 1”, “Ödev 2”, “Proje Tasarımı”, “Matematik Yanlış Sayısı” ve “Fizik Doğru Sayısı” öznitelikler arasındaki farklılıkların istatistiksel anlamlılığı ortaya konulmuştur. İlgili Post Hoc testleri (Scheffe ve Tamhane), gruplar arası farklılıkların hangi düzeyde olduğunu belirlemek için kullanılmıştır. Homojen gruplar için Scheffe post-hoc testleri ve homojen olmayan gruplar için ise Tamhane testleri uygulanmıştır.

Şekil 5.21'de, ANOVA testi ile anlamlı fark gösteren “Hazırlık Programında Geçirilen Dönem Sayısı” değişkenine ilişkin varyans analiz sonuçları sunulmuştur. Bu değişken için yapılan Post Hoc Test sonuçları Şekil 5.22'de, homojen alt gruplara ilişkin sonuçlar ise Şekil 5.23'de yer almaktadır. Şekillerde görüldüğü üzere, hazırlık programına 4 dönem katılan öğrenciler diğer gruplara kıyasla daha başarılı bulunmuştur. Ayrıca, 2 dönem hazırlık eğitimi alan öğrencilerin hiç hazırlık eğitimi almayanlara göre daha başarılı olduğu gözlemlenmiştir.

Test of Homogeneity of Variances					
		Levene Statistic	df1	df2	Sig.
Grade Point Average	Based on Mean	38,181	2	1265	,000
	Based on Median	5,756	2	1265	,003
	Based on Median and with adjusted df	5,756	2	1262,281	,003
	Based on trimmed mean	31,937	2	1265	,000

ANOVA					
Grade Point Average					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	3,335	2	1,667	6,990	,001
Within Groups	301,734	1265	,239		
Total	305,069	1267			

Şekil 5.21. “Hazırlık Programında Geçirilen Dönem Sayısı” varyans sonuçları.

Multiple Comparisons

Dependent Variable: Grade Point Average.

	(I) Number_of_Semesters_i n_Preparatory_Program	(J) Number_of_Semesters_j n_Preparatory_Program	Mean Difference (I- J)	Std. Error	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
Scheffe	,00	2,00	-,10966*	,03560	,009	-,1969	-,0224
		4,00	-,61836	,28238	,091	-,13104	,0737
	2,00	,00	,10966*	,03560	,009	,0224	,1969
		4,00	-,50870	,28381	,201	-,12042	,1868
	4,00	,00	,61836	,28238	,091	-,0737	1,3104
		2,00	,50870	,28381	,201	-,1868	1,2042
Tamhane	,00	2,00	-,10966*	,03633	,008	-,1968	-,0225
		4,00	-,61836*	,01511	,000	-,6545	-,5822
	2,00	,00	,10966*	,03633	,008	,0225	,1968
		4,00	-,50870*	,03304	,000	-,5882	-,4292
	4,00	,00	,61836*	,01511	,000	,5822	,6545
		2,00	,50870*	,03304	,000	,4292	,5882

*. The mean difference is significant at the 0.05 level.

Şekil 5.22. “Hazırlık Programında Geçirilen Dönem Sayısı” post hoc testi sonuçları.

Grade Point Average				
	Number_of_Semesters_i n_Preparatory_Program	N	Subset for alpha = 0.05	
			1	2
Scheffe ^{a,b}	,00	1035	,3816	
	2,00	230	,4913	,4913
	4,00	3		1,0000
	Sig.		,894	,091

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 8,859.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Şekil 5.23. “Hazırlık Programında Geçirilen Dönem Sayısı” Scheffe sonuçları.

“Alınan Ders Sayısı”, “Ders Tekrarı Sayısı” ve “Dersi Alan Öğrenci Sayısı” Post Hoc Test sonuçları incelendiğinde, öğrenci sayısının ve alınan ders sayısının az olduğu sınıflarda başarı oranının yükseldiği ve dersi 4 veya daha fazla kez tekrar eden öğrencilerde başarısızlık olasılığının arttığı belirlenmiştir. Şekil 5.24’de “Alınan Ders Sayısı”, Şekil 5.25’de “Ders Tekrarı Sayısı” ve Şekil 5.26’da da “Dersi Alan Öğrenci Sayısı” post hoc testi sonuçları verilmiştir.

Grade Point Average

	Number of Courses Taken	N	Subset for alpha = 0.05 1
Scheffe ^{a,b}	8,00	234	,2650
	4,00	19	,3158
	9,00	19	,3158
	7,00	190	,4158
	6,00	707	,4314
	3,00	17	,4706
	2,00	8	,5000
	5,00	74	,5541
	Sig.		,719

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 25,514.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Şekil 5.24. “Alınan Ders Sayısı” post hoc testi sonuçları.

Grade Point Average

	Number of Course Repeats	N	Subset for alpha = 0.05 1
Scheffe ^{a,b}	3,00	10	,0000
	4,00	2	,0000
	2,00	34	,1176
	1,00	173	,2428
	,00	1049	,4433
	Sig.		,507

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 7,860.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Şekil 5.25. “Ders Tekrarı Sayısı” post hoc testi sonuçları.

Grade Point Average

	Number of Students	N	Subset for alpha = 0.05 1
Scheffe ^{a,b}	78,00	56	,1964
	64,00	63	,2063
	58,00	14	,2143
	107,00	65	,2308
	85,00	46	,2826
	53,00	43	,3023
	96,00	59	,3220
	76,00	97	,3299
	66,00	12	,3333
	94,00	72	,3611
	75,00	103	,3689
	60,00	46	,3696
	62,00	13	,3846
	88,00	49	,3878
	68,00	56	,4107
	43,00	28	,4286
	65,00	43	,4419
	59,00	89	,4831
	40,00	26	,5000
	49,00	56	,5536
	46,00	27	,5556
	70,00	73	,5890
	44,00	32	,5938
	72,00	53	,6038
	41,00	8	,6250
	50,00	15	,6667
	54,00	9	,6667
	47,00	12	,7500
	36,00	3	1,0000
	Sig.		,379

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 20,962.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Şekil 5.26. “Dersi Alan Öğrenci Sayısı” post hoc testi sonuçları.

“Fizik Doğru Sayısı” Post Hoc Test sonuçları incelendiğinde, Fizik dersinde en fazla doğru cevap veren öğrencilerin daha başarılı oldukları belirlenmiştir. Şekil 5.27’de “Fizik Doğru Sayısı” post hoc testi sonuçları verilmiştir.

Grade Point Average			
	Physics Correct	N	Subset for alpha = 0.05 1
Scheffe ^{a,b}	12,00	4	,2500
	1,00	66	,2576
	2,00	114	,3070
	4,00	202	,3663
	8,00	88	,3750
	6,00	198	,3939
	3,00	175	,4114
	,00	48	,4375
	5,00	197	,4467
	7,00	118	,4746
	9,00	39	,5385
	11,00	8	,7500
	10,00	11	,8182
	Sig.		,225

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 22,533.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Şekil 5.27. “Fizik Doğru Sayısı” post hoc testi sonuçları.

Son olarak “Matematik Yanlış Sayısı” Post Hoc Test sonuçları incelendiğinde, Matematik dersinde en az yanlış cevap veren yani en çok doğru yapan öğrencilerin daha başarılı oldukları belirlenmiştir. Şekil 5.28’de “Matematik Yanlış Sayısı” post hoc testi sonuçları verilmiştir.

Grade Point Average			Subset for alpha = 0.05
	Mathematics Incorrect	N	1
Scheffe ^{a,b}	15,00	26	,2308
	2,00	86	,2907
	7,00	108	,2963
	17,00	12	,3333
	23,00	3	,3333
	12,00	34	,3529
	1,00	60	,3667
	9,00	98	,3673
	,00	13	,3846
	5,00	149	,4094
	4,00	150	,4133
	11,00	40	,4250
	8,00	79	,4304
	10,00	48	,4375
	6,00	146	,4384
	3,00	155	,4581
	18,00	8	,5000
	13,00	15	,5333
	14,00	23	,6087
	16,00	9	,6667
	20,00	2	1,0000
	22,00	4	1,0000
	Sig.		,808

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 12,286.

b. The group sizes are unequal. The harmonic mean of the group sizes is used. Type I error levels are not guaranteed.

Şekil 5.28. “Matematik Yanlış Sayısı” Soru Sayısı post hoc testi sonuçları.

5.5.4. Duyarlılık analizi

Yukarıda elde edilen XAI (Açıklanabilir Yapay Zekâ) çıktıları ve istatistiksel analiz sonuçları, hibrit PSO-DNN modelinin tahmin performansının belirli özniteliklere karşı yüksek duyarlılık gösterdiğini ortaya koymaktadır. SHAP (SHapley Additive exPlanations) ve LIME (Local Interpretable Model-agnostic Explanations) metodolojileri, modelin genel davranışını ve bireysel örneklerdeki karar dinamiklerini açıklarken; t-testi ve ANOVA analizleri, bu özniteliklerin varyans farklılıklarını ve istatistiksel anlamlılıklarını nicel olarak doğrulamıştır.

Temel Bulgular:

1. **Metodolojik Uyum:** SHAP ve LIME ile elde edilen model tabanlı bulgular, t-testi ve ANOVA sonuçlarıyla tutarlılık göstermiştir. Bu uyum, hem model şeffaflığını artırmış hem de sonuçların geçerliliğini desteklemiştir.
2. **Kritik Öznitelikler:** Tüm analizlerde, “Alınan Ders Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Matematik Yanlış Sayısı”, ve “Fizik Doğru Sayısı” özellikleri, modelin tahmin performansı üzerinde yüksek etkiye sahip ortak değişkenler olarak belirlenmiştir. Bu özniteliklerin, model kararlarında tutarlı ve anlamlı bir rol oynadığı gözlemlenmiştir.
3. **Metodolojik Farklılıklar:** SHAP ve LIME, model çıktılarına katkı sağlayan öznitelikleri vurgularken; ANOVA, gruplar arasındaki istatistiksel farklılıkları öne çıkarmıştır. Örneğin, “Lise Başarı Puanı” ve “TYT Yerleştirme Puanı” gibi özellikler, model tabanlı yorumlarda önemli etkiye sahipken, varyans analizinde diğer ölçütlerin etkisi daha belirgin olmuştur.

Eğitimsel Çıkarımlar:

- **Sınıf Büyüklüğü ve Ders Yüğü:** Küçük sınıflar ve kontrollü ders yükünün akademik başarıyı olumlu yönde etkilediği tespit edilmiştir.
- **Hazırlık Eğitiminin Rolü:** Hazırlık eğitiminin başarı üzerinde istatistiksel olarak anlamlı pozitif bir etkisi olduğu ve hazırlık süresi ile başarı arasında doğrusal bir ilişki bulunduğu belirlenmiştir.
- **STEM Performansının Önemi:** Matematik ve fen bilimleri (STEM) alanlarındaki performansın, genel akademik başarıyı kritik düzeyde etkilediği ve temel yeterliliklerin bu süreçte kilit rol oynadığı anlaşılmıştır.

Eğitim verilerinde özniteliklerin etkilerini çok yönlü değerlendirmek için XAI ve istatistiksel analizlerin entegre kullanımı, kapsamlı bir duyarlılık analizi sağlamaktadır. Bu yaklaşım, model performansını iyileştirmenin yanı sıra yorumlanabilirlik ve güvenilirlik açısından da önemli avantajlar sunar. Modelde öne çıkan özniteliklerin belirlenmesi, yalnızca modelin iç işleyişinin anlaşılmasına değil, aynı zamanda eğitimciler ve politika yapıcılar için kişiselleştirilmiş müdahale stratejilerinin geliştirilmesine de olanak tanır. Böylece, hem küresel ölçekteki eğitim politikaları hem de bireysel öğrenci destek mekanizmaları daha etkin bir şekilde optimize edilebilir [189, 195].



6. SONUÇLAR VE ÖNERİLER

Eğitim, her toplumun sosyo-ekonomik kalkınmasında kritik bir rol oynar. Bireylerin bilgi ve becerilerini geliştirerek yaşam kalitelerini artırmalarına, iş gücüne katkı sağlamalarına ve dünyayı daha iyi anlamalarına yardımcı olur. Ancak eğitim sürecinde yaşanan başarısızlıklar, sadece mezuniyetin gecikmesine değil, bireylerin topluma katma değer sağlayacak meslekleri edinmelerine de engel olabilir. Bu nedenle, akademik başarının tahmini ve başarısızlık riski taşıyan öğrencilerin erken belirlenmesi önemlidir. Literatürde, akademik başarının genellikle sınıf içi çabalara dayanarak tahmin edildiği görülmektedir.

Bu çalışmada, öğrencilerin önceki eğitim aşamalarında edindikleri akademik becerilere dayanarak başarılarını tahmin etmek, dönem içi değişken akademik performans verilerinin etkisini değerlendirmek ve en etkili öznitelikleri belirlemek amaçlanmıştır. Üniversite mühendislik programında öğrenim gören 1268 öğrencinin verileri analiz edilmiştir. Veri seti; demografik özellikler, akademik performans ve lise ile yükseköğretim giriş sınavları olmak üzere üç kategoriye ayrılmıştır. Toplamda 12 öngörücü değişken öğrencilerin üniversitedeki akademik performansını yansıtırken, 50 değişken lise dönemindeki akademik becerileri temsil etmektedir. Başarı durumu "geçti" veya "kaldı" olarak sınıflandırılmıştır. Tahmin işlemleri için Parçacık Sürüsü Optimizasyonu (PSO) ile Derin Sinir Ağlarını (DNN) birleştiren hibrit bir model kullanılmıştır.

Öğrenci başarısının erken tahmini için en yüksek öngörü doğruluğuna sahip özellikler belirlenmiştir. Korelasyon analizine göre GPA ile en yüksek ilişkiye sahip öznitelikler arasında “Hazırlık Programında Geçirilen Dönem Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Alınan Ders Sayısı”, “Arasınav”, “Kısa Sınav 1”, “Kısa Sınav 2”, “Kısa Sınav 3”, “Ödev 1”, “Ödev 2”, “Proje Tasarımı”, “Temel Matematik Doğru Sayısı”, “Kimya Doğru Sayısı” ve “Biyoloji Doğru Sayısı” yer almaktadır. Lojistik regresyon analizine göre ise “Ders Tekrarı Sayısı” -0.811 B katsayısı ile en yüksek etkiye sahiptir. %5 anlamlılık düzeyinde “Hazırlık Programında Geçirilen Dönem Sayısı”, “Dersi Alan Öğrenci Sayısı”, “Ders Tekrarı Sayısı”, “Lise

Başarı Puanı” ve “Fizik Doğru Sayısı” değişkenleri modele anlamlı katkı sağlamaktadır. Bu öz niteliklerin kullanımı, öğrencilerin başarı potansiyelinin erken belirlenmesine ve akademik müdahalelerin zamanında uygulanmasına olanak tanıyabilir.

PSO-DNN modeli, dönem başında, vize öncesinde ve final öncesinde geleneksel makine öğrenmesi ve derin öğrenme modelleriyle karşılaştırılmıştır. Dönem başında demografik (D), akademik (P) ve HEIE (H) verilerinin kombinasyonları değerlendirilmiş, PSO-DNN modeli tüm veri kombinasyonlarında diğer modellere kıyasla daha yüksek doğruluk, F1 skoru, kesinlik ve duyarlılık değerleri sunmuştur. En iyi sonuçlar DPH veri kombinasyonu ile elde edilerek, demografik, akademik ve HEIE verilerinin birlikte kullanımının tahmin performansını artırdığı gösterilmiştir. PSO-DNN modeli, DPH veri kombinasyonu ile dönem başında %63,3 doğruluk, %56,1 F1 skoru, %63,8 kesinlik ve %63,3 duyarlılık değerlerine ulaşmıştır. RF modeli ise %62,7 doğruluk ve %57,2 AUC ile ikinci en iyi performansı göstermiştir. Karar Ağaçları (DT) modeli ise en düşük performansı sergilemiştir.

Dönem başında sabit akademik performans verileriyle yapılan tahmin çalışmaları, değişken akademik performans verilerinin eklenmesiyle tekrar değerlendirilmiş ve tahmin performansının zaman ilerledikçe belirgin şekilde arttığı gözlemlenmiştir. Başlangıçta en iyi sonuçları veren PSO-DNN modeli, ara sınav ve final öncesinde RF modeli tarafından geçilmiştir. Final öncesinde tüm modellerin doğruluk, F1 skoru, kesinlik ve hatırlama değerleri önemli ölçüde iyileşmiş, bu da daha fazla verinin tahmin başarısını artırdığını göstermiştir.

Modelin karar mekanizmasını anlamak için SHAP ve LIME açıklanabilir yapay zeka (XAI) teknikleri kullanılmıştır. XAI analizleri, öğrencilerin sınıflandırılmasını etkileyen temel özellikleri belirleyerek tahmin sürecinin yorumlanmasını geliştirmiştir. “Dersi Alan Öğrenci Sayısı”, “Lise Başarı Puanı”, “Ders Tekrar Sayısı”, “TYT Yerleştirme Puanı”, “TYT Başarı Sıralama Yüzdesi”, “Matematik Yanlış Sayısı”, “Sosyal Bilimler Yanlış Sayısı”, “SAY Başarı Sıralama Yüzdesi” ve “Alınan Ders Sayısı” en önemli değişkenler olarak belirlenmiştir. SHAP ve LIME analizleri, istatistiksel testlerle desteklenmiş ve t-testi ile ANOVA sonuçlarıyla tutarlılık göstermiştir. Bu analizler, modelin belirli öz niteliklere yüksek duyarlılık gösterdiğini ortaya koymuştur. Küçük sınıfların ve kontrollü ders yükünün akademik başarıyı olumlu etkilediği, hazırlık eğitiminin başarı üzerinde istatistiksel olarak anlamlı pozitif

bir etkisi olduğu tespit edilmiştir. STEM alanlarındaki performansın akademik başarıya kritik bir katkı sağladığı gözlemlenmiştir.

Çalışmada Türkiye'deki akademik performans göstergeleri kullanılmış olup, yalnızca tek bir üniversite ve dersle sınırlı olması genelleştirilebilirliği kısıtlamaktadır. Bu nedenle, farklı dersleri kapsayan xAPI-Edu-Data veri seti ile bir karşılaştırma yapılmıştır. Önerilen model, literatürdeki diğer beş çalışmaya kıyasla daha yüksek doğruluk sağlamıştır. Yalnızca Sixhaxa (2022) tarafından kullanılan SVM [193] ve Vijayalakshmi (2019) tarafından kullanılan DNN [190] yöntemleri biraz daha iyi sonuçlar elde etmiştir. Bu başarı, PSO'nun DNN modelinin hiperparametrelerini optimize etme gücüne dayanmaktadır.

Ancak, teknik altyapı gereksinimleri ve işlem süreleri nedeniyle modelin hiperparametreleri (sürü büyüklüğü, maksimum iterasyon sayısı ve gizli katman sayısı gibi) sınırlanmıştır. Bu kısıtlamaların gevşetilmesi modelin performansını artırabilir, ancak aşırı öğrenme riski, hesaplama maliyetleri ve uzun eğitim süreleri gibi zorlukları da beraberinde getirebilir.

Gelecek çalışmalar için öneriler şunlardır: Modelin farklı ders, üniversite ve ülke verileri ile eğitilip test edilmesi; farklı optimizasyon teknikleri ve derin öğrenme algoritmalarıyla hibrit modellerin incelenmesi; ek XAI teknikleriyle modelin açıklanabilirliğinin artırılması; modelin eğitim kurumlarına entegre edilmesi ve bulut tabanlı API'ler aracılığıyla yaygınlaştırılması; transfer öğrenme teknikleriyle farklı eğitim ortamlarına uyarlanması ve veri güvenliği ile gizliliğin sağlanmasına yönelik çalışmalar yapılması. Bu gelişmeler, eğitimde veri odaklı karar alma süreçlerini destekleyerek öğrenci başarısının artırılmasına katkı sağlayacaktır.



KAYNAKLAR

- [1] Baker, R. S. J. (2010). Data mining for education. In *International Encyclopedia of Education* (3rd ed., Vol. 7, pp. 112–118). McGraw.
- [2] *Educational data mining*. (2025). <https://educationaldatamining.org/>
- [3] Huebner, R. A. (2013). A survey of educational data-mining research. *Research in Higher Education Journal*, 19, 1–13.
- [4] Calders, T., & Pechenizkiy, M. (2012). Introduction to the special section on educational data mining. *ACM SIGKDD Explorations Newsletter*, 13(2), 3–6. <https://doi.org/10.1145/2207243.2207245>
- [5] Romero, C., & Ventura, S. (2010). Educational Data Mining: A Review of the State of the Art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 40(6), 601–618. <https://doi.org/10.1109/TSMCC.2010.2053532>
- [6] Romero, C., & Ventura, S. (2013). Data mining in education. *WIREs Data Mining and Knowledge Discovery*, 3(1), 12–27. <https://doi.org/10.1002/widm.1075>
- [7] Romero, C., & Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33(1), 135–146. <https://doi.org/10.1016/j.eswa.2006.04.005>
- [8] Romero, C., Romero, J. R., & Ventura, S. (2014). A Survey on Pre-Processing Educational Data. In A. Peña-Ayala (Ed.), *Educational Data Mining* (Vol. 524, pp. 29–64). Springer International Publishing. https://doi.org/10.1007/978-3-319-02738-8_2
- [9] Scheuer, O., & McLaren, B. M. (2012). Educational Data Mining. In N. M. Seel (Ed.), *Encyclopedia of the Sciences of Learning* (pp. 1075–1079). Springer US. https://doi.org/10.1007/978-1-4419-1428-6_618
- [10] Castro, F., Vellido, A., Nebot, À., & Mugica, F. (2007). Applying Data Mining Techniques to e-Learning Problems. In L. C. Jain, R. A. Tedman, & D. K. Tedman (Eds.), *Evolution of Teaching and Learning Paradigms in Intelligent Environment* (Vol. 62, pp. 183–221). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-71974-8_8
- [11] Baker, R. S. J. d., & Yacef, K. (2009). *The State of Educational Data Mining in 2009: A Review and Future Visions*. 1(1), 3–17. <https://doi.org/10.5281/ZENODO.3554657>
- [12] Peña, A., Domínguez, R. A. S., & Medel, J. J. (2009). Educational data mining: A sample of review and study case. *World Journal on Educational Technology*, 2(2009), 118–139.

- [13] Peña-Ayala, A. (2014). Educational data mining: A survey and a data mining-based analysis of recent works. *Expert Systems with Applications*, 41(4), 1432–1462. <https://doi.org/10.1016/j.eswa.2013.08.042>
- [14] Romero, C., Ventura, S., Pechenizkiy, M., & Baker, R. S. J. d. (Eds.). (2010). *Handbook of Educational Data Mining* (0 ed.). CRC Press. <https://doi.org/10.1201/b10274>
- [15] Bousbia, N., & Belamri, I. (2014). Which Contribution Does EDM Provide to Computer-Based Learning Environments? In A. Peña-Ayala (Ed.), *Educational Data Mining* (Vol. 524, pp. 3–28). Springer International Publishing. https://doi.org/10.1007/978-3-319-02738-8_1
- [16] Albreiki, B., Zaki, N., & Alashwal, H. (2021). A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques. *Education Sciences*, 11(9), 552. <https://doi.org/10.3390/educsci11090552>
- [17] Tsiakmaki, M., Kostopoulos, G., Kotsiantis, S., & Ragos, O. (2020). Transfer Learning from Deep Neural Networks for Predicting Student Performance. *Applied Sciences*, 10(6), 2145. <https://doi.org/10.3390/app10062145>
- [18] Akçapınar, G., Altun, A., & Aşkar, P. (2019). Using learning analytics to develop early-warning system for at-risk students. *International Journal of Educational Technology in Higher Education*, 16(1), 40. <https://doi.org/10.1186/s41239-019-0172-z>
- [19] Sukhbaatar, O., Usagawa, T., & Choimaa, L. (2019). An Artificial Neural Network Based Early Prediction of Failure-Prone Students in Blended Learning Course. *International Journal of Emerging Technologies in Learning (iJET)*, 14(19), 77. <https://doi.org/10.3991/ijet.v14i19.10366>
- [20] Yağcı, M. (2022). Educational data mining: Prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9(1), 11. <https://doi.org/10.1186/s40561-022-00192-z>
- [21] Gupta, R., & Gueneau, C. (2021). Feature Correlation with Student Education Performance: Student Feature Correlation with Student Academic Performance in the Student Performance Dataset. *Journal of Student Research*, 10(2), 1–13. <https://doi.org/10.47611/jsrhs.v10i2.1680>
- [22] Sikder, Md. H., Hosen, Md. R., Fatema, K., & Islam, Md. A. (2022). Predicting Students' Performance in Final Examination using Deep Neural Network. *Asian Journal of Research in Computer Science*, 218–227. <https://doi.org/10.9734/ajrcos/2022/v14i4306>
- [23] Alhassan, A., Zafar, B., & Mueen, A. (2020). Predict Students' Academic Performance based on their Assessment Grades and Online Activity Data. *International Journal of Advanced Computer Science and Applications*, 11(4), 185–194. <https://doi.org/10.14569/IJACSA.2020.0110425>
- [24] Al-Azawei, A., & Al-Masoudy, M. A. A. (2020). Predicting Learners' Performance in Virtual Learning Environment (VLE) based on Demographic, Behavioral and Engagement Antecedents. *International Journal of Emerging Technologies in Learning (iJET)*, 15(09), 60. <https://doi.org/10.3991/ijet.v15i09.12691>

- [25] Alsariera, Y. A., Baashar, Y., Alkawsi, G., Mustafa, A., Alkahtani, A. A., & Ali, N. (2022). Assessment and Evaluation of Different Machine Learning Algorithms for Predicting Student Performance. *Computational Intelligence and Neuroscience*, 2022, 1–11. <https://doi.org/10.1155/2022/4151487>
- [26] Bütüner, R., & Calp, M. H. (2022). Estimation of the Academic Performance of Students in Distance Education Using Data Mining Methods. *International Journal of Assessment Tools in Education*, 9(2), 410–429. <https://doi.org/10.21449/ijate.904456>
- [27] Aluko, R. O., Daniel, E. I., Shamsideen Oshodi, O., Aigbavboa, C. O., & Abisuga, A. O. (2018). Towards reliable prediction of academic performance of architecture students using data mining techniques. *Journal of Engineering, Design and Technology*, 16(3), 385–397. <https://doi.org/10.1108/JEDT-08-2017-0081>
- [28] Qiu, F., Zhang, G., Sheng, X., Jiang, L., Zhu, L., Xiang, Q., Jiang, B., & Chen, P. (2022). Predicting students' performance in e-learning using learning process and behaviour data. *Scientific Reports*, 12(1), 453. <https://doi.org/10.1038/s41598-021-03867-8>
- [29] Adejo, O. W., & Connolly, T. (2018). Predicting student academic performance using multi-model heterogeneous ensemble approach. *Journal of Applied Research in Higher Education*, 10(1), 61–75. <https://doi.org/10.1108/JARHE-09-2017-0113>
- [30] Rong, Y., He, T., Li, Z., & Liu, G. (2023). *Achievement Performance Prediction Model Based on Deep Neural Network of Student Similarity*. Proceedings of the 4th International Conference on Modern Education and Information Management, ICMEIM 2023, September 8–10, 2023, Wuhan, China, Wuhan, People's Republic of China. <https://doi.org/10.4108/eai.8-9-2023.2340180>
- [31] Mi, H., Gao, Z., Zhang, Q., & Zheng, Y. (2022). Research on Constructing Online Learning Performance Prediction Model Combining Feature Selection and Neural Network. *International Journal of Emerging Technologies in Learning (iJET)*, 17(07), 94–111. <https://doi.org/10.3991/ijet.v17i07.25587>
- [32] Ojajuni, O., Ayeni, F., Akodu, O., Ekanoye, F., Adewole, S., Ayo, T., Misra, S., & Mbarika, V. (2021). Predicting Student Academic Performance Using Machine Learning. In O. Gervasi, B. Murgante, S. Misra, C. Garau, I. Blečić, D. Taniar, B. O. Apduhan, A. M. A. C. Rocha, E. Tarantino, & C. M. Torre (Eds.), *Computational Science and Its Applications – ICCSA 2021* (Vol. 12957, pp. 481–491). Springer International Publishing. https://doi.org/10.1007/978-3-030-87013-3_36
- [33] Waheed, H., Hassan, S.-U., Nawaz, R., Aljohani, N. R., Chen, G., & Gasevic, D. (2023). Early prediction of learners at risk in self-paced education: A neural network approach. *Expert Systems with Applications*, 213, 118868. <https://doi.org/10.1016/j.eswa.2022.118868>
- [34] Yousafzai, B. K., Khan, S. A., Rahman, T., Khan, I., Ullah, I., Ur Rehman, A., Baz, M., Hamam, H., & Cheikhrouhou, O. (2021). Student-Performulator: Student Academic Performance Using Hybrid Deep Neural Network. *Sustainability*, 13(17), 9775. <https://doi.org/10.3390/su13179775>

- [35] Nabil, A., Seyam, M., & Abou-Elfetouh, A. (2021). Prediction of Students' Academic Performance Based on Courses' Grades Using Deep Neural Networks. *IEEE Access*, 9, 140731–140746. <https://doi.org/10.1109/ACCESS.2021.3119596>
- [36] Sayed, B. T., Madanan, M., & Biju, N. (2022). An Efficient Artificial Intelligence-Based Educational Data Mining Approach for Higher Education and Early Recognition System. *SN Computer Science*, 4(2), 130. <https://doi.org/10.1007/s42979-022-01562-7>
- [37] Venkatachalam, B., & Sivanraju, K. (2023). Predicting Student Performance Using Mental Health and Linguistic Attributes with Deep Learning. *Revue d'Intelligence Artificielle*, 37(4), 889–899. <https://doi.org/10.18280/ria.370408>
- [38] Chen, H.-C., Prasetyo, E., Tseng, S.-S., Putra, K. T., Prayitno, Kusumawardani, S. S., & Weng, C.-E. (2022). Week-Wise Student Performance Early Prediction in Virtual Learning Environment Using a Deep Explainable Artificial Intelligence. *Applied Sciences*, 12(4), 1885. <https://doi.org/10.3390/app12041885>
- [39] Li, X., Zhu, X., Zhu, X., Ji, Y., & Tang, X. (2020). Student Academic Performance Prediction Using Deep Multi-source Behavior Sequential Network. In H. W. Lauw, R. C.-W. Wong, A. Ntoulas, E.-P. Lim, S.-K. Ng, & S. J. Pan (Eds.), *Advances in Knowledge Discovery and Data Mining* (Vol. 12084, pp. 567–579). Springer International Publishing. https://doi.org/10.1007/978-3-030-47426-3_44
- [40] Li, X., Zhang, Y., Cheng, H., Li, M., & Yin, B. (2022). Student achievement prediction using deep neural network from multi-source campus data. *Complex & Intelligent Systems*. <https://doi.org/10.1007/s40747-022-00731-8>
- [41] Pereira, F. D., Oliveira, E. H. T. D., Oliveira, D. B. F. D., Carvalho, L. S. G. D., & Cristea, A. I. (2021). Interpretable AI to Understand Early Effective and Ineffective Programming Behaviours from CS1 Learners. *Anais Estendidos Do I Simpósio Brasileiro de Educação Em Computação (EDUCOMP Estendido 2021)*, 16–17. https://doi.org/10.5753/educomp_estendido.2021.14853
- [42] Mishra, P., Pandey, C., Singh, U., Keshri, A., & Sabaretnam, M. (2019). Selection of appropriate statistical methods for data analysis. *Annals of Cardiac Anaesthesia*, 22(3), 297. https://doi.org/10.4103/aca.ACA_248_18
- [43] Alabi, O., & Bukola, T. (2023). Introduction to Descriptive statistics. In B. Santhosh Kumar (Ed.), *Recent Advances in Biostatistics*. IntechOpen. <https://doi.org/10.5772/intechopen.1002475>
- [44] Iancu, M., Tilinca, M., & Achimas Cadariu, A. (2016). Biostatistics Methods Used in Celiac Disease Population Studies. *International Journal of Celiac Disease*, 2(4), 134–136. <https://doi.org/10.12691/ijcd-2-4-10>
- [45] Yuan, Y., Xu, H., Krishnamurthy, M., & Vijayakumar, P. (2024). Visualization analysis of educational data statistics based on big data mining. *Journal of Computational Methods in Sciences and Engineering*, 24(3), 1785–1793. <https://doi.org/10.3233/JCM-230003>

- [46] Gupta, S. (2012). The relevance of confidence interval and P-value in inferential statistics. *Indian Journal of Pharmacology*, 44(1), 143. <https://doi.org/10.4103/0253-7613.91895>
- [47] Lee, D. K. (2016). Alternatives to P value: Confidence interval and effect size. *Korean Journal of Anesthesiology*, 69(6), 555. <https://doi.org/10.4097/kjae.2016.69.6.555>
- [48] Park, J., Lee, H., & Kim, Y. B. (2015). Bootstrap generated confidence interval for time averaged measure. *International Journal of Modeling, Simulation, and Scientific Computing*, 06(03), 1550030. <https://doi.org/10.1142/S1793962315500300>
- [49] Hemming, K., & Taljaard, M. (2021). Why proper understanding of confidence intervals and statistical significance is important. *Medical Journal of Australia*, 214(3), 116. <https://doi.org/10.5694/mja2.50926>
- [50] Sugawara, S., & Noma, H. (2021). A unified method for improved inference in random effects meta-analysis. *Biostatistics*, 22(1), 114–130. <https://doi.org/10.1093/biostatistics/kxz020>
- [51] Wang, J., & Bi, J. (2017). Relationship between the confidence interval and the p value. *Applied Mathematical Sciences*, 11, 1901–1906. <https://doi.org/10.12988/ams.2017.76193>
- [52] Budak, H. (2018). Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(Özel), 21. <https://doi.org/10.19113/sdufbed.01653>
- [53] Saygin, E., & Baykara, M. (2021). Karaciğer Yetmezliği Teşhisinde Özellik Seçimi Kullanarak Makine Öğrenmesi Yöntemlerinin Başarılarının Ölçülmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 33(2), 367–377. <https://doi.org/10.35234/fumbd.832264>
- [54] Deperlioğlu, Ö. (2023). Tıbbi Veri Kümelerinde Genetik Algoritmalarla Özellik Seçimi ve Sınıflandırma Başarımına Etkisi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 11(1), 68–80. <https://doi.org/10.21923/jesd.1117976>
- [55] Varol, A. B., & İşeri, İ. (2019). Lenf Kanseri İlişkin Patoloji Görüntülerinin Makine Öğrenimi Yöntemleri ile Sınıflandırılması. *European Journal of Science and Technology*, 404–410. <https://doi.org/10.31590/ejosat.638372>
- [56] Gedikli, E., & Yurdusever, T. (2024). EEG Sinyallerinden Meta-Sezgisel Optimizasyon Algoritmalarına Dayalı Özellik Seçimi. *Black Sea Journal of Engineering and Science*, 7(4), 717–723. <https://doi.org/10.34248/bsengineering.1490063>
- [57] Houssein, E. H., Emam, M. M., Ali, A. A., & Suganthan, P. N. (2021). Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review. *Expert Systems with Applications*, 167, 114161. <https://doi.org/10.1016/j.eswa.2020.114161>
- [58] Smiti, A. (2020). When machine learning meets medical world: Current status and future challenges. *Computer Science Review*, 37, 100280. <https://doi.org/10.1016/j.cosrev.2020.100280>

- [59] Kühl, N., Goutier, M., Hirt, R., & Satzger, G. (2019). *Machine Learning in Artificial Intelligence: Towards a Common Understanding*. Hawaii International Conference on System Sciences. <https://doi.org/10.24251/HICSS.2019.630>
- [60] Zhang, L., He, M., & Shao, S. (2020). Machine learning for halide perovskite materials. *Nano Energy*, 78, 105380. <https://doi.org/10.1016/j.nanoen.2020.105380>
- [61] Deperlioğlu, Ö., & Köse, U. (2024). *Python İle Makine Öğrenmesi Temel Kavramlar – Sınıflandırma Regresyon – Kümeleme*. Seçkin Yayıncılık.
- [62] Nakaura, T., Higaki, T., Awai, K., Ikeda, O., & Yamashita, Y. (2020). A primer for understanding radiology articles about machine learning and deep learning. *Diagnostic and Interventional Imaging*, 101(12), 765–770. <https://doi.org/10.1016/j.diii.2020.10.001>
- [63] Sun, H., Burton, H. V., & Huang, H. (2021). Machine learning applications for building structural design and performance assessment: State-of-the-art review. *Journal of Building Engineering*, 33, 101816. <https://doi.org/10.1016/j.jobe.2020.101816>
- [64] Canhoto, A. I. (2021). Leveraging machine learning in the global fight against money laundering and terrorism financing: An affordances perspective. *Journal of Business Research*, 131, 441–452. <https://doi.org/10.1016/j.jbusres.2020.10.012>
- [65] Onyewe, A., Kana, A. F., Abdullahi, F. B., & Abdulsalami, A. O. (2021). An Enhanced Adaptive k-Nearest Neighbor Classifier Using Simulated Annealing. *International Journal of Intelligent Systems and Applications*, 13(1), 34–44. <https://doi.org/10.5815/ijisa.2021.01.03>
- [66] Shahnazari, K., & Ayyoubzadeh, S. M. (2024). A novel nearest neighbors algorithm based on power muirhead mean. *Intelligent Decision Technologies*, 18(3), 2019–2031. <https://doi.org/10.3233/IDT-240890>
- [67] Hu, L.-Y., Huang, M.-W., Ke, S.-W., & Tsai, C.-F. (2016). The distance function effect on k-nearest neighbor classification for medical datasets. *SpringerPlus*, 5(1), 1304. <https://doi.org/10.1186/s40064-016-2941-7>
- [68] Pulungan, A., Zarlis, M., & Suwilo, S. (2020). *Performance Analysis of Distance Measures in K-Nearest Neighbor*. Proceedings of the 1st International Conference on Management, Business, Applied Science, Engineering and Sustainability Development, ICMASES 2019, 9-10 February 2019, Malang, Indonesia, Samarinda, Indonesia. <https://doi.org/10.4108/eai.3-8-2019.2290748>
- [69] Peng, X., Chen, R., Yu, K., Ye, F., & Xue, W. (2020). An Improved Weighted K-Nearest Neighbor Algorithm for Indoor Localization. *Electronics*, 9(12), 2117. <https://doi.org/10.3390/electronics9122117>
- [70] Azadkia, M. (2019). *Optimal choice of k for k-nearest neighbor regression*. <https://doi.org/10.48550/ARXIV.1909.05495>
- [71] Setiyorini, T., & Asmono, R. T. (2020). Implementation of Gain Ratio and K-Nearest Neighbor for Classification of Student Performance. *Jurnal Pilar Nusa Mandiri*, 16(1), 19–24. <https://doi.org/10.33480/pilar.v16i1.813>

- [72] Okun, O., & Priisalu, H. (2008). Ensembles of k-nearest neighbors and dimensionality reduction. *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, 2032–2039. <https://doi.org/10.1109/IJCNN.2008.4634077>
- [73] Hosmer, D. W., & Lemeshow, S. (2000). *Applied Logistic Regression* (1st ed.). Wiley. <https://doi.org/10.1002/0471722146>
- [74] Kleinbaum, D. G. (1994). *Logistic Regression*. Springer New York. <https://doi.org/10.1007/978-1-4757-4108-7>
- [75] Almoallem, Y. D., Taha, I. B. M., Mosaad, M. I., Nahma, L., & Abu-Siada, A. (2021). Application of Logistic Regression Algorithm in the Interpretation of Dissolved Gas Analysis for Power Transformers. *Electronics*, 10(10), 1206. <https://doi.org/10.3390/electronics10101206>
- [76] Genkin, A., Lewis, D. D., & Madigan, D. (2007). Large-Scale Bayesian Logistic Regression for Text Categorization. *Technometrics*, 49(3), 291–304. <https://doi.org/10.1198/004017007000000245>
- [77] Akinci, S., Kaynak, E., Atilgan, E., & Aksoy, Ş. (2007). Where does the logistic regression analysis stand in marketing literature?: A comparison of the market positioning of prominent marketing journals. *European Journal of Marketing*, 41(5/6), 537–567. <https://doi.org/10.1108/03090560710737598>
- [78] Gholipour, K., Asghari-Jafarabadi, M., Iezadi, S., Jannati, A., & Keshavarz, S. (2018). Modelling the prevalence of diabetes mellitus risk factors based on artificial neural network and multiple regression. *Eastern Mediterranean Health Journal*, 24(08), 770–777. <https://doi.org/10.26719/emhj.18.012>
- [79] Wang, Z., Dong, W., & Yang, K. (2022). Spatiotemporal Analysis and Risk Assessment Model Research of Diabetes among People over 45 Years Old in China. *International Journal of Environmental Research and Public Health*, 19(16), 9861. <https://doi.org/10.3390/ijerph19169861>
- [80] Samawi, H. M., Rochani, H., Linder, D., & Chatterjee, A. (2017). More efficient logistic analysis using moving extreme ranked set sampling. *Journal of Applied Statistics*, 44(4), 753–766. <https://doi.org/10.1080/02664763.2016.1182136>
- [81] Pannakkong, W., Thiwa-Anont, K., Singthong, K., Parthanadee, P., & Buddhakulsomsiri, J. (2022). Hyperparameter Tuning of Machine Learning Algorithms Using Response Surface Methodology: A Case Study of ANN, SVM, and DBN. *Mathematical Problems in Engineering*, 2022, 1–17. <https://doi.org/10.1155/2022/8513719>
- [82] Samui, P. (2013). Support vector classifier analysis of slope. *Geomatics, Natural Hazards and Risk*, 4(1), 1–12. <https://doi.org/10.1080/19475705.2012.684725>
- [83] Breiman, L. (2001). *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- [84] Probst, P., Wright, M. N., & Boulesteix, A. (2019). Hyperparameters and tuning strategies for random forest. *WIREs Data Mining and Knowledge Discovery*, 9(3), e1301. <https://doi.org/10.1002/widm.1301>

- [85] Pujianto, U., Taufani, A. R., & Aziz, J. A. (2021). Random forest algorithm for algorithm for prediction of high school science students acceptance snmptn based on students assesment report. *Jurnal Informatika*, 15(3), 29. <https://doi.org/10.26555/jifo.v15i3.a25413>
- [86] Rochmawati, N., Hidayati, H. B., Yamasari, Y., Yustanti, W., Rakhmawati, L., Tjahyaningtijas, H. P. A., & Anistyasari, Y. (2020). Covid Symptom Severity Using Decision Tree. *2020 Third International Conference on Vocational Education and Electrical Engineering (ICVEE)*, 1–5. <https://doi.org/10.1109/ICVEE50212.2020.9243246>
- [87] Kingsford, C., & Salzberg, S. L. (2008). What are decision trees? *Nature Biotechnology*, 26(9), 1011–1013. <https://doi.org/10.1038/nbt0908-1011>
- [88] Anmala, J., & Turuganti, V. (2021). Comparison of the performance of decision tree (DT) algorithms and extreme learning machine (ELM) model in the prediction of water quality of the Upper Green River watershed. *Water Environment Research*, 93(11), 2360–2373. <https://doi.org/10.1002/wer.1642>
- [89] Tangirala, S. (2020). Evaluating the Impact of GINI Index and Information Gain on Classification using Decision Tree Classifier Algorithm*. *International Journal of Advanced Computer Science and Applications*, 11(2). <https://doi.org/10.14569/IJACSA.2020.0110277>
- [90] Aghaabbasi, M., Ali, M., Jasiński, M., Leonowicz, Z., & Novák, T. (2023). On Hyperparameter Optimization of Machine Learning Methods Using a Bayesian Optimization Algorithm to Predict Work Travel Mode Choice. *IEEE Access*, 11, 19762–19774. <https://doi.org/10.1109/ACCESS.2023.3247448>
- [91] Rizky, M. H., Faisal, M. R., Budiman, I., Kartini, D., & Abadi, F. (2024). Effect of Hyperparameter Tuning Using Random Search on Tree-Based Classification Algorithm for Software Defect Prediction. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 18(1), 95. <https://doi.org/10.22146/ijccs.90437>
- [92] Oktaviani, I. D., & Abdulloh, F. F. (2024). Comparison PSO And IWPSO Performance In Optimizing Decision Tree Algorithm On Heart Disease Dataset. *Sinkron*, 9(1), 375–383. <https://doi.org/10.33395/sinkron.v9i1.13208>
- [93] Öztemel, E. (2012). *Yapay Sinir Ağları*. Papatya Yayıncılık.
- [94] Prayugo, M. B. D., Nafisa, N. A., Yulianas, A., & Fahmi, H. (2023). Human Voice Recognition System with Backpropagation Neural Network Method. In E. Susanti, J. Juhari, & M. N. Jauhari (Eds.), *Proceedings of the 12th International Conference on Green Technology (ICGT 2022)* (Vol. 221, pp. 432–442). Atlantis Press International BV. https://doi.org/10.2991/978-94-6463-148-7_43
- [95] Mishra, M. V., Agarwal, Smt. M., & Puri, N. (2018). Comprehensive and Comparative Analysis of Neural Network. *International Journal of Computer Application*, 2(8), 125–137. <https://doi.org/10.26808/rs.ca.i8v2.15>
- [96] Karaki, Y., & Ivanov, N. (2020). Hyperparameters of Multilayer Perceptron with Normal Distributed Weights. *Pattern Recognition and Image Analysis*, 30(2), 170–173. <https://doi.org/10.1134/S1054661820020054>

- [97] Ke, K.-C., & Huang, M.-S. (2020). Quality Prediction for Injection Molding by Using a Multilayer Perceptron Neural Network. *Polymers*, 12(8), 1812. <https://doi.org/10.3390/polym12081812>
- [98] Kuo, P.-H., & Huang, C.-J. (2018). A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting. *Energies*, 11(1), 213. <https://doi.org/10.3390/en11010213>
- [99] Ogorodnyk, O., Lyngstad, O. V., Larsen, M., Wang, K., & Martinsen, K. (2019). Application of Machine Learning Methods for Prediction of Parts Quality in Thermoplastics Injection Molding. In K. Wang, Y. Wang, J. O. Strandhagen, & T. Yu (Eds.), *Advanced Manufacturing and Automation VIII* (Vol. 484, pp. 237–244). Springer Singapore. https://doi.org/10.1007/978-981-13-2375-1_30
- [100] Ryu, S., Noh, J., & Kim, H. (2016). Deep Neural Network Based Demand Side Short Term Load Forecasting. *Energies*, 10(1), 3. <https://doi.org/10.3390/en10010003>
- [101] Kayaalp, K., & Süzen, A. A. (2018). *Derin Öğrenme ve Türkiye’deki Uygulamaları*. IKSAD Yayınevi.
- [102] Yılmaz, A., & Kaya, U. (2019). *Derin Öğrenme*. Kodlab Yayın Dağıtım.
- [103] Elmas, Ç. (2021). *Yapay Zeka Uygulamaları Yapay Sinir Ağı | Makine Öğrenmesi – Derin Öğrenme | Derin Ağlar – Bulanık Mantık | Sinirsel Bulanık Mantık – Genetik Algoritma*. Seçkin Yayıncılık.
- [104] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT press.
- [105] Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- [106] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [107] Nair, V., & Hinton, G. E. (n.d.). *Rectified Linear Units Improve Restricted Boltzmann Machines*.
- [108] Olah, C. (2015). *Recurrent neural network*. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [109] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [110] Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.1412.3555>
- [111] Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). *Generative Adversarial Networks*. <https://doi.org/10.48550/ARXIV.1406.2661>
- [112] Zhu, J.-Y., Park, T., Isola, P., & Efros, A. A. (2017). Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks. *2017 IEEE International Conference on Computer Vision (ICCV)*, 2242–2251. <https://doi.org/10.1109/ICCV.2017.244>

- [113] Yi, X., Walia, E., & Babyn, P. (2019). Generative adversarial network in medical imaging: A review. *Medical Image Analysis*, 58, 101552. <https://doi.org/10.1016/j.media.2019.101552>
- [114] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need* (Version 7). arXiv. <https://doi.org/10.48550/ARXIV.1706.03762>
- [115] Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). [No title found]. *Proceedings of the 2019 Conference of the North*, 4171–4186. <https://doi.org/10.18653/v1/N19-1423>
- [116] Beltagy, I., Peters, M. E., & Cohan, A. (2020). *Longformer: The Long-Document Transformer* (Version 2). arXiv. <https://doi.org/10.48550/ARXIV.2004.05150>
- [117] Kitaev, N., Kaiser, L., & Levskaya, A. (2020). *Reformer: The Efficient Transformer* (Version 2). arXiv. <https://doi.org/10.48550/ARXIV.2001.04451>
- [118] Bahrampour, S., Ramakrishnan, N., Schott, L., & Shah, M. (2016). *Comparative Study of Caffe, Neon, Theano, and Torch for Deep Learning*. 1–11.
- [119] Bahrampour, S., Ramakrishnan, N., Schott, L., & Shah, M. (2015). *Comparative Study of Deep Learning Software Frameworks* (Version 3). arXiv. <https://doi.org/10.48550/ARXIV.1511.06435>
- [120] Alalawi, K., Athauda, R., & Chiong, R. (2023). Contextualizing the current state of research on the use of machine learning for student performance prediction: A systematic literature review. *Engineering Reports*, 5(12). <https://doi.org/10.1002/eng2.12699>
- [121] Chakrapani, P., & D, C. (2022). Academic Performance Prediction Using Machine Learning: A Comprehensive & Systematic Review. *2022 International Conference on Electronic Systems and Intelligent Computing (ICESIC)*, 335–340. <https://doi.org/10.1109/ICESIC53714.2022.9783512>
- [122] Nabil, A., Seyam, M., & Elfetouh, A. A. (2022). Predicting students' academic performance using machine learning techniques: A literature review. *International Journal of Business Intelligence and Data Mining*, 20(4), 456. <https://doi.org/10.1504/IJBIDM.2022.123214>
- [123] Xiao, W., & Hu, J. (2023). A state-of-the-art survey of predicting students' performance using artificial neural networks. *Engineering Reports*, 5(8). <https://doi.org/10.1002/eng2.12652>
- [124] Iam-On, N., & Boongoen, T. (2017). Generating descriptive model for student dropout: A review of clustering approach. *Human-Centric Computing and Information Sciences*, 7(1), 1. <https://doi.org/10.1186/s13673-016-0083-0>
- [125] Hui, Y. K., & Kwok, L. F. (2019). A review on learning analytics. *International Journal of Innovation and Learning*, 25(2), 197. <https://doi.org/10.1504/IJIL.2019.097673>
- [126] Namoun, A., & Alshantiti, A. (2020). Predicting Student Performance Using Data Mining and Learning Analytics Techniques: A Systematic Literature Review. *Applied Sciences*, 11(1), 237. <https://doi.org/10.3390/app11010237>

- [127] Ordoñez-Avila, R., Reyes, N. S., Meza, J., & Ventura, S. (2023). Data mining techniques for predicting teacher evaluation in higher education: A systematic literature review. *Heliyon*, 9(3), e13939. <https://doi.org/10.1016/j.heliyon.2023.e13939>
- [128] Shahiri, A. M. (2015). A Review on Predicting Student's Performance Using Data Mining Techniques. *Procedia Computer Science*, 9. <https://doi.org/doi:10.1016/j.procs.2015.12.157>
- [129] Nawang, H., Makhtar, M., & Hamza, W. M. A. F. W. (2021). A systematic literature review on student performance predictions. *International Journal of Advanced Technology and Engineering Exploration*, 8(84). <https://doi.org/10.19101/IJATEE.2021.874521>
- [130] Pawar, P. S., & Jain, R. (2021). A review on Student Performance Prediction using Educational Data mining and Artificial Intelligence. *2021 IEEE 2nd International Conference on Technology, Engineering, Management for Societal Impact Using Marketing, Entrepreneurship and Talent (TEMSMET)*, 1–7. <https://doi.org/10.1109/TEMSMET53515.2021.9768773>
- [131] Xiao, W., Ji, P., & Hu, J. (2022). A survey on educational data mining methods used for predicting students' performance. *Engineering Reports*, 4(5). <https://doi.org/10.1002/eng2.12482>
- [132] Aulakh, K., Roul, R. K., & Kaushal, M. (2023). E-learning enhancement through educational data mining with Covid-19 outbreak period in backdrop: A review. *International Journal of Educational Development*, 101, 102814. <https://doi.org/10.1016/j.ijedudev.2023.102814>
- [133] Saqr, M., Elmoazen, R., Tedre, M., López-Pernas, S., & Hirsto, L. (2022). How well centrality measures capture student achievement in computer-supported collaborative learning? – A systematic review and meta-analysis. *Educational Research Review*, 35, 100437. <https://doi.org/10.1016/j.edurev.2022.100437>
- [134] Shafiq, D. A., Marjani, M., Habeeb, R. A. A., & Asirvatham, D. (2022). Student Retention Using Educational Data Mining and Predictive Analytics: A Systematic Literature Review. *IEEE Access*, 10, 72480–72503. <https://doi.org/10.1109/ACCESS.2022.3188767>
- [135] Zaffar, M., Hashmani, M. A., Savita, K. S., & Khan, S. A. (2021). A review on feature selection methods for improving the performance of classification in educational data mining. *International Journal of Information Technology and Management*, 20(1/2), 110. <https://doi.org/10.1504/IJITM.2021.114161>
- [136] Saa, A. A., Al-Emran, M., & Shaalan, K. (2019). Factors Affecting Students' Performance in Higher Education: A Systematic Review of Predictive Data Mining Techniques. *Technology, Knowledge and Learning*, 24(4), 567–598. <https://doi.org/10.1007/s10758-019-09408-7>
- [137] Khan, A., & Ghosh, S. K. (2021). Student performance analysis and prediction in classroom learning: A review of educational data mining studies. *Education and Information Technologies*, 26(1), 205–240. <https://doi.org/10.1007/s10639-020-10230-3>

- [138] Alyahyan, E., & Düşteğör, D. (2020). Predicting academic success in higher education: Literature review and best practices. *International Journal of Educational Technology in Higher Education*, 17(1), 3. <https://doi.org/10.1186/s41239-020-0177-7>
- [139] Alatawi, H. Q., & Hechmi, S. (2022). A Survey of Data Mining Methods for Early Prediction of Students' Performance. *2022 2nd International Conference on Computing and Information Technology (ICCIT)*, 171–174. <https://doi.org/10.1109/ICCIT52419.2022.9711642>
- [140] López-Zambrano, J., Lara Torralbo, J. A., & Romero, C. (2021). Early Prediction of Student Learning Performance Through Data Mining: A Systematic Review. *Psicothema*, 33.3, 456–465. <https://doi.org/10.7334/psicothema2021.62>
- [141] Bai, X., Zhang, F., Li, J., Guo, T., Aziz, A., Jin, A., & Xia, F. (2021). Educational Big Data: Predictions, Applications and Challenges. *Big Data Research*, 26, 100270. <https://doi.org/10.1016/j.bdr.2021.100270>
- [142] Muthukrishnan, S. M., Govindasamy, M. K., & Mustapha, M. N. (2017). *Systematic Mapping Review on Student's Performance Analysis Using Big Data Predictive Model*. 9(4S), 29.
- [143] Hernández-Blanco, A., Herrera-Flores, B., Tomás, D., & Navarro-Colorado, B. (2019). A Systematic Review of Deep Learning Approaches to Educational Data Mining. *Complexity*, 2019, 1–22. <https://doi.org/10.1155/2019/1306039>
- [144] Kitchenham, B. (2007). *Guidelines for performing Systematic Literature Reviews in Software Engineering*. <https://www.researchgate.net/publication/302924724>
- [145] Almahdi, A. A., & Sharef, B. T. (2023). Deep Learning Based An Optimized Predictive Academic Performance Approach. *2023 International Conference on IT Innovation and Knowledge Discovery (ITIKD)*, 1–6. <https://doi.org/10.1109/ITIKD56332.2023.10099652>
- [146] Wen, X., & Juan, H. (2023). Early Prediction of Students' Performance Using a Deep Neural Network Based on Online Learning Activity Sequence. *Applied Sciences*, 13(15), 8933. <https://doi.org/10.3390/app13158933>
- [147] Anjali, C. A., & Bai, V. R. (2022). An Early Prediction of Dropouts for At-risk Scholars in MOOCs using Deep Learning. *2022 International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS)*, 1–6. <https://doi.org/10.1109/IC3SIS54991.2022.9885328>
- [148] Leelaluk, S., Minematsu, T., Taniguchi, Y., Okubo, F., Yamashita, T., & Shimada, A. (2022). Scaled-Dot Product Attention for Early Detection of At-risk Students. *2022 IEEE International Conference on Teaching, Assessment and Learning for Engineering (TALE)*, 316–322. <https://doi.org/10.1109/TALE54877.2022.00059>
- [149] Al-azazi, F. A., & Ghurab, M. (2023). ANN-LSTM: A deep learning model for early student performance prediction in MOOC. *Heliyon*, 9(4), e15382. <https://doi.org/10.1016/j.heliyon.2023.e15382>

- [150] Wan, H., Li, M., Zhong, Z., & Luo, X. (2023). Early Prediction of Student Performance with LSTM-Based Deep Neural Network. *2023 IEEE 47th Annual Computers, Software, and Applications Conference (COMPSAC), 2023-June*, 132–141. <https://doi.org/10.1109/COMPSAC57700.2023.00026>
- [151] Qin, K., Xie, X., He, Q., & Deng, G. (2023). Early Warning of Student Performance With Integration of Subjective and Objective Elements. *IEEE Access*, 11, 72601–72617. <https://doi.org/10.1109/ACCESS.2023.3295580>
- [152] Kusumawardani, S. S., & Alfarozi, S. A. I. (2023). Transformer Encoder Model for Sequential Prediction of Student Performance Based on Their Log Activities. *IEEE Access*, 11, 18960–18971. <https://doi.org/10.1109/ACCESS.2023.3246122>
- [153] Pereira, F. D., Fonseca, S. C., Oliveira, E. H. T., Cristea, A. I., Bellhauser, H., Rodrigues, L., Oliveira, D. B. F., Isotani, S., & Carvalho, L. S. G. (2021). Explaining Individual and Collective Programming Students' Behavior by Interpreting a Black-Box Predictive Model. *IEEE Access*, 9, 117097–117119. <https://doi.org/10.1109/ACCESS.2021.3105956>
- [154] Tanuar, E., Heryadi, Y., Lukas, Abbas, B. S., & Gaol, F. L. (2018). Using Machine Learning Techniques to Earlier Predict Student's Performance. *2018 Indonesian Association for Pattern Recognition International Conference (INAPR)*, 85–89. <https://doi.org/10.1109/INAPR.2018.8626856>
- [155] Waheed, H., Hassan, S.-U., Aljohani, N. R., Hardman, J., Alelyani, S., & Nawaz, R. (2020). Predicting academic performance of students from VLE big data using deep learning models. *Computers in Human Behavior*, 104, 106189. <https://doi.org/10.1016/j.chb.2019.106189>
- [156] Aljohani, N. R., Fayoumi, A., & Hassan, S.-U. (2019). Predicting At-Risk Students Using Clickstream Data in the Virtual Learning Environment. *Sustainability*, 11(24), 7238. <https://doi.org/10.3390/su11247238>
- [157] Yu, C.-C., & Wu, Y. (Leon). (2021). Early Warning System for Online STEM Learning—A Slimmer Approach Using Recurrent Neural Networks. *Sustainability*, 13(22), 12461. <https://doi.org/10.3390/su132212461>
- [158] Aljuid, M. Y. S. L. Z. (2021). Deep Learning Based Method For Prediction of Software Engineering Project Teamwork Assessment in Higher Education. *Journal of Theoretical and Applied Information Technology*, 99(9). www.jatit.org
- [159] Mao, Y., Marwan, S., & Price, T. W. (2020). What Time is It? Student Modeling Needs to Know. *Proceedings of the 10th International Conference on Educational Data Mining*, 171–182.
- [160] Aslam, N. M., Khan, I. U., Alamri, L. H., & Almuslim, R. S. (2021). An Improved Early Student's Academic Performance Prediction Using Deep Learning. *International Journal of Emerging Technologies in Learning (iJET)*, 16(12), 108. <https://doi.org/10.3991/ijet.v16i12.20699>
- [161] Kim, B.-H., Vizitei, E., & Ganapathi, V. (2018). *GritNet: Student Performance Prediction with Deep Learning* (arXiv:1804.07405). [arXiv. http://arxiv.org/abs/1804.07405](http://arxiv.org/abs/1804.07405)

- [162] Wang, X., Wu, P., Liu, G., Huang, Q., Hu, X., & Xu, H. (2019). Learning performance prediction via convolutional GRU and explainable neural networks in e-learning environments. *Computing*, 101(6), 587–604. <https://doi.org/10.1007/s00607-018-00699-9>
- [163] Raga, R. C., & Raga, J. D. (2019). Early Prediction of Student Performance in Blended Learning Courses Using Deep Neural Networks. *2019 International Symposium on Educational Technology (ISET)*, 39–43. <https://doi.org/10.1109/ISET.2019.00018>
- [164] Surenthiran, S., Rajalakshmi, R., & Sujatha, S. S. (2021). Student Performance Prediction Using Atom Search Optimization Based Deep Belief Neural Network. *Optical Memory and Neural Networks*, 30(2), 157–171. <https://doi.org/10.3103/S1060992X21020119>
- [165] Karimi, H., Derr, T., Huang, J., & Tang, J. (2020). *Online Academic Course Performance Prediction using Relational Graph Convolutional Neural Network*. 7.
- [166] Chen, F., & Cui, Y. (2020). Utilizing Student Time Series Behaviour in Learning Management Systems for Early Prediction of Course Performance. *Journal of Learning Analytics*, 7(2), 1–17. <https://doi.org/10.18608/jla.2020.72.1>
- [167] Hu, Q., & Rangwala, H. (2020). *Academic Performance Estimation with Attention-based Graph Convolutional Networks* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2001.00632>
- [168] Hassan, S., Waheed, H., Aljohani, N. R., Ali, M., Ventura, S., & Herrera, F. (2019). Virtual learning environment to predict withdrawal by leveraging deep learning. *International Journal of Intelligent Systems*, 34(8), 1935–1952. <https://doi.org/10.1002/int.22129>
- [169] Wang, L., Sy, A., Liu, L., & Piech, C. (2017). Learning to Represent Student Knowledge on Programming Exercises Using Deep Learning. *Proceedings of the 10th International Conference on Educational Data Mining*, 324–329.
- [170] Du, X., Yang, J., Hung, J.-L., & Shelton, B. (2020). Educational data mining: A systematic review of research and emerging trends. *Information Discovery and Delivery*, 48(4), 225–236. <https://doi.org/10.1108/IDD-09-2019-0070>
- [171] Uliyan, D., Aljaloud, A. S., Alkhalil, A., Amer, H. S. A., Mohamed, M. A. E. A., & Alogali, A. F. M. (2021). Deep Learning Model to Predict Students Retention Using BLSTM and CRF. *IEEE Access*, 9, 135550–135558. <https://doi.org/10.1109/ACCESS.2021.3117117>
- [172] Park, H. S., & Yoo, S. J. (2021). Early Dropout Prediction in Online Learning of University using Machine Learning. *JOIV: International Journal on Informatics Visualization*, 5(4), 347. <https://doi.org/10.30630/joiv.5.4.732>
- [173] Adnan, M., Habib, A., Ashraf, J., Mussadiq, S., Raza, A. A., Abid, M., Bashir, M., & Khan, S. U. (2021). Predicting at-Risk Students at Different Percentages of Course Length for Early Intervention Using Machine Learning Models. *IEEE Access*, 9, 7519–7539. <https://doi.org/10.1109/ACCESS.2021.3049446>

- [174] Du, X., Yang, J., & Hung, J.-L. (2020). An Integrated Framework Based on Latent Variational Autoencoder for Providing Early Warning of At-Risk Students. *IEEE Access*, 8, 10110–10122. <https://doi.org/10.1109/ACCESS.2020.2964845>
- [175] ÖSYM. (2025). [Resmi Kurum Web Sitesi]. ÖSYM. https://dokuman.osym.gov.tr/pdfdokuman/2025/YKS/kilavuz_ykd06022025.pdf
- [176] Clerc, M., & Kennedy, J. (2002). The particle swarm—Explosion, stability, and convergence in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation*, 6(1), 58–73. <https://doi.org/10.1109/4235.985692>
- [177] Kameyama, K. (2009). Particle Swarm Optimization-A Survey. *IEICE Transactions on Information and Systems*, E92-D(7), 1354–1361. <https://doi.org/10.1587/transinf.E92.D.1354>
- [178] Agung Bella Putra Utama, Aji Prasetya Wibawa, Muladi Muladi, & Andrew Nafalski. (2022). PSO Based Hyperparameter Tuning of CNN Multivariate Time-Series Analysis. *Jurnal Online Informatika*. <https://doi.org/10.15575/join.v7i2.858>
- [179] Pranolo, A., Mao, Y., Wibawa, A. P., Utama, A. B. P., & Dwiyanto, F. A. (2022). Optimized Three Deep Learning Models Based-PSO Hyperparameters for Beijing PM2.5 Prediction. *Knowledge Engineering and Data Science*, 5(1), 53. <https://doi.org/10.17977/um018v5i12022p53-66>
- [180] Sarkar, D., Khan, T., & Ahmed Talukdar, F. (2022). Hyperparameters optimization of neural network using improved particle swarm optimization for modeling of electromagnetic inverse problems. *International Journal of Microwave and Wireless Technologies*, 14(10), 1326–1337. <https://doi.org/10.1017/S1759078721001690>
- [181] Miranda, L. J. V. (2018). PySwarms: A research toolkit for Particle Swarm Optimization in Python. *The Journal of Open Source Software*, 3(21), 433. <https://doi.org/10.21105/joss.00433>
- [182] Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (Second edition). O'Reilly.
- [183] Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- [184] Powers, D. M. W. (2020). *Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation*. <https://doi.org/10.48550/ARXIV.2010.16061>
- [185] Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- [186] Mei, F., Li, X., Zheng, J., Sha, H., & Li, D. (2022). A data-driven approach to state assessment of the converter valve based on oversampling and Shapley additive explanations. *IET Generation, Transmission & Distribution*, 16(8), 1607–1619. <https://doi.org/10.1049/gtd2.12385>

- [187] Rajpurkar, A. R., Mateo, L. J., Murphy, S. E., & Boettiger, A. N. (2021). Deep learning connects DNA traces to transcription to reveal predictive features beyond enhancer–promoter contact. *Nature Communications*, 12(1), 3423. <https://doi.org/10.1038/s41467-021-23831-4>
- [188] Fu, L., Luo, K., Lv, J., Wang, X., Qin, S., Zhang, Z., Sun, S., Wang, X., Yun, B., He, Y., He, W., Li, W., & Chen, L. (2022). Integrating Expression Data-Based Deep Neural Network Models with Biological Networks to Identify Regulatory Modules for Lung Adenocarcinoma. *Biology*, 11(9), 1291. <https://doi.org/10.3390/biology11091291>
- [189] Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2020). Explainable AI: A Review of Machine Learning Interpretability Methods. *Entropy*, 23(1), 18. <https://doi.org/10.3390/e23010018>
- [190] Vij., V., & Ven., K. (2019). Comparison of Predicting Student's Performance using Machine Learning Algorithms. *International Journal of Intelligent Systems and Applications*, 11(12), 34–45. <https://doi.org/10.5815/ijisa.2019.12.04>
- [191] Tuaha, S., Siddiqui, I. F., & Ali Arain, Q. (2019). Analyzing Students' Academic Performance through Educational Data Mining. *3C Tecnología_Glosas de Innovación Aplicadas a La Pyme*, 402–421. <https://doi.org/10.17993/3ctecno.2019.specialissue2.402-421>
- [192] Abubakari, M. S., Arifin, F., & Hungilo, G. G. (2020). Predicting Students' Academic Performance in Educational Data Mining Based on Deep Learning Using TensorFlow. *International Journal of Education and Management Engineering*, 10(6), 27–33. <https://doi.org/10.5815/ijeme.2020.06.04>
- [193] Sixhaxa, K., Jadhav, A., & Ajoodha, R. (2022). Predicting Students Performance in Exams using Machine Learning Techniques. *2022 12th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 635–640. <https://doi.org/10.1109/Confluence52989.2022.9734218>
- [194] Pujianto, U., Agung Prasetyo, W., & Rakhmat Taufani, A. (2020). Students Academic Performance Prediction with k-Nearest Neighbor and C4.5 on SMOTE-balanced data. *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 348–353. <https://doi.org/10.1109/ISRITI51436.2020.9315439>
- [195] Singh, Dr. S., Pratap Singh, Dr. D., & Chandra, Mr. K. (2024). Enhancing Transparency and Interpretability in Deep Learning Models: A Comprehensive Study on Explainable AI Techniques. *Interantional Journal of Scientific Research in Engineering and Management*, 08(02), 1–13. <https://doi.org/10.55041/IJSREM28675>

EKLER

EK A. Resmi Cevap Yazısı



EK A



T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ REKTÖRLÜĞÜ
Rektörlük

Sayı : E-83892146-713.01-72081
Konu : Veri Kullanımı Hk. (Öğr. Gör. Ahmet
KALA)

REKTÖRLÜK MAKAMINA

İlgi : Veri Talebi Hk..pdf

Üniversitemiz Bilgi İşlem Daire Başkanlığı bünyesinde görev yapmakta olan Öğr. Gör. Ahmet KALA'nın "*Büyük Veri ve Derin Öğrenme Algoritmaları Kullanarak Öğrenci Akademik Performansının Erken Tahmini*" başlıklı doktora tezinizde yararlanmak üzere Üniversitemizden talep etmiş olduğu "Öğrenci Bilgi Yönetim Sistemi" ile "Uzaktan Eğitim Verileri"nin 6698 Kişisel Verilerin Korunması Kanunu hükümlerine riayet etmek koşuluyla kullanma izni verilmesi hususunu;
Olurlarınıza arz ederim.

Dr. Öğr. Üyesi Gökhan ERGEN
Genel Sekreter

OLUR
Prof. Dr. Mehmet SARIBIYIK
Rektör

Ek: İlgi Yazı (3 Sayfa)

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Doğrulama Kodu :BSUBAJEUTC Pin Kodu :75592

Belge Takip Adresi : https://ebys.subu.edu.tr/enVision/Validate_Doc.aspx?eD=BSUBAJEUTC&eS=72081

Adres: Rektörlük

Telefon No: 0 264 616 00 54 Faks No: 0 264 616 00 14

e-Posta: subu@subu.edu.tr Elektronik Ağ: www.subu.edu.tr

Kep Adresi: sakaryaygulamalibilimler@hs01.kep.tr

Bilgi için: Ebru Özyol

Unvanı: Ayniyat Saymanı



Şekil A.1. Resmi Cevap Yazısı.

ÖZGEÇMİŞ

Ad-Soyad : Ahmet KALA

ÖĞRENİM DURUMU:

- **Lisans** : 2003, Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yükseklisans** : 2014, Bilecik Şeyh Edebali Üniversitesi, Makine ve İmalat Mühendisliği Anabilim Dalı, Makine ve İmalat Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2004-2006 yılları arasında Talu Tekstil’de Üretim Planlama Mühendisi olarak çalıştı.
- 2006 yılında Başak Traktör’de Üretim Planlama Mühendisi olarak çalıştı.
- 2006-2010 yılları arasında Federal Elektrik’te Endüstri Planlama Sorumlusu olarak çalıştı.
- 2010-2021 yılları arasında Bilecik Şeyh Edebali Üniversitesi’nde Öğrenci Bilgi Sistem Sorumlusu ve Yazılımcısı olarak Öğretim Görevlisi kadrosunda çalıştı.
- 2021 yılından beri Sakarya Uygulamalı Bilimler Üniversitesi Bilgi İşlem Daire Başkanlığı’nda Öğrenci Bilgi Sistemi Yazılımcısı olarak Öğretim Görevlisi kadrosunda çalışmaktadır.

TEZDEN TÜRETİLEN ESERLER:

- Kala A., Torkul O., Yıldız T. T. and Selvi I. H., (2024). Early Prediction of Student Performance in Face-to-Face Education Environments: A Hybrid Deep Learning Approach With XAI Techniques. *IEEE Access*, 12(1), 191635-191649. <https://doi.org/10.1109/ACCESS.2024.3516816>.
- Kala, A., Torkul, O., Yıldız, T., & Selvi, İ. H. (2025). Early prediction of students’ performance through deep learning: a systematic and bibliometric literature review. *Sakarya University Journal of Computer and Information Sciences*, 8(1), 152-170. <https://doi.org/10.35377/saucis...1635558>.

DİĞER ESERLER: