



**GERÇEK İŞLETME VERİLERİNE DAYALI MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE ANAEROBİK METAN ÜRETİMİNİN TAHMİNİ VE
SİMÜLASYON ANALİZİ**

YÜKSEK LİSANS TEZİ

Alican YAĞIN

Danışman

Prof. Dr. Yüksel OĞUZ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

Mayıs 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**GERÇEK İŞLETME VERİLERİNE DAYALI MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE ANAEROBİK METAN
ÜRETİMİNİN TAHMİNİ VE SİMÜLASYON ANALİZİ**

Alican YAĞIN

Danışman

Prof. Dr. Yüksel OĞUZ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Mayıs 2025

TEZ ONAY SAYFASI

Alican YAĞIN tarafından hazırlanan “Gerçek İşletme Verilerine Dayalı Makine Öğrenmesi Yöntemleri İle Anaerobik Metan Üretiminin Tahmini ve Simülasyon Analizi” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 16 / 05 / 2025 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Anabilim Dalı Adı Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Yüksel OĞUZ

Başkan : Prof. Dr. Selim KÖROĞLU
Pamukkale Üniversitesi, Mühendislik Fakültesi **İmza**

Üye : Prof. Dr. Yüksel OĞUZ
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi **İmza**

Üye : Doç. Dr. Ögt. Üyesi Tolga ÖZER
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi **İmza**

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... / / tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı beyan ederim.

16 / 05 / 2025

İmza

Alican YAĞIN

ÖZET

Yüksek Lisans Tezi

GERÇEK İŞLETME VERİLERİNE DAYALI MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ANAEROBİK METAN ÜRETİMİNİN TAHMİNİ VE SİMÜLASYON ANALİZİ

Alican YAĞIN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Yüksel OĞUZ

Gerçek bir biyogaz işletmesinden elde edilen operasyonel verilere dayalı olarak, anaerobik metan üretiminin tahmini amacıyla veri odaklı modelleme yöntemleri geliştirilmiştir. Çalışma, ardışık yapıda kurgulanmış bir tahmin zinciri yaklaşımına dayanmaktadır. Bu zincirin ilk halkasında, atık miktarı ve giriş bileşenleri temel alınarak reaktör içi Kuru Madde (KM), Organik Kuru Madde (OKM), Uçucu Yağ Asitleri (FOS) ve Toplam Alkali Kapasite (TAC) tahmin edilmiştir. İkinci halkada ise bu parametreler ve atık miktarı birlikte değerlendirilerek nihai metan üretimi öngörülmüştür. Bu yapı kapsamında, Makine Öğrenmesi (Machine Learning-ML) algoritmaları Karar Ağaçları (Decision Tree-DT), Rastgele Ormanlar (Random Forest-RF), Destek Vektör Regresyonu (Support Vector Machine-SVM), Gradyan Artırmalı Makineler (Gradient Boosting Machine-GBM), K-En Yakın Komşu (K-Nearest Neighbors-KNN), Yapay Sinir Ağı (Artificial Neural Network-YSA) modelleri Levenberg-Marquardt Öğrenme Algoritması (Levenberg-Marquardt-trainLM), Bayesyen Regülasyonlu Öğrenme (Bayesian Regularization-TrainBR), Ölçeklenmiş Eşlenik Gradyan Algoritması (Scaled Conjugate Gradient- TrainSCG) ile çeşitli tahmin modelleri oluşturulmuştur. Her bir algoritma için ayrı hiperparametre optimizasyonları uygulanmıştır. Elde edilen bulgular, ML tabanlı modellerin genel olarak YSA modellerine kıyasla daha yüksek doğruluk ve genelleme başarısı sağladığını ortaya koymuştur. Özellikle Gradyan Artırmalı Makineler (GBM) ve Destek Vektör Regresyonu (SVR) gibi algoritmalar, sistemin karmaşık yapısına yüksek duyarlılıkla adapte olarak en başarılı tahmin performanslarına ulaşmıştır.

Geliştirilen veri odaklı modeller, MATLAB/Simulink ortamında tasarlanan kinetik denklemlere dayalı klasik modeller ile karşılaştırılmış, sabit parametrelili yapıların dinamik sistem davranışlarını yeterince temsil edemediği gösterilmiştir. Ayrıca, her aya ait minimum ve maksimum atık değerlerinden oluşturulan test setleriyle yapılan değerlendirmeler, geliştirilen modellerin gerçek saha koşullarındaki güvenilirliğini ortaya koymuştur. Bu yönüyle çalışma, biyogaz üretim süreçlerinde makine öğrenmesi temelli tahmin zincirlerinin pratik uygulanabilirliğini ve yüksek doğruluk potansiyelini göstererek literatüre özgün ve bütüncül bir katkı sunmaktadır.

2025, xxiii + 174 sayfa

Anahtar Kelimeler: Biyogaz, Yapay zekâ, Simulink, Enerji, Yapay Sinir Ağları, Makine Öğrenmesi, Hiperparametre Optimizasyonu

ABSTRACT

M.Sc. Thesis

PREDICTION AND SIMULATION ANALYSIS OF ANAEROBIC METHANE PRODUCTION USING MACHINE LEARNING METHODS BASED ON REAL OPERATIONAL

Alican YAĞIN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Electric-Electronic Engineering

Supervisor: Prof. Yüksel OĞUZ

In this study, data-driven modeling techniques have been developed to estimate anaerobic methane production using real operational data obtained from a functioning biogas plant. The methodological framework is constructed around a sequential prediction chain. In the initial stage of this chain, the reactor's internal characteristics—namely Total Solids (TS), Volatile Solids (VS), Volatile Fatty Acids (VFA), and Total Alkalinity Capacity (TAC)—are estimated based on the input waste quantity and composition. Subsequently, these predicted parameters, in conjunction with waste load, are employed to forecast methane yield. The predictive models are built using a range of Machine Learning (ML) algorithms including Decision Trees (DT), Random Forests (RF), Support Vector Machines (SVM), Gradient Boosting Machines (GBM), and K-Nearest Neighbors (KNN), as well as Artificial Neural Networks (ANN) trained with Levenberg–Marquardt (trainLM), Bayesian Regularization (trainBR), and Scaled Conjugate Gradient (trainSCG) algorithms. Tailored hyperparameter optimization procedures were applied to each model individually. The outcomes indicate that ML-based models generally outperform ANN approaches in terms of accuracy and generalization capacity. Among these, GBM and SVM-based regressors demonstrated superior predictive performance by effectively capturing the nonlinear and complex behavior of the anaerobic digestion system. Additionally, these data-oriented models were benchmarked against classical

kinetic models constructed in the MATLAB/Simulink environment. The comparative analysis revealed that fixed-parameter kinetic equations fall short in adequately representing the dynamic behavior of real-world biogas systems. Moreover, evaluation using test sets composed of the monthly minimum and maximum waste inputs confirmed the robustness of the developed models under operational conditions. Accordingly, this work offers an original and comprehensive contribution to the literature by demonstrating the practical applicability and high accuracy potential of machine learning–driven prediction chains in biogas production systems.

2025, xxiii + 174 pages

Keywords: Biogas, Artificial Intelligence, Simulink, Energy, Artificial Neural Networks, Machine Learning, Hyperparameter Optimization

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Prof. Dr. Yüksel OĞUZ araştırma ve yazım süresince yardımlarını esirgemeyen her konuda öneri ve eleştirileriyle yardımlarını gördüğüm Sayın Prof. Dr. Selim KÖROĞLU hocama, arkadaşlarıma ve Çobanlar biyogaz santrali işletme müdürü Sayın Hilmi AKBAY'a teşekkür ederim.

Bu araştırma boyunca manevi desteklerinden dolayı kıymetli eşim Fatma Nuran YAĞIN ve kızım Bilge YAĞIN a teşekkür ederim.

Alican YAĞIN

Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

	Sayfa
Alican YAĞIN.....	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER DİZİNİ.....	viii
SİMGELER ve KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiv
ÇİZELGELER DİZİNİ.....	xxi
RESİMLER DİZİNİ	xxii
1.GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	4
2.1 Biyogaz Tanımı	4
2.1.1 Biyogaz Üretim Süreci.....	5
2.1.1.1 Hidroliz Aşaması.....	6
2.1.1.2 Asidogenez Aşaması	7
2.1.1.3 Asetojenez Aşaması	7
2.1.1.4 Metanojenes Aşaması.....	7
2.2 Biyogaz Üretimini Etkileyen Faktörler.....	8
2.2.1 Sıcaklık.....	8
2.2.2 pH.....	9
2.2.3 Karbon-Azot Oranı (C/N)	9
2.2.4 Organik Yükleme Oranı	9
2.2.5 Uçucu Yağ Asitleri (VFA)	10
2.3 Yapay Sinir Ağları Yapısı.....	10
2.3.1 Yapay Sinir Ağları Eğitim Modelleri.....	12
2.3.2 Aktivasyon Fonksiyonları	14
2.3.3 Çok Katmanlı Yapay Sinir Ağları.....	17
2.3.4 Hata Hesaplama	19
2.3.5 Hiperparametre Optimizasyonu	20
2.4 Makine Öğrenmesi.....	21
2.4.1 Gözetimli Öğrenme Algoritmaları	22
2.4.2 Makine Öğrenmesinde Kullanılan Algoritmalar.....	23

2.4.2.1 Karar Ağaçları Algoritması	23
2.4.2.2 Rastgele Ormanlar Algoritması	24
2.4.2.3 Destek Vektör Regresyonu Algoritması	24
2.4.2.4 Gradyan Artırmalı Ağaçlar Algoritması	25
2.4.2.5 K-En Yakın Komşu Algoritması	25
2.4.3 Hata Hesaplama	26
2.4.4 Hiperparametre Optimizasyonu	27
2.5 Elektrik Üretim Tahmini	29
2.6 Biyogaz Santrali Tasarımları Yapılan Çalışmalar	30
2.7 Biyogaz Yapay Zekâ Çalışmaları	34
2.8 Elektrik Üretim Tasarımı Yapılan Çalışmalar	42
3. MATERYAL ve METOT	44
3.1 Biyogaz Santrali Biyogaz Üretim Süreci Simulink Modeli	45
3.1.1 Hidroliz Modeli	46
3.1.2 Asidojenez Modeli	48
3.1.3 Asedogenez Modeli	49
3.1.4 Metanojenez Modeli	51
3.1.5 MT ve PMSG Modeli	52
3.2 Kullanılan Veri Seti ve Ön İşleme	60
3.3 Anaerobik Metan Üretim Tahmini	61
3.3.1 Yapay Sinir Ağı Algoritmaları	61
3.3.1.1 Algoritma Yapısı ve En Başarılı Parametre Seçimi	62
3.3.1.1.1 KM Tahmin Algoritması	63
3.3.1.1.2 OKM Tahmin Algoritması	64
3.3.1.1.3 FOS Tahmin Algoritması	65
3.3.1.1.4 TAC Tahmin Algoritması	66
3.3.1.1.5 Metan Tahmin Algoritması	67
3.3.1.2 Hiperparametre Optimizasyonu ve Eğitim Süreci	68
3.3.2 Makine Öğrenmesi Algoritmaları	69
3.3.2.1 Algoritma Yapısı ve En Başarılı Parametre Seçimi	70
3.3.2.1.1 KM Tahmin Algoritması	71
3.3.2.1.2 OKM Tahmin Algoritması	72
3.3.2.1.3 FOS Tahmin Algoritması	73
3.3.2.1.4 TAC Tahmin Algoritması	73

3.3.2.1.5 Metan Tahmin Algoritması	74
3.3.2.1.6 Hiperparametre Optimizasyonu ve Eğitim Süreci.....	75
3.4. Elektrik Tahmini.....	77
4. BULGULAR	78
4.1 Makine Öğrenmesi Algoritmaları Performansı	78
4.1.1 KM Tahmini ve Performans Sonuçları	78
4.1.2 OKM Tahmini ve Performans Sonuçları	88
4.1.3 FOS Tahmini ve Performans Sonuçları	99
4.1.4 TAC Tahmini ve Performans Sonuçları	110
4.1.5 Metan Tahmini ve Performans Sonuçları	120
4.1.6 Hiperparametre Optimizasyonu Eğitim Sonuçları.....	130
4.2 Yapay Sinir Ağları Algoritmaları Performansları	132
4.2.1 KM Tahmini ve Performans Sonuçları	133
4.2.2 OKM Tahmini ve Performans Sonuçları	137
4.2.3 FOS Tahmini ve Performans Sonuçları	142
4.2.4 TAC Tahmini ve Performans Sonuçları	146
4.2.5 Metan Tahmini ve Performans Sonuçları	150
4.2.6 Hiperparametre Optimizasyonu Eğitim Sonuçları.....	153
4.3 Simulink Modeli Frekans ve Açısız Hız Grafik Çıktıları.....	153
5. TARTIŞMA ve SONUÇ	156
6. KAYNAKLAR.....	164

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

C	Karbon
CH ₄	Metan
CO ₂	Karbondioksit
F _{feed}	Besleme debisi
H ₂	Hidrojen
K _s	Doygunluk sabiti
K ₁	Kapasite katsayısı
K ₂	Reaksiyon kinetiği katsayısı
K ₃	Metan gazının büyüme hızıyla ilişkili verim faktörü
N	Azot
R	Korelasyon Katsayısı
R ²	Determinasyon Katsayısı
S _b	Substrat konsantrasyonu
S _v	Uçucu katı madde konsantrasyonu
S _{vin}	Giriş substrat konsantrasyonu
X _{meth}	Metanojen bakterilerin konsantrasyonu
b	Biyogaz reaktöründeki biyolojik atıkların yoğunluğu
gün ⁻¹	Günlük hız birimi
Kg/m ³	Yoğunluk
m ³	Hacim birimi
μ _m	Metanojenlerin büyüme hızı
μ _{mc}	Metanojenlerin maksimum büyüme hızı
%	Yüzde

Kısaltmalar

AC	Alternatif Akım
AC-DC	Alternatif Akım- Doğru Akım Dönüşümü
ACO	Karınca Koloni Optimizasyonu
AD	Anaerobik Sindirim

ADM1	Anaerobik Sindirim Modeli No.
ANFIS	Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
AcoD	Anaerobik Ko-digestion (Anaerobik Ortak Çürütme)
BEAD	Bağlam gerekebilir
BMP	Biyokimyasal Metan Potansiyeli
C/N	Karbon/Azot Oranı
DC	Doğru Akım
DPC	Doğrudan Güç Kontrolü
DT	Karar Ağaçları
FOS	Uçucu Organik Asitler
FS	Uçucu Katı Madde
FTIR	Fourier Dönüşümü Kızılötesi Spektroskopisi
GA	Genetik Algoritma
GBM	Gradyan Artırmalı Modeller
GES	Güneş Enerji Sistemi
HRT	Hidrolik Retansiyon Süresi
HTG	Yüksek Sıcaklık Gazlaştırma
KM	Katı Madde
KNN	K-En Yakın Komşu
KOİ	Atık Su Kirlilik Seviyesi
KW	Kilowatt
LCA	Yaşam Döngüsü Analizi
Leaky-ReLU	Doğrusal Olmayan Aktivasyon Fonksiyonu
ML	Makine Öğrenmesi
MLR	Çoklu Doğrusal Regresyon
MAE	Normalize Hata
MSE	Ortalama Kare Hatası
MW	Megawatt
OKM	Organik Katı Madde
OLR	Organik Yükleme Hızı
PMSG	Daimî Mıknatıs Senkron Jeneratör
PSO	Parçacık Sürü Optimizasyonu

R	Korelasyon Katsayısı
RBF	Radyal Tabanlı Fonksiyon
RF	Rastgele Ormanlar
RRC	Bağlam gerekebilir
RMSE	Kök Ortalama Kare Hata
RSM	Yanıt Yüzeyi Metodu
ReLU	Doğrusal Olmayan Aktivasyon Fonksiyonu
SVM	Destek Vektör Makineleri
T	Sıcaklık
TAC	Toplam Alkalinte kapasitesi
TRAINBR	Bayesian Regresyon Eğitimi
TRAINLM	Levenberg-Marquardt Eğitim Algoritması
TRAINSCG	Skalalı Konjuge Gradyan Eğitim Algoritması
TS	Toplam Katı Madde
VFA	Uçucu Yağ Asitleri
VS	Uçucu Katı Madde
YSA	Yapay Sinir Ağları
PURELIN	Doğrusal Aktivasyon Fonksiyonu
TANSIG	Tangens Sinyal Aktivasyon Fonksiyonu

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 Biyogaz sistemi üretim ve uygulama şeması.....	2
Şekil 2.1 Biyogaz Üretim Süreci Aşamaları	6
Şekil 2.3 Aktivasyon Fonksiyonları.....	15
Şekil 2.4 Çok Katmanlı Yapay Sinir Ağı Yapısı	18
Şekil 3.1 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan hidroliz MATLAB/Simulink modeli.....	48
Şekil 3.2 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan asidojenez MATLAB/Simulink modeli	49
Şekil 3.3 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan asetogenez MATLAB/Simulink modeli.	51
Şekil 3.4 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan metanojenez MATLAB/Simulink modeli.....	52
Şekil 3.5 MT hız kontrolü blok diyagram.....	53
Şekil 3.6 MT sıcaklık kontrolü blok diyagram	54
Şekil 3.7 MT yakıt kontrolü blok diyagram.....	54
Şekil 3.8 MT kontrol fonksiyonuna ait blok diyagramı.....	55
Şekil 3.9 MT bütüncül yapısı MATLAB/Simulink Modeli.....	56
Şekil 3.10 Dq0-abc dönüşümü MATLAB/Simulink modeli	58
Şekil 3.11 MT'ye entegre edilen daimi mıknatıslı senkron jeneratörün elektriksel model temsili.....	59
Şekil 3.12 Biyogaz yakıtlı güç sistemi tümleşik MATLAB/Simulink modeli	59
Şekil 3.13 YSA Modeli Akış Diyagramı	61
Şekil 3.14 KM Parametresi YSA Modelleme Süreci Akış Diyagramı	63
Şekil 3.15 OKM Parametresi YSA Modelleme Süreci Akış Diyagramı	65
Şekil 3.16 FOS Parametresi YSA Modelleme Süreci Akış Diyagramı	66
Şekil 3.17 FOS Parametresi YSA Modelleme Süreci Akış Diyagramı	67
Şekil 3.18 Metan YSA Modelleme Süreci Akış Diyagramı	68
Şekil 3.19 Hiperparametre Optimizasyonu ve Eğitim Süreci Akış Diyagramı	69
Şekil 3.20 Makine Öğrenmesi Kullanılan Modeller	70
Şekil 3.21 Makine Öğrenmesi Modeli Akış Diyagramı	71

Şekil 3.22 KM Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı ..	71
Şekil 3.23 OKM Parametresi Makine Öğrenmesi Modellemesi Süreci Akış Diyagramı	72
Şekil 3.24 FOS Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı .	73
Şekil 3.25 TAC Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı.	74
Şekil 3.26 TAC Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı.	75
Şekil 4.1 Karar Ağacı (DT) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi	79
Şekil 4.2 Karar Ağacı (DT) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi	79
Şekil 4.3 Karar Ağacı (DT) algoritması ile KM tahmini test verisi regresyon grafiği .	80
Şekil 4.4 Random Forest (RF) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi	80
Şekil 4.5 Random Forest (RF) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi	81
Şekil 4.6 Random Forest (RF) algoritması ile KM tahmini için test verisi regresyon grafiği	82
Şekil 4.7 Destek Vektör Makineleri (SVM) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi	82
Şekil 4.8 Destek Vektör Makineleri (SVM) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi	83
Şekil 4.9 Destek Vektör Makineleri (SVM) algoritması KM tahmini için test verisi ile regresyon grafiği	84
Şekil 4.10 Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi	84
Şekil 4.11 Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi	85
Şekil 4.12 Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmini için test verisi regresyon grafiği	86
Şekil 4.13 K-Nearest Neighbors (KNN) algoritması ile KM tahmini için eğitim ve test verilerine ait R^2 değişimi	86

Şekil 4.14 K-Nearest Neighbors (KNN) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi grafiği	87
Şekil 4.15 K-Nearest Neighbors (KNN) algoritması ile KM tahmini için test verisi regresyon grafiği	88
Şekil 4.16 Decision Tree (DT) algoritması ile OKM tahmini eğitim ve test verilerine ait R^2 değişimi grafiği	89
Şekil 4.17 Decision Tree (DT) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi	90
Şekil 4.18 Decision Tree (DT) algoritması ile OKM tahmini için test verisi regresyon grafiği	91
Şekil 4.19 Random Forest (RF) algoritması ile OKM tahmini eğitim ve test verilerine ait R^2 değişimi	92
Şekil 4.20 Random Forest (RF) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi	92
Şekil 4.21 Random Forest (RF) algoritması ile OKM tahmini için test verisi regresyon. grafiği	93
Şekil 4.22 Support Vector Machine (SVM) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi	94
Şekil 4.23 Support Vector Machine (SVM) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi grafiği	94
Şekil 4.24 Support Vector Machine (SVM) algoritması ile OKM tahmini için test verisi regresyon grafiği	95
Şekil 4.25 Gradient Boosting Machine (GBM) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi	96
Şekil 4.26 Gradient Boosting Machine (GBM) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi	96
Şekil 4.27 Gradient Boosting Machine (GBM) algoritması ile OKM tahmini eğitim ve test verisi regresyon grafiği	96
Şekil 4.28 K-Nearest Neighbors (KNN) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi	98
Şekil 4.29 K-Nearest Neighbors (KNN) algoritması ile OKM tahmini için eğitim ve test verilerine ait MSE değişimi	98

Şekil 4.30 K-Nearest Neighbors (KNN) algoritması ile OKM tahmini için test verisinin regresyon grafiği	99
Şekil 4.31 Decision Tree (DT) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği	100
Şekil 4.32 Decision Tree (DT) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişim grafiği	101
Şekil 4.33 Decision Tree (DT) algoritması ile FOS tahmini için test verisinin regresyon grafiği	102
Şekil 4.34 Random Forest (RF) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.	102
Şekil 4.35 Random Forest (RF) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişim grafiği.	103
Şekil 4.36 Random Forest (RF) algoritması ile FOS tahmini için test verisi regresyon grafiği.	104
Şekil 4.37 Support Vector Machine (SVM) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği	104
Şekil 4.38 Support Vector Machine (SVM) algoritması ile FOS tahmini eğitim ve test . verilerine ait MSE değişim grafiği.....	105
Şekil 4.39 Support Vector Machine (SVM) algoritması ile FOS tahmini için test verisi regresyon grafiği	106
Şekil 4.40 Gradient Boosting Machines (GBM) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	106
Şekil 4.41 Gradient Boosting Machines (GBM) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişimi grafiği.....	107
Şekil 4.42 Gradient Boosting Machines (GBM) algoritması ile FOS tahmini için test verisi regresyon grafiği.....	108
Şekil 4.43 K-Nearest Neighbors (KNN) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği	108
Şekil 4.44 K-Nearest Neighbors (KNN) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişim grafiği.....	109
Şekil 4.45 K-Nearest Neighbors (KNN) algoritması ile FOS tahmini için test verisine ait regresyon grafiği	110

Şekil 4.46 Decision Tree (DT) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği	110
Şekil 4.47 Decision Tree (DT) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği.....	111
Şekil 4.48 Decision Tree (DT) algoritması ile TAC tahmini için test verilerine ait regresyon grafiği.....	111
Şekil 4.49 Random Forest (RF) algoritması TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	114
Şekil 4.50 Random Forest (RF) algoritması TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği	114
Şekil 4.51 Random Forest (RF) algoritması ile TAC tahmini için test verilerine ait regresyon grafiği.....	114
Şekil 4.52 Support Vector Machine (SVM) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	115
Şekil 4.53 Support Vector Machine (SVM) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği	115
Şekil 4.54 Support Vector Machine (SVM) algoritması ile TAC tahmininin için test verisine ait regresyon grafiği.....	116
Şekil 4.55 Gradient Boosting Machine (GBM) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	117
Şekil 4.56 Gradient Boosting Machine (GBM) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği.....	117
Şekil 4.57 Gradient Boosting Machine (GBM) algoritması ile TAC tahmini için test verisine ait regresyon grafiği.....	118
Şekil 4.58 K-Nearest Neighbors (KNN) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği	119
Şekil 4.59 K-Nearest Neighbors (KNN) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği.....	119
Şekil 4.60 K-Nearest Neighbors (KNN) algoritması ile TAC tahmini için test verisine ait regresyon grafiği	120
Şekil 4.61 Karar Ağacı (DT) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.	121

Şekil 4.62 Karar ağaçları (DT) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.	121
Şekil 4.63 Karar ağaçları (DT) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.	122
Şekil 4.64 Rastgele Orman (RF) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.	123
Şekil 4.65 Rastgele Orman (RF) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.	123
Şekil 4.66 Rastgele Orman (RF) algoritması ile METAN tahmini için test verilerine ait regresyon grafiği.	123
Şekil 4.67 Destek Vektör Makineleri (SVM) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	125
Şekil 4.68 Destek Vektör Makineleri (SVM) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.	125
Şekil 4.69 Destek Vektör Makineleri (SVM) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.....	126
Şekil 4.70 Gradyan Artırma Makineleri (GBM) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	127
Şekil 4.71 Gradyan Artırma Makineleri (GBM) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.	127
Şekil 4.72 Gradyan Artırma Makineleri (GBM) algoritması ile METAN tahmini için test verisine ait regresyonu grafiği.	128
Şekil 4.73 En Yakın Komşular (KNN) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.....	129
Şekil 4.74 En Yakın Komşular (KNN) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.	129
Şekil 4.75 En Yakın Komşular (KNN) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.	130
Şekil 4.76 KM trainlm performans grafiği	134
Şekil 4.77 KM trainbr performans grafiği	135
Şekil 4.78 KM trainscg performans grafiği	135
Şekil 4.79 KM trainlm regresyon grafiği.....	136

Şekil 4.80 KM trainbr regresyon grafiği.....	136
Şekil 4.81 KM trainscg regresyon grafiği.....	137
Şekil 4.82 OKM trainlm performans grafiği.....	139
Şekil 4.83 OKM trainbr performans grafiği	139
Şekil 4.84 OKM trainscg performans grafiği	140
Şekil 4.85 OKM trainlm regresyon grafiği	140
Şekil 4.86 OKM trainbr regresyon grafiği.....	141
Şekil 4.87 OKM trainscg regresyon grafiği.....	141
Şekil 4.88 FOS trainlm performans grafiği.....	143
Şekil 4.89 FOS trainbr performans grafiği	143
Şekil 4.90 FOS trainscg performans grafiği	144
Şekil 4.91 FOS trainlm regresyon grafiği	144
Şekil 4.92 FOS trainbr regresyon grafiği.....	145
Şekil 4.93 FOS trainscg regresyon grafiği.....	145
Şekil 4.94 TAC trainlm performans grafiği.....	147
Şekil 4.95 TAC trainbr performans grafiği.....	147
Şekil 4.96 TAC trainscg performans grafiği.....	148
Şekil 4.97 TAC trainlm regresyon grafiği	148
Şekil 4.98 TAC trainbr regresyon grafiği	149
Şekil 4.99 TAC trainscg regresyon grafiği	149
Şekil 4.100 Metan tahmin trainlm performans grafiği.....	151
Şekil 4.101 Metan tahmin trainbr performans grafiği	151
Şekil 4.102 Metan tahmin trainscg performans grafiği.....	152
Şekil 4.103 Metan tahmin trainlm regresyon grafiği	152
Şekil 4.104 Simulink Modelinde Sistem Frekansının Zaman Değişim Grafiği	154
Şekil 4.105 Simulink Modelinde Açısız Hız Zaman Değişim Grafiği	154
Şekil 5.1 KM Parametresi Karşılaştırma Grafiği.....	156
Şekil 5.2 OKM Parametresi Karşılaştırma Grafiği	157
Şekil 5.3 FOS Parametresi Karşılaştırma Grafiği	158
Şekil 5.4 TAC Parametresi Karşılaştırma Grafiği	159
Şekil 5.5 Metan Parametresi Karşılaştırma Grafiği	160

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1 Biyogaz temel bileşenleri ve konsantrasyonları.....	5
Çizelge 2.2 Eğitim Algoritmaları Temel Farkları	13
Çizelge 3.1 Makine Öğrenmesi Algoritmalarında Optimize Edilen Hiperparametreler	77
Çizelge 4.1 RF algoritması hiperparametre sonuçları	130
Çizelge 4.2 DT algoritması hiperparametre sonuçları.....	131
Çizelge 4.3 SVM algoritması hiperparametre sonuçları	131
Çizelge 4.4 GBM algoritması hiperparametre sonuçları.....	131
Çizelge 4.5 KNN algoritması hiperparametre sonuçları	131
Çizelge 4.6 Eğitim algoritmaları performans sonuçları	132
Çizelge 4.7 Eğitim algoritmaları performans sonuçları	133
Çizelge 4.8 KM eğitim performans sonuçları	133
Çizelge 4.9 OKM eğitim performans sonuçları	138
Çizelge 4.10 FOS eğitim performans sonuçları	142
Çizelge 4.11 TAC eğitim performans sonuçları.....	146
Çizelge 4.12 Metan tahmin eğitim performans sonuçları	150
Çizelge 4.13 Bir tahmin modeli için belirlenen giriş ve çıkış parametreleri, kullanılan eğitim algoritmaları ve optimize edilen hiperparametrelerin kapsamlı bir özeti.....	153
Çizelge 5.1 En başarılı makine öğrenmesi algoritmalarının R^2 karşılaştırması.....	160
Çizelge 5.2 En başarılı yapay sinir ağları algoritmalarının R karşılaştırması	161
Çizelge 5.3 24 Günlük gerçek tesis verileri ML-YSA-Simulink Karşılaştırma Sonuçları	162

RESİMLER DİZİNİ

Sayfa

Resim 1.1 Biyogaz santrali üstten bakış	4
--	---



1.GİRİŞ


Dünya genelinde nüfusun her yıl artış göstermesi, sanayileşmenin hız kazanarak farklı alanlara yayılması ve bireylerin ihtiyaçlarıyla yaşam kalitelerinin yükselmesi, enerjiye olan talebin sürekli artmasına neden olmaktadır. Fosil yakıt rezervlerinin yakın gelecekte tükenme tehlikesi, çevreye yönelik duyarlılığın artması ve elektrik enerjisinin geniş çapta depolanamaması gibi etkenler, elektrik üretiminin anlık ihtiyacı karşılayacak düzeyde ve yüksek verimlilikle gerçekleştirilmesini zorunlu kılmaktadır (Çolak vd. 2008).

Dünya genelinde hızla yükselen enerji gereksinimi, bu ihtiyacı karşılayan kaynakların çevresel etkileriyle birlikte ele alındığında, yenilenebilir enerji türlerinin ne denli stratejik bir öneme sahip olduğu ortaya çıkmaktadır. Günümüzde yaygın olarak tercih edilen petrol, doğalgaz ve kömür gibi fosil yakıtlar ise tükenbilir nitelikte olmalarının yanı sıra, çevreye verdikleri zarar nedeniyle olumsuz bir profil çizmektedir (Balcı 2023).

Bu çerçevede biyogaz, yenilenebilir enerji kaynakları arasında yalnızca sürdürülebilir enerji üretimi potansiyeliyle değil, aynı zamanda atık yönetimine sunduğu çözüm odaklı katkılarla da ön plana çıkmaktadır. Organik kökenli atıkların anaerobik fermantasyon süreciyle metan gazına dönüşmesi sonucu elde edilen biyogaz, hem enerji üretiminde alternatif bir yaklaşım sunmakta hem de bütünsel atık yönetimi uygulamalarını desteklemektedir. Bu yönüyle biyogazın, çevresel etkilerin azaltılmasına yönelik stratejik bir enerji kaynağı olduğu açıkça ortaya konulmaktadır (Tümür 2025).

Afyonkarahisar ili, tarım ve hayvancılık faaliyetlerinin yoğun olarak sürdürüldüğü bir bölgede yer alması dolayısıyla biyogaz üretimi açısından önemli bir potansiyele sahiptir (Tarım ve Orman Bakanlığı Tarım Reformu Genel Müdürlüğü, 2024). Özellikle yüksek miktarda oluşan hayvansal atıkların değerlendirilmesi hem çevresel problemlerin azaltılmasına hem de enerjiye dönüştürme süreçlerine katkı sunmaktadır (Ertop vd. 2022). Bu doğrultuda, Çobanlar Biyogaz Santrali, bölgeye özgü çözümler ve yenilikçi uygulamalar bakımından örnek teşkil etmektedir (İnt.Kyn.7). Santral, hayvansal ve tarımsal kökenli atıklardan elde edilen metan gazını elektrik ve ısı enerjisine çevirerek bölge ekonomisine çeşitli açılardan katkı sağlamaktadır. Bu kapsamda biyogaz üretim tesislerinin kalkınma hedefleri ile örtüştüğü değerlendirilmektedir.

Biyogaz üretiminde, organik atıkların dönüşüm sürecinde gerçekleşen enerji üretim mekanizmaları; çeşitli parametrelerin etkisiyle farklılık arz etmektedir. Özellikle kullanılan hammaddenin cinsi, bu hammaddenin biyolojik ve kimyasal özellikleri, sıcaklık kontrolü, pH düzeyleri ve fermantasyon süresine bağlı olarak üretim verimliliğinde değişiklikler gözlemlenmektedir. Hammaddelerin bozunabilirlik düzeyi ile mikroorganizmaların aktivite seviyesi, biyogazın hem miktarını hem de kalitesini doğrudan etkilemektedir. Özellikle fermantasyon esnasındaki mikrobiyal faaliyetler, elde edilen gazın kalitesini artırmada kritik bir işlev üstlenmektedir. Bu süreçte yer alan parametrelerin etkin bir şekilde optimize edilmesi, üretim performansı açısından büyük bir önem taşımaktadır (FNR 2010).



Şekil 1.1 Biyogaz sistemi üretim ve uygulama şeması (Neshat vd. 2017)

Günümüzde teknolojik ilerlemeler doğrultusunda, biyogaz üretim süreçlerinin daha yüksek verimlilikle yürütülebilmesi için gelişmiş teknik yöntemlerden yararlanılmaktadır. Özellikle yapay zekâ ve makine öğrenmesi temelli algoritmalar, biyogaz üretimi sırasında ortaya çıkan karmaşık dinamiklerin daha doğru analiz edilmesini ve bu süreçlere ilişkin tahmin modellerinin oluşturulmasını mümkün kılmaktadır. Bu tür teknolojiler, üretimde rol oynayan çok sayıda değişkenin eşzamanlı olarak değerlendirilmesine olanak tanıyarak, sürecin daha etkin bir biçimde optimize edilmesini sağlamaktadır (Çelik 2022). Yapay zekâ destekli modelleme yaklaşımlarının, özellikle enerji verimliliğinin artırılması ve emisyon seviyelerinin düşürülmesi açısından

kayda değer katkılar sunduğu belirtilmektedir (Guo vd. 2022). Bu bağlamda söz konusu teknolojilerin, biyogaz üretimini hem daha verimli kılmak hem de çevre dostu enerji dönüşümlerine zemin hazırlamak açısından stratejik bir araç olduğu değerlendirilmektedir (Eshkaftaki ve Ebrahimi 2022).

Çobanlar Biyogaz Santrali, bölgesel düzeyde organik kökenli atıkların enerjiye dönüştürülmesinde model niteliği taşımakta olup, tarımsal atıklardan evsel kaynaklı atıklara kadar uzanan geniş bir spektrumun etkin biçimde değerlendirilmesine imkân sunmaktadır. Tesis bünyesinde gerçekleştirilen faaliyetler, yalnızca enerji arzını desteklemekle kalmayıp aynı zamanda çevresel sürdürülebilirliğe de önemli katkılar sağlamaktadır. Enerji dönüşüm süreçlerine ilişkin parametreler ile reaktör performansını doğrudan etkileyen KM, OKM, FOS ve TAC gibi göstergelerin düzenli şekilde izlenmesi, tesisin işletme stratejileri açısından belirleyici bir unsur olarak öne çıkmaktadır. Özellikle biyogaz üretiminde kullanılan organik atıkların türü ile KM ve OKM oranları, reaktör içerisinde gerçekleşen mikrobiyal faaliyetlerin verimliliği üzerinde doğrudan etkili olmaktadır.

Bu çalışma kapsamında Çobanlar Biyogaz Santrali'ndeki organik atık ve reaktör içi parametrelerin toplanması, analiz edilmesi ve zaman içindeki değişimlerinin izlenmesi hedeflenmektedir. Bu verilerin yapay zekâ tabanlı tahmin modellerinin geliştirilmesine sağlam bir temel sunduğu düşünülmektedir. Böylelikle, santraldeki metan üretim miktarının geleceğe dönük olarak tahmin edilmesi ve süreç kontrolünün iyileştirilmesi hedeflenmektedir. Metan üretimindeki olası dalgalanmaların öngörülmesi sayesinde, santral verimliliğinin artırılması, işletme maliyetlerinin azaltılması ve sürdürülebilir bir enerji yönetimi yaklaşımının benimsenmesi mümkün olmaktadır. Dolayısıyla Çobanlar Biyogaz Santrali gerek sahip olduğu teknolojik altyapı gerekse süreç optimizasyonuna yönelik çalışmalarıyla, ülkemizdeki ve uluslararası alandaki biyogaz üretim faaliyetlerine akademik ve uygulamalı anlamda değerli katkılar sunmaktadır.

2. LİTERATÜR BİLGİLERİ

Bu bölümde, temel alınan biyogaz santrali tasarımı, yapay zekâ tabanlı tahmin yöntemleri ve elektrik üretim modelleri ele alınarak, literatürde yer alan geçmiş çalışmalardan ve ilgili diğer alanlardaki yaklaşımlardan ayrıntılı biçimde bahsedilmekte; bu doğrultuda kapsamlı bir değerlendirme yapılmaktadır.

2.1 Biyogaz Tanımı

Sanayileşmenin ve nüfusun hızlı biçimde artması, enerji tüketimini de aynı doğrultuda yükseltmektedir (Mombekova vd. 2024). Bu durum küresel ölçekte yeni enerji kaynakları üzerine yürütülen araştırmaları hızlandırmakta ve fosil yakıtlar yerine yenilenebilir alternatiflerin tercih edilmesini teşvik etmektedir (Lui vd. 2021). Güneş, rüzgâr ve biyogaz santralleri gibi temiz enerji yöntemlerine yönelik ilgi bu çerçevede gitgide yaygınlaşmaktadır (Breyer 2022). Özellikle biyogaz santralleri, enerji üretimine farklı ve yenilikçi bir bakış açısı sunmaktadır (Zhang vd. 2023). Organik atıkların anaerobik sindirimi sonucu, oksijensiz ortamda bakteriler yardımıyla çeşitli son ürünler oluşmakta ve açığa çıkan metan içeriği biyogaz olarak adlandırılmaktadır (Haugen ve Husain 2012). Bu yöntemin en önemli katkılarından biri, kendiliğinden bozulan biyoatıklardan kaynaklanan metan salınımını azaltarak iklim değişikliğiyle mücadeleye destek sağlamasıdır (Goodwin vd. 2021).



Resim 1.1 Biyogaz santrali üstten bakış


Biyogaz, dört aşamada gerçekleşmekte olan bir süreç olarak tanımlanmakta ve her aşamada ortaya çıkan son ürün, bir sonraki aşamanın temel girdisini oluşturmaktadır (Osman vd. 2021). Sürecin nihai aşamasında ise metan ve karbondioksit içeren bir gaz karışımı elde edilmektedir (Peker ve Çelik 2019). Biyogazın içeriğinde genel olarak %50 ile %70 arasında metan, %30 ile %50 arasında karbondioksit, %1'den daha az azot, %0,01 ile %0,2 arasında oksijen, 10 ile 5000 ppm arasında hidrojen sülfür ve 0 ile 500 ppm arasında amonyak bulunmakta olduğu ifade edilmektedir. Çizelge 2.1'de, biyogazın temel bileşenleri ve bu bileşenlerin konsantrasyonları detaylı biçimde sunulmaktadır (Jameel vd. 2024).

Çizelge 2.1 Biyogaz temel bileşenleri ve konsantrasyonları (Jameel vd. 2024).

Bileşen Adı	Hacimsel Oranı/Miktarı
Metan	% (50-70)
Karbondioksit	% (30-50)
Azot	% (0,1-1)
Oksijen	% (0,01-0,2)
Hidrojen Sülfür	10-5000 ppm
Amonyak	0-500 ppm

2.1.1 Biyogaz Üretim Süreci

Biyogaz üretim süreci, organik atıkların arıtılması amacıyla tasarlanmış ve sürdürülebilir nitelik taşıyan bir yaklaşım olarak öne çıkmaktadır (Gülen ve Çeşmeli 2012). Bu süreçte, öncelikle kullanılacak hammaddenin karakterizasyonunu belirlemek üzere laboratuvar analizleri gerçekleştirilmektedir. Söz konusu analizler arasında toplam katı (Total Solids-TS) ve uçucu katı (Volatile Solids-VS) oranlarının tespiti, pH değeri ve tamponlama kapasitesi ile karbon (C), azot (N) ve karbon/azot (C/N) oranlarının ölçümü yer almaktadır (Şenol ve Açikel, 2019). Birbirini takip eden biyokimyasal tepkimeler aracılığıyla organik maddenin daha basit bileşenlere parçalanmasını ve metan gazına dönüşmesini sağlamaktadır (Kerimak vd. 2023). Anaerobik fermantasyon ise hidroliz, asidogenez, asitojenez ve metanojenez aşamalarını içeren çok basamaklı bir süreç şeklinde tanımlanmaktadır (Akdeniz Acar 2019). Bu aşamalar, şekil 2.1'de görüldüğü gibi birbirini takip eden biyokimyasal tepkimeler aracılığıyla organik maddenin daha basit bileşenlere parçalanmasını ve sonunda metan gazına dönüşmesini sağlamaktadır.



Şekil 2.1 Biyogaz Üretim Süreci Aşamaları (İnt.Kyn.6)

2.1.1.1 Hidroliz Aşaması

Bu aşamada çözünmeyen karmaşık biyokütle, hidrolitik bakterilerin hücre dışı enzimlerinin etkisiyle çözünür bileşiklere dönüştürülmektedir (Rehman vd. 2019). Bu bakteriler, biyokütleyi daha basit bileşiklere parçalayan ilk mikroorganizma grubunu oluşturmaktadır. Karbonhidratlar, yağlar ve proteinler ise bu süreçte şekerlere, yağ asitlerine ve amonyak asitlerine dönüştürülmektedir (Zhang vd. 2019). Hidroliz aşamasının sonunda, karmaşık organik maddeler büyük oranda uçucu yağ asitlerine ($[\text{CH}_3(\text{CH}_2)_n\text{COOH}]$) ve diğer daha basit organik bileşiklere ayrılmaktadır. Bu nedenle


söz konusu aşama, “uçucu yağ asitleri oluşum aşaması” olarak da adlandırılmaktadır (Pathmasiri vd. 2013).

2.1.1.2 Asidogenez Aşaması

İkinci adım, hidrolizden elde edilen çözünür organik maddelerin, kısa zincirli yağ asitlerine ve alkollere dönüştürülmesi şeklinde gerçekleşmektedir (Rabii vd. 2019). Bu aşamada çoğu asit, asetik aside dönüştürülme sürecine tabi tutulmakta ve bunun sonucunda propiyonik, bütirik, valerik gibi farklı organik asitler de ortaya çıkmaktadır (Zhang vd. 2019). Söz konusu süreçte hidrojen, glikozun fermantasyonu ile üretilmekte olup bu işlemi gerçekleştiren mikroorganizma topluluğu “asit oluşturmalar” olarak adlandırılmaktadır (Mokhtarani vd. 2025). Bu topluluk, homoasetojenik bakteriler ve bazı fakültatif bakterilerden meydana gelmektedir. Ayrıca bu aşamada, asetik asitler ile su, karbondioksit ve hidrojene dönüştürülmektedir (Sukphun vd. 2021).

2.1.1.3 Asetojenez Aşaması

Bu aşamada asetik asidin hidrojenasyon yoluyla yaygın biçimde üretimini temsil etmektedir (Chaikitkaew vd. 2024). Bunun yanı sıra asetik asit, dehidrojenasyon süreci aracılığıyla da oluşabilmektedir (Lemaigre vd. 2023). Anaerobik fermantasyon sürecinde, asetik asitler çok sayıda yağ asidi arasında en bol üretilen organik asitler olarak dikkati çekmektedir (Wainaina vd. 2019). Asetojenez aşamasında gerçekleşen hidrojenasyon ve dehidrojenasyon tepkimelerini gösteren denklem (1) ve denklem (2)’ de sunulmaktadır (Husain, 1998):



2.1.1.4 Metanojenez Aşaması

Anaerobik sindirimin son aşaması, organik asitlerin metan üreten mikroorganizmaların etkisiyle metana dönüştürülmesini içermektedir. Metanojenezis olarak adlandırılan bu

süreç, iki temel aşamadan oluşmaktadır. Birinci aşamada, asetik asidin metana dönüştürülmesi söz konusu olup, toplam reaksiyonların yaklaşık %70'ini oluşturmaktadır. İkinci aşamada ise süreç sırasında üretilen karbondioksit kullanılarak, hidrojenin metana dönüşümü gerçekleşmekte ve geri kalan %30'luk kısmı temsil etmektedir. Aşağıdaki denklem (3) asetik asitten kaynaklanan asetotrofik metan üretimini, denklem (4) ise H₂'den kaynaklanan hidrojotrofik metan üretimini göstermektedir (Husain, 1998):



2.2 Biyogaz Üretimini Etkileyen Faktörler

Biyogaz üretim sürecinde, metanojenik mikroorganizmaların biyokimyasal aktivitelerini etkileyen her parametre, üretim miktarını doğrudan veya dolaylı olarak belirlemektedir (Chen vd. 2008). Bu süreçte biyogaz üretimini etkileyen başlıca faktörler arasında hammadde biyogaz potansiyeli, aşı maddelerinin varlığı, substrat tipi, pH seviyesi, sıcaklık, organik yükleme oranı, hidrolik bekletme süresi, karbon-azot oranı (C/N), uçucu yağ asitleri ve inhibitör bileşiklerin konsantrasyonu yer almaktadır (Asfaw ve Benti 2022).

2.2.1 Sıcaklık

Metanojenik bakteriler gerek aşırı yüksek gerekse aşırı düşük sıcaklıklarda biyolojik aktivitelerini sürdürememekte ve bu durum biyogaz üretim miktarını ciddi ölçüde sınırlamaktadır (Sudiartha vd. 2023). Bu nedenle, biyogazın üretileceği reaktörün sıcaklık seviyesi hem biyogaz üretim hızını hem de toplam üretim miktarını doğrudan etkilemektedir. Ayrıca metanojenik bakteriler sıcaklık dalgalanmalarına karşı son derece hassas yapılar sergilemekte, bu nedenle reaktör içindeki sıcaklığın sabit tutulması kritik önem arz etmektedir (Khoshnevisan vd. 2020). Sıcaklık, yalnızca biyogaz üretimini değil aynı zamanda reaktörün bekleme süresi ve hacim tasarımı gibi operasyonel parametreleri de şekillendirmektedir (Saleh vd. 2019).

2.2.2 pH

Biyogaz üretiminde pH seviyesi, anaerobik sindirim süreçlerinin etkinliği açısından temel belirleyici parametrelerden biri olarak öne çıkmaktadır (Ward vd. 2008). Metan üreten mikroorganizmalar, nötr veya hafif alkalın pH seviyelerinde optimal biyolojik aktivite göstermekte olup, anaerobik sindirim sürecinde maksimum biyogaz üretimi genellikle 6.8 ile 7.2 arasındaki pH aralığında gerçekleşmektedir ve pH değerinin 6.7'nin altına düşmesi, metan üretici mikroorganizmalar için toksik bir ortam oluşturarak biyogaz üretimini durma noktasına getirebilmektedir (Chen vd. 2008). Bu tür durumlarda, reaktördeki asit oranını azaltmak amacıyla organik madde beslemesi durdurulmakta ve gerektiğinde kalsiyum hidroksit gibi kimyasal düzenleyiciler kullanılmaktadır (Gashaw, 2014).

2.2.3 Karbon-Azot Oranı (C/N)

C/N oranı, organik substratlardaki karbon ve azotun göreceli miktarlarını ifade etmekte ve anaerobik bakterilerin enerji üretimi ile biyokütle sentez süreçlerini doğrudan etkilemektedir (Dioha vd. 2013). Karbon, bakteriler için enerji kaynağı olarak kullanılmakta, azot ise hücresel büyüme ve üreme süreçlerinde kritik bir yapı taşı olarak görev almaktadır (Saha vd. 2025). Eğer C/N oranı gereğinden yüksek olursa, metanojenler protein ihtiyaçlarını karşılamak için azotu hızla tüketmekte, bu durum ise azotun organik maddeden kaybolmasına ve karbon kaynaklarının yetersiz kullanımına yol açmaktadır (Wang vd. 2014). Sonuç olarak, biyogaz üretim süreci ciddi şekilde aksamakta veya tamamen durabilmektedir (Neshat vd. 2017).

2.2.4 Organik Yükleme Oranı

Organik yükleme oranı, biyoreaktörlere günlük olarak iletilen organik maddenin miktarını ifade eden operasyonel bir parametre olarak tanımlanmaktadır (Chen vd. 2008). Bu oran, biyogaz üretim verimliliği üzerinde doğrudan etkili olmakta ve optimal düzeyde tutulmadığı durumlarda, reaktördeki pH seviyesinin düşmesi sonucu gaz üretim süreçlerinin aksamasına neden olabilmektedir (Neshat vd. 2017). Yüksek organik yükleme oranları, asidik fermantasyon ürünlerinin birikmesine yol açarak metanojenik bakterilerin aktivitesini baskılayabilmektedir.

2.2.5 Uçucu Yağ Asitleri (VFA)


Asetik asit, bütirik asit ve propiyonik asit, anaerobik sindirim sürecinin biyokimyasal metabolik yollarında oluşan ara ürünler olup, bu süreçte meydana gelen biyolojik reaksiyonların yönelimi ve etkinliğinin izlenmesinde kritik göstergeler arasında yer almaktadır (Patel vd. 2021). Bu organik asitler, metanojenik mikroorganizmalar tarafından kullanılan substratların biyolojik dönüşüm performansını niceliksel olarak değerlendirmeye olanak sağlamaktadır (Waina vd. 2019). Ancak söz konusu organik asitlerin süreç içerisinde aşırı birikimi, sistemin tamponlama kapasitesini aşarak pH seviyesinin 6'nın altına düşmesine neden olmakta, bu durum ise mikrobiyal konsorsiyum içerisindeki metanojenik mikroorganizmaların biyokimyasal aktivitelerinin inhibisyonuna veya metabolik yollarının sapmasına yol açmaktadır (Chen vd. 2008). Anaerobik sindirimin ürün profili bozulmakta ve hedeflenen metan üretimi yerine düşük katma değerli veya istenmeyen yan ürünlerin oluşumu gözlemlenmektedir. Bu durum biyoreaktör süreçlerinin istikrarını ve sürdürülebilirliğini ciddi ölçüde tehdit eden bir faktör olarak değerlendirilmektedir (Kizito vd. 2025).

2.3 Yapay Sinir Ağları Yapısı

Yapay sinir ağları (YSA), insan beynindeki biyolojik nöronların yapısına ve işlevine dayalı olarak geliştirilen bir modelleme yöntemidir (Schmidhuber vd. 2015). Biyolojik sinir sisteminde yer alan soma, yapay sinir ağlarındaki nöronlara; dendritler girdilere aksonlar çıktılara ve sinapslar ise ağırlıklara karşılık gelmektedir (Haykin, 2009). Bu ağlarda, nöronlar birbirleriyle sinyalleri bir nörondan diğerine ileten ağırlıklı bağlantılar aracılığıyla bağlanmaktadır (Goodfellow vd 2016). Biyolojik sinir hücreleri arasındaki iletişim, sinapslar üzerinden gerçekleşirken, yapay sinir ağlarında bu süreç, ağırlıklandırılmış matematiksel bağlantılarla modellenmektedir (Levitan ve Kaczmarek, 2015).

Yapay sinir ağlarında öğrenme süreci, bu bağlantı ağırlıklarının belirli bir algoritma ile güncellenmesi yoluyla gerçekleşmektedir. Girdi verileri katmanlar arasında işlenerek, ağın çıktısı ile hedef değer arasındaki fark azaltılmaya çalışılmaktadır ve sayede YSA'lar, doğrusal olmayan ve karmaşık ilişkiler içeren problemlerde yüksek tahmin performansı

gösterebilmektedir (Karapınar ve Şentürk 2016). Veri odaklı analizlerin esnek ve güçlü çözümler sunduğu gözlenmektedir. Şekil 2.2’de yapay sinir ağı hücresi görülmektedir.



Şekil 2.2 Yapay Sinir Ağı Hücresi (Int.Kyn.3)

Yapay sinir ağı, aldığı girdileri işleyerek belirli bir aktivasyon fonksiyonundan geçirip bir çıktı üretmektedir (Schmidhuber 2015). Bu yapı, biyolojik sistemlerdeki bilgi işleme sürecinin soyut bir yansımasıdır (Hassabis vd 2017). Nöron yapısının detaylı bir şekilde incelenmesi durumunda, girdilerin tutulduğu düğümler, bu girdilere atanmış ağırlıklar, tüm girdilerin ve ağırlıkların çarpım ve toplamını içeren bir toplama fonksiyonu, bu fonksiyonun çıktısını işleyerek sonucu belirleyen bir aktivasyon fonksiyonu ve nihai çıktı unsurları öne çıkmaktadır (LeCun vd. 2015). Yapay sinir ağlarının bu karmaşık ancak düzenli yapısı, birçok mühendislik ve bilimsel alanda öğrenme, sınıflandırma ve tahmin gibi görevler için güçlü bir araç olarak kullanılmasına olanak tanımaktadır (Vellido vd. 2012).

Yapay sinir ağları, biyolojik sistemlerden esinlenmekle birlikte, insan beyninden çok daha farklı bir çalışma mekanizmasına sahiptir (Zador, 2019). Örneğin yapay sinir ağları paralel işleme yetenekleriyle karmaşık veri setlerini analiz ederken, doğrusal olmayan ilişkileri öğrenebilme kabiliyeti sayesinde geleneksel yöntemlere göre üstünlük sağladığı gözlenmekte ve bu özellikleri büyük veri analitiği, görüntü işleme ve doğal dil işleme gibi alanlarda kullanımlarını giderek daha yaygın hale getirmektedir (Gülcü ve Kuş, 2019).

2.3.1 Yapay Sinir Ağları Eğitim Modelleri

Yapay sinir ağlarının eğitimi için kullanılan yöntemler, algoritmanın veriye uyum sağlama kapasitesini artırarak tahmin doğruluğunu yükseltmeyi hedeflemektedir. TRAINLM, TRAINSCG ve TRAINBR, bu bağlamda öne çıkan üç önemli eğitim algoritmasıdır.

TRAINLM algoritması, Levenberg-Marquardt optimizasyon tekniğine dayanmaktadır ve sinir ağı modellerinin ağırlık ve yanlılık değerlerini iyileştirmek için tasarlanmıştır (Thander ve Bhowmik, 2023). Bu algoritma, doğrusal olmayan modelleme problemleri için oldukça etkili bir yöntem olarak bilinmektedir. TRAINLM, hesaplama maliyetini düşük tutarken hızlı bir eğitim süreci sağlayarak özellikle karmaşık veri kümelerinde yüksek doğruluk sunmaktadır. Ayrıca, öğrenme sürecinde hata oranını en aza indirmek amacıyla ağı parametrelerini dinamik olarak optimize etmektedir (Bilski vd. 2023). TRAINLM algoritması, daha küçük veri kümelerinde etkili olmasının yanı sıra, genellikle kısa eğitim süreleri gerektiren uygulamalarda tercih edilmektedir. Bu özellikler, algoritmanın küçük veri setlerinde bile etkili tahminler yapabilmesini sağlamaktadır. Levenberg-Marquardt algoritmasının ikinci türev bilgisi gerektirmemesi, TRAINLM'in hem basit hem de güçlü bir optimizasyon aracı olarak öne çıkmasını sağlamaktadır. Eğitim sürecindeki bu verimlilik, özellikle mühendislik ve biyolojik sistemlerin modellenmesinde geniş bir kullanım alanı yaratmaktadır (Chen ve Wang 2020).

TRAINSCG algoritması, ölçeklendirilmiş birleşik gradyan yöntemine dayanmaktadır ve sinir ağı modellerinin ağırlık ile yanlılık değerlerini güncelleyerek öğrenme süreci optimize etmektedir (Youliau ve Cheng, 2011). Bu yöntem, büyük veri kümeleri üzerinde etkili çalışabilen ve hesaplama maliyetini düşüren ölçeklendirme tekniği sayesinde öne çıkmaktadır. TRAINSCG, eğitim sırasında doğrusal olmayan problemlerin çözümünde daha kararlı bir yaklaşım sunarak genelleştirme kapasitesini artırmaktadır. Özellikle karmaşık ve çok boyutlu veri yapılarıyla çalışırken güvenilir sonuçlar üretebilmesi, bu algoritmayı geniş çaplı uygulamalar için uygun hale getirmektedir (Hagan ve Menhaj 1994). Bununla birlikte, algoritmanın matematiksel istikrarı ve düşük bellek gereksinimi, büyük veri işleme projelerinde önemli bir avantaj sağlamaktadır. Ayrıca TRAINSCG,

veri setinin boyutundan bağımsız olarak istikrarlı sonuçlar üretebilmesi nedeniyle yaygın şekilde kullanılmaktadır. (Chen ve Wang 2020)

TRAINBR algoritması, LM optimizasyonunun düzenlenmiş bir versiyonu olarak geliştirilmiştir (Kayri 2016). Bu yöntem, sinir ağlarının genelleştirme kapasitesini artırmak için hata ve ağırlık varyasyonlarını azaltmaktadır (Foressee ve Hagan, 1997).

TRAINBR, aşırı uyum problemini önlemek amacıyla düzenleme tekniklerini entegre ederek güvenilir bir model oluşturulmasını sağlamaktadır. Algoritma, özellikle sınırlı veri kümesiyle çalışırken yüksek doğruluk sunmakta ve eğitim sürecinde genelleştirme başarısını artırmaktadır (Cruz vd. 2023). Bunun yanı sıra, TRAINBR algoritması, parametrelerin etkili bir şekilde optimize edilmesine olanak tanıyarak sinir ağı modellerinin performansını en üst düzeye çıkarmaktadır. TRAINBR, hata ve ağırlık varyasyonlarını aynı anda minimize ederek güvenilir sonuçlar sunmaktadır ve özellikle hassas tahmin gerektiren uygulamalarda sıkça tercih edilmektedir (Dhamodharavadhani vd. 2020). Bu bağlamda, algoritma hem eğitim hem de test aşamalarında genelleme başarısını artırarak aşırı uyum riskini azaltmaktadır. Bu yönüyle TRAINBR biyolojik sistemlerin karmaşık yapılarının modellenmesinde istikrarlı ve tutarlı sonuçlar elde edilmesini sağlamaktadır. Bu nedenle Trainbr yüksek doğruluk sunmaktadır. Modelin tahmin kabiliyetini bozabilecek sapmalar bu algoritma sayesinde büyük ölçüde önlenmektedir. Eğitim algoritmalarının temel farkları Çizelge 2.2 de gösterilmiştir (İnt. Kyn 5)

Çizelge 2.2 Eğitim Algoritmaları Temel Farkları

Özellik	TRAINLM	TRAINSCG	TRAINBR
Eğitim Hızı	Genellikle daha hızlıdır ve özellikle orta büyüklükteki ağlar için önerilir.	Daha yavaştır, ancak büyük ağlar ve veri setleri için daha uygun olabilir.	Orta hızdadır; küçük ve orta ölçekli veri setleri için uygundur.
Hafıza Kullanımı	Yüksek; büyük ağlar için hafıza sınırlamaları olabilir.	Daha düşük; hafıza kullanımı açısından daha verimlidir.	Orta düzeyde; hafıza kullanımı trainlm'den düşük, trainscg'den yüksektir.

Çizelge 2.2 (Devam): Eğitim Algoritmaları Temel Farkları


Özellik	TRAİNLNLM	TRAİNSCG	TRAİNBR
Algoritma Türü	İkinci dereceden optimizasyon yöntemi (Levenberg-Marquardt).	Ölçeklendirilmiş konjugegradyan yöntemi.	Levenberg-Marquardt optimizasyonu ile Bayesian düzenleme.
Uygulama Alanı	Küçük ve orta ölçekli veri setleri ve ağlar için idealdir.	Büyük veri setleri ve ağlar için daha uygundur.	Özellikle küçük veri setlerinde aşırı öğrenmeyi önlemek için kullanılır.
Genelleme Yeteneği	Aşırı öğrenme riski vardır; düzenleme gerektirebilir.	Aşırı öğrenme riski daha düşüktür, ancak performans veri setine bağlıdır.	İyi genelleme sağlar; düzenleme otomatik olarak yapılır.
Doğrulama Gereksinimi	Doğrulama veri seti kullanımı önerilir.	Doğrulama veri seti kullanımı önerilir.	Dahili düzenleme nedeniyle doğrulama veri seti gerektirmez.

2.3.2 Aktivasyon Fonksiyonları

Yapay sinir ağlarında gerçekleştirilen matris işlemleri, ağırlık ve ağırlık elemanlarının doğrusal bir yapıya sahip olmasını sağlamaktadır (İnik ve Ülker 2017). Ancak, bu doğrusal yapı, aktivasyon fonksiyonları aracılığıyla doğrusal olmayan bir yapıya dönüştürülmektedir. Aktivasyon fonksiyonlarının bu dönüşümü gerçekleştirmesi, ağırlık karmaşık ilişkileri öğrenebilmesini sağlarken, aynı zamanda elemanlarının kolay türevlenebilir olmasına katkıda bulunmaktadır (Goodfellow 2016). Bu durum, özellikle ağırlık öğrenme süreçlerinde ve optimizasyon algoritmalarında kritik bir avantaj sunmaktadır.

Yapay sinir ağlarında hesaplama verimliliğini artırmak amacıyla, doğrusal olmayan ancak türevlenebilirliği yüksek aktivasyon fonksiyonları tercih edilmektedir. Bu yaklaşım, modelin optimizasyon sürecini hızlandırmakta ve öğrenme sürecinde daha düşük hesaplama yükü ile daha hızlı sonuç alınmasını sağlamaktadır (Nwankpa vd, 2018). Böylece yapay sinir ağı, büyük veri setleriyle daha verimli şekilde çalışabilmekte ve daha hızlı yakınsama göstermektedir (Goodfellow 2016).

Aktivasyon fonksiyonlarının sağladığı doğrusal olmayan yapı, aynı zamanda ağıın genelleştirme yeteneğini artırarak farklı veri türlerini işleme ve doğru tahminler yapma becerisini güçlendirmektedir (Goodfellow 2016). Bu bağlamda, yapay sinir ağlarında aktivasyon fonksiyonlarının etkili bir şekilde seçimi ve kullanımı, modelin performansını doğrudan etkilemekte ve ağıın öğrenme kapasitesini üst düzeye çıkarmaktadır (Medium, 2024). Sıklıkla kullanılan aktivasyon fonksiyonları Şekil 2.3’te gösterilmiştir.



Şekil 2.3 Aktivasyon Fonksiyonları (İnik ve Ülker, 2017)

Sigmoid Aktivasyon Fonksiyonu, Yapay sinir ağlarında sınıflandırma problemleri için yaygın olarak tercih edilen aktivasyon fonksiyonlarından biri olan sigmoid, gelen girdileri 0 ile 1 arasında değerler üretecek şekilde dönüştürmektedir (Goodfellow 2016). Bu özellik, özellikle olasılık temelli çıktılar üretilmesi gereken durumlarda avantaj sağlamaktadır (Glorot ve Bengio 2010). Ancak sigmoid fonksiyonunun bazı sınırlamaları da bulunmaktadır (Nwankpa vd. 2018).

Bu fonksiyonun en büyük dezavantajlarından biri, derin ağlarda belirli bir noktadan sonra türevlenen değerlerin sıfıra yaklaşmasıdır. Bu durum, kaybolan eğim problemi olarak adlandırılmakta ve derin öğrenme modellerinde öğrenme sürecini zorlaştırmaktadır. Kaybolan eğim problemi, ağıın ağırlıklarının güncellenmesinde kullanılan gradyanların küçülmesiyle birlikte, özellikle alt katmanlardaki öğrenme hızının ciddi şekilde yavaşlamasına neden olmaktadır (Glorot ve Bengio 2010).

Bu zorluk sigmoid fonksiyonunun türev değerlerinin küçük olması ve doyumluk bölgelerinde türevlerin neredeyse sıfıra yaklaşmasıyla daha belirgin hale gelmektedir (Glorot ve Bengio 2010). Bunun sonucunda, ağı parametreleri yeterince optimize edilemeyebilir ve öğrenme süreci verimsiz hale gelebilmektedir (Bengio vd. 1994). Bu sorun, özellikle çok katmanlı ve karmaşık ağlarda, modern derin öğrenme yaklaşımlarında sigmoid fonksiyonu yerine ReLU gibi daha etkin aktivasyon fonksiyonlarının kullanımına yol açmıştır (Nair ve Hinton 2010).

Tanjant hiperbolik (tanh) aktivasyon fonksiyonu, gelen girdileri -1 ile 1 arasında bir çıktı aralığına dönüştürmektedir (LeCun vd. 1998). Çıktıların bu aralıkta olması, verilerin sıfır merkezli dağılmasını sağlamak ve bu durum gradyanların daha dengeli yayılmasına olanak tanımaktadır (Haykin 2009). Bu özellik, özellikle derin öğrenme süreçlerinde optimizasyonun daha etkili yürütülmesini sağlamakta, bu nedenle tanh fonksiyonu sigmoid fonksiyonuna kıyasla sıklıkla tercih edilmektedir (Bengio vd. 2012). Ayrıca tanh fonksiyonunun çıkışlarının negatif değerlere sahip olabilmesi, sinir ağı katmanları arasında bilgi akışının daha zengin bir şekilde temsil edilmesini mümkün kılmaktadır.

Tanh aktivasyon fonksiyonunun sahip olduğu avantajlara rağmen, derin yapıli sinir ağlarında kaybolan gradyan problemi bu fonksiyon için de geçerliliğini korumaktadır (Glorot ve Bengio, 2010). Bu durum tanh fonksiyonunun doyumluk bölgelerinde türev değerlerinin sıfıra yaklaşmasından kaynaklanmakta ve öğrenme sürecinde gradyanların üst katmanlara iletilmesini güçleştirmektedir (Bengio vd.1994). Bu nedenle özellikle derin katmanlı ağlarda parametre güncellemeleri yetersiz kalmakta ve öğrenme süreci ciddi şekilde yavaşlayabilmektedir (LeCun vd. 2012).

Doğrultulmuş Lineer Ünite (ReLU) fonksiyonu, negatif girişlerde sıfır pozitif girişlerde ise doğrusal bir çıktı üretmesiyle dikkat çekmektedir (Nair ve Hinton, 2010). Bu basit ve etkili yapısı sayesinde gradyanlar pozitif bölgelerde sabit kalmakta ve öğrenme süreci daha verimli ve istikrarlı bir biçimde yürütülebilmektedir (Nair ve Hinton, 2010). ReLU fonksiyonu, doyumluk bölgelerine sahip olmaması nedeniyle özellikle derin yapay sinir ağlarda bilgi öğrenmenin kesintisiz ve sürdürülebilir biçimde devam etmesini sağlamaktadır (Glorot ve Bengio, 2010).

Sızdırılmış Doğrultulmuş Lineer Ünite (Leaky-ReLU) fonksiyonu, klasik ReLU'nun negatif girişleri sıfıra eşitlemesiyle ortaya çıkan ve nöronların tamamen pasif hale gelmesine yol açan “ölü ReLU” problemini önlemek amacıyla geliştirilmiştir (Nair ve Hinton, 2010). Bu problem, negatif değerlerin yoğun olduğu durumlarda, bazı nöronların öğrenme sürecine katkı sunamamasına ve bu nedenle modelin kapasitesinin azalmasına neden olmaktadır (Glorot ve Bengio, 2010). Derin öğrenme literatüründe bu sınırlamaların etkileri uzun süredir tartışılmakta ve farklı aktivasyon fonksiyonlarıyla aşılmaya çalışılmaktadır (Schmidhuber, 2015).


Bu sorunu çözmek amacıyla, Leaky-ReLU aktivasyon fonksiyonu önerilmiştir. Leaky-ReLU, negatif değerler için sıfır yerine küçük ve sabit bir eğim uygulayarak bu bölgedeki bilgilerin tamamen kaybolmasını önlemektedir (Nair ve Hinton 2010). Bu fonksiyonda, negatif değerlerde kullanılan eğim α ile ifade edilmekte olup, genellikle 0.01 gibi küçük bir sabit değer seçilmektedir (Glorot ve Bengio 2010).

Eğer bu α parametresi, modelin diğer parametreleriyle birlikte öğrenilecek biçimde tanımlanırsa, bu yapı Parametrik ReLU (PReLU) olarak adlandırılmaktadır (Goodfellow, 2016). PReLU, farklı katmanlarda farklı eğimlerin öğrenilmesine olanak sağlayarak, modelin genelleme yeteneğini artırmaktadır. Leaky-ReLU ve PReLU, derin öğrenme modellerinde yaygın olarak kullanılan ve klasik ReLU fonksiyonunun sınırlamalarını aşmayı amaçlayan önemli aktivasyon fonksiyonlarıdır (Schmidhuber 2015).

2.3.3 Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı yapay sinir ağları, bir girdi katmanı, şekil 2.4'te bir veya birden fazla gizli katman ve bir çıktı katmanından oluşmaktadır (Haykin 2009). Girdi katmanı, verilerin ağ ile ilk kez etkileşime geçtiği bölümdür ve bu veriler, ağın yapısına bağlı olarak sonraki katmanlara iletilmektedir (Goodfellow 2016). Girdiler, yapay sinir ağı içindeki nöronlara belirli ağırlıklar aracılığıyla aktarılmakta ve her nöron bu bilgileri işlemektedir (LeCun vd. 2015). Gizli katmanlardaki nöronlar, kendilerine ulaşan sinyalleri aktivasyon fonksiyonları yardımıyla işleyerek bir sonraki katmana iletir (Schmidhuber 2015). Bu katmanlar arasındaki etkileşimler modelin karmaşık ve doğrusal olmayan ilişkileri

öğrenebilmesini mümkün kılar. Bu yapıdaki gizli katman sayısı ve katman başına düşen nöron sayısı, problemin yapısına ve modelin öğrenme kapasitesine bağlı olarak belirlenmektedir (Bengio ve Courville, 2016).



Şekil 2.4 Çok Katmanlı Yapay Sinir Ağı Yapısı (Özturan vd., 2008)

Her bir nöron kendisine ulaşan girdiler ile bu girdilere karşılık gelen ağırlıkların çarpımlarının toplamı sonucunda bir net girdi değeri üretmektedir (Haykin 2009). Bu net giriş, önceden belirlenmiş aktivasyon fonksiyonu aracılığıyla işlenerek nöronun çıktısını oluşturmaktadır (Bengio ve Courville 2016).

Üretilen bu ara çıktılar, ağı ileri beslemeli yapısı gereği bir sonraki katmana iletilmekte ve sonunda çıktı katmanına ulaşmaktadır (Schmidhuber 2015). Çıktı katmanında hesaplanan sonuç, hedeflenen çıktıyla karşılaştırılarak bir hata değeri belirlenmektedir (LeCun vd. 2015). Bu hata, yapay sinir ağının tahmin doğruluğunu yansıtan temel ölçütlerden biri olarak değerlendirilmektedir (Goodfellow 2016).

Elde edilen hata değeri, seçilen optimizasyon algoritması aracılığıyla kullanılarak ağırlıkların güncellenmesini sağlamaktadır (Glorot ve Bengio 2010). Bu güncelleme işlemi, ağı öğrenme sürecinin temelini oluşturmakta ve katmanlar arasında yer alan nöronlar arası etkileşimi doğrudan etkilemektedir (Schmidhuber 2015). Sonuç olarak çok

katmanlı yapay sinir ağları; sınıflandırma, regresyon ve tahmin gibi karmaşık yapıdaki problemlerin çözümünde yaygın olarak kullanılmaktadır (Bengio ve Courville, 2016).

2.3.4 Hata Hesaplama

Yapay sinir ağlarının çıktı katmanında ürettiği değerlerin, hedeflenen sonuçlara ne derece yaklaştığı, modelin öğrenme başarımını doğrudan etkilemektedir (Karapınar ve Şentürk, 2016). Beklenen ve hesaplanan çıktılar arasındaki fark, sınıflandırma ya da regresyon problemlerinde modelin doğruluğuna ilişkin temel bir performans ölçütü olarak değerlendirilir (Wainaina vd. 2019).

Bu nedenle özellikle çok katmanlı yapılarda çıktıların normalizasyonu sağlanmakta ve hata hesaplamaları belirlenen fonksiyonlar üzerinden gerçekleştirilmektedir (Patel vd. 2021). İkili sınıflandırmalarda sigmoid fonksiyonu tercih edilirken, çok sınıflı yapılarda olasılık temelli tahminler için softmax fonksiyonu kullanılmaktadır (Zador, 2019). Eğitim sürecinde modelin başarımını ölçmek amacıyla ortalama kareli hata (MSE), ortalama mutlak hata (MAE) ya da çapraz entropi gibi hata fonksiyonları tercih edilmektedir (Gülcü ve Kuş, 2019). Softmax fonksiyonunun temel mantığı, her sınıf için hesaplanan aktivasyon değerlerinin toplam içindeki payını temsil eden olasılık değerlerinin hesaplanmasına dayanır; bu sayede en yüksek olasılığa sahip olan sınıf, modelin tahmini olarak belirlenir (Chaikitkaew vd. 2024).

Sonraki aşamada, çapraz Entropi yöntemi yardımıyla her bir veri örneği (girdi) için oluşan hata, Denklem (6)'ya uygun şekilde belirlenmektedir (Goodfellow vd.2016). Elde edilen tekil hata değerleri, Denklem (7)'de ifade edilen yöntemle birleştirilerek toplam hata (maliyet) hesaplanmaktadır (Bengio ve Aaron, 2016). Böylece, yapay sinir ağının öğrenme sürecindeki performansı hakkında kapsamlı bir değerlendirme yapılabilmekte ve gereken durumlarda ağın parametreleri ile ağırlıklarında güncellemeler gerçekleştirilmektedir (Goodfellow vd. 2016) .

$$g_i = \exp(a_i) / \sum_j \exp(a_j) \quad (5)$$

$$L(\hat{y}, y) = -y^{(i)} \log(\hat{y}^{(i)}) - (1 - y^{(i)}) \log(1 - \hat{y}^{(i)}) \quad (6)$$

$$J(W, b) = \sum_{i=1}^m L(\hat{y}, y^{(i)}) \quad (7)$$

2.3.5 Hiperparametre Optimizasyonu

Yapay sinir ağlarının performansını iyileştirmeye yönelik kritik bir süreç olan hiperparametre optimizasyonu, modelin eğitimi ve yapısı üzerinde belirleyici etkiye sahip parametrelerin sistematik biçimde belirlenmesini amaçlamaktadır (Gülcü ve Kuş, 2019). Bu süreç, ağ mimarisi, eğitim algoritmalarının tipi, aktivasyon fonksiyonlarının seçimi ve öğrenme oranının uygunluğu gibi birçok faktörün birlikte değerlendirilmesini gerektirir (Goodfellow vd. 2016).

Hiperparametrelerin doğru biçimde yapılandırılması, yalnızca eğitim verisi üzerindeki doğruluğu artırmakla kalmamakta, aynı zamanda modelin beklenmedik veri senaryoları karşısında da yüksek genelleme başarısı sergilemesine olanak tanımaktadır (Zador, 2019). Bu bağlamda yapılan optimizasyon çalışmaları, aşırı öğrenme gibi istenmeyen durumların önlenmesine de katkı sağlayarak modelin kararlılığını artırmaktadır (Bengio vd. 1994).

Böylelikle, teorik modellemeye pratik uygulama arasında denge kurularak, yapay sinir ağlarının karmaşık problemlere karşı daha esnek ve etkili çözümler üretebilme potansiyeli ortaya çıkarılmaktadır (Vellido vd 2012).

Bu amaç doğrultusunda farklı hiperparametre kombinasyonları çeşitli performans kriterleri kullanılarak test edilmekte; elde edilen sonuçlar ise modelin doğruluk, hata oranı ve genelleme kapasitesini yansıtan göstergelerle karşılaştırılmaktadır. En uygun hiperparametrelerin belirlenmesi modelin öğrenme süresini kısaltırken aşırı öğrenme riskinde minimize etmektedir. Bu değerlendirmeler sistematik bir iyileştirme sürecinin ayrılmaz bir parçasını oluşturmakta olup, modelin yalnızca mevcut verilerde yüksek doğruluk sağlamasının ötesinde, daha geniş veri dağılımlarına karşı dirençli bir yapı kurmasına olanak tanımaktadır. Akademik ve endüstriyel uygulamalarda büyük önem taşıyan bu dirençli yapı, model başarısının sürdürülebilir kılınması açısından kritik bir

role sahiptir (Bischl vd. 2023). Hiperparametre seçimi süreci sırasında, her bir konfigürasyon titizlikle denenmekte ve sonuçları istatistiksel metotlarla derinlemesine analiz edilmektedir. İlgili deneyler sonucunda belirlenen en iyi parametre kümesi, modelin hem hız hem de doğruluk bakımından optimal sonuçlar vermesine öncülük etmektedir. Bu noktada, uygun değerlerin belirlenmesi kadar, seçilen değerlerin modelin yapısal özellikleriyle bütünleşmesi de son derece ehemmiyet taşımaktadır. Nitekim seçilen hiperparametreler, modelin hangi hızda ve nasıl öğreneceğinden, hangi tür fonksiyonlarla girdi ve çıktı arasındaki ilişkiyi kurgulayacağına kadar pek çok detayı etkilemektedir. Sürecin nihayetinde, test verisi ve gerçek ortam uygulamaları üzerinde yapılan kapsamlı doğrulamalar ile modelin genelleme becerisi güvence altına alınmakta, böylelikle daha güvenilir ve güçlü tahmin modellerinin geliştirilmesi mümkün olmaktadır (Bischl vd. 2023).

2.4 Makine Öğrenmesi

Makine öğrenmesi verilerdeki örüntüleri keşfetmek ve bu örüntülere dayanarak kararlar almak amacıyla geliştirilmiş bir yapay zekâ dalıdır (Rutland vd. 2023). Geleneksel modelleme yöntemlerinin sınırlamalarını aşarak, karmaşık ve doğrusal olmayan ilişkileri analiz etme yeteneği sunar (Cangialosi vd. 2021). ML, insan müdahalesi olmadan, büyük veri kümeleri üzerinden genelleştirme yaparak yeni durumlar için tahminlerde bulunabilir ve bu özelliğiyle özellikle biyoproseslerde, atık su arıtımında ve anaerobik sindirim sistemlerinde süreç kontrolü ve optimizasyonu için güçlü bir araç olarak öne çıkmaktadır (Cruz vd. 2022). Anaerobik sindirim gibi kompleks biyolojik süreçlerde, sıcaklık, pH, organik yük gibi çok sayıda değişkenin birbirleriyle etkileşimli yapısını analiz etmek için makine öğrenmesi algoritmaları, doğrusal modellemeye göre çok daha üstün performans sergileyebilmektedir (Radočaj ve Jurišić, 2025). Bu bağlamda, Rastgele Ormanlar (RF), Karar Ağaçları (DT), Destek Vektör Makineleri (SVM), Gradyan Artırmalı Modeller (GBM) ve K-En Yakın Komşu (KNN) gibi makine öğrenmesi algoritmaları, karmaşık veri yapılarının yorumlanmasında ve model doğruluğunun artırılmasında sıklıkla tercih edilmektedir (Neupane vd. 2025).

Bilgisayar sistemlerinin açık programlama olmaksızın veri setlerinden öğrenerek kendilerini geliştirmesine imkân tanıyan bir yapay zekâ dalıdır (Rutland vd. 2023). ML

süreçleri genellikle üç temel aşamadan oluşur: eğitim, doğrulama ve test (Cruz vd. 2022). Eğitim aşamasında model, örüntüleri tanır; doğrulama aşamasında modelin genelleme yeteneği kontrol edilir; test aşamasında ise daha önce görülmemeyen veriler üzerinde başarıyı değerlendirilir (Neupane vd. 2025). Makine öğrenmesi yöntemleri temel olarak gözetimli öğrenme, gözetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç ana kategoriye ayrılır (Cangialosi vd 2021). Gözetimli öğrenmede, etiketli veriler kullanılarak giriş ve çıkışlar arasında bir haritalama öğrenilirken; gözetimsiz öğrenmede veri içindeki gizli yapılar ve örüntüler keşfedilir. Pekiştirmeli öğrenmede ise ajanlar, çevreden aldıkları ödül ve ceza sinyalleri ile öğrenme gerçekleştirir (Radočaj ve Jurišić, 2025). Özellikle anaerobik sindirim gibi biyoproseslerin modellenmesinde Random Forest (RF), Karar Ağaçları (DT), Destek Vektör Makineleri (SVM), Gradyan Artırmalı Modeller (GBM) ve K-En Yakın Komşu (KNN) gibi algoritmaların kullanımı öne çıkmış; doğrusal olmayan ve çok değişkenli süreçlerin başarılı bir şekilde modellenmesine olanak sağlamıştır (Cheon vd. 2022).

2.4.1 Gözetimli Öğrenme Algoritmaları

Gözetimli öğrenme, makine öğrenmesi kapsamında yer alan ve algoritmaların geçmişteki etiketli veriler üzerinden eğitilerek, gelecekteki bilinmeyen verilere ilişkin doğru tahminlerde bulunmalarını sağlayan bir yöntemdir ve öğrenme tipi, özellikle giriş-çıkış eşleşmelerinin bilindiği problemlerde kullanılarak yüksek doğrulukta sınıflandırma ve regresyon modelleri geliştirilmesine olanak tanır (Kotsiantis, 2007). Anaerobik sindirim gibi karmaşık biyolojik süreçlerin modellenmesinde gözetimli öğrenme algoritmaları büyük avantaj sağlamaktadır; çünkü bu yöntem, doğrusal olmayan ilişkileri yakalayarak sıcaklık, pH, organik yük oranı gibi parametrelerin süreç verimi üzerindeki etkilerini başarılı bir şekilde analiz edebilmektedir (Li vd. 2022). Rastgele Ormanlar (Random Forrest-RF), Karar Ağaçları (Decision Tree-DT), Destek Vektör Makineleri (Support Vector Machine-SVM), Gradyan Artırmalı Modeller (Gradient Boost Machine-GBM) ve K-En Yakın Komşu (K-Nearest Neighbors -KNN) gibi algoritmalar, özellikle biyogaz üretimi tahmini, süreç optimizasyonu ve hata teşhisi gibi alanlarda yoğunlukla kullanılmaktadır (Paramasivam vd. 2024). Son çalışmalar, RF ve XGBoost gibi ağaç tabanlı yöntemlerin, özellik önem derecelendirme ve model yorumlanabilirliği açısından üstün performans sergilediğini ortaya koymuştur (Sonwai vd. 2023). Bu yöntemler yüksek

yorumlanabilirlik sunmaktadır. Ayrıca laboratuvar ölçekli çalışmalardan sanayi ölçeğine geçiş sürecinde, gözetimli öğrenmenin sağlam tahminler sunarak süreci güvence altına aldığı vurgulanmaktadır (Fard ve Koupaie. 2024).

2.4.2 Makine Öğrenmesinde Kullanılan Algoritmalar

Makine öğrenmesi uygulamalarında, doğru algoritmanın seçimi, model performansını ve öngörü doğruluğunu doğrudan etkilemektedir (Abubakar vd 2024). Özellikle anaerobik sindirim gibi karmaşık biyolojik sistemlerin modellenmesinde; verilerin doğrusal olmayan doğası ve parametreler arasındaki güçlü etkileşimler nedeniyle çeşitli makine öğrenmesi algoritmalarının kullanımı büyük önem taşımaktadır (Ling vd. 2024). Bu kapsamda, Karar Ağaçları (Decision Trees- DT), Rastgele Ormanlar (Random Forest-RF), Destek Vektör Regresyonu (Support Vector Regression-SVR), Gradyan Artırmalı Modeller (Gradient Boosting Machines-GBM) ve K-En Yakın Komşu (K-Nearest Neighbors-KNN) gibi algoritmalar, biyogaz üretimi tahmini, süreç optimizasyonu ve performans artırımı gibi birçok kritik uygulama alanında yaygın olarak tercih edilmektedir (Mukasine vd. 2024). Her bir algoritmanın kendi güçlü yönleri ve sınırlamaları bulunmakta olup model seçimi yapılırken veri yapısına, problem türüne ve işlem kapasitesine göre değerlendirme yapılmaktadır (Adeleke vd. 2024). Son dönem çalışmaları, birden fazla algoritmanın birlikte kullanıldığı ensemble yöntemlerinin öngörü doğruluğunu artırmada etkili olduğunu göstermektedir (Radočaj ve Jurišić 2025). Bu bölümde, çalışmada kullanılan beş ana makine öğrenmesi algoritmasının temel prensipleri, avantajları ve kullanım alanları detaylı bir şekilde ele alınacaktır.

2.4.2.1 Karar Ağaçları Algoritması

Karar ağaçları (Decision Trees- DT), makine öğrenmesi alanında hem sınıflandırma hem de regresyon problemlerinde sıklıkla kullanılan sezgisel bir yöntemdir. Bu algoritma, veriyi dallara ayırarak bir ağaç yapısı oluşturur ve her dal, belirli bir özelliğe göre veri setini daha homojen alt gruplara ayırır (Ganeshan vd. 2024). Karar ağaçlarının temel avantajı, modelin kolay yorumlanabilir olması ve verilerdeki doğrusal olmayan ilişkileri etkin bir şekilde öğrenebilmesidir (Ling vd. 2024). Anaerobik sindirim gibi karmaşık biyoproseslerde, sıcaklık, pH, organik yük gibi değişkenlerin biyogaz üretimi üzerindeki etkilerini analiz etmek için karar ağaçları sıkça tercih edilmektedir. Özellikle laboratuvar

ölçeğinden sanayi ölçeğine geçişte, hızlı tahmin yapabilmeleri ve açıklanabilirlik sağlamaları önemli bir avantaj sunmaktadır (Mukasine vd. 2024). Ancak karar ağaçları, tek başına kullanıldığında aşırı öğrenmeye eğilimli olabilmektedir. Bu durumu azaltmak için ağaç derinliğinin sınırlandırılması veya ağaç budama tekniklerinin uygulanması önerilmektedir (Adeleke vd. 2024). Son dönem çalışmalarda, karar ağaçları ayrıca daha güçlü ensemble yöntemlerin (Rastgele Ormanlar veya Gradyan Artırmalı Modeller) temel yapı taşları olarak da kullanılmaktadır (Radočaj ve Jurišić 2025).

2.4.2.2 Rastgele Ormanlar Algoritması

Rastgele Ormanlar (Random Forest-RF), çoklu karar ağacı modellerinin bir araya getirilmesiyle oluşturulan güçlü bir topluluk öğrenme yöntemidir. Her bir karar ağacı, veri setinin rastgele bir alt kümesi ve rastgele seçilmiş değişkenler kullanılarak eğitilmekte, nihai tahmin ise bu ağaçların çoğunluk oyu veya ortalaması ile yapılmaktadır (Ganeshan vd. 2024). Bu yapı, bireysel karar ağaçlarının aşırı öğrenme eğilimini azaltarak genel modelin doğruluk ve genelleme kabiliyetini artırır (Ling vd. 2024). Özellikle anaerobik sindirim gibi çok değişkenli, doğrusal olmayan sistemlerin modellenmesinde RF algoritması yaygın şekilde kullanılmakta ve yüksek öngörü başarımı sergilemektedir (Mukasine vd. 2024). Ayrıca RF modelleri özellik önem sıralaması çıkararak hangi parametrelerin model performansına daha çok katkı sağladığını belirleyebilmekte, bu yönüyle de sistem analizi için değerli bilgiler sunmaktadır (Savan-Roumi vd. 2024). Son zamanlardaki çalışmalarda RF algoritması, biyogaz üretimi optimizasyonu, süreç performansı tahmini ve biyogaz kalite değerlendirmesi gibi pek çok alanda üstün doğruluk oranları ile öne çıkmıştır (Radočaj ve Jurišić 2025).

2.4.2.3 Destek Vektör Regresyonu Algoritması

Destek Vektör Regresyonu (Support Vector Regression-SVR), doğrusal ve doğrusal olmayan ilişkileri modelleyebilen, güçlü bir makine öğrenmesi algoritmasıdır. SVR, temelinde destek vektör makineleri (SVM) prensiplerine dayanır; ancak sınıflandırma yerine sürekli değerlerin tahmini amacıyla kullanılır (Chen vd. 2022). Bu yöntem, belirli bir hata toleransı içinde, mümkün olan en düz fonksiyonu oluşturmaya çalışarak veri setindeki gürültüyü minimize eder (Chen vd. 2022). SVR, çekirdek (kernel) fonksiyonları kullanarak giriş uzayını daha yüksek boyutlu bir alana dönüştürebilir; bu sayede doğrusal

olmayan ilişkileri etkili biçimde modelleyebilir (Ling vd. 2024). Anaerobik sindirim ve biyogaz üretimi gibi karmaşık biyolojik süreçlerde, SVR, az miktarda veriden yüksek doğrulukta tahminler üretebilmesi ve aşırı öğrenmeye karşı dayanıklı olması sayesinde öne çıkmaktadır (Zou vd. 2024). Son çalışmalar, SVR'nin biyogaz üretimi tahmini, metan emisyonu modellemesi ve ağır metal immobilizasyonu gibi çok değişkenli problemlerde üstün başarı sağladığını göstermiştir (Ahmad vd. 2024).

2.4.2.4 Gradyan Artırmalı Ağaçlar Algoritması

Gradyan Artırmalı Ağaçlar (Gradient Boosting Machines-GBM), zayıf öğrencilerin (genellikle karar ağaçları) ardışık olarak eğitilmesi ve her adımda önceki modelin hata kalıntılarının minimize edilmesi esasına dayanan güçlü bir topluluk öğrenme yöntemidir. GBM, her yeni modelin, önceki modellerin yapamadığı hataları düzeltmeye çalışarak doğruluk oranını artırır ve böylece yüksek performanslı öngörüler elde eder (Zhang vd., 2023). Özellikle doğrusal olmayan, çok değişkenli veri setlerinde üstün başarı gösteren GBM algoritması, biyogaz üretimi ve metan gazı tahmini gibi alanlarda etkin şekilde kullanılmaktadır (Jeong vd., 2021). Yapılan çalışmalarda, GBM'nin otomatik makine öğrenmesi süreçlerinde diğer birçok modelin üzerinde başarı sağladığı ve biyogaz üretim tahminlerinde anahtar faktörleri belirlemede kritik rol oynadığı rapor edilmiştir (Zhang vd., 2023). Ayrıca LightGBM gibi GBM türevleri, biyogaz üretimi verilerini daha hızlı ve daha doğru şekilde analiz ederek, sistem optimizasyonu ve çevresel etkilerin azaltılması gibi önemli katkılar sağlamaktadır (Zou vd. 2024). GBM algoritmasının temel avantajları arasında yüksek tahmin doğruluğu, esnek modelleme kapasitesi ve farklı veri türleri ile çalışabilme kabiliyeti bulunmaktadır (Adeleke vd. 2024). Hiperparametre ayarlamalarının dikkatlice yapılmaması durumunda aşırı öğrenmeye yatkın olabileceği de göz önünde bulundurulmalıdır (Tryhuba vd. 2024).

2.4.2.5 K-En Yakın Komşu Algoritması

K-En Yakın Komşu (K-Nearest Neighbors-KNN) algoritması, sınıflandırma ve regresyon problemlerinde kullanılan, sezgisel ve örüntü tabanlı bir makine öğrenmesi yöntemidir. KNN, eğitim veri setinde en yakın K veri noktasını belirleyerek ve bu komşuların sonuçlarına dayanarak tahmin yapar; bu sayede herhangi bir matematiksel model

oluşturulmasına gerek kalmadan veriye dayalı öngörüler sunar (De Clercq vd. 2019). Anaerobik sindirim süreçlerinde, sıcaklık, pH, organik yük gibi değişkenlerin etkileri arasındaki ilişkiyi yakalamada KNN algoritması, özellikle küçük ve orta ölçekli veri kümelerinde etkin sonuçlar vermektedir (Li vd. 2022). Yapılan çalışmalarda KNN algoritması belirli koşullarda yüksek doğruluk oranları sunabilmiş; örneğin, endüstriyel biyogaz üretimi verileri üzerinde %87'ye kadar doğruluk sağladığı rapor edilmiştir. Bununla birlikte, KNN algoritmasının doğruluğu, seçilen K değeri ve kullanılan mesafe metriğine oldukça duyarlıdır (Yalçinkaya ve Yücel 2025). Yakın dönem çalışmaları, biyogaz üretim tahmininde KNN'nin, diğer algoritmalarla (RF, SVR gibi) kıyaslandığında daha düşük genel doğruluk sağladığını, ancak belirli koşullarda rekabetçi bir performans gösterebildiğini ortaya koymuştur (Li vd. 2022). KNN'nin temel avantajı, modelin hızlı uygulanabilir olması ve karmaşık model parametrisasyonu gerektirmemesidir; buna karşılık, büyük veri setlerinde hesaplama maliyetinin artabileceği ve gürültülü verilerde performansının düşebileceği de göz önünde bulundurulmalıdır.

2.4.3 Hata Hesaplama

Makine öğrenmesi modellerinin performans değerlendirmesinde hata hesaplama metrikleri büyük bir öneme sahiptir. Bu metrikler, modelin gerçek değerler ile tahmin edilen değerler arasındaki farkı ölçerek modelin doğruluğunu, hassasiyetini ve genelleme yeteneğini değerlendirmeye olanak tanır (Ling vd. 2024). Anaerobik sindirim süreçleri, biyogaz üretimi ve metan emisyon tahminleri gibi karmaşık biyolojik sistemlerde, küçük hata oranları elde etmek süreç optimizasyonu için kritik öneme sahiptir (Ganeshan vd. 2024). Makine öğrenmesi çalışmalarında en yaygın kullanılan hata ölçütleri arasında Ortalama Mutlak Hata, Ortalama Kare Hatası, Kök Ortalama Kare Hatası ve R^2 yer almaktadır (Chai ve Draxler 2022).

MAE, modelin tahmin ettiği değerlerin gerçek değerlerden ortalama mutlak sapmasını ölçerken (Denklem 8), MSE her sapmanın karesini alarak büyük hatalara daha fazla ağırlık verir (Denklem 9). RMSE, MSE'nin karekökü alınarak hesaplanır (Denklem 10) ve hata birimini gerçek verilerle aynı seviyeye getirir, bu sayede yorumlanması daha kolay olur (Yildirim ve Ozkaya, 2023). Özellikle biyogaz üretiminde tahmin modellerinin

doğruluğunu değerlendirirken RMSE düşük çıktığında modelin başarılı olduğu kabul edilmektedir (Rossi vd. 2022). R^2 Skoru ise modelin açıklayabildiği varyans oranını ölçerek, tahmin kalitesinin bir özetini sunar (Denklem 11). Yüksek bir R^2 değeri modelin giriş değişkenleri ile hedef değişken ilişkisini iyi öğrendiğini gösterir (Mukasine vd. 2024). Bununla birlikte çalışmalarda yalnızca tek bir hata metriğine bağlı kalmanın, modelin farklı boyutlardaki performansını tam anlamıyla yansıtmayabileceği belirtilmiştir (Zhang vd. 2023). Bu nedenle birden fazla hata metriği birlikte kullanılarak, modelin hem hassasiyet hem de genelleme yeteneği daha bütüncül bir şekilde değerlendirilmektedir. Özellikle ensemble yöntemlerde ve karmaşık biyolojik verilerin modellenmesinde bu yaklaşım önerilmektedir (Mowbray vd. 2021).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (11)$$

2.4.4 Hiperparametre Optimizasyonu

Makine öğrenmesi modellerinin performansı yalnızca kullanılan algoritmaya değil aynı zamanda hiperparametrelerin doğru seçimine de bağlıdır. Hiperparametreler, model

eđitimi bařlamadan nce belirlenen, modelin đrenme srecini ve sonularını dođrudan etkileyen dıřsal ayarlardır. Dođru hiperparametre seimi, bir modelin ařırı đrenme veya eksik đrenme gibi istenmeyen durumlara girmesini nlerken, tahmin dođruluđunu, genelleme kapasitesini ve iřlem verimliliđini artırmaktadır (Putra vd. 2023). Anaerobik sindirim, biyogaz retimi ve metan emisyon tahmini gibi kompleks biyolojik srelerin modellemesinde, hiperparametre optimizasyonu sre sonularının gvenilirliđini dođrudan etkileyen bir adım olarak kritik neme sahiptir (Mahmoodi-Eshkaftaki ve Ebrahimi, 2021).

Karar Ađaları (DT) algoritmasında hiperparametre optimizasyonu, ađacın bymesini ve dallanmasını sınırlayarak modelin ařırı đrenmesini nlemek amacıyla yapılmaktadır. Bu bađlamda maksimum derinlik, minimum yaprak boyutu ve blnme kriteri gibi parametreler optimize edilmektedir (Cinar vd. 2022). Derinlik parametresi ađacın derinliđini kontrol ederek modelin sadeleřmesini sađlarken, criterion parametresi her blnmede hangi kalite metriđinin kullanılacađını belirlemektedir. Anaerobik sindirim srelerinde DT algoritmasında bu parametrelerin hassas ayarlanması, modelin hem dođruluk hem de aıklanabilirlik aısından gl performans sergilemesini sađlamaktadır (Chiu vd. 2022).

Rastgele Ormanlar (RF) algoritmasında ise hiperparametre optimizasyonu, bireysel karar ađalarının eřitliliđini artırarak genel model dođruluđunu iyileřtirmek iin kritik rol oynamaktadır. RF modellerinde optimize edilen temel parametreler ađa sayısı ($n_estimators$), maksimum derinlik (max_depth) ve maksimum zellik sayısı ($max_features$) olarak ne ıkmaktadır (Ganeshan vd. 2024). zellikle byk veri kmelerinde, yksek $n_estimators$ deđerisi ile dřk $max_features$ kombinasyonu kullanılarak hem ařırı đrenme nlenmekte hem de modelin genelleme yeteneđi artırılmaktadır (Mohamed vd. 2025). Anaerobik sindirim verilerinde yapılan uygulamalarda RF algoritmasının dođru hiperparametre kombinasyonlarıyla %90'ın zerinde dođruluk sađladıđı rapor edilmiřtir.

Destek Vektr Makineleri (SVM) algoritmasında hiperparametre optimizasyonu, karar sınırlarının esnekliđini ve modelin genel bařarımını dođrudan belirlemektedir. Bu

algoritmada C (ceza parametresi), çekirdek fonksiyonu türü (kernel) ve gamma değerleri optimize edilmektedir (Guo vd. 2022). C parametresi, sınıflandırma hatalarına toleransı belirlerken, gamma değeri karar sınırının eğriliğini düzenler. Kernel seçimi ise modelin doğrusal mı yoksa doğrusal olmayan ilişkileri mi öğrenebileceğini belirler. Anaerobik sindirim uygulamalarında, özellikle RBF çekirdek fonksiyonunun kullanımıyla ve optimize edilmiş C-gamma değerleri ile SVM modellerinin yüksek doğruluk ve genelleme performansı elde ettiği görülmektedir (Jeong vd. 2021). Gradyan Artırmalı Ağaçlar (GBM) algoritmasında hiperparametre optimizasyonu, modelin adım adım daha doğru hale gelmesini ve öğrenme sürecinde hata birikimini minimize etmeyi hedeflemektedir. Optimize edilen ana parametreler arasında öğrenme oranı (learning_rate), maksimum derinlik (max_depth), ağaç sayısı (n_estimators) ve subsample oranı bulunmaktadır (Zhang vd., 2023). Learning_rate, her adımda yapılan güncellemelerin boyutunu kontrol ederken, subsample oranı veri alt örnekleme yaparak modelin aşırı öğrenmesini önlemektedir. Yapılan çalışmalar, GBM modellerinde learning_rate ve max_depth parametrelerinin dikkatli ayarlanmasının, biyogaz üretim tahminlerinde RMSE değerlerini anlamlı derecede düşürdüğünü göstermektedir (Mukasine vd. 2024).

K-En Yakın Komşu (KNN) algoritmasında hiperparametre optimizasyonu, modelin hem doğruluk oranını hem de işlem süresini doğrudan etkileyen önemli bir unsurdur. Burada optimize edilen temel parametreler K değeri (komşu sayısı) ve mesafe metriği seçimidir (De Clercq vd. 2019). K değeri, kaç komşunun dikkate alınacağını belirlerken, mesafe metriği benzerlik ölçüsünü etkiler. Çok küçük bir K değeri modele aşırı hassasiyet kazandırarak gürültüye açık hale getirebilirken, çok büyük bir K değeri genelleme kapasitesini azaltabilmektedir (Yildirim ve Ozkaya, 2023). Anaerobik sindirim verileri üzerinde yapılan KNN çalışmaları, orta düzey K değerleri (5-10) kullanıldığında en iyi performansın elde edildiğini göstermiştir.

2.5 Elektrik Üretim Tahmini

Biyogazdan elektrik üretiminin tahmini, sistemin sahip olduğu metan oranı, üretim hacmi ve termodinamik verimlilik gibi parametrelere bağlı olarak hesaplanabilmektedir. Bu kapsamda yapılan çalışmalarda, biyogaz içeriğindeki metan oranının, metanın özgül ısı

değeriyle çarpılması ve sistemin elektriksel verimliliğiyle ilişkilendirilmesi yoluyla elde edilen teorik enerji miktarı hesaplanmaktadır (Admasu vd. 2022). Denklem (12)'de sunulan denkleme göre, elektrik enerjisi hesaplamasında biyogaz hacmi (Q_{biyogaz}), metan içeriği (f_{CH_4}), Metan özgül ısı değeri (CP_{CH_4}) ve elektriksel verimlilik (η_{elektrik}) dikkate alınmakta ve denklem (12) kullanılmaktadır.

$$E_{\text{elektrik}} = Q_{\text{biyogaz}} \times f_{\text{CH}_4} \times CP_{\text{CH}_4} \quad (12)$$

Özellikle deneysel olarak belirlenen metan üretim oranlarına ve biyogaz verimine dayalı sistemlerin enerji dönüşüm potansiyelinin hesaplanmasında etkin bir araç olarak değerlendirilmektedir (Ruwa vd.2022). Literatürde 1 m³ metanın yaklaşık 9.97 kWh enerji içerdiği belirtilmekte olup, bu enerji potansiyelinin ne kadarının elektrik olarak elde edilebileceği, sistemin verimlilik katsayısına bağlıdır. Söz konusu yöntem, anaerobik sindirim tesislerinden elde edilen biyogazın enerji dönüşüm verimliliğini belirlemek açısından bilimsel temelli bir yaklaşım sunmaktadır (Admasu vd., 2022).

2.6 Biyogaz Santrali Tasarımları Yapılan Çalışmalar

Biyogaz üretiminde kullanılan anaerobik ortak sindirim (Anaerobic Co-Digestion-AcoD) süreci kapsamlı bir biçimde ele alınmaktadır. Söz konusu araştırmada, tek bir substratla yapılan sindirime kıyasla birden fazla organik girdinin birlikte işlenmesinin metan üretimini artırdığı ve süreç stabilitesini yükselttiği ortaya konmuştur. Bu doğrultuda, organik materyallerin ayrışma potansiyelini belirlemede biyokimyasal metan potansiyeli (Biochemical Methane Potential-BMP) testlerinin önemli bir rol üstlendiği vurgulanmaktadır. Anaerobik sindirim Modeli No.1 (Anaerobic Digestion Model No.1-ADM1) modelinin, AcoD süreçlerinin optimizasyonunda kritik bir araç işlevi gördüğü belirtilmektedir (Hagos vd. 2017).

Anaerobik sindirim, organik atıkları biyogaza dönüştüren etkili bir biyoteknolojik süreç olarak öne çıkmaktadır. Hayvan gübresinin enerji üretimi, besin değeri yüksek gübre elde edilmesi ve sera gazı emisyonlarının azaltılması gibi avantajları bulunmaktadır. Ancak, gübresin düşük ve dengesiz karbon-azot (C/N) oranı, tek başına kullanıldığında sindirim verimliliğini sınırlamaktadır. Bu sorunu gidermek amacıyla, yüksek karbon içeriğine

sahip lignoselülozik atıkların gübre ile birlikte co-sindirime tabi tutulması önerilmektedir. Literatürde yapılan çalışmalar, co-sindirimin biyogaz ve metan üretimini artırdığını, süreç stabilitesini iyileştirdiğini ve sıcaklık, pH, organik yükleme oranı, hidrolik tutma süresi gibi parametrelerin performans üzerindeki etkilerini ortaya koymuştur. Ayrıca, fiziksel, kimyasal ve biyolojik ön işlemlerin substratların biyo yararlanabilirliğini artırarak biyogaz verimini yükselttiği görülmüştür. Sürdürülebilir enerji üretimi ve çevresel faydalar sağlamada önemli bir yöntem olarak değerlendirilmektedir (Neshat vd. 2017). Gıda atıklarının anaerobik sindirimi için pilot ölçekli bir sistem üzerinde dinamik modelleme ve simülasyon çalışması gerçekleştirmiştir. Çalışmada, ADM1 kullanılarak reaktör performansı değerlendirilmektedir. Araştırmada, organik yükleme hızının ve hidrolik bekleme süresinin (Hydraulic Retention Time-HRT) biyogaz üretimi üzerindeki etkileri ayrıntılı biçimde incelenmektedir. Elde edilen sonuçlar, çamur geri dönüşümünün biyogaz üretimini %31 oranında artırarak sistem stabilitesini önemli ölçüde desteklediğini göstermektedir. Ayrıca, reaktördeki metan ve karbondioksit oranlarının, besleme düzenine bağlı olarak değişkenlik gösterdiği ifade edilmektedir. Bu doğrultuda, biyogaz üretimi süreçlerinde modelleme tabanlı optimizasyonun büyük önem taşıdığı ve söz konusu süreçlerin endüstriyel ölçekteki uygulamalara geçişinin, pilot ölçekli testlerle desteklenmesi gerektiği vurgulanmaktadır (Rathnasiri 2016).

Biyogaz üretimini artırmak amacıyla geliştirilen biyolojik yenilikler ve stratejiler incelenmektedir. Üretim süreçleri; üretim öncesi, üretim sırası ve üretim sonrası yaklaşımlar olarak üç ana grupta sınıflandırılmaktadır. Üretim öncesinde, biyolojik yöntemler arasında mantar ve mikrobiyal konsorsiyum kullanımı, enzimatik işlemler, mikroaerasyon ve silajlama gibi teknikler öne çıkmaktadır. Bu yöntemler, biyogaz verimini artırmada etkili olmasına rağmen, zaman ve kaynak gereksinimi nedeniyle uygulamada zorluklar yaratmaktadır. Her yöntemin avantajının farklı olduğu gözlemlenmektedir. Ayrıca, çoğu veri laboratuvar düzeyinde elde edildiğinden, ticari ölçekte karar almayı destekleyecek bilgiler sınırlıdır. Gelecekte, biyogaz tesislerinin daha verimli tasarımları için gerekli verilerin sağlanması ve ekonomik analizlerin doğrulukla yapılması önem taşımaktadır. Bu bağlamda yaşam döngüsü değerlendirmesi (Life Cycle Assessment-LCA) gibi kapsamlı yöntemlerin entegrasyonu önerilmektedir (Tabatabaei vd. 2020).

Anaerobik sindirim sistemlerinde patojen inaktivasyonu, biyogaz üretimi süreçlerinin başarısını etkileyen kritik bir unsur olarak değerlendirilmektedir. Çalışmalar sindirim süreçleri sırasında patojenlerin farklı koşullar altında inaktive edilebileceğini göstermektedir. Ancak, çevresel faktörler ve patojen türleri üzerindeki etkiler tam anlamıyla anlaşılmış değildir. Bu derleme çalışması, çeşitli patojenlerin inaktivasyonu üzerindeki anahtar faktörleri incelemekte ve farklı sıcaklık, işletim modları, ara ürünler ve direnç mekanizmalarının etkilerini değerlendirmektedir. Özellikle termofilik koşulların, gram-negatif bakteriler, nematodlar ve virüsler gibi çeşitli patojenlerin etkili bir şekilde inaktive edilmesini sağladığı görülmüştür. Bununla birlikte, mezofilik ve düşük sıcaklık koşullarında patojenlerin etkisiz hale getirilmesi sınırlıdır. Araştırmalar, kurutulmuş anaerobik sindirimin, uçucu yağ asitleri ve amonyak birikiminden dolayı patojen inaktivasyonu açısından umut verici bir yöntem olduğunu ortaya koymaktadır (Jiang vd. 2020).

Katı atıkların anaerobik sindirimi amacıyla matematiksel bir modelleme çalışması yürütmektedir. Söz konusu araştırmada, ADM1 kullanılarak atık substratların kompozisyonlarının biyogaz üretimine olan etkileri ayrıntılı biçimde analiz edilmektedir. Elde edilen bulgular, pH seviyeleri ile uçucu yağ asitlerinin biyogaz üretim süreci üzerinde belirleyici bir role sahip olduğunu göstermektedir. MATLAB yazılımı aracılığıyla yürütülen simülasyonlarda, farklı operasyonel parametrelerin biyogaz üretimindeki değişime nasıl etki ettiği test edilmektedir. Çalışma sonuçları, enerji üretimini artırmak ve maliyetleri düşürmek bakımından süreç optimizasyonunun kritik bir önem taşıdığını ortaya koymaktadır (Manjusha ve Beevi 2016).

Süt hayvanı gübresi ile mantar yetiştiriciliğinden kalan substratların anaerobik sindirimi esnasında metan üretimi ve pH değerlerini modellemektedir. Çalışmada Anaerobic ADM1 kullanılarak substrat oranlarının ve hidrolik bekleme süresinin sistem performansı üzerindeki etkileri detaylı bir biçimde ele alınmaktadır. Simülasyon sonuçları, substrat oranlarının ve HRT'nin optimize edilmesi durumunda metan üretim verimliliğinin artabileceğini göstermektedir. Model, farklı deneysel koşullarla doğrulanmış olup biyogaz üretiminin optimizasyonu açısından güvenilir bir araç olarak değerlendirilmektedir. Söz konusu çalışma, biyogaz üretim süreçlerinde dinamik

modelleme yaklaşımının hem sistem verimliliğini hem de sürdürülebilirliği artırmada önemli bir rol üstlendiğini ortaya koymaktadır (Shi vd. 2014).

Anaerobik sindirim süreçlerini modellemek ve optimize etmek amacıyla MATLAB yazılımını kullanarak dinamik bir model geliştirmiş bulunmaktadır. Bu çalışmada, modifiye edilmiş Hill modeline dayanarak biyometan üretiminin zamana bağlı değişimi kapsamlı bir biçimde incelenmektedir. Araştırmada, organik yükleme hızı, sıcaklık ve pH gibi parametrelerin biyogaz üretimi üzerindeki etkileri ayrıntılı şekilde analiz edilmiş olup, geliştirilen model deneysel verilerle karşılaştırıldığında yaklaşık %92 doğruluk oranı sunarak güvenilirliğini kanıtlamaktadır. Ayrıca farklı işletim koşulları altında optimum biyogaz üretiminin sağlanması için söz konusu modelin endüstriyel uygulamalara uygun olduğu vurgulanmaktadır. Çalışma, biyogaz tesislerinin süreç stabilitesini artırmak ve verimliliğini optimize etmek adına simülasyon tabanlı yaklaşımların büyük önem taşıdığını ortaya koymaktadır (Ganeshan ve Rajendran 2022).

Gıda atıklarından biyogaz üretimi üzerine bir benzetim çalışması gerçekleştirmiş bulunmaktadır. Aspen Plus yazılımı kullanılarak, termofilik koşullar altında iki aşamalı bir sindirim sistemi modellenmiştir. Çalışmada organik yükleme oranları ve yağ konsantrasyonlarının metan üretimi üzerindeki etkileri ayrıntılı biçimde değerlendirilmiştir. Elde edilen sonuçlar %40 ila %60 oranında yağ içeriğine sahip substratların yaklaşık %77.10'luk en yüksek metan verimini sağladığını göstermektedir. Bu bulgular, biyogaz üretim süreçlerinde substrat bileşimi ve proses parametrelerinin titizlikle yönetilmesi gerektiğini açıkça ortaya koymaktadır. Söz konusu çalışma, endüstriyel ölçekli biyogaz tesislerinin tasarımı ve optimizasyonu açısından önemli bir rehber konumunda bulunmaktadır (Menacho vd. 2022).

Büyük ölçekli biyogaz tesislerindeki biyometan üretim potansiyelini ve kinetiklerini kapsamlı biçimde analiz etmektedir. Bu doğrultuda, farklı substratların karakterizasyonu yapılarak hidrolik bekleme sürelerinin HRT biyometan verimliliği üzerindeki etkileri değerlendirilmektedir. Elde edilen bulgular organik yükleme hızının metan üretim süreçlerini optimize etmede kritik bir rol oynadığını göstermektedir. Ayrıca substratların kimyasal yapısı ile sistem stabilitesi arasındaki etkileşimlerin çeşitli modelleme

yöntemleri aracılığıyla incelendiği ifade edilmektedir. Biyogaz üretim süreçlerinde verimliliği artırmak ve çevresel sürdürülebilirliği sağlamak adına tasarım ile proses iyileştirmelerinin kaçınılmaz olduğunu vurgulayarak literatüre önemli katkılar sunmaktadır. (Sekmen 2022). Çalışmada kullanılan modeller, anaerobik sindirim sürecinin dinamik doğasını yansıtarak daha doğru tahminlemelere olanak tanımaktadır. Bunun yanı sıra, enerji dönüşüm süreçlerinin ekonomik ve çevresel etkileri de çok boyutlu olarak ele alınmaktadır.

2.7 Biyogaz Yapay Zekâ Çalışmaları

Anaerobik sindirim (Anaerobic Digestion-AD) aracılığıyla biyolojik atıkların dönüştürülmesi ve sürdürülebilir enerji üretiminin sağlanması amacıyla geliştirilen matematiksel modellerin parametrik tanımlamaları ve belirsizlik analizleri ele alınmaktadır. Çoklu doğrusal regresyon (Multi Linear Regresion-MLR) ve Genetik Algoritma (Genetic Algorithm-GA) gibi iki farklı yaklaşım, model performansının kıyaslanmasında kullanılarak p-değerlerinin hesaplanması ve hipotez testleri yardımıyla istatistiksel anlamlılık incelenmektedir. Matlab yazılımında gerçekleştirilen bu parametrik tahmin çalışmaları, özellikle model kararlılığı, tahmin doğruluğu ve endüstriyel ölçekli süreçlere uyarlanabilirlik gibi hususlara ışık tutmaktadır. MLR yönteminin birçok parametrede daha istatistiksel olarak anlamlı sonuçlar verdiği görülürken, GA yönteminin de fiziksel kısıtların uygulanabildiği optimizasyonlarda avantajlı olabileceği anlaşılmaktadır. Ayrıca, literatürde Python gibi farklı programlama ortamlarında da benzer yöntemlerin uygulanarak biyogaz üretimi ve çürütücü tasarımlarının optimize edildiği belirtilmekte, bu süreçte hem parametre belirsizlikleri hem de performans metriklerinin sistemli biçimde değerlendirilmesinin büyük önem arz ettiği vurgulanmaktadır (Chaabna ve Semcheddine 2024).

Biyogaz üretiminin tahmini amacıyla MATLAB ve Python yazılımları kullanılarak Çoklu doğal regresyon, Genetik algoritma ve Yapay Sinir Ağları gibi çeşitli algoritmalar uygulandığı gözlemlenmektedir. Bu çalışmalar kapsamında, Doğrusal Olmayan Otoregresif Ağı (Nonlinear Autoregressive Network-NARNET) modeli ile oluşturulan yapay sinir ağları, LM algoritması kullanılarak eğitilmekte ve %48 ile %49 oranında

tahmin doğruluğu sağlamaktadır. Ayrıca, öznitelik seçimi teknikleriyle biyogaz üretimine katkıda bulunan değişkenler belirlenmekte ve modellerin performansı optimize edilmektedir (Özince 2019).

Bio-elektrokimyasal anaerobik sindirim (BEAD) reaktörlerinde metan veriminin tahmini amacıyla MATLAB ve Python programları kullanılarak Tekrarlayan Sinir Ağı (RNN), Rastgele Orman (RF), XGBoost, Destek Vektör Regrasyonu (SVR) ve Uzun-Kısa Süreli Bellek (LSTM) algoritmaları uygulanmıştır. RNN modeli, %97 R^2 değeri ile en yüksek doğruluğu sağlarken, 1-step ahead yeniden eğitim yöntemi %37,3 oranında doğruluk artışı göstermiştir. Ayrıca pH'nin tek giriş parametresi olarak kullanılması, gerçek zamanlı tahminlerde pratik uygulanabilirlik sunmuş ve BEAD süreçlerinin istikrarlı yönetimine katkıda bulunmuştur (Cheon, vd. 2022).

Karışık lignoselülozik ko-substratlarla sığır gübresi kullanılarak biyogaz üretiminin davranışını tahmin etmek amacıyla yapay sinir ağı (YSA) modeli uygulanmaktadır. YSA algoritması, geleneksel yöntemlerle açıklanamayan karmaşık problemlerin çözümünde başarıyla kullanılmaktadır. Çalışmada, biyogaz üretim parametreleri olan bileşim, sıcaklık ve zaman dikkate alınarak YSA ile modelleme ve optimizasyon gerçekleştirilmektedir. Elde edilen model, deneysel değerlere %10 sapma ile %99,7 doğrulukta biyogaz üretimini tahmin etmektedir (Ghatak 2018).

Biyogaz üretiminin tahmininde yapay sinir ağı YSA ve Adaptif Nöral Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System-ANFIS) modelleri başarıyla kullanılmaktadır. Bu çalışmalarda MATLAB yazılımı üzerinden geliştirilmiş YSA ve ANFIS algoritmaları, sıcaklık, pH, FOS/TAC oranı gibi operasyonel parametreleri girdiler olarak alarak biyogaz hacmini yüksek doğrulukla tahmin etmektedir. Elde edilen modellerde R^2 değerleri 0.78 ile 0.81 arasında değişmekte ve düşük RMSE değerleriyle süreç optimizasyonunda etkin sonuçlar sağlamaktadır. Bu yaklaşımlar biyodigester performansının iyileştirilmesinde önemli katkılar sunmaktadır (Rego vd. 2018).

Biyogaz üretim hızının modellenmesinde yapay sinir ağı yapay sinir ağı, bulanık mantık ve çoklu regresyon analizleri başarıyla kullanılmaktadır. Çalışmada tam ölçekli

anaerobik çamur sindirim sisteminden elde edilen verilerle yapay sinir ağları ve bulanık mantık modelleri geliştirilmiş, giriş parametreleri olarak influent çamur akış hızı, toplam katılar, toplam uçucu katılar, alkalinite ve uçucu yağ asitleri dikkate alınmıştır. Bulanık mantık modeli, yapay sinir ağları ve çoklu regresyon modellerine kıyasla daha yüksek doğruluk ($R^2=0.88$) sağlamaktadır. Bu doğruluk seviyesi özellikle süreç kontrolü ve performans tahmini açısından karar destek mekanizmalarının güçlendirilmesinde önemli bir avantaj sağlamaktadır. Bu yöntemler karmaşık ve doğrusal olmayan biyogaz üretim süreçlerinin etkin tahmininde önemli katkılar sunmaktadır (Yetilmezsoy vd. 2021).

Atık depolama sahalarından metan emisyonunun modellenmesinde YSA, ANFIS ve SVM gibi makine öğrenimi teknikleri başarıyla kullanılmaktadır. Bu çalışmada, toplam 9327 ton kapasiteli iki pilot depolama sahasında üç yıllık veri toplanmış ve MATLAB yazılımı kullanılarak modeller geliştirilmiştir. Sızıntı suyu resirkülasyonu sisteminin metan emisyonu üzerindeki etkisi değerlendirilmiş, bu sistemin kullanılmadığı durumda metan emisyonunun %35 oranında azaldığı gözlemlenmiştir. Sonuçlar SVM modelinin metan üretimini %90 ve %82 doğruluk oranıyla tahmin ettiğini göstermekte olup, YSA ve ANFIS modellerine kıyasla üstün performans sergilemiştir. Bu bulgular, makine öğrenimi yöntemlerinin biyogaz üretiminin öngörülmesinde önemli potansiyel taşıdığını ortaya koymaktadır (Mehrdad vd 2021).

Cassava atık sularından biyogaz üretiminin tahmin edilmesi amacıyla YSA modelleri değerlendirilmiştir. MATLAB programı kullanılarak yedi farklı eğitim algoritması uygulanmış ve LM algoritması en yüksek doğruluk ($R=0.9999$) sağlamıştır. Ayrıca, genetik algoritma (GA) ile optimize edilen YSA mimarisi, daha hızlı öğrenme ve üstün tahmin performansı sunmaktadır. GA-YSA hibrit modeli, bireysel YSA modellerine kıyasla daha doğru sonuçlar elde edilmektedir. Bu yaklaşım, anaerobik sindirim süreçlerinin izlenmesi ve optimizasyonunda etkin bir araç olarak kullanılmaktadır. (Cruz vd. 2023)

Atık su arıtma tesisinde tam ölçekli AD sürecinde biyogaz kalitesini olumsuz etkileyen H_2S giderimi YSA modeli kullanılmıştır. 54 günlük AD operasyon verileri MATLAB programı ile 5-3-1 mimarili YSA modeli ve parçacık sürüsü optimizasyonu (PSO)

algoritmasıyla eğitilmiş ve doğrulanmıştır. Optimizasyon sonucunda H₂S konsantrasyonu %49 oranında azaltılarak 6117 ppm'den 3107 ppm'ye düşürülmüştür. Göreceli önem analizi, pH ve birincil çamur fraksiyonunun biyogaz kalitesi üzerindeki en kritik etkenler olduğunu gözlemlenmektedir. Bu modelin uygulaması, AD süreçlerinde H₂S üretiminin etkin kontrolü için düşük maliyetli bir çözüm sunduğu gözlemlenmektedir (Seyedlar vd. 2024).

Almanya'daki bir tarımsal biyogaz tesisinde ölçülen 15 süreç değişkeni kullanılarak YSA modeli geliştirilmiştir. Biyogaz üretim hızının tahmini için uçucu yağ asitleri konsantrasyonu, toplam katılar, uçucu katılar asit deterjan lifi, asit deterjan lignin, nötr deterjan lifi, amonyum azotu, hidrolik tutma süresi ve organik yükleme oranı gibi girdiler MATLAB programı kullanılarak YSA modellerine dahil edilmiştir. Değişken seçimi amacıyla GA ve karınca kolonisi optimizasyonu (Ant Colony Optimization-ACO) yöntemleri uygulanmış, bu sayede önemli süreç değişkenleri belirlenmiş ve model boyutu azaltılmıştır. Optimum YSA modeli, %6,24 tahmin hatası ve R²=0,9 doğruluk katsayısı ile biyogaz üretimini başarılı bir şekilde öngörmüştür. GA ve ACO entegrasyonu, YSA modelinin tahmin kapasitesini artırarak daha güvenilir sonuçlar elde edilmesini sağlamıştır. Bu yaklaşım, biyogaz üretiminin etkin ve güvenilir tahmininde önemli katkılar sunmaktadır (Beltramo vd. 2018).

Anaerobik çürütme performansının tahmininde geleneksel matematiksel modellerin, süreçteki karmaşık ve doğrusal olmayan ilişkiler nedeniyle sınırlı başarı gösterdiği belirtilmektedir. Bu eksiklikleri gidermek için makine öğrenimi (Machine learning-ML) algoritmaları kullanılmaktadır. Örneğin, RNN algoritması, %98,72 gibi yüksek bir başarı oranı ile metan verimini tahmin etmiştir. Çalışmalar, zaman serisi verileriyle eğitilen modellerin geçiş dönemlerinde daha etkili olduğunu göstermektedir. Bu doğrultuda, veri güncellenebilirliği ve esnek algoritma yapısı önemli bir avantaj sağlamaktadır. Retraining yönteminin, özellikle pH gibi kolay izlenebilir parametrelerle, tahmin doğruluğunu artırdığı ve gerçek zamanlı uygulamalarda avantaj sağladığı vurgulanmaktadır. Böylece, süreç kontrolü daha hassas yürütülmekte ve operasyonel verimlilik artmaktadır. Bu bulgular ML'nin biyolojik süreç modellemesindeki potansiyelini ortaya koymaktadır (Park vd. 2021).

Sığır gübresinden farklı organik atıklarla birlikte biyogaz üretimini tahmin etmek için yapay sinir ağı (ANN) modeli kullanılmıştır. MATLAB yazılımı ile geliştirilen model, giriş parametreleri olarak çalışma günleri, giriş KOİ, pH, alkalinite, amonyak, toplam fosfor, hidrolik bekleme süresi (HRT), atık oranı ve ön işleme parametrelerini kullanmıştır. ANN yapısında, dört gizli katmanda tangent sigmoid (tansig) ve çıkış katmanında lineer transfer fonksiyonu (purelin) kullanılmıştır. En iyi sonuçlar dört nöronlu gizli katman ve scaled conjugate gradient algoritmasıyla elde edilmiştir. Modelin doğrulama ($R^2=0.79$) ve test ($R^2=0.75$) adımları biyogaz tahmin performansında yüksek bir başarı sergilemiştir. Bu kapsamda modelin pratik uygulanabilirliğinin oldukça yüksek olduğu değerlendirilmektedir. Simülasyon sonuçları, biyogaz üretiminin %20–30 atık ekleme oranıyla optimize edilebileceğini göstermiştir (Tufaner vd. 2017).

Yam kabuğu substratından biyogaz üretiminin simülasyonunu ve modellemesini gerçekleştirerek termo-kimyasal ön işleme yönteminin etkinliğini araştırmıştır. Modelleme süreci, MATLAB programı kullanılarak ANFIS, YSA ve RSM teknikleri ile yürütülmüştür. Substratın yapısal dönüşümü, FTIR ve SEM analizleri ile doğrulanmıştır. Termo-kimyasal ön işleme yöntemi, substratın biyo-yararlanabilirliğini artırmış ve anaerobik sindirim sürecinde biyogaz üretimini optimize etmiştir. ANFIS, ANN ve RSM yöntemlerinin karşılaştırılması sonucunda, ANFIS modelinin en iyi performansı sergilediği ve en düşük hata değerlerine sahip olduğu belirlenmiştir. Optimizasyon çalışmaları neticesinde, maksimum 356,24 mL biyogaz üretimi; 0.04 NaOH konsantrasyonu, 60 saniye işlem süresi ve 80 °C sıcaklık koşullarında elde edilmiştir. Ayrıca, kinetik analizler sonucunda Modified Logistics modeli, biyogaz üretiminin reaksiyon mekanizmasını en iyi açıklayan model olarak tanımlanmıştır. Üretilen biyogazın saflaştırılması ile %92 oranında metan saflığına ulaşılmıştır (Onu vd. 2022).

Ev tipi gıda katı atıkları ve atık suyun anaerobik ko-digesyon süreçlerinde biyogaz verimini tahmin etmek amacıyla ANN yöntemi kullanılmıştır. Modelleme işlemleri için MATLAB yazılımı ve içindeki ANN Toolbox kullanılmıştır. LM geri yayılım algoritması ile 6 giriş, 10 gizli katman ve 1 çıkış katmanından oluşan çok katmanlı bir ANN modeli oluşturulmuş ve eğitilmiştir. Model, toplam katı madde, uçucu katı madde, sıcaklık, organik yükleme oranı, pH ve besleme oranı gibi verilerle eğitilmiş ve biyogaz verimi

tahmin edilmiştir. Elde edilen sonuçlar, modelin yüksek doğrulukta olduğunu göstermiştir. Modelin başarısı gelecekteki biyogaz üretim tahminlerinde güvenilir bir araç olarak kullanılabileceğini ortaya koymaktadır. Doğrulama için MSE değeri 5.1×10^{-4} , regresyon değeri (R) ise 0.98378 olarak bulunmuştur. Bu sonuçlar modelin biyogaz verimini doğru bir şekilde tahmin edebildiğini kanıtlamaktadır (Orhororo vd. 2017).

Çöp sızıntı suyu ve ananas kabuğunun anaerobik ko-dijesyon süreçleriyle biyogaz üretiminin tahmini için ANN modelleri geliştirilmiştir. Modelleme işlemleri, MATLAB (R2010b) yazılımındaki Neural Network Toolbox 7.0 kullanılarak gerçekleştirilmiştir. Hyperbolik tanjant sigmoid (tansig) ve doğrusal transfer (purelin) fonksiyonlarının kullanıldığı çok katmanlı ileri beslemeli bir ANN mimarisi oluşturulmuş ve LM geri yayılım algoritması ile eğitilmiştir. Veri ayrımı rastgele yapılmış olup, eğitim için %70, doğrulama için %15 ve test için %15 oranları kullanılmıştır. En iyi sonuçlar, 8 gizli nöronlu ağ ile elde edilmiştir. Modelin doğrulama setinde elde edilen MSE değeri 2.67×10^{-2} ve regresyon katsayısı (R) 0.9942 olarak bulunmuştur. Yüksek R değeri, modelin çıktılar ile hedefler arasında güçlü bir korelasyon gösterdiğini doğrulamaktadır. (Jaroenpoj, vd. 2014).

Biyogaz digesterinin hidrotermal gazifikasyon (Hydrothermal Gasification-HTG) süreçlerindeki performansını, sıcaklık, basınç ve besleme konsantrasyonu gibi temel parametrelerin etkilerini incelemek amacıyla gerçekleştirilmiştir. Ayrıca besleme materyalindeki inorganik içeriklerin gaz bileşimi üzerindeki etkileri de dikkate alınmaktadır. MATLAB tabanlı bir termodinamik model kullanılarak, gaz üretimi ve bileşimi tahmin edilmektedir. Çalışma, sıcaklık artışının hidrojen (H_2) üretimini artırırken metan (CH_4) miktarını azalttığını, karbondioksit (CO_2) miktarının ise sınırlı bir değişim gösterdiğini ortaya koymaktadır. Basınç etkisinin daha sınırlı olduğu, ancak CH_4 miktarını artırdığı ve hidrojen miktarını bir miktar azalttığı gözlemlenmektedir. Besleme konsantrasyonundaki artışın, metan üretimini artırırken hidrojen ve toplam gaz verimini düşürdüğü belirlenmektedir. Sonuçlar, besleme materyalindeki inorganik içeriklerin karbonat tuzlarının oluşumunu teşvik ettiği ve bu durumun hidrojen ve CH_4 miktarlarını artırdığına işaret etmektedir. Elde edilen bulgular, hidrotermal gazifikasyon (Hydrothermal Gasification-HTG) süreçlerinin iyileştirilmesi ve entegre sistemlerin tasarımına yönelik önemli bir katkı sunmaktadır (Rahma vd.2023).

Biyogaz üretim sürecinin analizi ve biyogaz akış hızının tahmini için bir yöntem geliştirilmiştir. Veri üretimi için ADM1 kullanılmış ve bu model Matlab/Simulink platformunda uygulanmıştır. ANN, biyogaz akış hızını tahmin etmek için kullanılmıştır. Optimizasyon amacıyla ACO uygulanarak önemli süreç değişkenleri belirlenmiş ve model boyutu küçültülerek performans artırılmıştır. Simülasyon sonuçlarına göre ANN modelleri yalnızca üç giriş nöronu (amino asitler, karbonhidratlar ve proteinler) ve üç gizli nöron ile biyogaz akış hızını başarıyla tahmin edebilmiştir. Tahmin doğruluğu kök ortalama kare hatası (RMSE) %5.22 ve belirleme katsayısı (R^2) 0.88 olarak hesaplanmıştır (Beltramo vd. 2016).

Atık su arıtma tesislerinde koku sınıflarının ve konsantrasyonlarının izlenmesi için makine öğrenmesi tabanlı bir sistem geliştirilmiştir. Bu çalışmada, Random Forest (Rastgele Orman-RF) ve çok katmanlı yapay sinir ağı (MLP) algoritmaları uygulanmıştır. RF algoritması, sınıflandırma için %97 Cohen's kappa ve konsantrasyon tahmini için %4 Normalize RMSE ile en iyi performansı göstermiştir. Araştırmada, RF'nin karmaşık koku kaynaklarını doğru şekilde sınıflandırmada ve ölçmede yüksek doğruluk sağladığı rapor edilmektedir (Cangialosi vd. 2021).

Anaerobik sindirimde makine öğrenmesi uygulamaları süreç stabilitesini artırmakta ve üretkenliği optimize etmektedir. Çalışmada, yapay sinir ağı, destek vektör makinesi), rastgele orman ve adaptif bulanık sinir sistemi gibi algoritmaların kullanıldığı örnekler sunulmuştur. ANN modelleri laboratuvar ölçeğinde yüksek doğruluk göstermekte; RF ve XGBoost ise endüstriyel ölçekte metan üretimi tahmininde başarılı bulunmuştur. RMSE ve R^2 değerlerinin çoğu çalışmada %90'ın üzerinde olduğu vurgulanmaktadır (Cruz vd. 2022).

Anaerobik sindirimde metan üretimini tahmin etmek amacıyla çeşitli topluluk makine öğrenmesi modelleri karşılaştırılmıştır. RF, SVM, Extreme XGBoost ve ANN gibi algoritmalar kullanılmıştır. Topluluk modelleri, bireysel yöntemlere göre daha düşük varyanslı ve daha istikrarlı sonuçlar üretmiştir. Özellikle 10 katlı çapraz doğrulama ile yapılan 100 tekrarda, düşük RMSE ve yüksek R^2 değerleri elde edilmiştir. En iyi sonuç çoklu algoritmaların birleşimi ile sağlanmıştır (Radočaj ve Jurišić, 2025).

Yeşil bina uygulamaları kapsamında biyogaz enerjisinin sürdürülebilir bir şekilde sağlanması amacıyla çok modellenli bir akıllı çerçeve geliştirilmiştir. Yapay zekâ teknikleri arasında ANFIS algoritması, kümülatif biyogaz üretiminin tahmininde en yüksek başarıyı göstermektedir. ANFIS modeli, doğruluk ölçütü olan korelasyon katsayısı (R^2) açısından 0.99 değeri ile öne çıkmaktadır. Bu başarı, diğer algoritmalar olan Random Tree, Random Forest ve Yapay Sinir Ağları'na göre daha yüksek bulunmuştur. Sonuç olarak, önerilen sistem entegre kontrol kabiliyeti sayesinde biyogaz üretiminin optimize edilmesinde etkili olmaktadır (Shahsavari vd. 2021).

Tükenmiş mantar kompostunun anaerobik sindirimi sürecinde biyogaz üretimini tahmin etmek amacıyla veri odaklı modeller geliştirilmiştir. KNN ve SVM algoritmaları kullanılmıştır. SVM modeli, 35°C sıcaklıkta $R^2 = 0.9973$ ve 55°C sıcaklıkta $R^2 = 0.9989$ değerleri ile en yüksek doğruluğu sağlamaktadır. Aynı zamanda SVM modeli, KNN modeline kıyasla %58.4 ve %49.5 daha düşük RMSE değerleri göstermektedir. Bu sonuçlara istinaden, SVM modelinin biyogaz üretiminin doğru ve istikrarlı tahmininde oldukça güvenilir bir yöntem olduğunu ortaya koyduğu gözlemlenmiştir (Salehi vd. 2022).

Anaerobik sindirim sürecinde antibiyotik direnç genleri ve mobil genetik elementlerin bolluğundaki değişimlerin tahmin edilmesi amacıyla çeşitli makine öğrenmesi algoritmaları uygulanmaktadır. ANN, RF ve XGBoost yöntemleri karşılaştırılmıştır. ANN modeli, R^2 değeri ve düşük RMSE sonuçları açısından diğer algoritmalara üstünlük sağlamaktadır. Çalışmada, işletme modu, ortak sindirim kullanımı ve bekleme süresinin ARG ve MGE bolluğunda en etkili faktörler olduğu tespit edilmektedir (Haffiez vd. 2022).

Gıda atığı kaynaklı AD süreçlerinde çevresel faktörler ve mikrobiyal toplulukların etkileşimlerini incelemek amacıyla yorumlanabilir makine öğrenmesi modelleri geliştirilmiştir. Çalışmada RF, XGBoost ve SVR gibi algoritmalar kullanılmıştır. RF algoritması, test aşamasında $R^2 = 0.9879$ değeri ile en yüksek doğruluk oranına ulaşmaktadır. Geliştirilen modeller biyogaz üretim süreçlerinin daha derinlemesine anlaşılmasına süreç kontrol stratejilerinin iyileşmesine katkı sağlamaktadır. Ayrıca SHAP

analizine göre, bakteriyel cinsler, biyogaz verimliliği üzerinde çevresel faktörlerden daha büyük bir etkiye sahiptir. Bu bulgular AD performansının optimizasyonu için mikrobiyal topluluk yapısının önemini vurgulamaktadır (Guo vd. 2025).

Biyokütlenin biyokimyasal bileşimi temel alınarak BMP tahmini amacıyla makine öğrenmesi tabanlı hibrit modeller geliştirilmiştir. GAN ile veri artırımı yapılmış ve GBR, RF, SVM ve ANN algoritmaları kullanılmıştır. GBR modeli, GAN ile artırılmış veri setinde test aşamasında $R^2 = 0.9177$ değeri ile en yüksek doğruluğa ulaşmaktadır. Grid search optimizasyonu ile R^2 değeri 0.9213'e yükseltilmiştir. Bulgular, selüloz içeriğinin BMP üzerinde en etkili değişken olduğunu göstermektedir (Adeleke vd. 2024).

2.8 Elektrik Üretim Tasarımı Yapılan Çalışmalar

Biyoyakıtlı Brayton döngüsü, GES ve su kaynaklı ısı pompalarını entegre eden bir kojenerasyon mikro şebekesinin tasarımını ve optimizasyonunu gerçekleştirmiştir. Önerilen sistem, enerji tüketim maliyetlerini %71.6 oranında azaltarak günlük enerji maliyetini 2903.8 dolardan 823.6 dolara düşürmüştür. Ayrıca, şebeke elektrik talebinde %78.96'lık bir azalma sağlanmış ve bu da şebeke üzerindeki yükün önemli ölçüde hafiflemesine katkıda bulunmuştur. Biyoyakıt kullanımı, karbon emisyonlarını azaltarak çevresel faydalar sağlamış ve sürdürülebilir enerji hedeflerine önemli ölçüde katkıda bulunmuştur. GES, düşük talep saatlerinde fazla enerjiyi depolayarak, yüksek talep sırasında bu enerjiyi serbest bırakmış ve böylece enerji arz-talep dengesini başarıyla sağlamıştır. Yapılan simülasyonlar, sistemin esnek ve güvenilir olduğunu, farklı endüstriyel senaryolara uyarlanabilir bir çözüm sunduğunu göstermiştir. Elde edilen sonuçlar hem ekonomik hem de çevresel açıdan önerilen yaklaşımın etkili olduğunu ortaya koymaktadır (Taheri vd. 2023).

Mikro türbin jenerasyon sistemleri biyogaz santralleri için modelleme ve simülasyon yoluyla incelenmiştir. MATLAB/Simulink tools'u kullanılarak gerçekleştirilen çalışmada, tek şaftlı mikro türbin modeli Rowen'in gaz türbini modeline dayandırılmış ve hız, sıcaklık ile yakıt akışı kontrolü sağlanmıştır. Kalıcı mıknatıslı senkron jeneratör, dq-dönüşümlü model kullanılarak analiz edilmiş ve 30.000-100.000 rpm arasında yüksek hızlarda çalışması optimize edilmiştir. Güç elektroniği arayüzü, AC-DC doğrultucu ve

DC-AC inverter ile sinüzoidal darbe genişlik modülasyonu kontrolüne dayalı olarak tasarlanmış ve 60 Hz. sabit frekans sağlanmıştır. Simülasyon sonuçları, sistemin yük değişimlerine karşı kararlı bir şekilde yanıt verdiğini ve enerji dönüşüm verimliliğinin optimize edildiğini göstermektedir (Gaonkar ve Patel 2006).

Mikro türbin jenerasyon sisteminin dinamik modellemesi MATLAB/Simulink platformunda gerçekleştirilmiştir. Modelleme, gaz türbini, kalıcı mıknatıslı senkron jeneratör güç düzenleme birimi ve yük bileşenlerini içermektedir. Gaz türbini, hız, sıcaklık ve yakıt kontrol döngülerine dayalı olarak modellenmiştir. PMSG, qdo eksen eşdeğer devresi kullanılarak detaylı bir şekilde simüle edilmekte, jeneratörün yüksek hızlarda (60.000-120.000 rpm) kararlı bir performans sergilemesi sağlanmaktadır. Güç düzenleme biriminde SPWM kontrollü inverter ile doğrultulmuş DC gerilim 50-60 Hz frekansta AC gerilime dönüştürülmektedir. Simülasyon sonuçları, sistemin dinamik yük koşullarına hızlı bir şekilde yanıt verdiğini ve 2 saniye içinde kararlı duruma ulaştığını göstermektedir. Jeneratör aktif gücü ve inverter çıkış voltajı başarılı bir şekilde elde edilmiştir. Bu model, mikro türbinlerin dağıtık enerji üretim sistemlerindeki performansını analiz etmek ve şebeke entegrasyonu üzerindeki etkilerini değerlendirmek için etkili bir araç sunmaktadır (Abdollahi ve Vahedi 2005).

Bu çalışmada mikro türbinlerin dağıtık jeneratör olarak kullanımı için bir dinamik model geliştirilmiştir. Modelleme işlemi MATLAB/Simulink Toolbox ve Power System Blockset programları kullanılarak gerçekleştirilmiştir. Simülasyon sonuçlarına göre, mikro türbin 0.2 saniyede nominal hızına ulaşmakta ve 0.3 saniye içinde 1 p.u. voltaj profili sağlamaktadır. Jeneratörün ürettiği 1200 Hz. yüksek frekanslı gerilim önce doğrultularak DC gerilime dönüştürülmekte, ardından inverter yardımıyla 60 Hz'lik AC gerilime çevrilmektedir. Son aşamada, LC filtre harmonikleri azaltmakta ve PI regülatör yardımıyla yük voltajı 250 V tepe değerinde sabitlenmektedir. (Al-Hinai ve Feliachi 2002).

3. MATERYAL ve METOT

Biyogaz santralinde elde edilen tavuk atığına bağlı olarak anaerobik metan gazı üretiminin tahmin edilmesi amaçlanmaktadır. Bu doğrultuda üç farklı modelleme yaklaşımı benimsenmiş ve geliştirilen modellerin tahmin kapasiteleri karşılaştırmalı olarak değerlendirilmektedir.

İlk modelleme yaklaşımında, yapay sinir ağları (YSA) kullanılarak metan üretimi tahmini gerçekleştirilmektedir. Bu kapsamda TrainLM (Levenberg-Marquardt), TrainBR (Bayesian Regularization) ve TrainSCG (Scaled Conjugate Gradient) olmak üzere üç farklı eğitim algoritması kullanılmıştır. Bu algoritmalar, hiperparametre optimizasyonu süreciyle birlikte değerlendirilmiş olup özellikle gizli katman sayısı, nöron sayısı ve aktivasyon fonksiyonlarının belirlenmesinde etkili olmaktadır. YSA modellerinde giriş parametreleri olarak atık miktarı, katı madde (KM) ve organik katı madde (OKM) değerleri kullanılmış; bu parametreler doğrultusunda digester içerisindeki biyokimyasal değişimler öğrenilerek metan üretimi tahmin edilmiştir.

İkinci modelleme yaklaşımı kapsamında, çeşitli makine öğrenmesi (Machine Learning - ML) algoritmaları kullanılarak metan gazı üretimi öngörülmektedir. Bu çerçevede Karar Ağaçları (Decision Tree-DT), Rastgele Ormanlar (Random Forrest-RF), Destek Vektör Regresyonu (Support Vector Machine-SVM), Gradyan Artırmalı Makineler (Gradiend Boost Machine-GBM) ve K-En Yakın Komşu (K-Nearest Neighbors -KNN) algoritmaları uygulanmıştır. Her bir algoritma için model yapısına özgü hiperparametreler, sistematik tarama ve deneme-yanılma temelli yaklaşımlar aracılığıyla optimize edilmiştir. ML modelleri, giriş parametreleri olan atık miktarı, KM ve OKM değerleri üzerinden eğitilmiş; model doğruluğu hata metrikleri ve istatistiksel performans göstergeleri ile analiz edilmiştir.

Üçüncü modelleme yaklaşımında ise, literatürde yer alan kinetik denklemler temel alınarak biyogaz üretim süreci Simulink ortamında modellenmiştir. Bu modelde, KM ve OKM değerleri giriş olarak alınmakta; sistemden çıkan metan gazı miktarı ile buna bağlı olarak elde edilen elektrik üretimi simule edilmektedir. Geliştirilen Simulink modeli, gerçek santral verileri ile karşılaştırılarak doğruluk açısından test edilmiştir.

Her iki modelleme yaklaşımda da tahmin performansını artırmak amacıyla hiperparametre optimizasyonu süreci uygulanmıştır. YSA modellerinde farklı eğitim algoritmaları ile birlikte yapısal hiperparametreler optimize edilirken, ML algoritmalarında ise yöntemlere özgü parametreler sistematik olarak değerlendirilmiştir. Ayrıntılı hiperparametre yapılandırmaları ve optimizasyon sonuçları ilgili bölümlerde detaylı olarak sunulmaktadır.

Çalışmada kullanılan veri seti, Afyonkarahisar ili sınırlarında yer alan Çobanlar Biyogaz Santrali'ne ait günlük üretim verilerinden oluşmaktadır. Verilerin hazırlanması sürecinde arıza, bakım ve resmî tatil günleri dışlanmış; toplamda 305 günlük aktif veri değerlendirmeye alınmıştır. Metan gazı içeriği yaklaşık %55 olan bu veriler, eğitim ve test süreçlerinde kullanılarak modellerin gerçek saha koşullarına duyarlılığı artırılmaya çalışılmıştır.

3.1 Biyogaz Santrali Biyogaz Üretim Süreci Simulink Modeli

Biyogaz üretim sürecinin matematiksel temellere dayalı olarak modellenmesi ve zamana bağlı dinamik simülasyonunun gerçekleştirilmesi amacıyla Simulink yazılımından yararlanılmaktadır. Anaerobik sindirimin temel biyolojik aşamaları olan hidroliz, asidogenez, asetogenez ve metajenez süreçleri, sistematik bir yapı içerisinde modellenmekte ve her bir biyolojik adım, literatürde önerilen kinetik prensiplere uygun şekilde lineer diferansiyel denklemler aracılığıyla temsil edilmektedir (Husain, 1998). Bu kapsamda, biyokimyasal reaksiyonların dinamikleri detaylı bir biçimde ele alınarak, reaktördeki substrat tüketimi ve mikrobiyal büyüme mekanizmalarının zamanla değişimi modellenmektedir. Simülasyon süreci, biyogaz üretim sürecinin farklı çalışma koşulları altında nasıl değiştiğini öngörmeye ve sistem performansının iyileştirilmesine olanak tanımaktadır (Pathmasiri vd. 2013).

Simulink modelinde kullanılan diferansiyel denklemler, literatürde tanımlanan kinetik parametreler ve deneysel veriler ile ilişkilendirilerek yapılandırılmaktadır. Böylece modelin hem doğruluğu hem de güvenilirliği artırılmakta ve tahmin edilen sonuçlar ile gerçek ölçümler arasındaki uyum güçlendirilmektedir (Saeed vd. 2019). Modelleme

sürecinde reaktör sıcaklığı, reaktör hacmi, giriş atık miktarı, KM, OKM, FOS ve TAC gibi birçok operasyonel parametre dikkate alınmaktadır.

Her bir parametrenin değişimi, model üzerinde ayrı ayrı analiz edilmekte ve sistem davranışına olan etkileri değerlendirilerek süreç optimizasyonu hedeflenmektedir. Bu kapsamlı analiz yaklaşımı, biyogaz üretim sürecinin daha verimli ve kararlı bir şekilde yürütülmesini desteklemektedir.

Süreç sonunda hesaplanan metan gazı üretimi, mikro türbin (MT) modülü ile entegre edilerek biyogazdan elektrik üretimi simüle edilmektedir (Gaonkar ve Patel, 2006). Bu entegrasyon sayesinde elde edilen biyogazın enerji dönüşüm verimliliği gerçek zamanlı olarak değerlendirilmekte ve sistemin toplam performansı izlenmektedir. Mikro türbin modeli, Simulink ortamında matematiksel ifadeler ile tanımlanmış olup, yakıt tüketimi, shaft gücü ve jeneratör çıkışı gibi parametreler dinamik olarak hesaplanmaktadır. Böylece biyogaz üretimi ile elektrik üretimi süreçleri eş zamanlı ve entegre bir yapı içerisinde analiz edilebilmektedir. Geliştirilen model hem biyolojik süreçlerin hem de enerji üretim sistemlerinin kinetik prensiplere dayalı hesaplamalarını gerçekleştirmekte ve gelecekteki çalışma senaryoları için güçlü bir simülasyon altyapısı sunmaktadır.

3.1.1 Hidroliz Modeli

Hidroliz, anaerobik sindirim süreçlerinin başlangıç aşaması olup, kompleks organik maddelerin mikroorganizmalar tarafından salgılanan ekstrasellüler enzimler aracılığıyla çözünmüş organik bileşiklere dönüştürülmesini sağlamaktadır (Pathmasiri vd. 2013). Bu aşamada organik materyalin biyolojik olarak kullanılabilir forma indirgenmesini sağlayarak, anaerobik sindirimin sonraki evreleri için temel hazırlamaktadır (Saeed vd. 2019). Hidroliz süreci sırasında, enzimatik aktiviteler sonucu kompleks yapılar çözünür hale gelirken, mikrobiyal topluluklar tarafından daha ileri biyokimyasal dönüşümler için gerekli ara ürünler oluşturulmaktadır (Husain, 1998).


Bu çalışmada, hidroliz aşaması, matematiksel olarak birinci dereceden kinetik bir denklemle modellenmiştir. Sürecin temel diferansiyel denklemi denklem (13)'te ifade edilmektedir (Pathmasiri vd. 2013):

$$\frac{d(S_b)}{dt} = (S_{b_{in}} - S_b) \cdot \frac{F_{feed}}{V} + \frac{\mu_m \cdot K_1 \cdot X_{acid}}{\frac{K_s}{S_b} + 1} \quad (13)$$

Denklemdaki parametrelerin açıklamaları:

- S_b : Reaktördeki biyolojik olarak parçalanabilir katı madde konsantrasyonu (kg/m^3),
 $S_{b_{in}}$: Reaktöre giren biyolojik olarak parçalanabilir katı madde konsantrasyonu (kg/m^3),
 F_{feed} : Reaktöre beslenen günlük substrat miktarı ($\text{m}^3/\text{gün}$),
 V : Reaktör hacmi (m^3),
 μ_m : Mikroorganizmaların maksimum büyüme hızı (gün^{-1}),
 K_1 : Asit üreten mikroorganizmaların dönüşüm katsayısı (kg/m^3)
 X_{acid} : Asit üreten mikroorganizmaların konsantrasyonu (kg/m^3)
 K_s : asit üreten mikroorganizmalar (asidogenler) için Monod yarı-hız sabiti (kg/m^3)

Denklem (13)'de tanımlanan diferansiyel denklem yapısı, anaerobik sindirim sürecinin zamana bağlı dinamiklerini modellemek amacıyla yapılandırılmıştır. Bu matematiksel model, Simulink ortamında blok diyagramlar aracılığıyla temsil edilerek görselleştirilmiştir (Saeed vd. 2019). Şekil 3.1'de verildiği üzere, substratların ayrışımı, mikrobiyal büyüme ve metan üretimi gibi temel süreçleri içeren bu model, sistemin işleyişini zamana bağlı olarak simüle etmeye olanak sağlamaktadır (Pathmasiri vd. 2013). Modelde her bir biyokimyasal adım, literatürde belirtilen kinetik prensipler doğrultusunda parametrelerle ilişkilendirilmiş ve Simulink blokları ile yapılandırılmıştır. Her bir biyokimyasal adım, literatürde belirtilen kinetik prensipler doğrultusunda parametrelerle ilişkilendirilmiş ve Simulink blokları ile yapılandırılmıştır. Ayrıca, kullanılan modelde metan üretimi, asidogen ve metanogen popülasyonları ile doğrudan ilişkilendirilerek modellenmiştir; Euler yöntemi ve ode23 çözümleyicisiyle de doğrulama analizleri gerçekleştirilmiştir. Böylece hem Matlab kod tabanlı hem de blok tabanlı yaklaşımlarla sistem davranışı zamana bağlı olarak detaylı biçimde incelenebilmiştir (Saeed vd. 2019). Bu yapı sayesinde akış hızı ve substrat kompozisyonu gibi parametrelerin metan üretimi üzerindeki etkileri sayısal olarak değerlendirilebilmektedir. Bu şekilde biyogaz üretim süreci daha bütüncül ve sistematik bir yaklaşımla detaylı şekilde analiz edilebilmektedir.



Şekil 3.1 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan hidroliz MATLAB/Simulink modeli.

3.1.2 Asidojenez Modeli

Asidojenez, anaerobik sindirim sürecinin ikinci aşaması olup, hidroliz sonucu oluşan çözünmüş organik bileşiklerin uçucu yağ asitlerine dönüştürülmesini kapsamaktadır. Bu süreç asidojenik mikroorganizmaların aktiviteleri sonucunda gerçekleşmekte ve biyogaz üretimi için kritik bir ara ürün olan VFA'ları üretmektedir. Ayrıca bu aşamada karbon dioksit (CO₂) ve hidrojen (H₂) gibi gazlar da açığa çıkmaktadır.

Asidojenez aşaması, Simulink modelinde denklem (14)'te diferansiyel denklem ile temsil edilmiştir (Pathmasiri vd. 2013):

$$\frac{d(S_v)}{dt} = (S_{v_{in}} - S_v) \cdot \frac{F_{feed}}{V} + \frac{\mu_m \cdot K_2 \cdot X_{acid}}{\frac{K_s}{S_b} + 1} - \frac{\mu_{mc} \cdot K_3 \cdot X_{meth}}{\frac{K_{sc}}{S_v} + 1} \quad (14)$$

Denklemdaki parametrelerin açıklamaları:

S_v : Reaktördeki toplam uçucu yağ asidi (VFA) konsantrasyonu (kg/m³),

S_b : Reaktördeki biyolojik olarak parçalanabilir katı madde konsantrasyonu (kg/m³),

$S_{v_{in}}$: Reaktöre giren substrat uçucu yağ asidi konsantrasyonu (kg/m³),

F_{feed} : Reaktöre beslenen günlük substrat miktarı (m³/gün),

V : Reaktör hacmi (m^3),

μ_m : Mikroorganizmaların maksimum büyüme hızı ($gün^{-1}$),

K_1 : Asit üreten mikroorganizmaların dönüşüm katsayısı (kg/m^3)

X_{acid} : Asit üreten mikroorganizmaların konsantrasyonu (kg/m^3)


μ_{mc} : Metanojenik mikroorganizmaların büyüme hızı ($gün^{-1}$),

X_{meth} Metanojenik mikroorganizmaların konsantrasyonu (kg/m^3)

K_2 : deneysel veriler kullanılarak tahmin edilen verim

K_3 : Metan gazının büyüme hızıyla ilişkili verim faktörü

Denklem (14)'de tanımlanan diferansiyel denklem yapısı, asidojeniz sürecinin zamana bağlı biyokimyasal dönüşümlerini modellemek amacıyla yapılandırılmıştır. Bu yapı, Simulink ortamında blok diyagramlar aracılığıyla temsil edilerek görselleştirilmiştir (Saeed vd. 2019). Şekil 3.2'de kinetik parametreler doğrultusunda yapılandırılmıştır. Modelde, hidroliz sonrası oluşan çözünmüş organik bileşiklerin uçucu yağ asitlerine dönüşüm süreci zamana bağlı olarak simüle edilmiştir.



Şekil 3.2 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan asidojeniz MATLAB/Simulink modeli

3.1.3 Asedogenez Modeli

Asetogenez, anaerobik sindirim sürecinin üçüncü aşaması olup, uçucu yağ asitlerinin (VFA), hidrojen (H_2) ve karbon dioksit (CO_2) yardımıyla asetata dönüştürülmesini kapsamaktadır (Hagos vd. 2017). Bu süreç asetojenik mikroorganizmaların aktiviteleri

ile gerçekleşmekte ve metan üretimi için kritik bir ara ürün olan asetatı oluşturmaktadır. Aynı zamanda bu aşamada üretilen (H_2) konsantrasyonu, metanojenik mikroorganizmaların aktivitesini doğrudan etkilemektedir (Neshat vd. 2017).

Asetogenez süreci, Simulink modelinde denklem (15)'te görüldüğü üzere diferansiyel denklemle modellenmiştir (Pathmasiri vd. 2013):

$$\frac{d(X_{acid})}{dt} = \left[\frac{\mu_m}{\frac{K_s}{S_b} + 1} - K_d - \left(\frac{F_{feed}/b}{V} \right) \right] \cdot X_{acid} \quad (15)$$

Denklemdaki parametrelerin açıklamaları;

X_{acid} : Reaktördeki asit üreten mikroorganizmaların konsantrasyonu (kg/m^3)

μ_m : Mikroorganizmaların maksimum büyüme hızı ($gün^{-1}$),

K_s : Asitogenler için Monod yarı-hız sabiti (kg/m^3),

S_b : Reaktördeki biyolojik olarak parçalanabilir katı madde konsantrasyonu (kg/m^3),


K_d : Mikroorganizmaların ölüm hızı ($gün^{-1}$),

F_{feed} : Reaktöre beslenen günlük substrat miktarı ($m^3/gün$),

B : Reaktördeki biyolojik atıkların yoğunluğu (kg/m^3),

V : Reaktör hacmi (m^3)

Denklem (15)'de tanımlanan diferansiyel denklem yapısı, asetogenez sürecinin zamana bağlı biyokimyasal dönüşümlerini modellemek amacıyla yapılandırılmıştır. Bu model Simulink ortamında blok diyagramlar aracılığıyla temsil edilerek Şekil 3.3'te gösterilmiştir (Saeed vd. 2019). Şekil 3.3'te verilen yapı, ara ürünlerin asetat gibi son ürünlere dönüşümünü zamana bağlı olarak simüle etmeye olanak sağlamaktadır (Pathmasiri vd. 2013). Model, literatürde tanımlanan kinetik prensipler doğrultusunda parametrik olarak yapılandırılmıştır. Aynı zamanda modelin farklı senaryolar altında yeniden yapılandırılmasına da olanak sağlamaktadır. Bu sayede reaktör içerisindeki kimyasal süreçlerin dinamik karakteristikleri detaylı biçimde analiz edilebilmektedir.



Şekil 3.3 Anaerobik sindirim sürecinin diferansiyel denklem yapısına göre oluşturulan asetogenez MATLAB/Simulink modeli.

3.1.4 Metanojenes Modeli

Metanojenез, anaerobik sindirimin son aşaması olup, metan (CH_4) ve karbon dioksit (CO_2) gibi biyogaz bileşenlerinin üretimini gerçekleştiren temel süreçtir (Hagos vd. 2017). Bu aşama, asetojenik süreçte üretilen asetat ve hidrojen (H_2) gibi ara ürünlerin metanojenik mikroorganizmalar tarafından dönüştürülmesiyle gerçekleşmektedir (Husain, 1998). Metanojenik mikroorganizmalar, biyogaz üretiminde doğrudan etkili olan son ürünleri oluşturur ve bu aşamada enerji verimliliği büyük ölçüde belirlenir (Gaonkar ve Patel, 2006).

Metanojenез sürecinin temel diferansiyel denklem, denklem (16)'da sunulmaktadır (Pathmasiri vd. 2013):

$$\frac{d(X_{meth})}{dt} = \left[\frac{\mu_{mc}}{\frac{K_{sc}}{S_v} + 1} - K_{dc} - \left(\frac{F_{feed}/b}{V} \right) \right] \cdot X_{meth} \quad (16)$$

Denklemdaki parametrelerin açıklamaları;


X_{meth} Metanojenik mikroorganizmaların konsantrasyonu (kg/m^3)

μ_{mc} : Metanojenlerin maksimum büyüme hızı (gün^{-1}),

K_{sc} : Metanojenler için Monod yarı-hız sabiti (kg/m^3)

S_v : Reaktördeki uçucu yağ asidi (VFA) konsantrasyonu (kg/m^3),

K_{dc} : Metanojenlerin ölüm hızı sabiti (gün^{-1}),



Şekil 3.5 MT hız kontrolü blok diyagram

Mikro türbin sistemlerinde hız kontrolü, referans hız ile jeneratör rotor hızının karşılaştırılması sonucu elde edilen hız hatası üzerinden sağlanmaktadır (Pathmasiri vd. 2013). Geliştirilen modelde, hız kontrolü için lead-lag transfer fonksiyon yapısı tercih edilmiş ve bu yapı Simulink ortamında droop kontrollü sabit hız referansı ile modellenmiştir (Gaonkar ve Patel, 2006).

Sistemde kullanılan hız kontrolüne ilişkin transfer fonksiyonu denklem (17)'de ifade edilmektedir (Khorshidi vd. 2014):

$$K(s) = \frac{K(T_1s + 1)}{T_2s + Z} \quad (17)$$

Denklemdaki parametrelerin açıklamaları:

K: Hız kontrolörü kazancı


T_1 : Lead (ileri faz) zaman sabiti

T_2 : Lag (geri faz) zaman sabiti

Z: Gönernor sabiti

Sıcaklık kontrolü, yanma çıkış sıcaklığının belirli bir referans değerinde sabitlenmesini amaçlamaktadır. Bu kontrol mekanizmasında egzoz gazı sıcaklığı, termokupllar ve radyasyon kalkanları aracılığıyla ölçülmekte ve LVG sistemi üzerinden türbin çıkışı sınırlanmaktadır (Saeed vd. 2019). Termokupttan elde edilen sinyalin referans sıcaklığı aşması durumunda, sıcaklık kontrol çıkışı azaltılarak türbin yakıt girişi

sınırlanmaktadır. Bu yapıya ilişkin sıcaklık kontrolü blok diyagramı şekil 3.6’da sunulmaktadır.



Şekil 3.6 MT sıcaklık kontrolü blok diyagram

Sistemde kullanılan sıcaklık kontrolüne ilişkin transfer fonksiyonu denklem (18)’de ifade edilmektedir (Pathmasiri vd. 2013):

$$T_x = T_R - 700(1 - W_f) + 550(1 - N) \quad (18)$$

Denklemdaki parametrelerin açıklamaları:


T_x : Türbin egzoz sıcaklığı (C°)

T_R : Referans sıcaklık (C°)

W_f : Yakıt akış sinyali (p.u.)

N : Normalize rotor hızı (p.u.)

Mikro türbinin yakıt sistemi, yakıt valfi ve aktüatör mekanizmasından oluşmakta olup, bu sistemin çıkışı hız ve sıcaklık kontrol sinyalleriyle yönlendirilmektedir (Saeed vd. 2019). Yakıt akış sinyali W_f türbinin ihtiyaç duyduğu yakıt miktarını temsil ettiği görülmektedir. Sisteme ait blok diyagramı şekil 3.7’de sunulmaktadır.



Şekil 3.7 MT yakıt kontrolü blok diyagram

Sistemde kullanılan yakıt sistem kontrolüne ilişkin transfer fonksiyonu denklem (19)'da ifade edilmektedir (Pathmasiri vd. 2013):

$$W_f = \frac{K_f}{T_f s + C} E_i \quad (19)$$

Denklemdaki parametrelerin açıklamaları:


W_f : Yakıt akış talebi (p.u)

K_f : Yakıt valfi ve aktüatör kazancı

T_f : Yakıt sistem zaman sabiti

E_i : Giriş sinyali

Sistem MT kontrol fonksiyonlarına ait tüm kontrol fonksiyonları şekil 3.8'de blok diyagram olarak sunulmaktadır (Saeed vd. 2019).



Şekil 3.8 MT kontrol fonksiyonuna ait blok diyagramı

Mikro türbinin kompresörü, yanma odasına yeterli miktarda hava beslemesini sağlamakta ve türbin ile birlikte çalışmaktadır (Saeed vd. 2019). Kompresör-türbin etkileşimi, gazın gecikmeli taşınmasını da içerecek şekilde bir modelle temsil edilmektedir. Yakıt kontrol sistemi, LVG çıkışını temel alarak yakıt valfi dinamiklerini simüle etmekte ve türbinin çalışmasını dengelemektedir. Kompresör-türbin etkileşimi, normalize rotor hızı ve yakıt akışı parametrelerine bağlı olarak modellenmiş; sistemin tüm bu bileşenleri

MATLAB/Simulink ortamında blok diyagramlar aracılığıyla yapılandırılmıştır. Şekil 3.9’da verilen model, mikro türbinin dinamik kontrol bileşenlerini içeren bütüncül yapısını göstermektedir (Saeed vd. 2019). Bu bütünleşik yaklaşım, mikro türbin performansının farklı işletme koşulları altında güvenilir bir şekilde simüle edilmesini mümkün kılmaktadır (Erario vd. 2022). Modelde kullanılan bileşenler arasında kurulan geri besleme ilişkileri sayesinde sistem kararlılığı sürekli olarak izlenebilmektedir. Bu yapı hem enerji üretim verimliliğinin değerlendirilmesine hem de olası kontrol stratejilerinin karşılaştırılmasına imkân tanımaktadır.

Şekil 3.9 MT bütüncül yapısı MATLAB/Simulink Modeli

PMSG modeli genellikle dq0 referans çerçevesi kullanılarak ifade edilmektedir (Gaonkar ve Patel, 2006). Bu referans sisteminde stator akımı, gerilimi ve akı bileşenleri d (doğrudan eksen) ve q (kuadratur eksen) bileşenlerine ayrılarak analiz edilmektedir.

Daimî mıknatıslı senkron jeneratörün elektriksel modeli, stator sargılarında oluşan gerilim-akım ilişkileri ve manyetik akı bileşenlerini dikkate alan diferansiyel denklemler temelinde oluşturulmuştur. Sistem, dq0 referans çerçevesinde yapılandırılmış olup, gerilim denklemleri ve manyetik akı ilişkileri Simulink bloklarıyla zamana bağlı olarak modellenmiştir. Elektriksel modelde, d ve q eksenlerine ait gerilim-akım etkileşimleri, elektromanyetik tork üretimi ve rotorun dinamik davranışı bir bütün olarak ele alınmaktadır. PMSG konfigürasyonu dq0 referans çerçevesinde ifade edilmektedir (Saeed vd. 2019).

Dq0 eksen gerilim denklemleri denklem (20) ve denklem (21) 'de sunulmaktadır (Saeed vd. 2019):

$$\frac{d}{dt}id = \frac{1}{L_d}(V_d - Ri_d + L_q\omega i_q - PW_{iq}) \quad (20)$$

$$\frac{d}{dt}iq = \frac{1}{L_q}(V_q - Ri_q + L_d\omega i_d - PW_{id}) \quad (21)$$


Manyetik kayıpları ihmal edilirse d-q eksen gerilim denklemleri denklem (22) ve denklem (23) te görüldüğü üzere sadeleşmektedir.

$$V_d = Ri_d + \frac{d}{dt}id - \omega L_q i_q \quad (22)$$

$$V_q = Ri_q + \frac{d}{dt}iq - \omega L_d i_d + \omega_r \quad (23)$$

Şekil 3.10'da dq0-abc faz sistemine dönüşüm sağlayan MATLAB/Simulink modeli verilmiştir. Dönüşüm, üç fazlı sistemlerdeki zamana bağlı sinyallerin analizini

kolaylaştırmak amacıyla uygulanmaktadır. Dq0 dönüşümü ile elde edilen bileşenler sistemin dengeli ve dengesiz durumlar altında incelenmesine olanak tanımaktadır. Modelde, dönüşüm matrisleri blok diyagram yapısı içerisinde tanımlanmış ve sinyallerin doğru biçimde fazlara ayrılması sağlanmıştır. (Saeed vd. 2019). Bu yapı sistem davranışının kontrol algoritmalarıyla daha hassas biçimde izlenmesine katkı sağlamaktadır.



Şekil 3.10 Dq0-abc dönüşümü MATLAB/Simulink modeli

Manyetik tork matematiksel ifadesi denklem 24'te sunulmaktadır (Gaonkar ve Patel, 2006):


$$T_e = 1.5P(i_q(L_d - L_q)i_d) \quad (24)$$

Denklem (25) ve denklem (26)'da rotorun açısal hızı, mekanik sistem dinamiğinden elde edilmektedir (Saeed vd. 2019):

$$\frac{d\omega_r}{dt} = \frac{1}{J}(T_e - F\omega_r - T_m) \quad (25)$$


$$\frac{d\theta}{dt} = \omega_r \quad (26)$$

Şekil 3.11’de MT ve PMSG sistemlerine ait MATLAB/Simulink toplu bağlantılı temsili model yapısı, sistem dinamiklerinin etkileşimlerini yansıtacak şekilde ayrıntılı olarak gösterilmektedir (Saeed vd. 2019).



Şekil 3.11 MT’ye entegre edilen daimî mıknatıslı senkron jeneratörün (PMSG) elektriksel modelinin MATLAB/Simulink temsili.

Şekil 3.12’de biyogaz yakıtlı sistemin MATLAB/Simulink tabanlı tümleşik model yapısı, bileşenler arası etkileşimler ve kontrol stratejileriyle birlikte ayrıntılı biçimde sunulmaktadır (Saeed vd. 2019).



Şekil 3.12 Biyogaz yakıtlı güç sistemi tümleşik MATLAB/Simulink modeli

3.2 Kullanılan Veri Seti ve Ön İşleme

Çalışmada kullanılan veri seti, Afyonkarahisar ili sınırlarında yer alan Çobanlar Biyogaz Santrali'nden elde edilen gerçek zamanlı süreç verilerinden oluşmaktadır. Veri toplama süreci, biyogaz üretim süreçlerinin sürekli izlenmesine olanak sağlayan otomatik veri toplama sistemleri ve günlük laboratuvar analizleri aracılığıyla yürütülmüştür. Toplanan veriler; tavuk atığı miktarı, atık KM ve atık OKM gibi biyogaz üretimi açısından kritik öneme sahip parametreleri içermektedir. Ayrıca digester içerisindeki reaktör verileri olan KM, OKM, FOS ve TAC değişkenleri de veri setine dâhil edilmiştir. Proses sonucu olarak değerlendirdiğimiz metan ve elektrik üretim değişkenleri de veri setine eklenmektedir.

Veri seti oluşturulurken, sistemin olağan dışı çalıştığı dönemler veri setine dahil edilmemiştir. Olağan dışı durumlar kapsamında arıza günleri, haftalık tatiller ve yıllık izin gibi üretim dışı zaman aralıkları veri setinden çıkarılmış; yalnızca üretimin istikrarlı şekilde sürdüğü günlere ait veriler değerlendirmeye alınmıştır. Süreç sonucunda toplamda 305 günlük optimize edilmiş bir veri seti elde edilmiştir.


Veri ön işleme aşamasında, eksik, aykırı ya da ölçüm hatası içeren değerler elenmiş ve kalan veriler normalize edilmiştir. Normalize işlemi sayesinde, farklı ölçeklerdeki değişkenlerin model tarafından eşit önemde değerlendirilmesi sağlanarak öğrenme sürecinin istikrarı artırılması amaçlanmıştır. Bu işlemde özellikle makine öğrenmesi algoritmalarında değişkenler arası dengesizlikten kaynaklanabilecek yanlı öğrenme eğilimlerinin önüne geçilmesi hedeflenmiştir.

Her iki modelleme yaklaşımında da giriş parametreleri olarak atık miktarı, KM ve OKM değerleri kullanılmış; çıkış parametresi olarak ise reaktör içerisindeki KM, OKM, FOS ve TAC değerleri tahmin edilmeye çalışılmıştır. Sonrasında elde edilen verilerle birlikte atık miktarı sisteme giriş olarak alınarak metan üretim tahmini ve üretilebilecek enerji miktarı çıktıları alınmıştır. Elde edilen veriler, eğitim ve test amacıyla rastgele olacak şekilde %70-%30 oranında iki gruba ayrılmıştır. Bu oranlama, modellerin genelleme kabiliyetini artırmakta ve aşırı öğrenme riskini azaltmaktadır.

Veri setinin hazırlanma sürecinde gösterilen titizlik, elde edilen model sonuçlarının geçerliliği ve güvenilirliği açısından büyük önem arz etmektedir. Bu kapsamlı ve dengeli veri yapısı, biyogaz üretim süreçlerinin dinamiklerinin doğru biçimde modellenmesine olanak tanımakta ve farklı modelleme tekniklerinin başarımlarının nesnel biçimde karşılaştırılabilmesi için sağlam bir temel oluşturmaktadır.

3.3 Anaerobik Metan Üretim Tahmini

3.3.1 Yapay Sinir Ağı Algoritmaları



Şekil 3.13 YSA Modeli Akış Diyagramı

Anaerobik metan üretiminin tahmini amacıyla geliştirilen YSA modeli eğitilmiş ve farklı eğitim algoritmalarının performansları karşılaştırmalı olarak analiz edilmiştir. Eğitim algoritmalarının seçimi, model doğruluğunun artırılması ve tahmin performansının iyileştirilmesi amacıyla gerçekleştirilmiştir. Bu doğrultuda, her algoritmanın öğrenme hızı, genelleme yeteneği ve hata oranı gibi kriterler dikkate alınarak değerlendirme yapılmıştır. Bu kapsamda Levenberg-Marquardt Algoritması (Levenberg-Marquardt-LM), Bayes Regresyonu (Bayesian Regularization-BR) ve Ölçeklenmiş Eşlenik Gradyan (Scaled Conjugate Gradient SCG) algoritmaları kullanılmıştır.

Modelin eğitimi sırasında her algoritma için ayrı ayrı eğitim prosedürleri uygulanmış ve veri seti eğitim %70, doğrulama %15 ve test %15 alt kümelerine ayrılmıştır. Bu veri ayrımı, modelin genelleme yeteneğini geliştirmek ve aşırı öğrenme riskini azaltmak amacıyla tercih edilmiştir. Model başarımı, ortalama kare hata (MSE) ve korelasyon katsayısı (R) gibi istatistiksel metriklerle değerlendirilmiş ancak ilgili performans sonuçları bulgular bölümünde detaylı olarak sunulmuştur.

LM algoritması, hızlı öğrenme kabiliyeti ve yüksek doğruluk düzeyi ile öne çıkmakta; BR algoritması ise aşırı öğrenmeyi önlemeye yönelik Bayesian istatistik temelli yaklaşımı ile tercih edilmektedir. SCG algoritması ise düşük bellek gereksinimi ve büyük veri setlerinde daha kararlı sonuçlar sunması nedeniyle çalışmaya dâhil edilmiştir.

Eğitim sürecinde her bir algoritma için maksimum 1000 epoch ve $1e-6$ hedef hata değeri uygulanmış; erken durdurma mekanizması ile doğrulama setinde gözlemlenen performans kaybı durumunda eğitim sonlandırılmıştır. Her algoritmaya ait eğitim süreci boyunca model başarımları izlenmiş, değerlendirme sonuçlarına ise sonraki bölümlerde yer verilmiştir.

Metan üretimi tahmini iki aşamalı bir YSA modeli ile gerçekleştirilmiştir. İlk aşamada reaktör içi parametreler (KM, OKM, FOS, TAC) tahmin edilmiş; ikinci aşamada bu tahminlerle birlikte atık miktarı giriş parametresi olarak kullanılarak metan üretimi öngörülmüştür. Oluşturulmuş olan bu yapı literatürde tahmin zinciri yaklaşımı olarak tanımlanmakta olup, modelleme sürecinin kademeli olarak yapılandırılmasını sağlamaktadır.

Eğitim sürecinde her algoritma için aynı yöntemsel yaklaşım izlenmiş ve performans değerlendirme metrikleri elde edilmiştir. Bu kapsamda, modelin doğruluğuna ilişkin başarı ölçütleri ve detaylı analiz sonuçları ilerleyen bölümlerde (Bulgular ve Sonuçlar) sunulmuştur.


3.3.1.1 Algoritma Yapısı ve En Başarılı Parametre Seçimi

KM, OKM, FOS TAC ve Metan parametrelerinin performans analizi, modelin genel tahmin doğruluğunu ve farklı algoritmaların etkinliğini ortaya koymak amacıyla gerçekleştirilmiştir. Bu parametreler, modelin biyolojik süreçleri doğru bir şekilde temsil etmesi ve çıktı tahminlerini optimize etmesi açısından kritik öneme sahiptir. Her bir parametrenin performansı, eğitim ve test aşamalarındaki hata oranları ve regresyon katsayıları üzerinden değerlendirilecek, böylece algoritmaların tahmin kapasitesi detaylı bir şekilde incelenecektir. Elde edilen sonuçlar, hangi algoritmanın hangi parametre için daha uygun olduğunu belirlemeye olanak tanıyacaktır.

3.3.1.1.1 KM Tahmin Algoritması

Anaerobik metan üretimi sürecinde reaktör içi KM parametresinin tahmini amacıyla YSA tabanlı bir model geliştirilmiştir. Modelin giriş değişkenleri; günlük atık miktarı (ton), atık içerisindeki %KM ve %OKM oranlarından oluşmakta, çıkış değişkeni olarak ise bir gün sonrasına ait reaktör içi KM değeri hedeflenmiştir.

Şekil 3.14’de KM tahmini için geliştirilen yapay sinir ağı modelleme sürecinin adımlarını özetlemektedir. Süreç, veri girişinden başlayarak, modelin eğitime, hiperparametre optimizasyonuna ve performans analizine kadar tüm aşamaları kapsamaktadır.



Şekil 3.14 KM Parametresi YSA Modelleme Süreci Akış Diyagramı

Anaerobik metan üretimi sürecinde reaktör içi Katı Madde (KM) parametresinin tahmini amacıyla Yapay Sinir Ağı (YSA) tabanlı bir model geliştirilmiştir. Modelin giriş değişkenleri; günlük atık miktarı (ton), atık içerisindeki %KM ve %OKM oranlarından oluşmakta, çıkış değişkeni olarak ise bir gün sonrasına ait reaktör içi KM değeri hedeflenmiştir.

Veri seti, rastgele ayrıştırma yöntemiyle %70 eğitim, %15 doğrulama ve %15 test olmak üzere üç alt kümeye bölünmüştür. Giriş ve çıkış verileri, Min–Max normalizasyon yöntemiyle [0–1] Aralığına ölçeklendirilerek modelin öğrenme istikrarı artırılmıştır.

Model mimarisi, beş gizli katmandan oluşan çok katmanlı bir sinir ağı yapısında tasarlanmıştır. Her katmanda 10 adet nöron kullanılmış, aktivasyon fonksiyonu olarak pozitif lineer fonksiyon tercih edilmiştir. Eğitim algoritması olarak LM, BR ve SCG yöntemleri test edilmiştir. Modelin hiperparametre yapısı, her bir algoritma için ayrı ayrı olacak şekilde optimize edilmiştir.


Beş gizli katmandaki nöron sayıları 1 ila 50 arasında rastgele seçilerek toplam 100 iterasyon boyunca en iyi sonuç alınıp 100 iterasyon boyunca kaydedilip farklı yapılar denenmiş ve her iterasyonda eğitim ve test işlemleri gerçekleştirilmiştir. En düşük Test MSE değerini veren yapı, o algoritma için “en iyi model” olarak belirlenmiş ve “. mat” formatında kaydedilmiştir. Bu işlem, tüm algoritmalarda sistematik olarak tekrarlanarak karşılaştırmalı değerlendirmeye olanak tanımıştır.

Model başarımı, hem ortalama kare hata (Mean Squared Error-MSE) hem de korelasyon katsayısı (Correlation Coefficient-R) metrikleri ile değerlendirilmiştir. Eğitim sürecini görselleştiren performans grafikleri ve tahmin–gerçek değer uyumunu gösteren regresyon grafikleri oluşturularak her algoritmanın tahmin başarısı detaylı biçimde analiz edilmiştir.

3.3.1.1.2 OKM Tahmin Algoritması

Anaerobik sindirim sürecinde organik madde dönüşümünün izlenebilmesi açısından reaktör içerisindeki OKM değeri kritik bir parametre olarak değerlendirilmektedir (Yılmaz, 2019). OKM tahmini için YSA tabanlı bir model geliştirilmiştir. Modelin giriş değişkenleri; günlük atık miktarı (ton), atık içerisindeki %KM ve %OKM değerlerinden oluşmakta, çıkış değişkeni olarak ise bir gün sonrasında ait reaktör içi OKM değeri hedeflenmiştir. Bu yapı sayesinde, sistemin kısa vadeli dinamiklerine ilişkin öngörüler elde edilerek reaktör kontrolü daha etkin biçimde gerçekleştirilebilmektedir. Model, geçmiş veri örüntülerinden öğrenerek reaktör davranışını yüksek doğrulukla tahmin etme kapasitesine sahiptir.

Şekil 3.15’te OKM tahmini için geliştirilen yapay sinir ağı modelleme sürecinin adımlarını özetlemektedir. Veri seti %70 eğitim, %15 doğrulama ve %15 test olarak üçe ayrılmış; tüm giriş ve çıkış verileri Min–Max normalizasyon yöntemi ile [0–1] aralığına ölçeklendirilmiştir. Model, beş gizli katmandan oluşan çok katmanlı sinir ağı mimarisiyle tasarlanmış ve her bir katmana 10 adet nöron atanmıştır. Aktivasyon fonksiyonu olarak poslin fonksiyonu tercih edilmiş olup ayrıca ağ yapısı, deneme-yanılma yöntemiyle optimize edilerek en uygun katman ve nöron sayısı belirlenmiştir. Model doğrulama ve test aşamasında sonrasında elde edilen R^2 ve MSE değerleri kapsamlı biçimde değerlendirilmektedir.




Şekil 3.15 OKM Parametresi YSA Modelleme Süreci Akış Diyagramı

Eğitim algoritması olarak trainlm, trainbr ve trainscg yöntemleri test edilmiştir. Her algoritma için 100 iterasyonluk hiperparametre optimizasyonu, 100 iterasyon boyunca en iyi sonuç alınıp 100 iterasyon boyunca gerçekleştirilmiş, iterasyonlar boyunca her bir yapı eğitilmiş, test edilmiş ve en düşük MSE değerine sahip yapı “en iyi model” olarak belirlenmiştir.

Modelin başarımı, ortalama kare hata ve korelasyon katsayısı metrikleriyle değerlendirilmiştir. Ayrıca, eğitim ve test süreçlerini görselleştiren performans grafiklerinin yanı sıra tahmin ve gerçek değerler arasındaki ilişkiyi gösteren regresyon grafiklerine yer verilmiştir. Bu grafiksel analizler, modelin doğruluk düzeyini ve genelleme yeteneğini detaylı bir şekilde ortaya koymaktadır. Elde edilen düşük hata oranları ve yüksek korelasyon katsayıları, modelin tahmin kabiliyetinin güçlü olduğunu göstermektedir. Özellikle test verisi üzerinde elde edilen sonuçlar, modelin aşırı öğrenme eğiliminden uzak olduğunu kanıtlamaktadır. Bu değerlendirme süreci, geliştirilen yapay zekâ tabanlı sistemin güvenilirliğini destekleyen temel bulguları ortaya koymaktadır.

3.3.1.1.3 FOS Tahmin Algoritması

Şekil 3.16’da görüldüğü gibi FOS parametresinin tahmini amacıyla YSA temelli bir model geliştirilmiştir. Giriş parametreleri olarak atık miktarı (ton), % KM ve % OKM değerleri kullanılmış; çıkış parametresi olarak ise reaktör içerisindeki bir gün sonrasına ait FOS değeri hedeflenmiştir. Modelin eğitimi, geçmiş işletme verileri kullanılarak gerçekleştirilmiş ve farklı algoritmalar ile karşılaştırmalı analiz yapılmıştır. Elde edilen bulgular modelin öngörü yeteneğini ortaya koymaktadır.




Şekil 3.16 FOS Parametresi YSA Modelleme Süreci Akış Diyagramı

Model, üç farklı eğitim algoritması LM, BR, SCG kullanılarak yapılandırılmıştır. Her bir algoritma için maksimum 1000 epoch, $1e-6$ hedef hata değeri ve %70 eğitim, %15 doğrulama, %15 test oranları uygulanmıştır.

Veriler, Min-Max ölçeklendirme yöntemi ile normalize edilerek modelin istikrarlı şekilde öğrenmesi sağlanmış; eğitim süreci sonunda modelin başarımı Ortalama Kare Hata ve korelasyon katsayısı metrikleri ile değerlendirilmiştir. Her algoritma için en iyi performans değerleri kayıt altına alınmış, 100 iterasyonluk hiperparametre analiz süreciyle en uygun gizli katman kombinasyonları belirlenmiş ve her bir iterasyonda model performansı karşılaştırılmıştır.

3.3.1.1.4 TAC Tahmin Algoritması

Şekil 3.17’de görüldüğü üzere modelin eğitimi, LM, BR ve SCG olmak üzere üç farklı algoritma kullanılarak gerçekleştirilmiştir. Her algoritma için maksimum 1000 epoch, $1e-6$ hedef hata değeri ve %70 eğitim, %15 doğrulama, %15 test oranları uygulanmıştır. Eğitim sürecinde erken durdurma stratejisi benimsenerek aşırı öğrenmenin önüne geçilmiş ve modelin genelleme kapasitesi artırılmıştır. Ayrıca, her bir algoritmanın doğruluk düzeyi, hata oranı ve öğrenme eğrisi ayrı ayrı analiz edilmiştir. Elde edilen performans verileri, algoritmaların FOS tahmini üzerindeki etkilerini karşılaştırmalı olarak ortaya koymuştur. Bu analizler doğrultusunda, en uygun yapay sinir ağı modeli belirlenerek sonraki tahmin sürecinde kullanılmıştır. Modelin farklı veri türlerine karşı gösterdiği adaptasyon yeteneği de bu süreçte dikkate alınmıştır. Sadece eğitim verisi değil gerçek koşullarda uyum sağlayabilen esnek bir tahmin yapısı oluşturulmuştur.



Şekil 3.17 FOS Parametresi YSA Modelleme Süreci Akış Diyagramı

TAC parametresinin tahmini amacıyla YSA modeli geliştirilmiştir. Giriş verileri olarak günlük atık miktarı (ton), atık içerisindeki %KM ve % OKM değerleri kullanılmış; çıkış verisi olarak ise reaktör içerisindeki bir gün sonrasına ait TAC değeri hedeflenmiştir.


Veri seti, Min-Max normalizasyon yöntemi ile ölçeklendirilmiş ve bu sayede değişkenler arasındaki ölçüm farklarının model performansı üzerindeki etkisi minimize edilmiştir. Performans değerlendirmesi, Ortalama Kare Hata ve korelasyon katsayısı metrikleri kullanılarak yapılmış, her algoritma için 100 iterasyon boyunca hiperparametre analizleri gerçekleştirilmiş ve en düşük test hatasına sahip yapı "en iyi model" olarak seçilmiştir. Bu model, ileri tahmin sürecine entegre edilerek TAC tahminleri başarıyla yürütülmüştür.

3.3.1.1.5 Metan Tahmin Algoritması

Şekil 3.18’de anaerobik sindirim süreci sonucunda oluşan metan gazı miktarının tahmini amacıyla YSA tabanlı bir model geliştirilmiştir. Modelin giriş parametreleri olarak günlük atık miktarı (ton), reaktör içerisindeki %KM, %OKM, FO) ve TAC değerleri kullanılmış; çıkış parametresi olarak ise bir gün sonrasına ait metan üretim miktarı hedeflenmiştir.

Modelin eğitimi LM, BR ve SCG algoritmaları kullanılarak gerçekleştirilmiştir. Her algoritma için maksimum 1000 epoch, $1e-6$ hedef hata değeri ve %70 eğitim, %15 doğrulama, %15 test oranları benimsenmiştir. Eğitim süreci boyunca erken durdurma yöntemi uygulanmış modelin aşırı öğrenme riski önemli ölçüde azaltılması başarılmıştır. Veri seti, Min-Max normalizasyon yöntemiyle ölçeklendirilmiş; bu sayede giriş değişkenlerinin öğrenme sürecindeki ağırlıkları dengelenmiştir. Model mimarisi beş gizli

katmanlı sinir ağı yapısında tasarlanmış, her bir algoritma için 100 iterasyonluk hiperparametre optimizasyonu gerçekleştirilmiş ve en düşük test hatasına sahip yapı “en iyi model” olarak belirlenmiştir.



Şekil 3.18 Metan YSA Modelleme Süreci Akış Diyagramı

Model başarımı, Ortalama Kare Hata ve korelasyon katsayısı metrikleri ile analiz edilmiştir. Eğitim ve test aşamalarına ait performans eğrileri ve regresyon analizleriyle modelin tahmin kabiliyeti görsel olarak da değerlendirilmiş ve sonuçlar ileri değerlendirme aşamasına aktarılmıştır.

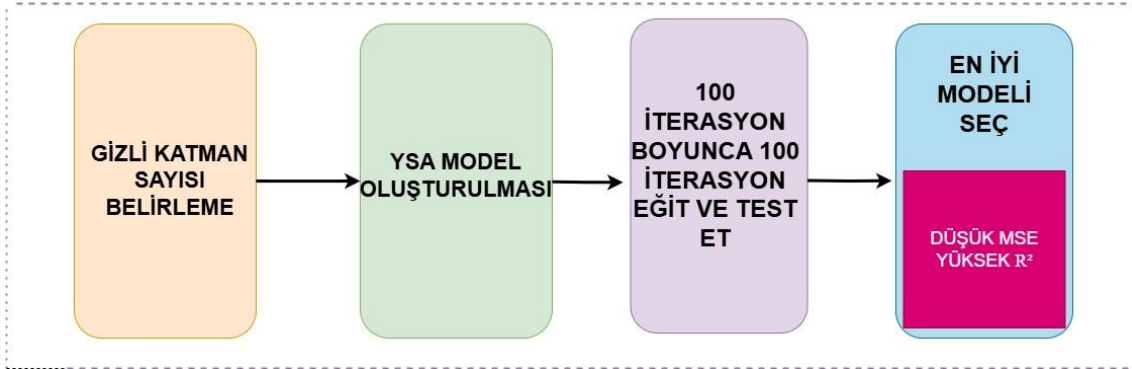
3.2.1.2 Hiperparametre Optimizasyonu ve Eğitim Süreci

YSA modellerinin genel başarımını artırmak amacıyla, her parametre tahmini için hiperparametre optimizasyon süreci uygulanmıştır. Bu süreçte modelin mimarisi (gizli katman sayısı ve her katmandaki nöron sayıları), öğrenme algoritması, eğitim-test bölünme oranları ve epoch sınırları gibi parametreler sistematik şekilde değerlendirilmiştir.

Şekil 3.19’da verilen optimizasyon süreci, her bir algoritma LM, BR ve SCG için ayrı ayrı yürütülmüş olup, 100 iterasyon boyunca rastgele oluşturulan farklı katman kombinasyonları 100 iterasyon test edilip en iyi sonuç o iterasyona kaydedilmiştir. Her

bir iterasyonda, modelin eğitim ve test süreçlerine ait ortalama kare hata (MSE) değerleri hesaplanmış ve en düşük test MSE'sine ulaşan yapı "en iyi model" olarak belirlenmiştir. Bu yapı, ileri aşamalarda metan üretimi tahmininde kullanılacak modelin çekirdeğini oluşturmaktadır.

HİPERPARAMETRE OPTİMİZASYONU



Şekil 3.19 Hiperparametre Optimizasyonu ve Eğitim Süreci Akış Diyagramı

Hiperparametre arama süreci boyunca, beş gizli katmandan oluşan sinir ağı mimarisi benimsenmiş, her iterasyonda bu katmanlara ait nöron sayıları [1–50] aralığında rastgele olarak belirlenmiştir. Eğitim süreci sırasında ağ yapıları fitnet fonksiyonu ile oluşturulmuş, Min-Max normalizasyonu uygulanmış giriş verileriyle eğitilmiş ve erken durdurma mekanizması etkinleştirilmiştir.

Her bir iterasyonda elde edilen MSE değeri, iterasyon numarası ve katman boyutları ile birlikte kayıt altına alınmış; sonuçlar Excel tabloları ve grafikler aracılığıyla analiz edilmiştir. En iyi model yapısı “.mat” formatında kaydedilerek tahmin sürecinde kullanılmak üzere sistem belleğine entegre edilmiştir.

3.3.2 Makine Öğrenmesi Algoritmaları

Biyogaz üretim sürecinde KM, OKM, FOS, TAC ve metan tahminleri için geliştirilen makine öğrenmesi modellerinin eğitimi ve performansının değerlendirilmesi amacıyla çeşitli algoritmalar kullanılmıştır. Kullanılan algoritmaların seçimi, model doğruluğunu artırmak, farklı veri yapılarında esnek çözümler sunmak ve genel tahmin performansını en üst düzeye çıkarmak amacıyla gerçekleştirilmiştir. Bu kapsamda Şekil 3.20’de

görüldüğü üzere DT, RF, SVR, GBM KNN algoritmaları uygulanmıştır. Algoritma tercihleri, her bir yöntemin veri özelliklerine uygunluk düzeyine, aşırı öğrenmeye karşı dayanıklılığına ve modelleme esnekliğine göre belirlenmiştir.




Şekil 3.20 Makine Öğrenmesi Kullanılan Modeller

3.3.2.1 Algoritma Yapısı ve En Başarılı Parametre Seçimi

Makine öğrenmesi algoritmaları ile gerçekleştirilen tahmin sürecinde, modelin yapısı ve kullanılan parametrelerin belirlenmesi, sonuçların doğruluğu açısından kritik bir rol oynamaktadır. Bu çalışmada her bir tahmin problemi (KM, OKM, FOS, TAC ve Metan) için farklı algoritmalar özelinde modeller yapılandırılmakta ve aynı kod mimarisi temel alınarak performans testleri yürütülmektedir. Modellerin eğitimi, MATLAB ortamında geliştirilen özel fonksiyonlar aracılığıyla gerçekleştirilmekte olup, giriş parametreleri olarak atık miktarı ve reaktör içi kimyasal özellikler kullanılmaktadır. Sistem akışı Şekil 3.21’de verilmiştir.

Çıkış parametresi, ilgili hedef değişkene göre belirlenmekte ve bu doğrultuda algoritmalar regresyon temelli olarak eğitilmektedir. Her bir model 100 iterasyon boyunca eğitilmekte ayrıca her iterasyonda hiperparametre değerleri rastgele oluşturularak, elde edilen test performansına göre en iyi sonuçlar belirlenmektedir. Model performansları, ortalama kare hata (MSE) ve determinasyon katsayısı (R^2) gibi istatistiksel ölçütlerle değerlendirilmektedir. En düşük hata ve en yüksek R^2 değerini sağlayan yapı, “en iyi model” olarak seçilmekte ve kaydedilmektedir.


Elde edilen modeller, daha sonra Simulink ortamında da kullanılmak üzere “.mat” formatında dışa aktarılmakta ve tüm algoritmalar aynı veri seti yapısı üzerinden karşılaştırmalı analizlere tabi tutulmaktadır. Bu yapı sayesinde, her algoritmanın süreç tahmini üzerindeki başarımı nesnel şekilde ortaya konmaktadır.



Şekil 3.21 Makine Öğrenmesi Modeli Akış Diyagramı

3.3.2.1.1 KM Tahmin Algoritması

Şekil 3.22’de KM parametresinin tahmini için makine öğrenmesi algoritmalarından DT, RF, SVM, GBM ve KNN yöntemleri uygulanmıştır. Modelleme sürecinde, atık miktarı (ton/gün), KM (%) ve OKM (%) giriş verileri olarak kullanılmış; çıkış değişkeni ise reaktör çıkışındaki KM değeridir.



Şekil 3.22 KM Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı


Veri seti öncelikle eksik değer kontrolü ve min-max normalizasyon işlemlerine tabi tutulmuştur. Bu aşamadan sonra, her algoritma için ayrı ayrı hiperparametre optimizasyonu gerçekleştirilmiş ve 100 iterasyonluk bir döngüde her bir iterasyonda en iyi model kaydedilmiştir. Eğitim ve test veri oranları %70-%30 olarak belirlenmiş, model başarımı ise Ortalama Kare Hata ve Determinasyon Katsayısı ile değerlendirilmiştir.

Hiperparametre optimizasyonu sonucunda en düşük test MSE ve en yüksek test R^2 değerine sahip model, tahmin sürecinde kullanılmak üzere seçilmiştir. Elde edilen en iyi

modeller “.mat” uzantılı dosyalar olarak kaydedilmiş, bu modeller Simulink ortamında fonksiyonel olarak entegre edilmiştir.

3.3.2.1.2 OKM Tahmin Algoritması

OKM parametresinin tahmini DT, RF, SVM, GBM ve KNN algoritmaları kullanılarak modelleme çalışmaları yürütülmektedir. Tahmin sürecinde giriş verileri olarak atık miktarı, KM (%) ve OKM (%) değerleri kullanılmakta; çıkış verisi ise reaktör çıkışındaki OKM parametresi olarak tanımlanmaktadır.



Şekil 3.23 OKM Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı

Veri seti, öncelikle eksik değer kontrolü ve aykırı gözlem analizi sonrasında min-max normalizasyon yöntemiyle ölçeklendirilmiştir. Bu işlemin ardından, her bir algoritma için 100 iterasyonluk hiperparametre optimizasyonu gerçekleştirilmiş ve her iterasyonda test verileri üzerinde en iyi performansı gösteren model kayıt altına alınmıştır. Eğitim ve test veri oranları sırasıyla %70 ve %30 olarak belirlenmiş; model performansı ise Ortalama Kare Hata ve Korelasyon katsayısı gibi doğruluk ölçütleriyle değerlendirilmiştir.


Gerçekleştirilen optimizasyon süreci sonucunda, test setinde en düşük MSE ve en yüksek R^2 değerine ulaşan model nihai tahmin modeli olarak seçilmiş ve “.mat” formatında kaydedilmiştir. Seçilen bu modeller, daha sonra Simulink ortamına aktarılmış ve sistem içerisinde fonksiyonel olarak entegre edilmiştir. Modelleme sürecine ait sistemin genel yapısı şekil 3.23’de şematik olarak sunulmaktadır. Şekilden de görüleceği üzere, süreç veri girişinden model eğitime, hiperparametre analizinden tahmin çıktısının elde edilmesine kadar sistematik bir bütünlük içerisinde yapılandırılmıştır.

3.3.2.1.3 FOS Tahmin Algoritması

FOS parametresinin tahmini amacıyla DT, RF, SVM, GBM ve KNN algoritmaları kullanılarak kapsamlı bir modelleme süreci yürütülmektedir. Modelde, atık miktarı, KM (%) ve OKM (%) parametreleri giriş olarak kullanılmış; çıkış parametresi ise reaktör çıkışındaki FOS değeri olarak belirlenmiştir.

Veri seti, aykırı ve eksik gözlemler açısından kontrol edilerek temizlenmiş ve ardından tüm girişler min-max normalizasyonu ile ölçeklendirilmiştir. Eğitim ve test veri oranları sırasıyla %70 ve %30 olacak şekilde yapılandırılmış; böylece modelin genelleme kabiliyeti artırılmıştır. Her algoritma için 100 iterasyon boyunca hiperparametre optimizasyonu gerçekleştirilmiş ve en düşük test MSE ile en yüksek test R^2 değerine sahip model seçilerek “.mat” formatında kaydedilmiştir.

Tahmin süreci sonunda elde edilen modeller, Simulink ortamına entegre edilerek ileri analizlerde kullanılmak üzere hazır hâle getirilmiştir. FOS tahminine ilişkin genel modelleme süreci Şekil 3.24’te sunulmuş olup süreç veri hazırlama, model eğitimi, doğruluk değerlendirmesi ve model seçimi adımlarından oluşmaktadır. Bu adımlar modelin genelleme kapasitesini artırıp optimize etmek için titizlikle yapılandırılmıştır.



Şekil 3.24 FOS Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı


3.3.2.1.4 TAC Tahmin Algoritması

TAC parametresinin tahmini amacıyla DT, RF, SVM, GBM ve KNN algoritmaları kullanılarak çok yönlü bir makine öğrenmesi süreci yürütülmektedir. Modelleme

aşamasında atık miktarı, KM (%) ve OKM (%) parametreleri giriş değişkeni olarak kullanılmış; çıkış değişkeni olarak ise reaktör çıkışındaki TAC değeri hedeflenmiştir.

Veri seti, öncelikle eksik ve aykırı veriler açısından analiz edilerek temizlenmiş, ardından min-max normalizasyon yöntemi ile tüm girişler ortak bir ölçeğe getirilmiştir. Eğitim ve test veri oranları %70-%30 olarak belirlenmiş olup, her algoritma için 100 iterasyonluk hiperparametre optimizasyonu gerçekleştirilmiştir. Bu süreçte her iterasyonda en düşük test MSE ve en yüksek test R^2 değerine ulaşan model belirlenerek nihai model olarak seçilmiştir.

Seçilen en iyi modeller, “.mat” formatında kaydedilerek Simulink ortamında fonksiyonel şekilde çalışacak biçimde entegre edilmiştir. TAC tahmini sürecine ait genel modelleme yapısı Şekil 3.25’te sunulmaktadır. Şekilden de görüldüğü üzere, tahmin süreci; veri hazırlama, model eğitimi, doğruluk değerlendirmesi ve model seçimi adımlarından oluşmaktadır. Bu yapının her adımı, modelin hem genelleme yeteneğini hem de endüstriyel uygulanabilirliğini artırmaya yönelik olarak sistematik biçimde yapılandırılmıştır. Böylece, tahmin edilen TAC değerleri yalnızca istatistiksel olarak değil, aynı zamanda proses kontrolü açısından da yüksek düzeyde tutarlılık göstermektedir.



Şekil 3.25 TAC Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı


3.3.2.1.5 Metan Tahmin Algoritması

Metan gazı üretiminin tahmini DT, RF, SVM, GBM ve KNN algoritmaları uygulanarak çok değişkenli bir modelleme süreci gerçekleştirilmiştir. Bu modelleme yapısında giriş

parametreleri olarak atık miktarı (ton/gün), KM, OKM, FOS ve TAC değerleri kullanılmış; çıkış parametresi ise reaktör çıkışındaki günlük metan üretim miktarı olarak tanımlanmıştır.

Veri seti, eksik gözlem ve aykırı değerler açısından değerlendirilmiş, ardından min-max normalizasyon yöntemi ile tüm giriş değişkenleri ölçeklendirilmiştir. Eğitim ve test veri oranları %70-%30 olarak ayrılmış ve her algoritma için 100 iterasyonluk hiperparametre optimizasyonu yapılmıştır. Bu süreçte, her iterasyonda elde edilen en iyi model “.mat” formatında kaydedilmiştir. Optimizasyon çıktıları, test veri setindeki MSE ve R² ölçütlerine göre değerlendirilmiş; bu doğrultuda en düşük hata ve en yüksek korelasyon katsayısına sahip modeller tercih edilmiştir.

Tahmin edilen metan gazı miktarları, daha sonra sistemin enerji üretim potansiyelini belirlemede kullanılmıştır. Elde edilen modeller, Simulink ortamında ilgili bloklara entegre edilerek hesaplamalı doğrulama süreciyle birlikte çalıştırılmıştır. Metan tahmini sürecine ilişkin genel modelleme yapısı Şekil 3.26’da sunulmaktadır. Şekilden de anlaşılabacağı üzere, çoklu giriş verileri ile beslenen bu yapı, metan üretiminin dinamiklerini yüksek doğrulukla modelleyebilmekte ve biyogaz sistem performansına yönelik anlamlı çıktılar üretebilmektedir.



Şekil 3.26 TAC Parametresi Makine Öğrenmesi Modelleme Süreci Akış Diyagramı

3.3.2.1.6 Hiperparametre Optimizasyonu ve Eğitim Süreci

Makine öğrenmesi modellerinin başarımı, yalnızca veri setinin yapısına değil, aynı zamanda kullanılan algoritmaların hiperparametre ayarlarına da doğrudan bağlıdır. Bu nedenle her algoritma için hiperparametre optimizasyonu ayrı ayrı gerçekleştirilmiş ve

100 iterasyon boyunca 100 iterasyonun en iyi performansı en uygun yapıların elde edilmesi hedeflenmiştir. Optimizasyon süreci sonunda belirlenen parametreler, modelin genelleme kapasitesini artırmak ve aşırı öğrenme riskini en aza indirmek amacıyla seçilmiştir.

Karar Ağacı (DT) algoritmasında temel olarak iki hiperparametre optimize edilmiştir: maksimum yaprak düğüm sayısı (min leaf size) ve bölme ölçütü (Max. Split). Maksimum derinlik, ağacın ne kadar derinlemesine büyüyebileceğini kontrol ederken, bölme ölçütü her dalın homojenliğini değerlendirmektedir. Derinliğin artırılması, modele daha fazla öğrenme kapasitesi kazandırır da aşırı öğrenme riskini artırdığından dengeleyici bir optimizasyon yaklaşımı izlenmiştir.

Rastgele Orman (RF) algoritmasında ağaç sayısı (NumTrees) hiperparametresi optimize edilmiştir. Ağaç sayısının artırılması, genellikle daha iyi genelleme sağlamakta ancak eğitim süresini uzattığı gözlemlenmiştir.

Destek Vektör Makineleri (SVM) algoritmasında kullanılan çekirdek fonksiyonu (kernel function), ceza parametresi (C) ve kernel genişliği (gamma) gibi hiperparametreler optimize edilmiştir. Ceza parametresi, hatalı sınıflamaların maliyetini kontrol ederken; gamma parametresi, karar yüzeyinin ne kadar hassas olacağını belirlemektedir. Bu parametrelerin optimizasyonu, SVM'in karmaşık ilişkileri daha iyi modelleyebilmesini sağladığı gözlemlenmiştir.

Artırmalı Karar Ağaçları (GBM) algoritmasında öğrenme oranı (learning rate), ağaç sayısı (NumTrees) ve maksimum derinlik parametreleri optimize edilmiştir. Öğrenme oranı, her adımda yapılan düzeltmenin boyutunu belirlemekte olup, küçük öğrenme oranları modelin istikrarlı öğrenmesini sağlarken, daha fazla öğrenici gerektirir. Bu parametreler birlikte optimize edilerek hem doğruluk hem de hesaplama maliyeti bakımından ideal yapı elde edilmiştir.

En Yakın Komşu (KNN) algoritmasında ise en yakın komşu sayısı (Num Neighbors), mesafe ölçütü (distance metric) ve ağırlıklandırma yöntemi (distance weighting) optimize

edilmiştir. Komşu sayısı azaldıkça model daha hassas fakat gürültüye açık hale gelirken; mesafe ölçütü modelin benzerlik anlayışını değiştirmektedir. Uygun kombinasyonlar denenerek, veri setine en iyi uyumu sağlayan yapı elde edilmiştir.

Eğitim süreci boyunca tüm modeller için eğitim-veri oranı %70, test-veri oranı %30 olarak sabit tutulmuş ve iteratif değerlendirmelerde test seti performansı temel alınmıştır. Elde edilen en iyi modeller “.mat” formatında kayıt altına alınmıştır. Çizelge 3.1’de optimize edilen parametreler gösterilmektedir.

Çizelge 3. 1 Makine Öğrenmesi Algoritmalarında Optimize Edilen Hiperparametreler

Algoritma	Optimize Edilen Hiperparametreler
Karar Ağacı	Düğüm Sayısı, Bölme Ölçütü
Rastgele Orman	Ağaç Sayısı
Destek Vektör Makinaları	Ceza Parametresi (C), Kernal Tipi, Kernal Genişliği
Artırmalı Karar Ağaçları	Öğrenme Oranı, Maksimum Derinlik
En Yakın Komşu	Komşu Sayısı, Mesafe Ölçütü, Ağırlıklandırma Yöntemi

3.4. Elektrik Tahmini

Bölüm 3.3’te açıklandığı üzere, metan üretim tahmini; yapay sinir ağı modelleri, makine öğrenmesi algoritmaları ve simülasyon tabanlı analiz yöntemleri kullanılarak elde edilmiştir. Bu çoklu yaklaşımlar sayesinde reaktöre giren atıkların içerdiği parametrelere göre metan çıkışı yüksek doğrulukla öngörülmüştür.

Elde edilen metan tahminleri, ardından üçüncü dereceden bir fonksiyon yardımıyla elektrik üretim değerine dönüştürülmüştür. Bu dönüşüm, Denklem 12’de gösterildiği üzere gerçeğe yakınsayan bir yapı sergilemekte olup, tahmin edilen metan hacminden elde edilecek elektriksel güç değerini ortaya koymaktadır. Bu yöntem ile sistemin nihai amacı olan enerji üretim tahminine ulaşılmıştır. Modelin başarımı, Çizelge 5.3’te sunulan ve biyogaz santralinden alınan 24 günlük gerçek veriye dayalı karşılaştırmalarla doğrulanmıştır. Bu karşılaştırmalarda sapma oranları, tahmin farkları ve modelin genelleme kabiliyeti açıkça gözlemlenmiştir.


4. BULGULAR

4.1 Makine Öğrenmesi Algoritmaları Performansı

Makine öğrenmesi algoritmaları kullanılarak gerçekleştirilen tahmin çalışmalarına ait performans analizleri detaylı şekilde sunulmaktadır. Her bir parametre (KM, OKM, FOS, TAC ve Metan) için uygulanan algoritmaların eğitim ve test verileri üzerindeki başarıları; Ortalama Kare Hata (MSE) ve Determinasyon Katsayısı (R^2) gibi istatistiksel metriklerle değerlendirilmiştir. Ayrıca hiperparametre optimizasyonu süreci sonunda elde edilen en iyi modellerin sonuçları da regresyon ve hata analizleri eşliğinde grafiklerle desteklenmiştir. İlgili grafik ve tablolar, algoritmaların güçlü ve zayıf yönlerini karşılaştırmalı olarak ortaya koymakta ve model seçiminde bilimsel bir temel sunmaktadır. Böylece modellerin genelleme yetenekleri, veri seti üzerindeki öğrenme davranışları ve tahmin başarımları düzeyleri görsel olarak karşılaştırılmıştır. Bu analizler, farklı algoritmaların yetkinliklerinin sistematik bir şekilde değerlendirilmesini sağlamaktadır. Ayrıca, parametre bazlı karşılaştırmalar sayesinde hangi algoritmanın hangi değişken üzerinde daha etkili sonuçlar verdiği açık biçimde gözlemlenebilmektedir. Bu bağlamda, en yüksek R^2 ve en düşük MSE değerlerine ulaşan modeller ön plana çıkarılarak değerlendirilmiştir. Elde edilen bulgular, tahmin modellerinin doğruluk, güvenilirlik ve uygulanabilirlik düzeylerinin nesnel olarak belirlenmesine katkı sağlamaktadır.


4.1.1 KM Tahmini ve Performans Sonuçları

Şekil 4.1’de görüldüğü üzere, Karar Ağacı algoritması kullanılarak gerçekleştirilen KM tahmin sürecinde eğitim verisi üzerinde elde edilen R^2 değerleri, test verisine kıyasla genel olarak daha yüksek seviyelerde seyretmektedir. Ancak hem eğitim hem de test setinde belirgin dalgalanmalar gözlemlenmektedir. Test R^2 değerlerinde sıkça sıfıra yakın ya da negatif korelasyon katsayıları kaydedilmesi, modelin genelleme kapasitesinin oldukça sınırlı kaldığını ve aşırı öğrenme eğiliminin yüksek olduğunu göstermektedir. Bu durum, DT algoritmasının KM verisi üzerinde istikrarlı ve güvenilir bir tahmin performansı sergilemediğini ortaya koymaktadır. Dolayısıyla bu algoritma, KM parametresi için uzun vadeli ve sürdürülebilir bir öngörü aracı olarak tercih edilmemelidir.



Şekil 4.1 Karar Ağacı (DT) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi


Şekil 4.2’de görüldüğü üzere, Karar Ağacı (DT) algoritmasının eğitim seti üzerindeki MSE değerleri daha düşük seviyelerde bulunmakta, ancak test seti üzerindeki MSE değerlerinde belirgin dalgalanmalar ve yükselmeler gözlemlenmektedir. Bu durum, modelin eğitim verisine iyi uyum sağlarken test verisinde genelleme kapasitesinin zayıf kaldığını göstermektedir.



Şekil 4.2 Karar Ağacı (DT) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi


Şekil 4.3’de görüldüğü üzere, Karar Ağacı (DT) algoritması ile KM tahmini için oluşturulan regresyon grafiğinde, tahmin edilen değerler ile gerçek değerler arasında

belirgin sapmalar bulunmaktadır. Bu durum, modelin doğrusal ilişkiyi tam olarak yakalayamadığını ve tahmin doğruluğunun sınırlı düzeyde kaldığını göstermektedir.




Şekil 4.3 Karar Ağacı (DT) algoritması ile KM tahmini test verisi regresyon grafiği

Şekil 4.4’de görüldüğü üzere RF algoritması ile KM tahmini için elde edilen R^2 grafiğinde, eğitim verisi üzerinde yüksek korelasyon katsayıları korunurken, test verisinde belirgin dalgalanmalar ve düşük R^2 değerleri gözlemlenmektedir. Bu durum, modelin test verisi üzerinde sınırlı genelleme yeteneğine sahip olduğunu göstermektedir.




Şekil 4.4 Random Forest (RF) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi

Şekil 4.5’de görüldüğü üzere, RF algoritması ile gerçekleştirilen KM tahmini sürecinde eğitim verisinde düşük ve istikrarlı MSE değerleri gözlemlenirken, test verisinde dalgalı ve zaman zaman yükselen hata değerleri kaydedilmiştir. Bu durum, modelin eğitim verisine uyum sağladığını ancak test verisine tam olarak genelleyemediğini göstermektedir. Test verisindeki hata artışları, modelin aşırı öğrenme eğiliminde olabileceğine işaret etmektedir. Özellikle veri dağılımındaki heterojenlik modelin genelleme yeteneğini sınırlandırmış ve tahmin doğruluğunu düşürmüştür. Bu duruma istinaden hiperparametre ayarlarının belirli alt gruplarda yeterince optimize edilmemesi, bazı örneklerde hata sapmalarına neden olmuştur. Bu bağlamda modelin performansını iyileştirmek adına daha dengeli bir veri ayrımı ve çapraz doğrulama yöntemlerinin uygulanması önerilmektedir. RF algoritmasının açıklanabilirlik avantajı sayesinde hangi giriş değişkenlerinin tahmin üzerinde baskın etkiye sahip olduğu da analiz edilerek modelin güvenilirliği artırılabilir. Dolayısıyla modelin karar süreçlerine yönelik şeffaflık ve güvenilirlik düzeyi daha ileri düzeyde geliştirilebilecektir.




Şekil 4.5 Random Forest (RF) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi

Şekil 4.6’da görüldüğü üzere, Random Forest (RF) algoritması ile gerçekleştirilen KM tahmininde tahmin edilen değerler ile gerçek değerler arasında belirli bir paralellik bulunmakla birlikte, dağılımın ideal regresyon doğrusundan sapmalar içerdiği gözlemlenmektedir.




Şekil 4.6 Random Forest (RF) algoritması ile KM tahmini için test verisi regresyon grafiği

Şekil 4.7’de görüldüğü üzere, SVM algoritması ile KM tahmini sürecinde eğitim verisi üzerinde yüksek R^2 değerleri elde edilirken, test verisinde ciddi dalgalanmalar ve düşük korelasyon katsayıları kaydedilmiştir. Bu durum, modelin eğitimde başarı sağladığı ancak test setinde genelleme performansının zayıf kaldığını göstermektedir ve modelin eğitim verisine aşırı uyum sağladığını ve farklı veri desenlerine karşı yeterli esneklik gösteremediğini ortaya koymaktadır.



Şekil 4.7 Destek Vektör Makineleri (SVM) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi


Şekil 4.8’de görüldüğü üzere, Destek Vektör Makineleri (SVM) algoritması ile KM tahmininde eğitim verisinde düşük MSE değerleri korunmakta iken, test verisinde hata oranlarında belirgin dalgalanmalar gözlemlenmektedir. Bu durum, modelin eğitim verisine iyi uyum sağladığını ancak test verisine genelleme yeteneğinin sınırlı olduğunu göstermektedir. Test verisindeki bu dalgalanmalar, modelin veri setindeki karmaşık örüntüleri tam olarak öğrenememesiyle ilişkilendirilebilir. Test verisinde beklenmeyen hata artışlarına ve tahmin sapmalarına yol açmıştır. Özellikle düşük örnek yoğunluğuna sahip bölgelerde modelin kararsızlık sergilediği gözlemlenmiştir. Ayrıca veri setindeki uç değerlerin model üzerindeki etkisi, genelleme başarımını olumsuz yönde etkilemiştir. Modelin bazı veri alt kümelerinde aşırı sapma üretmesine ve genel performansın düşmesine neden olmuştur. Dolayısıyla, model çıktılarının güvenilirliği veri dağılımına duyarlı hale gelmiş ve değerlendirme sürecinde dikkatle analiz edilmesi gerekmiştir. Modelin bu davranışı, veri dağılımındaki dengesizliklere karşı duyarlılığını ortaya koymaktadır. Özellikle test aşamasında gözlenen sapmalar, modelin bazı örüntüleri istikrarlı biçimde genellemediğini göstermektedir.



Şekil 4.8 Destek Vektör Makineleri (SVM) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi


Şekil 4.9’da görüldüğü üzere, SVM algoritması ile gerçekleştirilen KM tahmininde tahmin edilen değerler ile gerçek değerler arasında belirli bir paralellik sağlanmakla birlikte, regresyon doğrusundan sapmalar dikkati çekmektedir. Bu durum, modelin genel

tahmin doğruluğunun sınırlı olduğunu ve tahmin performansının tam idealden uzak olduğunu göstermektedir.




Şekil 4.9 Destek Vektör Makineleri (SVM) algoritması KM tahmini için test verisi regresyon grafiği

Şekil 4.10'ta görüldüğü üzere, Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmininde eğitim verisinde yüksek ve stabil R^2 değerleri elde edilmiştir. Ancak, test verisinde ciddi dalgalanmalar ve düşük korelasyon katsayıları gözlemlenmektedir.




Şekil 4.10 Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmini eğitim ve test verilerine ait R^2 değişimi

Şekil 4.11’de görüldüğü üzere, GBM algoritması ile gerçekleştirilen KM tahmini sürecinde eğitim verisi üzerinde oldukça düşük MSE değerleri elde edilmiştir. Buna karşın, test verisi üzerinde hata oranlarında düzensiz dalgalanmalar gözlemlenmektedir. Bu durum modelin eğitimde yüksek doğruluk sağlarken test verisinde aşırı öğrenme etkisi gösterdiğini ve genelleme kapasitesinin zayıf olduğunu göstermektedir. GBM’nin ardışık öğrenme yapısı, eğitim verisindeki örüntülere güçlü bir şekilde uyum sağlarken, yeni veriler karşısında esnekliğini kaybedebilmektedir. Bu durum, test setindeki değişkenliklere karşı modelin uyum kabiliyetini azaltmıştır. Özellikle varyansı yüksek bölgelerde tahmin doğruluğunun ciddi şekilde düştüğü tespit edilmiştir. Sonuçlar, GBM algoritmasının güçlü öğrenme kapasitesine rağmen, veri dengesizliklerine karşı dikkatli biçimde yapılandırılması gerektiğini ortaya koymuştur. Modelin karmaşık, düzensiz ve uç değer içeren veri kümelerinde daha tutarsız sonuçlar ürettiğini göstermektedir.




Şekil 4.11 Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi

Şekil 4.12’de görüldüğü üzere, GBM algoritması ile gerçekleştirilen KM tahmininde tahmin edilen değerler ile gerçek değerler arasında genel bir uyum gözlemlenmekte ancak bazı veri noktalarında ideal regresyon doğrusundan sapmalar oluşmaktadır. Bu durum, modelin genel tahmin performansının makul düzeyde olduğunu ancak tam doğruluk sağlanamadığını göstermektedir. Özellikle bazı noktalardaki sapmalar istatistiksel açıdan dikkat çekici ölçüde yüksektir.




Şekil 4.12 Gradyan Artırmalı Makine (GBM) algoritması ile KM tahmini için test verisi regresyon grafiği

Şekil 4.13'te görüldüğü üzere, K-Nearest Neighbors (KNN) algoritması ile gerçekleştirilen KM tahmininde eğitim verisi üzerinde zaman zaman yüksek R^2 değerleri kaydedilse de test verisi üzerinde R^2 değerlerinin genel olarak düşük olduğu ve ciddi dalgalanmaların yaşandığı gözlemlenmektedir. Bu durum, modelin eğitim setine aşırı uyum sağladığını göstermektedir.




Şekil 4.13 K-Nearest Neighbors (KNN) algoritması ile KM tahmini için eğitim ve test verilerine ait R^2 değişimi

Şekil 4.14'te görüldüğü üzere, KNN algoritması ile gerçekleştirilen KM tahmini sürecinde eğitim verisinde ve test verisinde MSE değerlerinde yüksek düzeyde dalgalanmalar gözlemlenmektedir. Özellikle test verisinde hata oranlarının belirli bir düzeyin altına inmediği dikkat çekmektedir. Bu durum, modelin genel tahmin stabilitesinin zayıf olduğunu göstermektedir. KNN algoritmasının örnek tabanlı yapısı, özellikle veri setinde gürültü veya dengesizlik mevcut olduğunda tahmin performansını olumsuz yönde etkileyebilmektedir. Veri noktaları arasındaki uzaklığa dayalı karar mekanizması, düşük yoğunluklu bölgelerde kararsız tahminlere neden olmaktadır. Bu durum, modelin lokal değişkenlikleri genelleme yeteneğinin yetersiz kalmasına yol açmaktadır. Ayrıca k değerinin seçimi, modelin aşırı hassas veya aşırı genel tepkiler vermesine neden olabileceği için sonuçlar üzerinde belirleyici rol oynamaktadır. Sonuç olarak, KNN algoritmasının KM tahminindeki yetersiz performansı, özellikle karmaşık ve düzensiz veri yapılarında sınırlı başarı sunduğunu göstermektedir.



Şekil 4.14 K-Nearest Neighbors (KNN) algoritması ile KM tahmini eğitim ve test verilerine ait MSE değişimi grafiği

Şekil 4.15'te görüldüğü üzere, KNN algoritması ile gerçekleştirilen KM tahmininde tahmin edilen değerlerin büyük kısmının sınırlı bir bantta toplandığı ve ideal regresyon doğrusundan belirgin sapmalar gösterdiği gözlemlenmektedir. Bu durum, modelin karmaşık ilişkileri öğrenmekte ve doğru tahminler üretmekte yetersiz kaldığını ortaya koymaktadır.



Şekil 4.15 K-Nearest Neighbors (KNN) algoritması ile KM tahmini için test verisi regresyon grafiği


KM tahmini için uygulanan makine öğrenmesi algoritmalarının genel performansı incelendiğinde, her modelin eğitim ve test verileri üzerinde farklı başarı seviyeleri sergilediği görülmektedir. Random Forest (RF) algoritması, eğitim setinde istikrarlı düşük hata (MSE) ve yüksek doğruluk (R^2) değerleri ile dikkat çekmiştir; ancak test setinde genelleme kapasitesinde sınırlı başarı sağlamıştır. Destek Vektör Makineleri (SVM) algoritması, eğitim setinde zaman zaman yüksek R^2 değerleri elde etmiş olsa da test setinde düşük ve dalgalı sonuçlar üretmiş, bu da aşırı öğrenmeye işaret etmektedir. Gradyan Artırmalı Makine (GBM) algoritması, eğitim verisi üzerinde mükemmel yakın sonuçlar verirken, test verisinde düşük R^2 ve yüksek hata oranları göstermiştir. K-Nearest Neighbors (KNN) algoritması ise hem eğitim hem de test verisi üzerinde dalgalı ve düşük doğruluk değerleri ile, bu veri seti için en zayıf performansı göstermiştir. Genel olarak RF algoritması, görece daha dengeli ve tutarlı sonuçlar sunarken, SVM ve GBM modelleri aşırı öğrenme riski taşımış, KNN ise düşük genelleme kapasitesi sergilemiştir.

4.1.2 OKM Tahmini ve Performans Sonuçları

% KM ve % OKM değerleri yer almakta olup, çıkış parametresi reaktörde ölçülen % OKM değeridir. Eğitim süreci boyunca modelin tahmin doğruluğunu artırmak ve hata oranlarını en aza indirmek amacıyla hiperparametre optimizasyonları gerçekleştirilmiştir.

Bu kapsamda, eğitim ve test hata oranlarının yanı sıra, tahmin edilen ve gerçek değerler arasındaki determinasyon katsayısı kullanılarak performans analizleri yapılmıştır.


Şekil 4.16’da görüldüğü üzere, Decision Tree (DT) algoritması ile OKM tahmininde eğitim ve test verileri üzerinde R^2 değerleri arasında belirgin dalgalanmalar gözlemlenmektedir. Test verisindeki düşük ve değişken korelasyon katsayıları, modelin genelleme kabiliyetinin sınırlı olduğunu ve veri setine göre aşırı öğrenme riskinin bulunduğunu göstermektedir. Modelin eğitim verisine fazlasıyla uyum sağladığını ancak bilinmeyen örnekler karşısında yeterli esneklik gösteremediğini ortaya koymaktadır. Ayrıca, veri setinde yer alan karmaşık örüntülerin karar ağacı yapısında tam anlamıyla temsil edilememesi, korelasyon düzeyini düşürerek model performansını zayıflatmıştır. Buna bağlı olarak, modelin bölgesel veri özelliklerine karşı duyarlılığı artmış ve bu durum tahmin doğruluğunda istikrarsızlıklara yol açmıştır. Özellikle sınır değerlerdeki sapmalar, modelin karar sınırlarını doğru şekilde oluşturamadığını ortaya koymaktadır.



Şekil 4.16 Decision Tree (DT) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi grafiği

Şekil 4.17’de görüldüğü üzere DT algoritması ile OKM tahmini sürecinde eğitim ve test verilerinde MSE değerleri arasında dalgalı bir seyir izlenmektedir. Eğitim verisinde hata oranları görece düşük kalmasına rağmen test verisinde geniş bir hata aralığı oluşmuştur. Bu durum modelin genel tahmin stabilitesini olumsuz etkilemiştir. Test verisinde


gözlemlenen bu tutarsızlık, modelin veri setindeki karmaşık yapıları yeterince genelleyemediğini ortaya koymaktadır. Özellikle karar ağacının dallanma yapısının, nadir örnekleri aşırı temsil etmesi bu sapmalara neden olmuş olabileceği düşünülmektedir.



Şekil 4.17 Decision Tree (DT) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi

Şekil 4.18’de görüldüğü üzere, DT algoritması ile elde edilen OKM tahmini sonuçlarında, tahmin edilen değerlerin önemli bir kısmının gerçek değerlerden sapma gösterdiği ve ideal regresyon doğrusundan uzaklaştığı gözlemlenmektedir. Bu durum, modelin doğruluk oranının sınırlı kaldığını ve genel tahmin başarısının düşük olduğunu işaret etmektedir. Özellikle test verisi üzerinde elde edilen düşük korelasyon katsayısı, modelin genelleme yeteneğinin zayıf olduğunu açıkça ortaya koymaktadır.


Ayrıca tahmin değerlerinin belirli aralıklarda kümelenme eğiliminde olduğu ve bu durumun modelin genelleme yeteneğini zayıflattığı anlaşılmaktadır. Özellikle yüksek değerli gözlemler için modelin sistematik bir şekilde düşük tahminler ürettiği gözlenmektedir. Bu bulgular, DT algoritmasının karmaşık yapısal ilişkileri yetersiz temsil ettiğini ve daha gelişmiş yöntemlerin değerlendirilmesi gerektiğini ortaya koymaktadır. Bu nedenle daha gelişmiş modelleme tekniklerine ihtiyaç duyulmaktadır.



Şekil 4.18 Decision Tree (DT) algoritması ile OKM tahmini için test verisi regresyon grafiği


Şekil 4.19’da görüldüğü üzere, RF algoritması ile gerçekleştirilen OKM tahmininde eğitim verisi üzerinde yüksek ve stabil R^2 değerleri elde edilmiştir. Ancak test verisinde zaman zaman dalgalanmalar gözlemlenmiştir. Bu durum, modelin eğitim setinde güçlü uyum sağlarken test setinde kısmen doğruluk kaybı yaşadığını göstermektedir. Özellikle test aşamasındaki bazı örneklerde beklenen tahmin hassasiyetinin sağlanamaması, modelin genelleme kapasitesinde sınırlılık oluşturmuştur. RF algoritmasının çok sayıda karar ağacından oluşan yapısı, genel anlamda güçlü performans sunmasına rağmen, uç değer içeren veya örüntü çeşitliliği yüksek alt kümelerde kararsızlıklar sergileyebildiği gözlemlenmiştir. Modelin test verisi üzerindeki dalgalı performansı, rastgeleleştirme sürecinde bazı örneklerin yeterince temsil edilememesinden kaynaklanıyor olabilir. Model çıktılarındaki bu değişkenlik, özellikle sınıflar arası geçişlerin belirsiz olduğu veri noktalarında daha belirgin hâle gelmiştir.

Bununla birlikte, hiperparametre ayarlarının bazı iterasyonlarda test doğruluğunu olumlu yönde etkilediği, bazı iterasyonlarda ise modelin aşırı öğrenme eğiliminde olduğu dikkati çekmektedir. Bu durum, modelin optimizasyon sürecinde her bir alt ağacın karar katkısının veri dağılımına göre dikkatle ayarlanması gerektiğini göstermektedir. Genel olarak, RF algoritması yüksek eğitim başarımları sunsa da test seti üzerindeki düzensiz varyasyonlar algoritmanın daha dengeli parametre aralıklarıyla yeniden değerlendirilmesini gerekli kılmaktadır.




Şekil 4.19 Random Forest (RF) algoritması ile OKM tahmini eğitim ve test verilerine ait R^2 değişimi

Şekil 4.20’de görüldüğü üzere, RF algoritması ile OKM tahmini sürecinde eğitim verisinde düşük MSE değerleri gözlemlenmiştir. Test verisi üzerinde bazı iterasyonlarda hata oranlarında artışlar kaydedilmiştir. Modelin genel tahmin performansının eğitimde güçlü, test verisinde dalgalı olduğunu gözlenmektedir. Model tahminlerde sınırlı kalmış, genelleme açısından dikkatle değerlendirilmesi gerekmektedir.




Şekil 4.20 Random Forest (RF) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi

Şekil 4.21’de görüldüğü üzere, RF algoritması ile OKM tahmini sonucunda elde edilen değerlerin büyük çoğunluğu ideal regresyon doğrusuna yakın konumlanmıştır. Ancak bazı veri noktalarında sapmalar mevcuttur. Bu durum, genel tahmin doğruluğunun yüksek olduğunu ancak küçük tutarsızlıkların da bulunduğunu göstermektedir.




Şekil 4.21 Random Forest (RF) algoritması ile OKM tahmini için test verisi regresyon grafiği

Şekil 4.22’de görüldüğü üzere, SVM algoritması ile gerçekleştirilen OKM tahmininde eğitim verisi üzerinde yüksek R^2 değerleri elde edilmiştir. Ancak test verisinde geniş dalgalanmalar ve düşük korelasyon katsayıları gözlenmiştir. Modelin eğitim verisine aşırı uyum sağladığını ve genelleme başarısının düşük olduğunu göstermektedir. Özellikle test verisinde gözlemlenen bu dalgalanmalar, modelin bilinmeyen örneklerde kararsız tahminler ürettiğini ortaya koymaktadır. Kernel fonksiyonunun seçiminde yapılan tercihin, veri setindeki doğrusal olmayan ilişkileri yetersiz temsil etmesi bu düşüşte etkili olabileceği ve düşük örnek yoğunluğuna sahip bölgelerde modelin korelasyon katsayısında ciddi düşüşler meydana geldiği gözlemlenmektedir. SVM algoritmasının dikkatli yapılandırılmadığı takdirde aşırı öğrenmeye açık hale gelebileceğini göstermektedir. Modelin belirli veri alt kümelerinde sergilediği bu performans dalgalanmaları, tahmin çıktılarının tutarlılığını zayıflatmıştır. Özellikle sınır değerlerdeki tahmin sapmaları, karar yüzeyinin yeterince genelleşici biçimde oluşturulamadığını düşündürmektedir.




Şekil 4.22 Support Vector Machine (SVM) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi

Şekil 4.23'te görüldüğü gibi, SVM algoritması ile OKM tahmininde eğitim verisinde düşük MSE değerleri yakalanmasına rağmen, test verisinde hata oranlarında belirgin bir dalgalanma meydana gelmiştir. Modelin aşırı öğrenme eğiliminde olduğunu ve farklı veri setlerinde sabit performans sergilemediğini göstermektedir. Özellikle test aşamasındaki performans düşüşü, modelin genelleme kapasitesinin yetersiz kaldığını göstermektedir.




Şekil 4.23 Support Vector Machine (SVM) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi grafiği

Şekil 4.24'te görüldüğü üzere, SVM algoritması ile elde edilen OKM tahmini sonuçlarında, gerçek değerlerle tahmin edilen değerler arasında sapmaların az olduğu gözlenmektedir. Regresyon doğrusuna olan uzaklık ve yayılım modelin tahmin gücünün daha başarılı olabileceği ayrıca aşırı öğrenme yaşamadığı açık bir şekilde gözlemlenebilmektedir.




Şekil 4.24 Support Vector Machine (SVM) algoritması ile OKM tahmini için test verisi regresyon grafiği

Şekil 4.25'te görüldüğü üzere, GBM algoritması ile eğitim setinde yüksek R^2 değerleri elde edilirken, test setinde R^2 değerlerinin düzensiz ve düşük seviyelerde seyrettiği gözlemlenmektedir. Bu durum, modelin eğitim verisine aşırı uyum sağladığını ancak test verisinde genelleme kapasitesinin zayıf kaldığını göstermektedir. GBM'nin ardışık öğrenme yapısı, eğitim örneklerine güçlü biçimde adapte olurken test verisinde performans kayıplarına yol açabilmektedir. Özellikle veri setindeki dengesizlikler ve gürültülü örnekler, modelin karar mekanizmasını olumsuz etkilemiştir. Test setindeki düşük korelasyon katsayıları, modelin doğrusal olmayan ilişkileri genellemediğini ortaya koymuştur. Bu durum, modelin fazla derinlikte öğrenme gerçekleştirdiğini ve erken durdurma gibi düzenleme yöntemlerine ihtiyaç duyduğunu göstermektedir. Ayrıca, modelin test setindeki performans değişkenliği, aşırı parametrisasyonun bir sonucu olarak değerlendirilmektedir.




Şekil 4.25 Gradient Boosting Machine (GBM) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi

Şekil 4.26’da görüldüğü gibi GBM algoritması ile eğitim setinde düşük MSE değerleri elde edilirken, test setinde MSE değerlerinin yüksek ve dalgalı olduğu dikkat çekmektedir. Bu durum, modelin eğitim verisine aşırı uyum sağladığını ve test verilerinde tahmin performansının düzensiz olduğunu göstermektedir. Modelde aşırı öğrenme gözlemlenmiştir.



Şekil 4.26 Gradient Boosting Machine (GBM) algoritması ile OKM tahmini eğitim ve test verilerine ait MSE değişimi


Şekil 4.27’de görüldüğü üzere, GBM algoritması ile gerçekleştirilen OKM tahmininde, tahmin edilen değerler ile gerçek değerler arasında belirgin sapmalar gözlemlenmektedir. Noktaların ideal regresyon doğrusundan uzaklaşması, modelin test verisi üzerinde düşük tahmin doğruluğuna ve yetersiz genelleme kapasitesine sahip olduğunu göstermektedir.



Şekil 4.27 Gradient Boosting Machine (GBM) algoritması ile OKM tahmini için test verisi regresyon grafiği


Şekil 4.28’de, K-Nearest Neighbors (KNN) algoritması ile yapılan OKM tahmininde eğitim ve test verileri için elde edilen R^2 değişimi gösterilmektedir. Eğitim verisinde bazı iterasyonlarda yüksek R^2 değerleri (1’e yakın) görülse de test verisinde R^2 değerlerinin düşük seviyelerde dalgalandığı gözlemlenmektedir. Özellikle test setinde R^2 ’nin birçok iterasyonda 0.1 ile 0.4 arasında değişmesi, modelin genelleme kapasitesinin yetersiz olduğunu göstermektedir. Bu durum, aşırı öğrenme etkisinin varlığını işaret etmektedir. Modelin yalnızca eğitim örnekleriyle sınırlı kalması, test verilerinde tahmin tutarlılığını ciddi ölçüde azaltmıştır.

Bu nedenle, KNN algoritmasının OKM tahminindeki başarımı sınırlı kalmış ve modelin güvenilirliği zayıflamıştır. Bu bağlamda, modelin farklı veri yapılarıyla karşılaştığında istikrarlı sonuçlar üretememesi, genel geçerliliğini sorgulanabilir hâle getirmiştir. Model yapısal tutarlılığı zayıflamıştır.




Şekil 4.28 K-Nearest Neighbors (KNN) algoritması ile OKM tahmini için eğitim ve test verilerine ait R^2 değişimi

Şekil 4.29 incelendiğinde, KNN algoritmasının eğitim ve test verileri için MSE değerleri arasındaki farklılık dikkat çekmektedir. Eğitim setinde bazı iterasyonlarda MSE sıfıra yaklaşırken, test setinde daha yüksek ve düzensiz bir hata dağılımı gözlemlenmektedir. Modelin yüksek varyans problemi yaşadığı söylenebilir.



Şekil 4.29 K-Nearest Neighbors (KNN) algoritması ile OKM tahmini için eğitim ve test verilerine ait MSE değişimi grafiği

Şekil 4.30'da tahmin edilen OKM değerleri ile gerçek değerler arasındaki ilişkiyi gösteren regresyon grafiği sunulmaktadır. Grafik incelendiğinde, tüm tahminlerin belirli bir bant içinde sıkıştığı ve veri noktalarının doğrusal referans çizgisine uzak konumlandığı görülmektedir. Bu durum, modelin farklı değerleri ayırt etme kabiliyetinin düşük olduğunu ve tahmin başarısının sınırlı kaldığını göstermektedir. Özellikle KNN algoritmasının tüm tahminleri neredeyse sabit bir değerde toplaması, modelin öğrenme sürecinde yeterli varyasyon oluşturamadığını işaret etmektedir. Seçilen komşu sayısının ya da mesafe metriğinin modele uygun belirlenmediğini göstermektedir. Ayrıca veri setinde bulunan örneklerin çok benzer olması durumunda, KNN'nin genelleme yeteneği zayıflayarak aşırı düzleştirilmiş tahminler üretme eğilimi göstermektedir. Modelin lokal yapılar yerine ortalama değerler etrafında kümelenen tahminler üretmesine neden olmuştur. KNN algoritmasının bu uygulamada etkili sonuçlar vermediği ve daha duyarlı algoritmaların tercih edilmesinin gerekliliği ortaya çıkmaktadır.




Şekil 4.30 K-Nearest Neighbors (KNN) algoritması ile OKM tahmini için test verisi regresyon grafiği

4.1.3 FOS Tahmini ve Performans Sonuçları


Şekil 4.31'de görüldüğü üzere, eğitim verilerinde R^2 değerlerinin dalgalı bir seyir izlediği ancak genel olarak %30 ile %85 arasında değiştiği tespit edilmiştir. Test verisinde ise R^2

değerleri daha düşük seyretmekte ve genel stabilite sağlanamamaktadır. Bu durum modelin genellenebilirliğinin sınırlı olduğunu göstermektedir.




Şekil 4.31 Decision Tree (DT) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği

Şekil 4.32 incelendiğinde, eğitim verisindeki MSE değerlerinin zaman zaman düşüşler gösterse de genel olarak yüksek seviyelerde seyrettiği görülmektedir. Test verisinde ise MSE değerleri dalgalı bir yapı göstermekte ve stabil bir tahmin performansı sergileyememektedir. Bu durum modelin hata oranlarının optimize edilemediğini göstermektedir. Özellikle iterasyonlar boyunca test hatalarında gözlenen keskin artışlar, modelin belirli veri alt kümelerine karşı hassasiyet geliştiremediğini ve genelleme kapasitesinin zayıf kaldığını ortaya koymaktadır. Karar Ağacı algoritmasının doğrusal olmayan örüntüler karşısında sınırlı yapısal esnekliğe sahip olması, bu tür dalgalanmaların temel nedeni olarak değerlendirilmektedir. Ayrıca modelin hiperparametre seçimlerinde yapılan değişiklikler, eğitim performansına sınırlı katkı sağlarken test performansında istikrarsızlığa yol açmıştır. MSE değerlerindeki düzensizlik, modelin öğrenme sürecinde gürültüden etkilenme eğiliminde olduğunu göstermektedir. Bu bağlamda, daha istikrarlı ve derin yapılandırmalara sahip algoritmaların tercih edilmesi gerektiği söylenebilir. DT algoritması bu çalışmada hedeflenen tahmin doğruluğunu ve kararlılığı sağlayamamış, alternatif yöntemlerin gerekliliğini ortaya koymaktadır.




Şekil 4.32 Decision Tree (DT) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişim grafiği

Şekil 4.33 incelendiğinde tahmin edilen FOS değerlerinin gerçek değerlerden önemli ölçüde sapmalar gösterdiği belirlenmiştir. Noktaların ideal doğrultudan uzak bir dağılım göstermesi, modelin regresyon doğruluğunun düşük olduğunu ortaya koymaktadır. Bu da DT algoritmasının FOS tahmini için yetersiz kaldığını göstermektedir. Test verisinde gözlemlenen düşük R^2 değeri, modelin karmaşık veri örüntülerini yakalayamadığını göstermektedir. Ayrıca karar ağacı yapısının fazla dallanması bazı veri gruplarında aşırı öğrenmeye, diğerlerinde ise yetersiz öğrenmeye yol açmıştır. Bu durum modelin genelleme yeteneğini zayıflatmış ve tahmin tutarlılığını düşürmüştür. Sonuçlar, FOS tahmini gibi hassas parametrelerde daha güçlü genelleme kapasitesine sahip algoritmaların tercih edilmesi gerektiğini ortaya koymuştur. Bu bulgular, özellikle değişkenliği yüksek parametrelerin tahmininde daha esnek ve uyarlanabilir modelleme yaklaşımlarına ihtiyaç duyulduğunu göstermektedir. Tahmin değerlerinin belirli eşiklerde kümelenme eğiliminde olması, modelin sürekli değişkenlik gösteren veriler üzerinde lineer olmayan davranışları ayırt etme gücünün zayıf olduğunu göstermektedir. Bu durum genelleme kapasitesini sınırlandırmaktadır. Bu da karar ağacı yapısının belirli örüntülere sıkı şekilde uyması, ancak veri çeşitliliği karşısında genelleme kabiliyetini kaybetmesine yol açmaktadır. Dolayısıyla, FOS gibi yüksek varyansa sahip çıktılarda daha gelişmiş ve parametrik öğrenme stratejilerine sahip yöntemlerin tercih edilmesi model başarımı açısından kritik öneme sahiptir.




Şekil 4.33 Decision Tree (DT) algoritması ile FOS tahmini için test verisi regresyon grafiği

Şekil 4.34'te RF algoritması ile FOS tahmininde eğitim verisi için R^2 değerleri genel olarak yüksek bir seyir izlerken, test verisi için elde edilen R^2 değerlerinin oldukça dalgalı olduğu ve düşük seviyelerde seyrettiği gözlemlenmektedir. Eğitim verisinde R^2 değerlerinin 0.6 ila 0.8 arasında değişmesi modelin eğitim aşamasında başarılı olduğunu göstermektedir. Test verisindeki düşük R^2 değerlerine rastlanması, modelin genellenebilirliğinin zayıf olduğunu ve aşırı öğrenme eğilimi gösterdiğini düşündürmektedir.




Şekil 4.34 Random Forest (RF) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.

Şekil 4.35'te görüldüğü üzere, RF algoritması ile gerçekleştirilen FOS tahmininde eğitim verisi MSE değerlerinin belirli bir aralıkta istikrarlı seyrettiği, ancak test verisi MSE değerlerinde düzensiz ve yüksek dalgalanmaların olduğu gözlenmektedir. Eğitim verisinde MSE değerleri düşük seviyelerde kalmasına rağmen, test verisinde zaman zaman önemli sıçramalar yaşanmıştır. Bu durum modelin eğitim verisine uyum sağladığını, ancak test verisinde yeterli başarıyı gösteremediğini ve modelin aşırı öğrenmeye maruz kaldığını işaret etmektedir.




Şekil 4.35 Random Forest (RF) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişim grafiği.

Şekil 4.36'da sunulan regresyon grafiğinde, RF algoritması ile tahmin edilen FOS değerlerinin gerçek değerlerle tam bir uyum göstermediği dikkat çekmektedir. Noktaların, ideal doğrusal çizgi etrafında yoğunlaşmaması ve geniş bir dağılım göstermesi, modelin tahmin performansının istenilen düzeyde olmadığını ortaya koymaktadır. Özellikle yüksek FOS değerlerinde modelin tahmin hatalarının daha da arttığı, sapmaların belirginleştiği görülmektedir. Modelin özellikle uç değerleri doğru bir şekilde öğrenemediğini göstermektedir veri setindeki heterojen yapının modelin karar mekanizmalarını zorladığı ve tahminlerde sapmalara neden olduğu anlaşılmaktadır. RF algoritmasının genel yapısı itibarıyla güçlü olmasına rağmen, FOS gibi geniş varyanslı değişkenlerde yeterli tutarlılığı sağlayamadığı görülmektedir. Bu durum öngörü gücünü azaltmaktadır.




Şekil 4.36 Random Forest (RF) algoritması ile FOS tahmini için test verisi regresyon grafiği.

Şekil 4.37’de görüldüğü üzere, SVM algoritması ile gerçekleştirilen FOS tahmininde eğitim ve test verilerine ait R^2 değerleri önemli farklılıklar göstermektedir. Eğitim verisinde R^2 değerleri genellikle 0.3 ile 0.5 arasında değişmektedir. Ancak test verisinde daha fazla dalgalanma gözlenmiş ve bazı iterasyonlarda R^2 değerinin oldukça düşük olduğu tespit edilmiştir. Bu sonuçlar, modelin öğrenme sürecinde stabilite problemi yaşadığını göstermektedir.




Şekil 4.37 Support Vector Machine (SVM) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği

Şekil 4.38’de sunulan MSE değişim grafiğinde, SVM algoritması için eğitim ve test verileri arasında dikkat çekici bir hata farkı olduğu görülmektedir. Eğitim MSE değerleri görece daha düşük aralıkta seyretmesine karşın, test MSE değerleri oldukça yüksektir ve iterasyonlar boyunca düzensiz bir dağılım göstermektedir. Bu durum, modelin test verilerinde istikrarlı tahminler üretemediğini ve aşırı öğrenme riskinin bulunduğunu göstermektedir.




Şekil 4.38 Support Vector Machine (SVM) algoritması ile FOS tahmini eğitim ve test verilerine ait MSE değişim grafiği

Şekil 4.39’da sunulan regresyon grafiği incelendiğinde, SVM algoritması ile elde edilen FOS tahminlerinin, gerçek değerlerle tam bir doğrusal ilişki kuramadığı görülmektedir. Tahminlerin büyük çoğunluğu belirli bir aralıkta kümelenmiş olup, yüksek FOS değerlerinin doğru tahmin edilemediği anlaşılmaktadır. Bu durum modelin karmaşık veri desenlerini öğrenme kapasitesinin sınırlı olduğunu ortaya koymaktadır. Bu sınırlı öğrenme kapasitesi, özellikle uç değerlerin ve ani değişimlerin bulunduğu veri yapılarında modelin başarımını düşürmüştür. Regresyon çizgisinden sapmaların yoğunluğu, modelin genelleme yeteneğinin zayıf olduğunu ve veri setine tam uyum sağlayamadığını göstermektedir. Bu sonuçlar SVM algoritmasının FOS tahmini gibi çok değişkenli ve doğrusal olmayan ilişkiler içeren problemler için dikkatle yapılandırılması gerektiğini ortaya koymaktadır. Özellikle yüksek varyansa sahip örneklerde, modelin yanıt hassasiyetinin düşük kalması, doğruluk oranlarını olumsuz yönde etkilemiştir.




Şekil 4.39 Support Vector Machine (SVM) algoritması ile FOS tahmini için test verisi regresyon grafiği

Şekil 4.40 'ta GBM algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişimi incelenmiştir. Eğitim setinde R^2 değerlerinin 0.85 ile 1.00 aralığında yüksek seviyede istikrarlı kaldığı gözlenmiştir. Buna karşın test setinde ciddi dalgalanmalar mevcuttur ve birçok iterasyonda R^2 değerinin düşük olduğu görülmektedir. Bu durum, GBM algoritmasının eğitim verisine aşırı uyum sağlarken test verilerinde istenilen doğruluk seviyesini koruyamadığını göstermektedir.



Şekil 4.40 Gradient Boosting Machines (GBM) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği


Şekil 4.41’de Eğitim ve test verilerine ait MSE değişimleri karşılaştırıldığında, GBM algoritmasının eğitim verisinde düşük hata oranları ile başarılı bir öğrenme gerçekleştirdiği anlaşılmaktadır. Ancak test setinde gözlemlenen düzensiz ve yüksek MSE değerleri, modelin yeni veriler karşısında yeterince genelleme yapamadığını ortaya koymaktadır. Özellikle bazı iterasyonlarda test hatasının aşırı yükselmesi dikkat çekmektedir.



Şekil 4.41 Gradient Boosting Machines (GBM) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişimi grafiği


Şekil 4.42’de GBM algoritması ile FOS tahmini yapılan test verilerine ait regresyon grafiğinde, tahminlerin çoğunlukla gerçek değerlere yakın olduğu ancak yüksek FOS değerlerinde belirgin sapmaların meydana geldiği görülmektedir. Özellikle aşırı değerlerde model doğruluğunun düştüğü gözlemlenmiştir. Bu sonuç modelin belirli aralıklarda daha iyi genelleme yapabildiğini, ancak uç değerler için tahmin hassasiyetinin azaldığını göstermektedir. Bu durum modelin öğrenme sürecinde yaygın veri desenlerine öncelik verdiğini ve nadir gözlemleri yeterince temsil edemediğini göstermektedir. Modelin karar mekanizmasının ağırlıklı olarak yoğun veri bölgelerine odaklandığını ve istisnai durumları göz ardı ettiğini ortaya koymaktadır.

Genel dağılımın referans doğrultusuna daha yakın seyretmesi, GBM algoritmasının FOS tahmininde DT ve RF gibi modellere kıyasla daha istikrarlı sonuçlar verdiğini göstermektedir. Bu da modelin doğrusal olmayan ilişkileri daha esnek şekilde öğrenebildiğini ortaya koymaktadır.




Şekil 4.42 Gradient Boosting Machines (GBM) algoritması ile FOS tahmini için test verisi regresyon grafiği

Şekil 4.43'te KNN algoritması ile gerçekleştirilen eğitim sürecinde R^2 değerlerinin oldukça dalgalı bir seyir izlediği görülmektedir. Eğitim verileri için R^2 değerlerinin birçok iterasyonda 1'e yakın olması, aşırı öğrenmeye işaret etmektedir. Ancak test verilerinde R^2 değerlerinin genellikle düşük ve düzensiz olması, modelin genel doğruluk açısından yetersiz kaldığını ve test verilerine genellemediği gözlemlenmiştir.




Şekil 4.43 K-Nearest Neighbors (KNN) algoritması ile FOS tahmini için eğitim ve test verilerine ait R^2 değişim grafiği

Şekil 4.44'te MSE grafiği incelendiğinde, eğitim verileri için bazı iterasyonlarda sıfıra yakın hata değerleri elde edildiği gözlemlenmektedir. Ancak test verilerinde hata değerleri yüksek seviyelerde seyretmektedir. Bu durum, KNN modelinin eğitim verilerine aşırı uyum sağladığını ancak yeni veriler üzerinde tahmin performansının düşük olduğunu göstermektedir. MSE'nin geniş aralıkta değişmesi de modelin kararsızlığını ortaya koymaktadır.



Şekil 4.44 K-Nearest Neighbors (KNN) algoritması ile FOS tahmini için eğitim ve test verilerine ait MSE değişim grafiği


Şekil 4.45 Regresyon grafiği incelendiğinde, tahmin edilen FOS değerlerinin gerçek değerlere göre belirli bir sabit seviyede kümелendiği ve geniş bir veri aralığında yayılım gösteremediği görülmektedir. Modelin gerçek verilerle olan ilişkisinin zayıf olduğu ve lineer bir tahmin başarısının sağlanamadığı anlaşılmaktadır. Bu durum da KNN algoritmasının bu veri seti ve problem için etkili bir tahmin performansı sunamadığını ortaya gözlemlenmektedir. Tüm tahminlerin üst sınıra yakın sabitlemesi, modelin komşuluk ilişkilerini yeterince ayırt edemediğini göstermektedir. Uç değerlerin ve varyansı yüksek örneklerin model tarafından temsil edilememesi, genelleme kabiliyetinin oldukça düşük olduğunu ortaya koymaktadır. Verilerin büyük bölümünde benzer tahmin değerlerinin üretilmesi, modelin karar verme süreçlerinde etkili örüntü çıkarımı yapamadığını göstermektedir. Bu nedenle, FOS tahmini gibi yüksek değişkenlik gösteren problemlerde daha karmaşık ve duyarlı algoritmaların tercih edilmesi gerekliliği ortaya çıkmaktadır.



Şekil 4.45 K-Nearest Neighbors (KNN) algoritması ile FOS tahmini için test verisine ait regresyon grafiği


4.1.4 TAC Tahmini ve Performans Sonuçları

Şekil 4.46’da Decision Tree (DT) algoritması ile TAC tahmini için elde edilen R^2 değişim grafiğinde, eğitim verisinde R^2 değerlerinin test verilerine göre daha yüksek olduğu gözlemlenmektedir. İterasyonlar boyunca dalgalanmalar sürmüştür ve modelin kararlı bir genel performans sergileyemediği anlaşılmaktadır.



Şekil 4.46 Decision Tree (DT) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği


Şekil 4.47’de TAC tahmini için DT algoritmasıyla elde edilen MSE değişim grafiği, eğitim verisi üzerinde düşük hata değerleri sağlarken test verisinde daha yüksek MSE değerleri göstermektedir. Bu durum modelin aşırı öğrenme eğiliminde olabileceğini ve genellemede zayıflık yaşadığını göstermektedir. Özellikle test verisinde gözlemlenen düzensiz ve dalgalı hata dağılımı, modelin doğruluk seviyesinin veri alt kümelerine göre değişkenlik gösterdiğini ortaya koymaktadır. Bu durum, modelin eğitim verisine fazlasıyla uyum sağladığını ancak yeni veriler karşısında istikrarlı tahminler üretilmediğini göstermektedir.



Şekil 4. 47 Decision Tree (DT) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği


Şekil 4.48’de Decision Tree (DT) algoritmasıyla gerçekleştirilen TAC tahminine ait regresyon grafiğinde, tahmin edilen değerlerin gerçek değerlere olan uzaklığı dikkat çekmektedir. Veri dağılımı, modelin yüksek hata payı barındırdığını ve doğrusal ilişkiyi kurmakta yetersiz kaldığını ortaya koymaktadır.

Noktaların belirli bantlar etrafında kümелendiği ve geniş bir aralıkta dağılmadığı görülmektedir. Bu durum, modelin çıktılarının genellikle sabit birkaç tahmin değerine odaklandığını ve veri setindeki varyasyonu yansıtamadığını göstermektedir. Özellikle yüksek TAC değerlerinde tahminlerin düşük seviyelerde kalması, modelin uç değerleri öğrenmede başarısız olduğunu işaret etmektedir.




Şekil 4.48 Decision Tree (DT) algoritması ile TAC tahmini için test verisine ait regresyon grafiği

Şekil 4.49'da RF algoritması ile yapılan TAC tahmini için elde edilen R^2 değişim grafiği sunulmaktadır. Eğitim verilerinde yüksek R^2 değerleri korunurken, test verilerinde dalgalanmalar gözlemlenmiştir. Özellikle test setinde bazı iterasyonlarda R^2 değerinin ani düşüşler göstermesi, modelin bilinmeyen veri örneklerinde kararsız sonuçlar ürettiğini ortaya koymaktadır.



Şekil 4.49 Random Forest (RF) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği

Şekil 4.50’de ki RF algoritmasına ait MSE değişim grafiği, eğitim verilerinde düşük hata seviyeleri sağlarken test verilerinde yüksek ve değişken MSE değerleri sergilemektedir. Bu durum, modelin test verilerinde genelleme kabiliyetinin sınırlı olduğuna ve varyansın arttığına işaret etmektedir.




Şekil 4.50 Random Forest (RF) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği

Şekil 4.51’de regresyon grafiğinde, RF algoritması ile elde edilen tahmin değerlerinin gerçek değerlerle kısmi bir uyum sergilediği gözlemlenmektedir. Veri noktalarının referans doğrusu etrafındaki dağınık dağılımı, modelin genel doğruluk oranının düşük seviyelerde kaldığını göstermektedir.

Veri noktalarının referans doğrusu etrafındaki dağınık dağılımı, modelin genel doğruluk oranının düşük seviyelerde kaldığını göstermektedir. Özellikle orta düzey TAC değerlerinde modelin tahmin başarımı görece daha iyi olsa da düşük ve yüksek uç değerlerde belirgin sapmalar dikkat çekmektedir. Bu durum, modelin uç değerleri yeterince öğrenemediğini ve genelleme kapasitesinin sınırlı kaldığını ortaya koymaktadır.

Tahmin edilen değerlerin çoğunlukla referans çizgisinin altında konumlanması, modelin sistematik olarak düşük tahmin eğiliminde olduğunu göstermektedir. Bu eğilim, modelin veri dağılımının tamamını temsil edemediğini göstermektedir.




Şekil 4.51 Random Forest (RF) algoritması ile TAC tahmini için test verisine ait regresyon grafiği

Şekil 4.52'de görüldüğü üzere, SVM algoritması ile yapılan TAC tahmininde eğitim ve test verilerinin R^2 değerlerinde önemli dalgalanmalar yaşanmaktadır. Test verilerindeki tutarsızlık, modelin genelleme başarısının sınırlı olduğunu ve istikrarlı bir tahmin gücü sağlayamadığını göstermektedir. Bu durum, özellikle doğrusal olmayan örüntülerin yoğun olduğu veri yapılarında SVM algoritmasının sınırlı temsil kabiliyetinden kaynaklanmaktadır. Kernel fonksiyonu ve C parametresi gibi hiperparametrelerin hassasiyeti, modelin farklı veri bölümlerinde tutarsız tahminler üretmesine neden olmuştur.


Eğitim verisinde yüksek R^2 değerleri elde edilmesine rağmen, test setindeki düşük korelasyon katsayıları modelin aşırı öğrenme eğiliminde olduğunu düşündürmektedir. Bu sonuçlar SVM algoritmasının TAC tahmini gibi değişkenliği yüksek problemlerde dikkatle yapılandırılması gerektiğini ortaya koymaktadır.

Bu durum, hiperparametre optimizasyonuna rağmen modelin veri setindeki yüksek değişkenliği yeterince genellemediğini ve SVM algoritmasının karmaşık yapılar karşısında sınırlı performans sergileyebileceğini göstermektedir. Bu durum SVM algoritmasının veri yapısındaki lokal örüntülere karşı duyarlılığının yeterli seviyede olmadığı gözlemlenmektedir.



Şekil 4.52 Support Vector Machine (SVM) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği


Şekil 4.53'te sunulan SVM algoritmasına ait MSE değişim grafiğinde, eğitim ve test verileri arasında belirgin hata farklılıkları gözlemlenmektedir. Test verisinde MSE değerlerinin düzensiz bir şekilde yükselmesi, modelin test setlerinde düşük genelleme başarısı ve yüksek varyans problemi yaşadığını ortaya koymaktadır.



Şekil 4.53 Support Vector Machine (SVM) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği


Şekil 4.54'te verilen regresyon grafiği, SVM algoritması kullanılarak yapılan TAC tahminlerinin gerçek değerlerle sınırlı bir uyum sergilediğini göstermektedir. Veri

noktalarının referans doğrusu etrafında düzensiz dağılması, modelin tahmin başarısının düşük seviyelerde kaldığını ve doğrusal ilişkinin zayıf olduğunu ortaya koymaktadır. Tahmin edilen değerlerin büyük ölçüde benzer aralıkta toplanması, modelin değişkenlik gösteren değerleri yeterince ayırt edemediğini göstermektedir. Bu durum modelin özellikle uç noktalardaki örnekler için yetersiz genelleme yaptığına işaret etmektedir.




Şekil 4.54 Support Vector Machine (SVM) algoritması ile TAC tahmini için test verisine ait regresyon grafiği

Şekil 4.55'te sunulan GBM algoritmasına ait R^2 grafiğinde, eğitim verisinde yüksek doğruluk oranı elde edilirken, test verilerinde önemli bir doğruluk kaybı gözlemlenmektedir. Eğitim aşamasında modelin neredeyse mükemmel sonuçlar üretmesi, aşırı öğrenme riskine işaret etmektedir. Bu durum, modelin eğitim verisindeki örüntülere fazlasıyla uyum sağladığını, ancak yeni ve görülmemiş veriler karşısında genelleme kabiliyetinin zayıfladığını göstermektedir. Test verilerinde gözlemlenen düşük R^2 değerleri, modelin doğrusal olmayan ilişkileri yeterince öğrenemediğine işaret etmektedir. Özellikle uç değerler ve değişkenlik gösteren gözlemler karşısında modelin tahmin başarımı ciddi şekilde düştüğü gözlemlenmektedir. Modelin yalnızca eğitim verisi üzerinde yüksek performans sergilemesi, genelleme yeteneğinin zayıf kaldığını göstermektedir. Bu durum, özellikle veri setindeki dengesizlikler ve karmaşık örüntüler karşısında modelin tahmin güvenilirliğini olumsuz ve aksi yönde etkilediği gözlemlenmektedir.



Şekil 4.55 Gradient Boosting Machine (GBM) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği


Şekil 4.56'da görülen GBM algoritmasına ait MSE değişim grafiği, eğitim verisinde düşük hata seviyeleri sağlanmasına karşın, test verilerinde daha yüksek ve dalgalı hata değerleri göstermektedir. Bu sonuçlar modelin eğitim verisine aşırı uyum sağladığını ve test verisinde genelleme gücünün zayıf kaldığını göstermektedir.



Şekil 4.56 Gradient Boosting Machine (GBM) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği


Şekil 4.57'de yer alan regresyon grafiğinde, GBM algoritması ile gerçekleştirilen TAC tahminlerinin, gerçek değerlerle sınırlı düzeyde bir korelasyon gösterdiği

gözlemlenmektedir. Veri noktalarının regresyon doğrusuna dağınık biçimde yayılması, modelin test verilerinde tutarlı bir tahmin gücüne ulaşamadığını göstermektedir. Özellikle bazı bölgelerdeki sapmalar, modelin yerel örüntüleri yeterince öğrenemediğini düşündürmektedir.




Şekil 4.57 Gradient Boosting Machine (GBM) algoritması ile TAC tahmini için test verisine ait regresyon grafiği

Şekil 4.58'de sunulan K-Nearest Neighbors (KNN) algoritmasına ait R^2 değişim grafiğinde, eğitim verilerinde yüksek R^2 değerleri görülürken, test verilerinde ciddi dalgalanmalar ve düşük değerler gözlemlenmektedir. Bu durum, modelin sadece eğitim verisine iyi uyum sağladığını ancak yeni verilerde başarısız olduğunu göstermektedir. KNN algoritmasının örnek tabanlı doğasının eğitim verisine yakın örneklerde başarılı tahminler üretmesini sağladığını ancak veri dışı örneklerde genelleme gücünün zayıf olduğunu ortaya koymaktadır. Özellikle test setinde gözlemlenen düşük R^2 değerleri, modelin veri yoğunluğu düşük bölgelerde kararsızlık sergilediğini göstermektedir. Komşu sayısı (k) ve uzaklık metriği gibi parametrelerin model performansı üzerinde doğrudan etkili olduğu anlaşılmaktadır. Bu bağlamda, KNN algoritmasının karmaşık ve düzensiz dağılıma sahip veri setlerinde istikrarlı tahmin sonuçları üretmekte zorlandığı görülmektedir. Bu nedenle model çıktılarında gözlemlenen yüksek varyans KNN algoritmasının genelleme kabiliyetinin sınırlı olduğunu bir kez daha doğruladığı görülmektedir.



Şekil 4.58 K-Nearest Neighbors (KNN) algoritması ile TAC tahmini için eğitim ve test verilerine ait R^2 değişim grafiği


Şekil 4.59'da gösterildiği gibi, K-Nearest Neighbors (KNN) algoritması için eğitim ve test verilerindeki MSE değişimleri belirgin farklılık göstermektedir. Eğitim verisinde çok düşük hata seviyeleri oluşurken, test verisinde yüksek hata değerleri gözlemlenmiştir.



Şekil 4.59 K-Nearest Neighbors (KNN) algoritması ile TAC tahmini için eğitim ve test verilerine ait MSE değişim grafiği

Şekil 4.60'da verilen regresyon grafiği, KNN algoritması ile yapılan TAC tahminlerinin gerçek değerlerle neredeyse sabit bir çizgi üzerinde toplandığını göstermektedir.

Tahminler arasındaki farklılıkların son derece sınırlı olması, modelin değişkenlikleri yeterince yakalayamadığını ve düşük doğruluk sergilediğini göstermektedir.




Şekil 4.60 K-Nearest Neighbors (KNN) algoritması ile TAC tahmini için test verisine ait regresyon grafiği

4.1.5 Metan Tahmini ve Performans Sonuçları

Giriş parametreleri; günlük atık miktarı, KM, OKM, FOS ve TAC değerlerinden oluşmaktadır. Çıkış değişkeni ise toplam metan üretim miktarıdır.


Şekil 4.61’de DT algoritması ile yapılan metan tahmininde, R^2 değişim grafiği incelendiğinde, eğitim verilerinde kısmi bir artış eğilimi gözlenmesine rağmen test verilerinde düşük korelasyon değerleri dikkati çekmektedir. Bu durum, modelin doğruluk kapasitesinin sınırlı olduğunu ve eğitim ile test verileri arasındaki performans farkının yüksek olduğunu göstermektedir. Modelin yeni veriler karşısında istikrarlı tahminler üretemediğini ve genelleme yeteneğinin zayıf kaldığını ortaya koymaktadır. Test verisinde gözlemlenen doğruluk kaybı yaşandığı gözlemlenmektedir. Bu sonuçlar, DT algoritmasının metan tahmininde güvenilir bir seçenek olmadığını göstermektedir.

Test setindeki MSE değerlerinde gözlemlenen ani sıçramalar, modelin bazı iterasyonlarda ciddi tahmin hataları ürettiğini göstermektedir. Bu dalgalı yapı, modelin aşırı dallanma veya yetersiz budama gibi yapısal sorunlar barındırabileceğine işaret etmektedir.




Şekil 4.61 Karar ağaçları (DT) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.

Şekil 4.62’de MSE değerleri üzerinden yapılan analizde, Decision Tree algoritmasının eğitim verileri için görece düşük hata seviyelerine ulaştığı, ancak test verilerinde zaman zaman ciddi hata artışlarının meydana geldiği gözlemlenmiştir. Bu dalgalanmalar, modelin eğitim verisine aşırı uyum sağladığını ve yeni verilere karşı genelleme yeteneğinin sınırlı olduğunu işaret etmektedir.




Şekil 4.62 Karar Ağacı (DT) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.

Şekil 4.63'te Metan tahmini için oluşturulan regresyon grafiğinde, gerçek ve tahmin edilen değerler arasında belirgin sapmalar gözlenmektedir. Noktaların doğrusal çizgiden önemli ölçüde uzaklaşması, modelin tahmin başarısının düşük olduğunu göstermektedir. Özellikle uç değerlerde ciddi hatalar meydana gelmiş ve modelin genel doğruluk seviyesi zayıf bulunmuştur.




Şekil 4.63 Karar ağaçları (DT) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.

Şekil 4.64'te Rastgele Orman algoritması ile gerçekleştirilen metan tahmininde, eğitim verisinde R^2 değerlerinin yüksek ve dengeli olduğu görülmektedir. Ancak test verilerinde R^2 değerleri oldukça dalgalı olup, genel olarak düşük seviyelerde seyretmektedir. Bu durum, modelin eğitim verisinde iyi uyum sağladığını fakat test verisinde genelleme kapasitesinin sınırlı kaldığını göstermektedir. Test verisindeki bu dalgalı yapı, modelin özellikle veri dağılımının değişkenlik gösterdiği bölgelerde tahmin tutarlılığını koruyamadığını ortaya koymaktadır. Eğitim verisine yüksek düzeyde uyum sağlayan model, yeni verilerde beklenen doğruluk seviyesini sürdürememiştir. Bu sonuçlar, Rastgele Orman algoritmasının metan tahmini sürecinde aşırı öğrenme eğilimi gösterdiğini ve veri setine özgü örüntülerde genelleme zorlukları yaşadığını göstermektedir. Modelin test performansındaki istikrarsızlık, farklı veri alt gruplarına karşı duyarlılığının yüksek olduğunu göstermektedir.




Şekil 4.64 Rastgele Orman (RF) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.

Şekil 4.65'te MSE değişim grafiği incelendiğinde, eğitim verilerinde hata değerlerinin düşük seviyelerde ve stabil olduğu, test verilerinde ise bazı iterasyonlar da ciddi hata artışları yaşandığı gözlemlenmektedir. Test verisindeki bu dalgalanmalar, modelin belirli veri alt kümelerinde başarısız olduğunu ve dış veriye karşı adaptasyon sorunları yaşadığını göstermektedir.




Şekil 4.65 Rastgele Orman (RF) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.

Şekil 4.66'da gerçek ve tahmin edilen metan değerleri arasındaki regresyon analizi sonucunda, veri noktalarının genel olarak doğrusal çizgi etrafında toplandığı görülmektedir. Bununla birlikte, bazı sapmalar ve uzak noktalar da gözlemlenmektedir. Bu durum, modelin genel olarak makul bir tahmin performansı sergilediğini ancak belirli değerlerde hata payının arttığını göstermektedir.




Şekil 4.66 Rastgele Orman (RF) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.

Şekil 4.67'de SVM algoritması ile yapılan metan tahmininde, eğitim ve test verilerine ait R^2 değerlerinin genel olarak düşük seviyelerde seyrettiği gözlemlenmiştir. Eğitim verisinde kısmi yükselmeler olmasına rağmen test verisinde oldukça düzensiz bir dağılım mevcuttur. Bu durum, modelin doğruluk seviyesinin yetersiz kaldığını göstermektedir. Test verisinde gözlemlenen düşük korelasyon değerleri, modelin genelleme kapasitesinin sınırlı olduğunu ortaya koymaktadır. SVM algoritmasının doğrusal olmayan ilişkileri temsil etmedeki zayıflığı, karmaşık veri yapılarında performans kayıplarına yol açmıştır. Modelin yalnızca sınırlı veri örüntülerine uyum sağlayabildiğini ve karmaşık ilişkileri yeterince öğrenemediğini göstermektedir. Ayrıca, iterasyonlar boyunca gözlenen ani sıçramalar ve düşüşler, modelin tahmin kararlılığını sağlayamadığını ve istikrarsız çıktılar ürettiğini ortaya koymaktadır. Bu tür dalgalı yapı SVM'nin metan tahmini gibi yüksek varyansa sahip karmaşık çıktılar için uygun bir yöntem olmadığını düşündürmektedir.




Şekil 4.67 Destek Vektör Makineleri (SVM) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.

Şekil 4.68’de SVM algoritmasının MSE değişim grafiği incelendiğinde, eğitim verisinde hata değerlerinin görece stabil olduğu, ancak test verisinde bazı iterasyonlarda ciddi artışlar meydana geldiği tespit edilmiştir. Özellikle belirli noktalarda test hatalarının ani yükselmesi, modelin dış veri üzerinde yeterli genelleme kabiliyeti oluşturamadığını göstermektedir.




Şekil 4.68 Destek Vektör Makineleri (SVM) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.

Şekil 4.69’da SVM algoritmasıyla elde edilen regresyon grafiğinde, gerçek ve tahmin edilen değerler arasındaki ilişki genel olarak zayıf bulunmuştur. Veri noktalarının doğrusal çizgiden geniş bir alana yayıldığı gözlenmiştir. Bu durum, modelin tahmin performansında önemli sapmalar olduğunu ve doğruluk seviyesinin sınırlı kaldığını açıkça göstermektedir.




Şekil 4.69 Destek Vektör Makineleri (SVM) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.

Şekil 4.70’de Gradient Boosting Machines algoritması kullanılarak yapılan metan tahmininde, eğitim verilerinde R^2 değerlerinin oldukça yüksek ve stabil olduğu gözlemlenmiştir. Test verisinde ise R^2 değerleri dalgalı bir seyir izlemektedir. Eğitimde mükemmel yakın sonuçlar elde edilmesine karşın test verisinde doğruluk kaybı gözlemlenmiştir. Aşırı öğrenme eğilimi dikkat çekmektedir. Bu durum modelin eğitim verisindeki örüntülere fazlasıyla odaklandığını ve bu nedenle yeni verilerde genelleme yapma kapasitesinin zayıfladığını ortaya koymaktadır. Özellikle test setindeki düşük korelasyon katsayıları, modelin yüksek varyansa sahip gözlemler karşısında tutarlı sonuçlar üretemediğini göstermektedir. GBM algoritmasının ardışık öğrenme yapısı, eğitim doğruluğunu artırsa da test performansında istikrarsızlığa neden olmuştur. Sonuçlar, modelin yalnızca sık rastlanan veri desenlerini doğru tahmin edebildiğini, ancak nadir, uç ve beklenmeyen örneklerde ciddi bir başarımlı kaybı yaşadığını göstermektedir.



Şekil 4.70 Gradyan Artırma Makineleri (GBM) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.


Şekil 4.71’de GBM algoritmasının MSE değerleri incelendiğinde, eğitim verisinde hata oranlarının oldukça düşük ve stabil olduğu, ancak test verilerinde ani sıçramaların meydana geldiği görülmektedir.



Şekil 4.71 Gradyan Artırma Makineleri (GBM) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.


Şekil 4.72’de gerçek ve tahmin edilen metan değerleri arasındaki regresyon analizi sonucunda, veri noktalarının genel olarak doğrusal çizgi etrafında toplandığı tespit edilmiştir. Ancak bazı sapmalar ve uç değerler mevcuttur. Bu durum, GBM

algoritmasının metan tahmininde genel olarak başarılı bir performans sergilediğini, ancak bazı durumlarda hata paylarının arttığını göstermektedir.




Şekil 4.72 Gradyan Artırma Makineleri (GBM) algoritması ile METAN tahmini için test verisine ait regresyonu grafiği.

Şekil 4.73 'de KNN algoritması ile gerçekleştirilen metan tahmininde, eğitim verisinde R^2 değerlerinin çok yüksek seviyelerde olduğu, ancak test verisinde oldukça düşük ve dalgalı bir seyir izlendiği gözlenmektedir. Bu durum, modelin eğitim verisine aşırı uyum sağladığını ve test verisinde anlamlı bir genelleme yapamadığını göstermektedir. Test verisinde gözlemlenen düşük korelasyon katsayıları, modelin genelleme kapasitesinin sınırlı olduğunu açıkça ortaya koymaktadır. Bu durum, KNN algoritmasının yalnızca eğitim verisi üzerinde etkili sonuçlar üretebildiğini ancak bilinmeyen veri örneklerinde tutarlı tahminler sunamadığını göstermektedir. Özellikle veri setinde yer alan varyansı yüksek gözlemler karşısında, modelin kararsız ve güvenilirlikten uzak sonuçlar ürettiği dikkat çekmektedir. KNN algoritmasının metan tahmini gibi doğrusal olmayan ve değişkenliği yüksek problemlerde yetersiz kaldığı söylenebilir. Modelin performansını artırmak için daha güçlü genelleme yeteneğine sahip algoritmaların tercih edilmesi gerekliliği açıkça ortaya çıkmaktadır. KNN algoritmasının başarımını sınırlayan temel etkenin, komşuluk ilişkilerinin yüksek boyutlu ve heterojen veri yapılarında yeterli ayırtıcılığı sağlayamaması olduğu değerlendirilmektedir. Bu nedenle yüksek karmaşıklığa sahip sistemlerde KNN algoritmasının tek başına yeterli olmadığı düşünülmektedir.




Şekil 4.73 En Yakın Komşular (KNN) algoritması ile METAN tahmini için eğitim ve test verilerine ait R^2 değişim grafiği.

Şekil 4.74'te KNN algoritması kullanılarak elde edilen MSE değişim grafiği incelendiğinde, eğitim verisinde hata değerlerinin sıfıra yakın olduğu, ancak test verisinde önemli hata dalgalanmalarının bulunduğu gözlemlenmiştir. Eğitimde yüksek başarı sağlanmasına rağmen test verisindeki bu dalgalanmalar, modelin ciddi şekilde aşırı öğrenme sorunu yaşadığını göstermektedir.



Şekil 4.74 En Yakın Komşular (KNN) algoritması ile METAN tahmini için eğitim ve test verilerine ait MSE değişim grafiği.

Şekil 4.75'te gerçek ve tahmin edilen metan değerleri arasındaki regresyon grafiği incelendiğinde, tahminlerin neredeyse sabit bir değere toplandığı görülmektedir. Bu durum, KNN algoritmasının metan üretimini doğru şekilde ayırt edemediğini ve tüm veri seti için tek tip bir sonuç ürettiğini göstermektedir. Model tahmin başarısız olmuştur.



Şekil 4.75 En Yakın Komşular (KNN) algoritması ile METAN tahmini için test verisine ait regresyon grafiği.

4.1.6 Hiperparametre Optimizasyonu Eğitim Sonuçları

Makine öğrenmesi hiperparametre çıktıları aşağıdaki tabloda yöntemler ve optimize edilen parametreler olarak detaylandırılmıştır. Her bir algoritma için 100 iterasyonluk en iyi eğitimi seçen ve bunu 100 iterasyon devam ettiren hiperparametre arama süreci gerçekleştirilmiş olup, bu süreçte her iterasyonda farklı parametre kombinasyonları denenmiştir. Çizelge 4.1'de RF algoritması için sonuçlar gösterilmektedir. Hiperparametre seçiminin model performansı üzerindeki etkisi analiz edilmiştir.

Çizelge 4.1 RF algoritması hiperparametre sonuçları

Parametreler	NumTrees	MSE Train	MSE Test	R ² Train	R ² Test
KM	94	0.01	0.008	0.63	0.54
OKM	147	1.19	1.31	0.65	0.79
FOS	219	177374.28	172390.06	0.66	0.75
TAC	233	5264836.17	3397645.33	0.68	0.71
METAN	131	55564953.13	2063158.83	0.56	0.72

Çizelge 4.2’de DT algoritması için gerçekleştirilen hiperparametre optimizasyonu sürecine ait en iyi parametre kombinasyonları ve ilgili performans metrikleri sunulmaktadır.

Çizelge 4.2 DT algoritması hiperparametre sonuçları

Parametreler	Min Leaf Size	Max Splits	MSE Train	MSE Test	R ² Train	R ² Test
KM	4	13	0.01	0.01	0.56	0.60
OKM	5	3	1.69	0.78	0.42	0.87
FOS	8	96	249043.22	147842.63	0.41	0.69
TAC	20	62	8281568.04	3517850.99	0.26	0.71
METAN	40	2	2688967.54	2682572,55	0.50	0.74

Çizelge 4.3’de SVM algoritması için gerçekleştirilen hiperparametre optimizasyonu sürecine ait en iyi parametre kombinasyonları ve ilgili performans metrikleri sunulmaktadır.

Çizelge 4.3 SVM algoritması hiperparametre sonuçları

Parametreler	Karnel	BoxC	Epsilon	MSE Train	MSE Test	R ² Train	R ² Test
KM	Gaussian	4.47	0.32	0.98	0.51	0.48	0.39
OKM	Lineaar	2.03	0.51	0.74	0.73	0.72	0.75
FOS	Gaussian	96.11	0.48	422780	491566	0.35	0.63
TAC	Gaussian	81.91	0.36	1096694	1214022	0.48	0.12
METAN	Gaussian	5.32	0.50	11258.22	35462.35	0.51	0.58

Çizelge 4.4’te GBM algoritması için hiperparametre analizine ait sonuçlar ayrıntılı olarak gösterilmektedir

Çizelge 4.4 GBM algoritması hiperparametre sonuçları

Parametreler	NumTrees	Learn Rate	MSE Train	MSE Test	R ² Train	R ² Test
KM	256	0.01	0.001	0.007	0.91	0.50
OKM	124	0.76	8.90	0.93	1	0.73
FOS	60	0.03	153007.32	75093.58	0.83	0.67
TAC	134	0.61	0.04	5394235.21	0.99	0.54
METAN	176	0.26	2.22E-07	0.01	0.85	0.36

Çizelge 4.5'te KNN algoritması için gerçekleştirilen hiperparametre optimizasyonu sürecine ait en iyi parametre kombinasyonları ve ilgili performans metrikleri sunulmaktadır.

Çizelge 4.5 KNN algoritması hiperparametre sonuçları

Parametreler	Num Neighbors	Distance	Weight	MSE Train	MSE Test	R ² Train	R ² Test
KM	11	Cityblock	İnverse	0	2.28	0.18	0.28
OKM	5	Cityblock	Equal	0	1.66	1	0.48
FOS	24	Euclidean	İnverse	0	486533.44	1	0.16
TAC	23	Cityblock	İnverse	114798.8	99082.81	0.31	0.44
METAN	15	Euclidean	Equal	1172285	5876654	0.14	0.51

4.2 Yapay Sinir Ağları Algoritmaları Performansları

Yapay Sinir Ağı modelleri ile gerçekleştirilen tahmin çalışmalarında farklı algoritmaların eğitim ve test verileri üzerindeki başarımlarını analiz etmek amacıyla çeşitli performans metrikleri değerlendirilmiştir. KM, OKM, FOS ve TAC süreçlerine ilişkin modellerde kullanılan eğitim algoritmaları (TrainLM, TrainBR, TrainSCG) için elde edilen ortalama kare hata ve regresyon katsayısı değerleri Çizelge 4.6'da karşılaştırmalı olarak sunulmuştur.

Çizelge 4.6 Eğitim algoritmaları performans sonuçları

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm (I)	0.000888782	0.001028833	0.98960411	0.974774076
Trainbr (I)	0.000920051	0.000617515	0.989559871	0.982535546
Trainscg (I)	0.000945568	0.001650102	0.988279079	0.976145537
Trainlm (J)	0.000715883	0.000687809	0.991235581	0.976950201
Trainbr (J)	0.037043318	0.047127769	3.77574E-34	-4.20203E-34
Trainscg (J)	0.001189137	0.001425261	0.982471529	0.988695323
Trainlm (K)	6.88039E-05	0.000161263	0.99935756	0.997154607
Trainbr (K)	0.040224076	0.062416954	1.46158E-34	-1.40068E-34
Trainscg (K)	0.000203179	0.000393833	0.997963884	0.997295152
Trainlm (L)	0.001200178	0.001989363	0.98386341	0.981473817
Trainbr (L)	0.046410429	0.017249159	-2.5334E-33	5.60271E-34
Trainscg (L)	0.003123868	0.001890266	0.960888634	0.971113039

I: KM, J: OKM, K: FOS, L: TAC

Çizelge 4.7’de 2.aşama metan tahmini sürecine ilişkin metan tahmini süreçlerine ilişkin modellerde kullanılan eğitim algoritmaları (TrainLM, TrainBR, TrainSCG) için elde edilen ortalama kare hata (MSE) ve regresyon sayısı R değerleri karşılaştırmalı olarak sunulmuştur

Çizelge 4.7 Eğitim algoritmaları performans sonuçları (Metan tahmin)

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm	8.66614E-05	0.001363527	0.998874683	0.989712292
Trainbr	0.031733073	0.031330116	2.60333E-33	0
Trainscg	0.001563181	0.00079006	0.979088421	0.970659092

4.2.1 KM Tahmini ve Performans Sonuçları


Aşağıda sunulan performans çıktıları ve grafiksel analizler, her algoritmanın öğrenme sürecine etkisini ve KM tahminindeki başarı düzeyini ortaya koymaktadır. Elde edilen bu bulgular, algoritmaların güçlü ve zayıf yönlerini karşılaştırmalı olarak değerlendirerek en uygun modelin seçiminde bilimsel temel sunmaktadır.

Çizelge 4.8 KM eğitim performans sonuçları

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm (I)	0.000888782	0.001028833	0.98960411	0.974774076
Trainbr (I)	0.000920051	0.000617515	0.989559871	0.982535546
Trainscg (I)	0.000945568	0.001650102	0.988279079	0.976145537


Çizelge 4.8’de, trainbr algoritması, test MSE değeri açısından en düşük hata oranını (0.000617515) sağlayarak KM tahmini bağlamında en başarılı algoritma olarak öne çıkmaktadır. Bu durum, trainbr algoritmasının genelleme kapasitesinin yüksek olduğunu ve hem eğitim hem de test süreçlerinde dengeli bir performans sunduğunu göstermektedir. Buna karşılık, trainlm algoritması eğitim aşamasında daha düşük bir hata oranı elde etmiş olmasına rağmen, test sürecindeki hata oranı açısından trainbr algoritmasına kıyasla daha yüksek değerler üretmiştir. Trainscg algoritması ise eğitim ve test süreçlerinde dengeli ve kararlı sonuçlar sağlamış, özellikle büyük veri setleri üzerinde çalışmak için uygun bir yapı sergilemiştir. Her üç algoritmanın performansı, eğitim, doğrulama ve test setleri üzerinde ayrı ayrı incelenmiştir:

Trainlm Algoritması Şekil 4.76’da eğitim süreci boyunca hatanın hızla azaldığı ve düşük bir minimum hata seviyesine ulaşıldığı görülmektedir. Grafik, test ve doğrulama setleri arasındaki paralelliği göstermekte olup, modelin aşırı öğrenme sorununu büyük ölçüde önlediğini işaret etmektedir. Eğitim, test ve doğrulama hatalarının birbirine yakın seyretmesi, modelin tüm veri alt kümeleri üzerinde dengeli ve güvenilir tahminler ürettiğini ortaya koymaktadır. Ayrıca, doğrusal ve kararlı hata eğrileri, öğrenme sürecinde modelin istikrarlı bir yapı kazandığını göstermektedir. Bu durum, trainlm algoritmasının hızlı öğrenme yeteneğiyle birlikte güçlü genelleme performansına sahip olduğunu ortaya koymaktadır. Özellikle karmaşık veri yapılarında bile modelin uyum yeteneğini koruyabilmesi, algoritmanın başarımını artıran önemli bir etkidir. Bu nedenle, trainlm algoritması biyogaz tahmini gibi çok değişkenli problemlerde etkili bir yaklaşım olarak öne çıkmaktadır.




Şekil 4.76 KM trainlm performans grafiği

Trainbr Algoritması Şekil 4.77’de Performans grafiği, özellikle test setinde elde edilen düşük hata oranını ve dengeli öğrenme sürecini net bir şekilde ortaya koymaktadır. Bu durum, algoritmanın genelleme kapasitesinin güçlü olduğunu ve hedef değerlerle uyumlu tahminler sunduğunu göstermektedir. Bu da modelin öğrenme sürecinde dengeyi koruduğunu göstermektedir. Eğitim ve doğrulama setleri arasındaki hata farkının düşük olması, aşırı öğrenmenin önlediğini desteklemektedir. Modelin tutarlı çıktılar üretmesi, farklı veri yapılarıyla çalışabilme esnekliğine sahip olduğunu göstermektedir.



Şekil 4.77 KM trainbr performans grafiği


Trainscg Algoritması Şekil 4.78’de eğitim sürecinin uzunluğu boyunca hatanın kararlı bir şekilde azaldığı gözlemlenmiştir. Daha uzun epoch sayısı gereksinimi, trainscg algoritmasının büyük veri setleri için etkili bir yöntem olduğunu ortaya koymaktadır.



Şekil 4.78 KM trainscg performans grafiği


Regresyon Grafikleri

Trainlm 4.79’da tahmin edilen ve gerçek değerler arasındaki ilişki, regresyon grafiği ile güçlü bir şekilde doğrulanmaktadır ($R = 0.97477$). Bu durum algoritmanın tahmin doğruluğunu kanıtlamaktadır.




Şekil 4.79 KM trainlm regresyon grafiği

Trainbr 4.80’de test setinde elde edilen en yüksek regresyon katsayısı ($R = 0.98253$) ile doğruluk açısından diğer algoritmalarla kıyasla üstün bir performans sergilemektedir.



Şekil 4.80 KM trainbr regresyon grafiği

Trainscg Şekil 4.81’de R değeri 0.97614 olarak hesaplanmış olup, modelin tahmin doğruluğunun yüksek seviyede olduğunu ve büyük veri setleri üzerinde kararlı bir performans sergilediğini göstermektedir. Bu sonuç algoritmanın karmaşık ilişkileri etkili biçimde öğrenebildiğini göstermektedir.



Şekil 4.81 KM trainscg regresyon grafiği

KM tahmini için en başarılı algoritma trainbr olarak belirlenmiştir. Bu algoritmanın düşük hata oranı ve yüksek regresyon katsayısı, modelin genelleme kapasitesini artırmakta ve hedef değerler doğrultusunda etkili tahminler üretmesini sağlamaktadır. Trainlm algoritması hızlı öğrenme kapasitesi ile öne çıkarken, trainscg algoritması eğitim ve test süreçlerinde kararlı bir performans sergileyerek, büyük veri setleri için önemli bir alternatif sunmaktadır.

4.2.2 OKM Tahmini ve Performans Sonuçları

Aşağıda sunulan performans çıktıları ve grafiksel analizler, her algoritmanın öğrenme sürecine etkisini ve OKM tahminindeki başarı düzeyini ortaya koymaktadır. Elde edilen bu bulgular, algoritmaların güçlü ve zayıf yönlerini karşılaştırmalı olarak değerlendirilerek en uygun modelin seçiminde bilimsel temel sunmaktadır. Ayrıca, model performansları hem görsel eğriler hem de metrikler üzerinden analiz edilerek genelleme yetenekleri somut şekilde ortaya konmuştur. Bu kapsamda, algoritmaların doğruluk, kararlılık ve aşırı öğrenme eğilimleri detaylı biçimde incelenmiş ve model tercihi yön verecek çıkarımlar yapılmıştır. Modelin başarımı, eğitim ve test hata oranları ve regresyon katsayıları üzerinden değerlendirilmiştir. OKM için elde edilen sonuçlar Çizelge 4.9’da


verilmiştir. Bu çizelge aracılığıyla, her bir algoritmanın test başarımı karşılaştırmalı biçimde değerlendirilebilmiştir. Elde edilen veriler, algoritmaların veri yapısına duyarlılığını ve tahmin gücünü sayısal olarak yansıtmaktadır. Özellikle yüksek korelasyon değerleri gösteren modeller, uygulama açısından öne çıkmaktadır. Bu analizler sayesinde, hangi algoritmanın OKM tahmini için daha uygun olduğu bilimsel verilere dayanarak belirlenmiştir. Ayrıca, test verilerindeki tutarlılık düzeyi, modellerin saha uygulamalarındaki güvenilirliğini öngörme açısından önemli bir ölçüt olarak değerlendirilmiştir.

Çizelge 4.9 OKM eğitim performans sonuçları

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm (J)	0.000715883	0.000687809	0.991235581	0.976950201
Trainbr (J)	0.037043318	0.047127769	3.77574E-34	-4.20203E-34
Trainscg (J)	0.001189137	0.001425261	0.982471529	0.988695323


Bu veriler ışığında, trainlm algoritması, OKM tahmini bağlamında en düşük test MSE değeri olan 0.000687809 ile en başarılı algoritma olarak öne çıkmaktadır. Bu durum, algoritmanın genelleme kapasitesinin güçlü olduğunu ve OKM parametresini tahmin etmede yüksek doğruluk sağladığını göstermektedir. Trainscg algoritması ise test MSE değeri açısından dengeli bir performans sunmuş, ancak eğitim aşamasında trainlm kadar düşük hata oranı elde edememiştir. Buna karşılık, trainbr algoritmasının yüksek hata oranları ve dengesiz regresyon katsayıları, bu algoritmanın OKM tahmininde etkisiz olduğunu göstermektedir. Her üç algoritmanın performansı, eğitim, doğrulama ve test setleri üzerinde ayrı ayrı incelenmiştir:

Trainlm algoritması Şekil 4.82’de eğitim, doğrulama ve test hatalarının hızla azaldığı ve minimum hata seviyesine ulaştığı gözlemlenmiştir. Grafik modelin aşırı öğrenme sorununu önlediğini ve genelleme kapasitesini artırdığını vurgulamaktadır. Eğitim sürecinde tüm veri setleri arasında uyumlu bir hata eğrisi izlenmiş, bu da modelin istikrarlı bir şekilde öğrenme gerçekleştirdiğini göstermektedir. Özellikle doğrulama setinde gözlemlenen düşük hata seviyesi, erken durdurma mekanizmasının etkin biçimde çalıştığını ortaya koymuştur. Trainlm algoritmasının hızlı yakınsama özelliği, modelin daha kısa sürede optimum ağırlıklara ulaşmasını sağlamıştır.




Şekil 4.82 OKM trainlm performans grafiği

Trainbr algoritması Şekil 4.83’de hata oranlarının yüksek olması ve regresyon katsayılarının tutarsızlığı, bu algoritmanın OKM tahmininde yeterli başarı sağlayamadığını göstermektedir.




Şekil 4.83 OKM trainbr performans grafiği

Trainscg algoritması Şekil 4.84’te grafik, dengeli bir öğrenme sürecini ve modelin kararlı performansını ortaya koymaktadır ancak trainlm’ye kıyasla daha yüksek hata oranlarına sahiptir. Bu durum, algoritmanın özellikle test verisi üzerinde daha düşük doğrulukla sonuçlar ürettiğini ve genelleme yeteneğinin sınırlı kaldığını göstermektedir.




Şekil 4.84 OKM trainscg performans grafiği

Trainlm Şekil 4.85’de tahmin edilen ve gerçek değerler arasında yüksek bir doğrusal ilişki bulunmaktadır ($R = 0.97695$). Bu durum algoritmanın OKM tahminindeki başarısını net bir şekilde ortaya koymaktadır.




Şekil 4.85 OKM trainlm regresyon grafiği

Şekil 4.86’da Trainbr Regresyon grafiği, bu algoritmanın tahmin doğruluğunun yetersiz olduğunu ve modelin öğrenme sürecinde sorunlar yaşadığını işaret etmektedir. Bu da modelin veriyle uyumunun zayıf olduğunu göstermektedir.



Şekil 4.86 OKM trainbr regresyon grafiği

Şekil 4.87’da Trainscg R değeri 0.98866 olarak hesaplanmış ve bu algoritmanın OKM tahminlerinde kabul edilebilir bir doğruluk sağladığını göstermektedir.



Şekil 4.87 OKM trainscg regresyon grafiği

OKM tahmini için trainlm algoritması en başarılı yöntem olarak belirlenmiştir. Bu algoritmanın düşük hata oranı ve yüksek regresyon katsayısı, modelin genelleme kapasitesini artırmakta ve güvenilir tahminler sağlamaktadır. Trainscg algoritması alternatif bir seçenek olarak değerlendirilebilirken eğitim aşamasında trainlm kadar düşük hata oranı elde edememiştir. Trainbr algoritması bu parametre için yetersiz performans

göstermiştir. OKM tahminine yönelik bu analiz, modelin genel başarımını optimize etmek için önemli veriler sunmaktadır.

4.2.3 FOS Tahmini ve Performans Sonuçları


Bu çalışma kapsamında, FOS tahmini için üç farklı algoritma (trainlm, trainbr ve trainscg) kullanılmış, her bir algoritmanın başarısı detaylı şekilde analiz edilmiştir. Giriş parametreleri olarak günlük atık miktarı (ton), KM ve OKM değerleri seçilmiş, çıkış parametresi ise reaktör içindeki FOS olarak hedeflenmiştir. FOS tahmini için modelin başarımı, eğitim (TrainMSE), test (TestMSE) hata oranları ve regresyon katsayıları (TrainR, TestR) ile değerlendirilmiştir. Ayrıca, modelin genelleme yeteneği test verilerindeki başarı düzeyi üzerinden yorumlanmıştır. Çizelge 4.10'da elde edilen sonuçlar özetlenmektedir:

Çizelge 4.10 FOS eğitim performans sonuçları

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm (K)	6.88039E-05	0.000161263	0.99935756	0.997154607
Trainbr (K)	0.040224076	0.062416954	1.46158E-34	-1.40068E-34
Trainscg (K)	0.000203179	0.000393833	0.997963884	0.997295152


Trainlm algoritmasının düşük hata oranı (TestMSE = 0.000161263) ile FOS tahmini açısından en başarılı algoritma olduğunu göstermektedir. Algoritmanın regresyon katsayısı (TestR = 0.99715), tahmin edilen değerlerin hedef değerlere oldukça yakın olduğunu kanıtlamaktadır. Trainscg algoritması ise dengeli bir performans sunmuş, ancak hata oranı açısından trainlm nin gerisinde kalmıştır. Trainbr algoritmasının ise yüksek hata oranları ve tutarsız regresyon katsayıları nedeniyle tahmin başarımında yetersiz kaldığı görülmüştür.

Şekil 4.88'de Trainlm algoritması, grafik, eğitim sürecinde hata oranının hızlı bir şekilde azaldığını ve minimum seviyeye ulaştığını göstermektedir. Modelin hem doğrulama hem test setlerinde paralel bir performans sergilemesi, aşırı öğrenme riskinin önlendiğini ve genelleme kapasitesinin güçlü olduğunu vurgulamaktadır. Modelin istikrarlı bir öğrenme süreci geçirdiğini ve farklı veri setleri üzerinde benzer başarı düzeyi sağlamaktadır




Şekil 4.88 FOS trainlm performans grafiği

Şekil 4.89’da Trainbr algoritması grafik, tahmin doğruluğundaki eksiklikleri ve yüksek hata oranlarını açıkça yansıtmaktadır. Model FOS tahmini bağlamında yeterli bir öğrenme gerçekleştirememiştir.




Şekil 4.89 FOS trainbr performans grafiği

Şekil 4.90’da Trainscg algoritması dengeli bir hata azalışı gözlemlenmiş, ancak trainlm ile kıyaslandığında test hatasının daha yüksek seviyelerde ve daha kararsız bir şekilde olduğu belirlenmiştir.




Şekil 4.90 FOS trainscg performans grafiği

Şekil 4.91’de Trainlm regresyon grafiği, hedef ve tahmin edilen değerler arasındaki ilişkiyi güçlü bir şekilde doğrulamakta ($R = 0.99715$), algoritmanın tahmin doğruluğunu göstermektedir.




Şekil 4.91 FOS trainlm regresyon grafiği

Şekil 4.92’de Trainbr algoritmanın düşük doğruluğunu ve yetersiz genelleme kabiliyetini yansıtan bir regresyon eğrisi ortaya koyulmuştur. Bu durum, modelin karmaşık ilişkileri öğrenmede zorlandığını göstermektedir.



Şekil 4.92 FOS trainbr regresyon grafiği

Şekil 3.93’de Trainscg için $R = 0.99729$ olarak hesaplanan regresyon katsayısı, modelin tahmin gücünün kabul edilebilir seviyede olduğunu göstermektedir.



Şekil 4.93 FOS trainscg regresyon grafiği

FOS tahmini için trainlm algoritması, düşük hata oranı ve yüksek doğruluk seviyeleri ile en başarılı yöntem olarak öne çıkmıştır. Trainscg algoritması, alternatif bir seçenek olarak

değerlendirilebilsede trainlm'nin sağladığı avantajları sunamamaktadır. Trainbr algoritması ise, öğrenme kapasitesindeki sınırlamaları nedeniyle FOS tahmininde etkisiz bir yöntem olarak belirlenmiştir.

4.2.4 TAC Tahmini ve Performans Sonuçları

TAC tahmini için üç farklı algoritma (trainlm, trainbr ve trainscg) kullanılarak model eğitimi gerçekleştirilmiş ve performans analizleri yapılmıştır. Giriş parametreleri olarak günlük atık miktarı (ton), KM ve OKM değerleri kullanılmış, çıkış parametresi olarak ise reaktör içindeki TAC hedeflenmiştir.


TAC tahmini için modelin performansı, eğitim (TrainMSE), test (TestMSE) hata oranları ve regresyon katsayıları (TrainR, TestR) ile değerlendirilmiştir. Çizelge 4.11'de elde edilen sonuçlar özetlenmiştir:

Çizelge 4.11 TAC eğitim performans sonuçları

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm (L)	0.001200178	0.001989363	0.98386341	0.981473817
Trainbr (L)	0.046410429	0.017249159	-2.5334E-33	5.60271E-34
Trainscg (L)	0.003123868	0.001890266	0.960888634	0.971113039


Sonuçlar incelendiğinde, trainlm algoritması, test MSE değeri açısından en düşük hata oranını (0.000305671) sağlayarak TAC tahmini için en başarılı algoritma olarak belirlenmiştir. Algoritmanın regresyon katsayısı (TestR = 0.98927), hedef ve tahmin edilen değerler arasında güçlü bir doğrusal ilişki olduğunu ortaya koymaktadır. Trainscg algoritması, daha yüksek test hata oranına rağmen kabul edilebilir bir performans sergilemiştir. Ancak, trainbr algoritması yüksek hata oranları ve yetersiz regresyon katsayıları ile TAC tahmininde etkisiz kalmıştır.

Şekil 4.94'te Trainlm algoritması performans grafiği, eğitim ve doğrulama süreçlerinde hata oranlarının hızla azaldığını ve modelin genelleme kapasitesinin yüksek olduğunu göstermektedir. Bu durum algoritmanın istikrarlı bir öğrenme süreci geçirdiğini ve aşırı öğrenme eğiliminden uzak kaldığını ortaya koymaktadır. Modelin doğruluk seviyesi oldukça yüksek olarak gözlemlenmektedir.




Şekil 4.94 TAC trainlm performans grafiği

Trainbr algoritması Şekil 4.95’de eğitim ve test süreçlerinde hatanın yüksek seviyelerde kalması, algoritmanın TAC tahminindeki etkinliğinin düşük olduğunu göstermektedir. Bu durum, modelin hem öğrenme hem de genelleme yeteneğinde yetersiz kaldığını ortaya koymaktadır.




Şekil 4.95 TAC trainbr performans grafiği

Şekil 4.96’da Trainscg algoritması dengeli bir öğrenme sürecini temsil eden grafik, modelin genelleme kapasitesini koruduğunu ancak trainlm algoritmasına kıyasla daha yüksek hata oranına sahip olduğunu göstermektedir. Bu nedenle algoritmanın doğruluk düzeyi sınırlı kalmakta ve daha güçlü alternatiflere ihtiyaç duyulmaktadır.




Şekil 4.96 TAC trainscg performans grafiği

Şekil 4.97’de Trainlm tahmin edilen ve gerçek değerler arasındaki ilişki yüksek bir doğruluk seviyesine işaret etmekte ($R = 0.98927$) ve algoritmanın başarılı bir tahmin gücü sunduğunu göstermektedir.




Şekil 4.97 TAC trainlm regresyon grafiği

Şekil4.98’de Trainbr düşük doğruluk ve yetersiz öğrenme kapasitesini yansıtan regresyon eğrisi, algoritmanın TAC tahmininde etkisiz olduğunu doğrulamaktadır. Gerçek ve tahmin edilen değerler arasındaki uyumsuzluk, modelin veriyi yeterince öğrenemediğini göstermektedir.



Şekil 4.98 TAC trainbr regresyon grafiği

Şekil 4.99’da Trainscg R değeri 0.98515 olarak hesaplanmış olup, modelin tahmin başarımının makul seviyede olduğunu göstermektedir.



Şekil 4.99 TAC trainscg regresyon grafiği

TAC tahmini için en başarılı algoritma trainlm olarak belirlenmiştir. Bu algoritma, düşük hata oranı ve yüksek regresyon katsayısı ile TAC tahmininde en uygun çözümü

sunmaktadır. Trainscg algoritması ise alternatif bir seçenek olarak değerlendirilebilirken, trainbr algoritması gerek yüksek hata oranları gerekse yetersiz regresyon katsayıları nedeniyle TAC tahmininde zayıf bir performans sergilemiştir. Bu bulgular, TAC parametresinin tahmini için modelin genel başarımını optimize etmek adına önemli bir temel sağlamaktadır.

4.2.5 Metan Tahmini ve Performans Sonuçları


Anaerobik sindirim sürecinden elde edilen metan gazı tahmini, biyogaz tesislerinin operasyonel verimliliğini artırmak ve enerji üretim kapasitesini optimize etmek amacıyla gerçekleştirilmiştir. Modelde kullanılan giriş parametreleri; günlük atık miktarı (ton), Reaktör parametreleri olan KM, OKM FOS ve TAC olarak belirlenmiştir.

Çizelge 4.12 Metan tahmin eğitim performans sonuçları

Algoritma	TrainMSE	TestMSE	TrainR	TestR
Trainlm	8.66614E-05	0.001363527	0.998874683	0.989712292
Trainbr	0.031733073	0.031330116	2.60333E-33	0
Trainscg	0.001563181	0.00079006	0.979088421	0.970659092


Çizelge 4.12’de de görülebileceği gibi, trainlm algoritması en düşük hata oranı (TestMSE: 0.001363527) ve en yüksek doğruluk oranı (TestR: 0.989712292) ile en başarılı sonuçları vermiştir. Trainscg algoritması dengeli bir performans sergilemekle birlikte, trainbr algoritmasının tahmin başarısı oldukça düşük seviyede kaldığı gözlemlenmektedir. Trainbr algoritmasının test setinde elde ettiği doğruluk oranının sıfıra yakın olması, modelin genelleme kapasitesinin son derece zayıf kaldığını göstermektedir. Trainlm algoritması ise hem eğitim hem test verilerinde istikrarlı ve yüksek korelasyon sunarak aşırı öğrenme eğiliminden uzak durmuştur. Trainscg algoritması düşük hata oranları ile tatmin edici bir başarı sağlamış ancak doğruluk oranı açısından trainlm’nin gerisinde kalmıştır. Bu durum Trainlm algoritmasının genelleme kapasitesinin daha güçlü olduğunu ortaya koymaktadır.

Şekil 4.100’de Trainlm algoritması eğitim sürecinde hata oranının hızla azaldığı ve doğrulama setinde de yüksek doğruluk sağlandığı görülmektedir. Modelin genelleme kapasitesinin güçlü olduğunu, aşırı öğrenme eğilimi göstermediğini ortaya koymaktadır.




Şekil 4.100 Metan tahmin trainlm performans grafiği

Trainbr algoritması şekil 4.101’de yüksek hata oranları ve düşük doğruluk ile modelin genelleme kapasitesinin yetersiz olduğunu göstermektedir. Algoritmanın eğitim sürecinde veriye aşırı uyum sağlayamadığını ve öğrenme başarımının sınırlı kaldığını ortaya koymaktadır.




Şekil 4.101 Metan tahmin trainbr performans grafiği

Şekil 4.102’de Trainscg algoritması dengeli bir öğrenme süreci sergilemekte ancak trainlm’nin performansının gerisinde kalmaktadır.



Şekil 4.102 Metan tahmin trainscg performans grafiği

Şekil 4.103’de Trainlm algoritmasının regresyon analizi, hedef ve tahmin edilen metan değerleri arasındaki güçlü doğrusal ilişkiyi ($R=0.98971$) ortaya koyarken, trainscg algoritması kabul edilebilir doğruluk sağlamış; trainbr algoritması ise etkisiz kalmıştır. Bu sonuçlar, trainlm algoritmasının metan tahmininde en başarılı yaklaşım olduğunu ortaya koymaktadır. Trainscg algoritması orta düzeyde bir genelleme yeteneği sergilerken, trainbr algoritması karmaşık veri ilişkilerini öğrenmede yetersiz kalmıştır.



Şekil 4.103 Metan tahmin trainlm regresyon grafiği

4.2.6 Hiperparametre Optimizasyonu Eğitim Sonuçları

Geliştirilen modellerin hiperparametre optimizasyon süreçleri sonucunda elde edilen eğitim çıktıları Çizelge 4.13’de özetlenmektedir. Her bir tahmin modeli için belirlenen giriş ve çıkış parametreleri doğrultusunda, en iyi başarıyı sağlayan algoritma ve buna karşılık gelen katman yapıları, nöron sayıları ve elde edilen en düşük hata değeri tablo hâlinde sunulmuştur. Bu kapsamda, her modelleme aşamasında 100 iterasyonluk arama stratejisi benimsenmiş ve her iterasyonda farklı mimariler denenmiştir. En düşük test hatasını sağlayan yapı optimal model olarak değerlendirilmiştir.

Çizelge 4.13 Bir tahmin modeli için belirlenen giriş ve çıkış parametreleri, kullanılan eğitim algoritmaları ve optimize edilen hiperparametrelerin kapsamlı bir özeti

Parametre	Eğitim Algoritma	Hiperparametre Katmanları, Nöron Sayıları ve ObjectiveValue					
		K1	K2	K3	K4	K5	ObjectiveValue
KM	Trainbr	38	48	12	46	5	0.018591626
OKM	Trainlm	46	50	5	36	44	1.204686529
FOS	Trainlm	46	50	5	36	44	127783.3295
TAC	Trainscg	43	9	13	39	33	3460038.055
Metan Tahmini	Trainlm	16	33	21	48	31	296023.269


K1: Katman 1, K2: Katman2, K3: Katman3, K4: Katman4, K5: Katman5

4.3 Simulink Modeli Frekans ve Açısız Hız Grafik Çıktıları

Şekil 4.104’de görüldüğü üzere, Simulink ortamında gerçekleştirilen sistem modeli doğrultusunda elde edilen frekans-zaman grafiği, sistemin dinamik davranışını ve kararlılığa ulaşma sürecini yansıtmaktadır. Başlangıçta yaklaşık 0 Hz. seviyesinden başlayan sistem frekansı, kısa bir süre içerisinde hızlı bir yükseliş sergileyerek 50 Hz. nominal frekans değerine ulaşmakta ve bu seviyede kararlı bir şekilde sabitlenmektedir. Grafikteki hızlı oturma süresi, sistemin ani değişimlere karşı etkili şekilde dengelendiğini göstermektedir.


Sistemin frekans sapması oluşturmada nominal değere ulaşması, yük değişimlerine karşı frekans stabilitesinin korunmasında önemli bir avantaj sağlamaktadır. Sistemin düşük frekansta herhangi bir salınım ya da osilasyon üretmemesi modelin kontrol parametrelerinin uygun şekilde ayarlandığını göstermektedir. Kararlı hale geliş süresi

oldukça kısa olduğu için sistemin ani yük değişimlerine karşı dinamik cevabı güçlü ve hızlıdır. Modelin frekans kontrol performansı hem geçici rejim davranışları hem de sürekli hal koşulları açısından tatmin edici düzeydedir.



Şekil 4.104 Simulink Modelinde Sistem Frekansının Zaman Değişim Grafiği

Mikro türbin destekli jeneratör yapısının ani yük değişimlerine karşı yeterli tepki hızına ulaştığını ve frekans sapmalarını minimum seviyede tutabildiğini ortaya koymaktadır. Sistemin yaklaşık 5sn içerisinde kararlı hale gelmesi, kontrolör parametrelerinin uygun olarak ayarlandığını ve frekans regülasyonunun başarılı şekilde gerçekleştirildiğini göstermektedir.




Şekil 4.105 Simulink Modelinde Açısal Hız Zaman Değişim Grafiği

Simulink modeli üzerinden elde edilen sistem çıktısına göre, rotorun kararlı durumdaki açısal hızı 157.90 rad/s olarak belirlenmiştir. Sistemin nominal çalışma koşulları altında mekanik dengeyi sağladığını ve senkron jeneratörün frekans üretimine uygun bir dönme hızında çalıştığını göstermektedir. Açısal hızın bu değerde sabitlenmesi, sistemin dinamik dengeye ulaştığını ve dışsal yük değişimlerine karşı kararlılığını koruduğunu ortaya koymaktadır.

Elde edilen bu WR değeri ile modelde hedeflenen 50 Hz frekans değeri arasında doğrudan bir uyum olduğu görülmektedir. Bu da mikro türbin ve jeneratör entegrasyonunun doğru yapılandırıldığını ve kontrol algoritmasının yeterli tepki süresiyle dengeye ulaşabildiğini göstermektedir. Sonuç olarak, 157.90 rad/s değeri, sistemin mekanik performansı açısından güvenilir ve kararlı bir işletim rejimine işaret etmektedir.

5. TARTIŞMA ve SONUÇ


Şekil 5.1’de verilen KM parametresi için R^2 karşılaştırma grafiği incelendiğinde, GBM algoritmasının hem eğitim hem de test verisi üzerindeki doğruluk performansı bakımından diğer algoritmalara kıyasla daha üstün bir genel performans sergilediği görülmektedir. Eğitim verisinde 0.91’e yaklaşan R^2 değeri, modelin örüntüleri etkin şekilde öğrendiğini gösterirken; test verisinde elde edilen 0.51’lik R^2 değeri, genelleme kabiliyetinin belirli düzeyde korunabildiğini ortaya koymaktadır. Diğer algoritmalarından DT ve KNN hem eğitim hem de test setlerinde düşük R^2 skorları ile modelleme başarısının zayıf kaldığını göstermektedir. Özellikle KNN algoritmasında gözlemlenen belirgin performans düşüklüğü, modelin KM parametresindeki değişken yapıya uyum sağlamakta yetersiz kaldığını ortaya koymaktadır. RF ve SVM algoritmaları, test setinde daha dengeli sonuçlar vermesine rağmen GBM’nin hem istatistiksel uyumu hem de öğrenme kapasitesi açısından daha baskın bir yapıda olduğu tespit edilmiştir.



Şekil 5.1 KM Parametresi Karşılaştırma Grafiği

Şekil 5.2’de sunulan OKM parametresi için R^2 karşılaştırma grafiği incelendiğinde, SVM algoritmasının test verisi üzerinde 0.76’ya ulaşan doğruluk seviyesiyle diğer algoritmalara kıyasla en dengeli ve genellenebilir sonucu ürettiği görülmektedir. Eğitim verisindeki 0.73’lük R^2 değeri, modelin öğrenme sürecinde aşırıya kaçmadan yapıyı kavradığını göstermektedir. Diğer algoritmalarından GBM, eğitim verisinde çok yüksek R^2 değeri (1.00) ile dikkat çekse de test verisinde gözlemlenen düşüş (0.72), aşırı öğrenme


riskini işaret etmektedir. Benzer şekilde KNN algoritması da eğitim verisine mükemmel uyum gösterirken test setinde ciddi doğruluk kaybı yaşamış ve genelleme kapasitesi zayıf kalmıştır. SVM'nin yüksek doğruluk seviyesi ve tutarlı performansı, OKM parametresindeki değişken yapıya karşı güçlü bir adaptasyon sergilediğini ortaya koymakta ve bu algoritmayı OKM tahmininde en başarılı yöntem haline getirmektedir.



Şekil 5.2 OKM Parametresi Karşılaştırma Grafiği


Şekil 5.3'te yer alan FOS tahmini R^2 karşılaştırmasına göre, GBM algoritması eğitim verisinde 0.83, test verisinde ise 0.67 R^2 skoruna ulaşarak en yüksek doğruluk ve genelleme başarımı sergileyen yöntem olmuştur. Bu sonuçlar, modelin hem öğrenme sürecinde istikrarlı bir yapıya sahip olduğunu hem de test verisi üzerinde dengeli ve güvenilir tahminler üretebildiğini göstermektedir. Diğer algoritmalarla karşılaştırıldığında, RF ve SVM algoritmaları test setinde 0.47 ve 0.62 gibi nispeten düşük R^2 değerlerine ulaşmış; bu da genelleme kapasitesinin sınırlı kaldığını ortaya koymuştur. KNN algoritması ise düşük eğitim ve test R^2 değerleriyle 0.37 ve 0.26 FOS gibi dalgalı yapıya sahip bir parametrede yeterince etkili olamamıştır. GBM algoritmasının basamaklı modelleme yapısı, özellikle karmaşık örüntüleri yakalamada sağladığı avantajla FOS tahmininde en yüksek başarıyı elde etmesini sağlamıştır. GBM algoritmasının basamaklı modelleme yapısı, özellikle karmaşık örüntüleri yakalamada sağladığı avantajla FOS tahmininde en yüksek başarıyı elde etmesini sağlamıştır. DT

algoritması ise düşük R^2 skorları ile öğrenme sürecinde sınırlı başarı göstermiş ve özellikle test verisinde yetersiz genelleme performansı sergilemiştir. Bu karşılaştırmalı analiz, FOS tahmini gibi değişkenliği yüksek parametrelerde güçlü model yapısına ve yüksek uyum yeteneğine sahip algoritmaların tercih edilmesinin gerekliliğini açıkça ortaya koymaktadır.



Şekil 5.3 FOS Parametresi Karşılaştırma Grafiği


Şekil 5.4 incelendiğinde, eğitim ve test verileri üzerinde en yüksek genel başarıyı Random Forest (RF) algoritmasının sağladığı görülmektedir. RF modeli, eğitim setinde yaklaşık 0.61, test setinde ise 0.71 gibi yüksek R^2 skorlarıyla dikkat çekmektedir. Bu durum, modelin hem öğrenme aşamasında hem de yeni veriler karşısında güçlü bir genelleme yeteneğine sahip olduğunu göstermektedir. GBM algoritması eğitim verisinde oldukça yüksek (1.0) bir R^2 değeri üretmesine karşın, test verisinde 0.53 ile daha düşük bir performans sergilemiş; bu da modelin aşırı öğrenmeye açık olduğunu ve genelleme kabiliyetinin sınırlı kalabileceğini işaret etmektedir. SVM ve KNN algoritmalarının test R^2 değerleri sırasıyla 0.13 ve 0.45 olarak belirlenmiş; bu durum modellerin TAC gibi sistem kararlılığına duyarlı bir parametreyi tahmin etmede yetersiz kaldığını ortaya koymuştur. RF algoritmasının çoklu karar ağaçlarıyla veri çeşitliliğini etkin bir biçimde modelleyebilmesi, bu algoritmanın TAC tahmininde en güvenilir yöntem olarak öne çıkmasına katkı sağlamaktadır.



Şekil 5.4 TAC Parametresi Karşılaştırma Grafiği

Şekil 5.5'te sunulan metan gazı tahminine ilişkin R^2 karşılaştırma grafiği incelendiğinde, Gradient Boosting Machine (GBM) algoritması hem eğitim hem de test veri kümelerinde en yüksek başarıyı gösteren yöntem olmuştur. Eğitim verisinde 0.88, test verisinde ise 0.72 seviyelerine ulaşan R^2 değerleri, modelin hem öğrenme yeteneğinin yüksek olduğunu hem de bilinmeyen veriler karşısında güçlü bir genelleme performansı sergilediğini ortaya koymaktadır. Diğer algoritmalarla karşılaştırıldığında, RF ve SVM modelleri daha düşük test performansları ile sınırlı kalmış; özellikle DT ve KNN algoritmaları ise karmaşık ve çok değişkenli metan üretimi süreçlerinde yeterli doğruluk düzeyine ulaşamamıştır. GBM'nin art arda zayıf öğreniciler oluşturarak güçlü bir tahmin yapısı kurması, sistemin çok değişkenli yapısal ilişkilerini başarılı bir şekilde modellemesini sağlamıştır. Bu durum, metan üretimi gibi çoklu girdilere bağlı, doğrusal olmayan sistemlerde GBM algoritmasının öne çıkan bir yöntem olduğunu teyit etmektedir. DT algoritmasının test R^2 değerinin 0.15 seviyesinde kalması, modelin genelleme yeteneğinin oldukça düşük olduğunu ve sistemin yapısal karmaşıklığını temsil etmekte yetersiz kaldığını göstermektedir. KNN algoritmasında ise eğitim verisinde R^2 değerinin 1'e yakın olmasına rağmen test verisinde ciddi bir düşüş yaşanmış, bu durum modelin aşırı öğrenme eğiliminde olduğunu ve gerçek veri karşısında tutarsız çıktılar ürettiğini göstermektedir. RF ve SVM algoritmaları ise daha dengeli sonuçlar sunmasına rağmen, GBM kadar yüksek doğruluk sağlayamamıştır. Sonuç olarak, GBM algoritması

hem yüksek doğruluk hem de güçlü genelleme başarısıyla metan tahmin problemi için en uygun model olarak öne çıkmaktadır.



Şekil 5.5 Metan Parametresi Karşılaştırma Grafiği

Çizelge 5.1’de en başarılı makine öğrenmesi tablosunda R^2 karşılaştırmaları detaylı biçimde verilmektedir.

Çizelge 5.1 En başarılı makine öğrenmesi algoritmalarının R^2 karşılaştırması

Parametre	Algoritma	Train R^2	Test R^2
KM	GBM	0.91112248	0.50842592
OKM	SVM	0.72977664	0.75501711
FOS	GBM	0.83316433	0.67028938
TAC	RF	0.60845667	0.71118859
METAN	GBM	0.85279214	0.36143741

Yapay Sinir Ağı (YSA) modelleri kapsamında yürütülen tahmin çalışmalarında her bir parametre için farklı eğitim algoritmalarının performansları karşılaştırılmıştır. KM tahmini için en başarılı sonuç, Train R = 0.9859 ve Test R = 0.9823 değerleriyle trainbr algoritması tarafından elde edilmiştir. OKM parametresi için trainlm algoritması, Train

R = 0.9912 ve Test R = 0.9769 ile en yüksek doğruluk seviyesine ulaşmıştır. FOS tahmininde yine trainlm algoritması öne çıkmış, Train R = 0.9993 ve Test R = 0.9971 değerleriyle güçlü bir öğrenme performansı sergilemiştir. TAC tahmininde trainscg algoritması, Train R = 0.9608 ve Test R = 0.9711 değerleriyle en başarılı sonuçları vermiştir. METAN üretimi tahmininde ise trainlm algoritması, Train R = 0.9988 ve Test R = 0.9897 ile yüksek doğruluk sağlamıştır. Çizelge 5.2 de YSA modellerindeki en başarılı algoritmalar verilmiştir.

Bu sonuçlar, her bir parametrenin yapısal farklılıklarına göre uygun algoritma seçiminin model başarısını doğrudan etkilediğini göstermektedir. Trainlm algoritmasının birçok parametrede öne çıkması, algoritmanın hızlı öğrenme ve yüksek genelleme kapasitesine sahip olduğunu ortaya koymaktadır. Trainscg algoritması ise özellikle TAC gibi osilasyonlu verilerde daha dengeli sonuçlar üretmiştir. Genel olarak değerlendirildiğinde, YSA modelleri doğruluk açısından oldukça başarılı sonuçlar vermiş ve sistemin yapısal doğruluğunu sağlam temellere oturtmuştur. Yapay zekâ temelli tahmin yaklaşımlarının biyogaz süreç modellemelerinde etkin ve güvenilir araçlar olduğunu desteklemektedir. Çizelge 5.2 de yapay sinir ağları algoritma karşılaştırmaları verilmektedir.

Çizelge 5.2 En başarılı yapay sinir ağları algoritmalarının R karşılaştırması

Parametre	Algoritma	Train R	Test R
KM	Trainbr	0.98595871	0.98235546
OKM	Trainlm	0.99123581	0.97695021
FOS	Trainlm	0.99935756	0.99715460
TAC	Trainscg	0.96088863	0.97111303
METAN	Trainlm	0.99887468	0.98971229

Bu çalışma kapsamında model başarımını gerçek saha koşulları altında değerlendirebilmek amacıyla her ay için maksimum ve minimum atık besleme değerleri seçilerek 24 adetlik bir test verisi oluşturulmuştur. Bu veri seti, sistemin hem düşük hem de yüksek yük altında gösterdiği tahmin doğruluğunu analiz etmek amacıyla seçilmiş olup, modellerin genelleme kabiliyetlerini ölçmek için önemli bir ölçüt teşkil etmektedir. Çizelge 5.3'te ML, YSA ve Simulink modellerinin gerçek tahmin değerlerine göre

ortalama mutlak hata (MAE) karşılaştırmalarına ilişkin sonuçlar tablo haline gösterilmektedir. Bu karşılaştırma, modellerin doğruluk düzeylerini değerlendirmek ve en düşük hata oranına sahip yöntemi belirlemek açısından önemli bir temel sunmaktadır.

Çizelge 5. 3 24 Günlük gerçek tesis verileri ML-YSA-Simulink Karşılaştırma Sonuçları

MAE (%)	KM	OKM	FOS	TAC	METAN	ENERJİ
ML Min	0.01	0.05	0.18	0.59	0.53	0.53
ML Mak	10.09	6.511	30.627	42.88	54.79	65,82
ML Ort	1.74	2.03	9.38	13.89	8.68	14.99
YSA Min	0.29	0.02	0.03	0.64	0.22	0.22
YSA Mak	12.45	6.15	36.95	38.55	57.15	80.75
YSA Ort	3.80	1.74	11.78	12.21	12	15.43
Sim. Min	-	-	-	-	11.40	20.61
Sim. Mak	-	-	-	-	61.37	41.02
Sim. Ort	-	-	-	-	26.16	31.59

ML: Makine öğrenmesi, YSA: Yapay Sinir Ağları, Sim.: Simulink Modeli

Gerçek saha verilerine dayalı olarak gerçekleştirilen mutlak hata analizleri, kullanılan modelleme yaklaşımları arasında anlamlı farklılıklar ortaya koymaktadır. Makine öğrenmesi algoritmaları, özellikle veri içerisindeki örüntüleri dinamik biçimde öğrenebilme kapasiteleri sayesinde yüksek genelleme başarısı sergilemiş ve reaktör performans parametrelerinin tahmininde güvenilir sonuçlar üretmiştir. Parametre bazında değerlendirildiğinde, ML tabanlı yapıların daha tutarlı ve düşük hata değerleri ile sonuçlar verdiği, bu nedenle de değişken yapıli biyolojik süreçler için daha uygun bir modelleme yaklaşımı sunduğu anlaşılmaktadır.

Yapay sinir ağı modelleri ise bazı parametrelerde başarılı tahminler üretmiş olsa da genel anlamda makine öğrenmesi algoritmalarına kıyasla daha yüksek hata değerleri ile sınırlı kalmıştır. Bu durum, ağı öğrenme esnasında parametre duyarlılığına karşı daha az esnek davranmasından ve genelleme performansındaki dalgalanmalardan kaynaklanmış olabilir. Veri setinin yapısı ve örnek dağılımı, yapay sinir ağlarının tüm parametrelerde istikrarlı sonuçlar üretmesini zorlaştırmış olabilir.

Simulink ortamında gerçekleştirilen kinetik modelleme ise teorik olarak anlamlı bir yapı sunmakla birlikte, sabit parametrelere dayalı yapısı nedeniyle sahadaki değişkenliği yansıtmakta yetersiz kalmıştır. Özellikle atık karakterizasyonundaki zamansal farklılıkların modellenememesi, hata oranlarının artmasına neden olmuş ve dinamik süreçlerin simülasyonunda önemli sınırlılıklar ortaya çıkarmıştır.

Tüm bu bulgular değerlendirildiğinde veri odaklı modelleme yaklaşımlarının özellikle makine öğrenmesine dayalı algoritmaların hem öğrenme yetenekleri hem de uyarlanabilirlik açısından daha avantajlı olduğu görülmektedir. Biyogaz üretim süreçlerinin tahmininde klasik modellerin yerini giderek daha fazla veri odaklı yapay zekâ yöntemlerine bırakacağını işaret etmektedir.

6. KAYNAKLAR

- Admasu N A, Pan J, Li C, 2022, Biogas production from beverage wastewater sludge for electricity generation, *Scientific Reports*, 12, 8731.
- Akdeniz Acar N, 2019, Bir biyogaz tesisinin üretim parametrelerinin deneysel olarak incelenmesi ve optimizasyonu, Doktora tezi, Süleyman Demirel Üniversitesi, YÖK Ulusal Tez Merkezi.
- Benti N E, Asfaw A, 2022, Challenges and solutions in biogas technology adoption in Ethiopia: A review, *Renewable and Sustainable Energy Reviews*, 153, 111760.
- Breyer C, 2022, On the history and future of 100% renewable energy systems research, *IEEE Journal of Photovoltaics*, 12(4), 1093–1101.
- Chaikitkaew S, Sittijunda S, Reungsang A, 2024, Conversion of carbon dioxide in biogas into acetic acid by *Clostridium thailandense* immobilized on porous support materials, *Heliyon*, 10(4), e26378.
- Chen Y, Cheng J J, Creamer K S, 2008, Inhibition of anaerobic digestion process: A review, *Bioresource Technology*, 99(10), 4044–4064.
- Çolak İ, Bayındır R, Demirtaş M, 2008, Türkiye'nin enerji geleceği, *TÜBAV Bilim Dergisi*, 1(2), 36–44.
- Çınar S Ö, Çınar S, Kuchta K, 2022, Machine learning algorithms for temperature management in the anaerobic digestion process, *Fermentation*, 8(2), 65.
- Çelik A, 2022, Yapay zekâ destekli biyogaz üretim sistemlerinin modelleme ve optimizasyonu, *Enerji Sistemleri ve Mühendisliği Dergisi*, 10(1), 10–20.
- Çınar M, Balcı A, 2021, Türkiye'de yenilenebilir enerji kaynaklarının gelişimi ve enerji politikalarına etkisi, *Uluslararası Enerji ve Politika Araştırmaları Dergisi*, 7(2), 45–63.
- De Clercq D, Jalota D, Shang R, Ni K, Zhang Z, Khan A, et al., 2019, Machine learning powered software for accurate prediction of biogas production: A case study on industrial-scale Chinese production data, *Journal of Cleaner Production*, 218, 390–399.

- Dhamodharavadhani S, Rathipriya R, 2020, Enhanced Logistic Regression (ELR) model for big data, Semantic Scholar.
- Dioha I J, Ikeme C H, Nafi'u T, Soba N I, Yusuf M B S, 2013, Effect of carbon to nitrogen ratio on biogas production, International Research Journal of Natural Sciences, 1(3), 1–10.
- Erario M L, De Giorgi M G, Przysowa R, 2022, Model-based dynamic performance simulation of a microturbine using flight test data, Aerospace, 9(2), 60.
- Fachagentur Nachwachsende Rohstoffe e.V. (FNR), 2010, Biyogaz Kılavuzu: Üretimden kullanıma, Terc. T.C. Çevre ve Şehircilik Bakanlığı, Çevre Yönetimi Genel Müdürlüğü, Türk-Alman Biyogaz Projesi Yayını.
- Foressee F D, Hagan M T, 1997, Gauss-Newton approximation to Bayesian learning, In Proceedings of the International Joint Conference on Neural Networks.
- Ganeshan K, Rajendran K, 2022, Dynamic modeling of anaerobic digestion using a modified Hill model: Simulation-based analysis of biogas production under variable operational conditions, Renewable Energy, 187, 1267–1278.
- Gaonkar D N, Patel R N, 2006, Modeling and simulation of microturbine based distributed generation system, In Proceedings of the IEEE Conference on Power Engineering Society General Meeting, 1–6, IEEE.
- Gashaw A, 2014, Anaerobic co-digestion of biodegradable municipal solid waste with human excreta for biogas production: A review, American Journal of Applied Chemistry, 2(4), 55–62.
- Ghatak M D, Ghatak A, 2018, Artificial neural network model to predict behavior of biogas production curve from mixed lignocellulosic co-substrates, Fuel, 232, 178–189.
- Glorot X, Bengio Y, 2010, Understanding the difficulty of training deep feedforward neural networks, In Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, 249–256.
- Goodfellow I, Bengio Y, Courville A, 2016, Deep learning, MIT Press.

- Goodwin K, Wiedmann T, Chen G, Teh S H, 2021, Benchmarking urban performance against absolute measures of sustainability – A review, *Journal of Cleaner Production*, 314, 128020.
- Guo H-n, Liu H-t, Wu S, 2022, Simulation, prediction and optimization of typical heavy metals immobilization in swine manure composting by using machine learning models and genetic algorithm, *Journal of Environmental Management*, 323, 116266.
- Gülcü A, Kuş Z, 2019, A survey of hyper-parameter optimization methods in convolutional neural networks, *Gazi University Journal of Science Part C: Design and Technology*.
- Haffiez N, Chung T H, Zakaria B S, Shahidi M, Mezbahuddin S, Maal-Bared R, Dhar B R, 2022, Exploration of machine learning algorithms for predicting the changes in abundance of antibiotic resistance genes in anaerobic digestion, *Science of The Total Environment*, 839, 156211.
- Hagan M T, Menhaj M, 1994, Training feedforward networks with the Marquardt algorithm, *IEEE Transactions on Neural Networks*, 5(6), 989–993.
- Hagos K, Zong J, Li D, Liu C, Lu X, 2017, Anaerobic co-digestion process for biogas production: Progress, challenges and perspectives, *Renewable and Sustainable Energy Reviews*, 76, 1485–1496.
- Haugen F, Bakke R, Lie B, 2012, State estimation of a pilot anaerobic digestion reactor, In *Proceedings of the 8th IFAC Symposium on Nonlinear Control Systems*, 123–128, IFAC.
- Hassabis D, Kumaran D, Summerfield C, Botvinick M, 2017, Neuroscience-inspired artificial intelligence, *Neuron*, 95(2), 245–258.
- Haykin S, 2009, *Neural networks and learning machines* (3rd ed.), Pearson.
- Husain A, 1998, Mathematical models of the kinetics of anaerobic digestion: A selected review, *Biomass and Bioenergy*, 14(5–6), 561–571.
- İnik Ö, Ülker E, 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85–104.

- Jaroenpoj S, Yu Q J, Ness J, 2014, Development of artificial neural network models for biogas production from co-digestion of leachate and pineapple peel, *The Global Environmental Engineers*, 1(2), 42–47.
- Jeong K, Abbas A, Shin J, Son M, Kim Y M, Cho K H, 2021, Prediction of biogas production in anaerobic co-digestion of organic wastes using deep learning models, *Water Research*, 205, 117697.
- Jiang Y, Xie S H, Dennehy C, Lawlor P G, Hu Z H, Wu G X, Zhan X M, Gardiner G E, 2020, Inactivation of pathogens in anaerobic digestion systems for converting biowastes to bioenergy: A review, *Renewable and Sustainable Energy Reviews*, 120, 109654.
- Jurado F, Ortega M, Cano A, Carpio J, 2002, Neuro-fuzzy controller for gas turbine in biomass-based electric power plant, *Electric Power Systems Research*, 60(2), 123–135.
- Karapınar Ş Z, Şentürk A, 2016, Yapay sinir ağları ile göğüs kanseri tahmini, *El-Cezeri Fen ve Mühendislik Dergisi*, 3(2), 345–350.
- Kayri M, 2016, Predictive abilities of Bayesian regularization and Levenberg–Marquardt algorithms in artificial neural networks: A comparative empirical study on social data, *Mathematical and Computational Applications*, 21(2), 20.
- Kerimak Öner M N, 2023, Gıda atıklarının fermentasyon ortamı olarak kullanıldığı anaerobik parçalanma yöntemi üzerine bir inceleme, *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(2), 1713–1741.
- Khorshidi A, Zolfaghari M, Hejazi M A, 2014, Dynamic modeling and simulation of microturbine generating system for stability analysis in microgrid networks, *International Journal of Basic Sciences & Applied Research*, 3(9), 663–670.
- Kizito S, Bah H, Tumutegereize P, 2022, Synergetic effects of biochar addition on mesophilic and high total solids anaerobic digestion of chicken manure, *Journal of Environmental Management*, 315, 115192.
- LeCun Y, Bengio Y, Hinton G, 2015, Deep learning, *Nature*, 521(7553), 436–444.

- LeCun Y, Bottou L, Orr G B, Müller K R, 2012, Efficient BackProp, In Montavon G, Orr G B, Müller K R (Eds.), *Neural networks: Tricks of the trade*, 9–48, Springer.
- Lemaigre S, Gerin P A, Adam G, Klimek D, Goux X, Herold M, Delfosse P, 2023, Potential of acetic acid to restore methane production in anaerobic reactors critically intoxicated by ammonia as evidenced by metabolic and microbial monitoring, *Biotechnology for Biofuels and Bioproducts*, 16, 188.
- Ling J Y X, Chan Y J, Chen J W, Chong D J S, Tan A L L, Arumugasamy S K, Lau P L, 2024, Machine learning methods for the modelling and optimisation of biogas production from anaerobic digestion: A review, *Environmental Science and Pollution Research*, 31(13), 19085–19104.
- Ling M, Hu X, Yu J, Lv C, 2024, New secondary decomposition ensemble support vector regression for monthly drought index forecasting.
- Liu X, Zhu F, Zhang R, Zhao L, Qi J, 2021, Recent progress on biodiesel production from municipal sewage sludge, *Renewable and Sustainable Energy Reviews*, 135, 110260.
- Mahmoodi-Eshkaftaki M, Ebrahimi R, 2021, Integrated deep learning neural network and desirability analysis in biogas plants: A powerful tool to optimize biogas purification, *Energy*, 231, 121073.
- Mahboubi Soufiani A, Patel A, Sárvári Horváth I, Taherzadeh M, Rova U, Christakopoulos P, Matsakas L, 2021, Volatile Fatty Acids (VFAs) Generated by Anaerobic Digestion Serve as Feedstock for Freshwater and Marine Oleaginous Microorganisms to Produce Biodiesel and Added-Value Compounds, *Frontiers in Microbiology*, 12, 614612.
- Manjusha C, Beevi S, 2016, Mathematical modeling and simulation of anaerobic digestion of solid waste, *Procedia Technology*, 24, 654–660.
- Menacho W A, Mazid A M, Das N, 2022, Modelling and analysis for biogas production process simulation of food waste using Aspen Plus, *Fuel*, 309, 122058.
- Mombekova G, Sultanbekova Z, Tulegenova A, 2024, The relationship between energy consumption, population and economic growth in developing countries, *International Journal of Energy Economics and Policy*, 14(2), 1–8.

- Mokhtarani B, Zanganeh J, Moghtaderi B, 2025, A review on biohydrogen production through dark fermentation, process parameters and simulation, *Energies*, 18(5), 1092.
- Mowbray M, Savage T, Wu C, Song Z, Cho B A, Del Rio-Chanona E A, Zhang D, 2021, Machine learning for biochemical engineering: A review, *Biochemical Engineering Journal*, 172, 108054.
- Mukasine A, Sibomana L, Jayavel K, Nkurikiyeyezu K, Hitimana E, 2024, Maximizing biogas yield using an optimized stacking ensemble machine learning approach, *Energies*, 17(2), 364.
- Nair V, Hinton G E, 2010, Rectified linear units improve restricted Boltzmann machines, In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, 807–814.
- Neupane B, Belkadi F, Formentini M, Rozière E, Hilloulin B, Faraji Abdolmaleki S, Mensah M, 2025, Machine learning algorithms for supporting life cycle assessment studies: An analytical review, *Sustainable Production and Consumption*, 56, 37–53.
- Neshat S A, Mohammadi M, Najafpour G D, Lahijani P, 2017, Anaerobic co-digestion of animal manures and lignocellulosic residues as a potent approach for sustainable biogas production, *Renewable and Sustainable Energy Reviews*, 79, 308–322.
- Nwankpa C E, Ijomah W, Gachagan A, Marshall S, 2018, Activation Functions: Comparison of Trends in Practice and Research for Deep Learning, *arXiv Preprint arXiv:1811.03378*, 8 November, Glasgow, UK, 1–12.
- Onu C E, Nweke C N, Nwabanne J T, 2022, Modeling of thermo-chemical pretreatment of yam peel substrate for biogas energy production: RSM, ANN, and ANFIS comparative approach, *Applied Surface Science Advances*, 11, 100299.
- Orhorhoro E K, Ebunilo P O, Sadjere G E, 2017, Development of a predictive model for biogas yield using artificial neural networks (ANNs) approach, *American Journal of Energy and Power Engineering*, 4(6), 71–77.
- Osman A I, Mehta N, Elgarahy A M, Al Hinai A, Al Muhtaseb A H, Rooney D W, 2021, Conversion of biomass to biofuels and life cycle assessment: a review, *Environmental Chemistry Letters*, 19, 4075–4118.

- Özince N, 2019, Atıksu Arıtma Tesisi Çürütücü Ünitesi Biyogaz Üretim Tahmin Sistemi, Yüksek lisans tezi, Niğde Ömer Halisdemir Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği ABD, YÖK Tez Merkezi.
- Park J-G, Jun H-B, Heo T-Y, 2021, Retraining prior state performances of anaerobic digestion improves prediction accuracy of methane yield in various machine learning models, *Applied Energy*, 298, 117250.
- Patel A, Mahboubi A, Horváth I S, Taherzadeh M J, Rova U, Christakopoulos P, Matsakas L, 2021, Volatile fatty acids (VFAs) generated by anaerobic digestion serve as feedstock for freshwater and marine oleaginous microorganisms to produce biodiesel and added-value compounds, *Frontiers in Microbiology*, 12, 614612.
- Pathmasiri T K K S, Haugen F, Gunawardena S H P, 2013, Simulation of a biogas reactor for dairy manure, *Annual Transactions of the Institution of Engineers, Sri Lanka*, 394–398.
- Peker B, Dadaşer-Çelik F, 2019, Termal ve kimyasal önışlemlerin atıksu çamuru ve şeker pancarı küspesi karışımından biyogaz eldesindeki etkilerinin belirlenmesi, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(3), 679–686.
- Putra L A, Huber B, Gaderer M, 2023, Estimation of acetic acid concentration from biogas samples using machine learning, *International Journal of Chemical Engineering*, 2023, Article ID 2871769.
- Rabii A, Aldin S, Dahman Y, Elbeshbishy E, 2019, A review on anaerobic co-digestion with a focus on the microbial populations and the effect of multi-stage digester configuration, *Energies*, 12(6), 1106.
- Radočaj D, Jurišić M, 2025, Comparative evaluation of ensemble machine learning models for methane production from anaerobic digestion, *Fermentation*, 11(3), 130.
- Rahma F N, Li T, Khalil R, Tran K-Q, 2023, Hydrothermal gasification of biogas digestate: A parametric study using a MATLAB-based code, *Chemical Engineering Transactions*, 105, 217–222.
- Rathnasiri P G, 2016, Dynamic modelling and simulation of pilot scale anaerobic digestion plant treating source separated food waste and effect of recycling sludge, *Procedia Environmental Sciences*, 35, 740–748.

- Rego A S C, Leite S A F, Leite B S, Grillo A V, Santos B F, 2019, Artificial neural network modelling for biogas production in biodigesters, *Chemical Engineering Transactions*, 74, 25–30.
- Rehman M S U, Rashid N, Saif A, Mahmood T, Han J I, 2013, Potential of anaerobic digestion for biomass pretreatment: A review, *Renewable and Sustainable Energy Reviews*, 36, 264–275.
- Rossi E, Pecorini I, Iannelli R, 2022, Multilinear regression model for biogas production prediction from dry anaerobic digestion of OFMSW, *Sustainability*, 14(8), 4393.
- Ruwa T L, Abbasoğlu S, Akün E, 2022, Energy and exergy analysis of biogas-powered power plant from anaerobic co-digestion of food and animal waste, *Processes*, 10(5), 871.
- Saeed M, Fawzy S, El-Saadawi M, 2019, Modeling and simulation of biogas-fueled power system, *International Journal of Green Energy*, 16(2), 125–151.
- Salehi R, Yuan Q, Chaiprapat S, 2022, Development of data-driven models to predict biogas production from spent mushroom compost, *Agriculture*, 12(8), 1090.
- Savand-Roumi E, Salehiyoun A R, Mohtasebi S S, 2024, Use of a biogas-specific e-nose with machine learning to identify biogas pattern changes linked to hydraulic retention times in an anaerobic digester: A case study, *Fuel*, 357, 130013.
- Seyedlar N H, Zamir S M, Nosrati M, Rene E R, 2024, H₂S mitigation for biogas upgrading in a full-scale anaerobic digestion process by using artificial neural network modeling, *Renewable Energy*, 232, 121016.
- Shahsavar M M, Akrami M, Gheibi M, Kavianpour B, Fathollahi-Fard A M, Behzadian K, 2021, Constructing a smart framework for supplying the biogas energy in green buildings using an integration of response surface methodology, artificial intelligence and Petri net modelling, *Energy Conversion and Management*, 248, 114794.
- Shi X-S, Yuan X-Z, Wang Y-P, Zeng S-J, Qiu Y-L, Guo R-B, Wang L-S, 2014, Modeling of the methane production and pH value during the anaerobic co-digestion of dairy manure and spent mushroom substrate, *Chemical Engineering Journal*, 244, 258–263.

- Sudiarta G A W, Imai T, Mamimin C, Reungsang A, 2023, Effects of temperature shifts on microbial communities and biogas production: An in-depth comparison, *Fermentation*, 9(7), 642.
- Sukphun P, Sittijunda S, Reungsang A, 2021, Volatile fatty acid production from organic waste with the emphasis on membrane-based recovery, *Fermentation*, 7(3), 159.
- Tabatabaei M, Aghbashlo M, Valijanian E, Shariat Panahi H K, Nizami A S, Ghanavati H, Sulaiman A, Mirmohamadsadeghi S, Karimi K, 2020, A comprehensive review on recent biological innovations to improve biogas production, Part 1: Upstream strategies, *Renewable Energy*, 146, 1204–1220.
- Taheri B, Jabari F, Akbari Foroud A, 2023, A green cogeneration microgrid composed of water-source heat pumps, a gravity energy storage, and a bio-fueled gas turbine: Design and techno-economic optimization, *Sustainable Cities and Society*, 95, 104594.
- Tarım ve Orman Bakanlığı Tarım Reformu Genel Müdürlüğü. (2024). Afyonkarahisar tarımsal yatırım rehberi. Tarımsal Yatırımcı Danışma Ofisi Yayınları.
- Tufaner F, Avşar Y, Gönüllü M T, 2017, Modeling of biogas production from cattle manure with co-digestion of different organic wastes using an artificial neural network, *Clean Technologies and Environmental Policy*, 19(9), 2255–2264.
- Tryhuba I, Tryhuba A, Hutsol T, et al., 2024, Prediction of biogas production volumes from household organic waste based on machine learning, *Energies*, 17(7), 1786.
- Tümür Ş, 2025, Evsel atıklardan biyogaz üretimi ve enerji potansiyeli: Diyarbakır örneği, *DUJE (Dicle University Journal of Engineering)*, 16(1), 217–228.
- Vellido A, Martí R, Lisboa P J G, 2012, Making machine learning models interpretable, In *Proceedings of the 20th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN)*, 163–172.
- Wainaina S, Awasthi M K, Taherzadeh M J, 2019, Bioengineering of anaerobic digestion for volatile fatty acids, hydrogen or methane production: A critical review, *Bioengineered*, 10(1), 437–458.

- Wang L, Long F, Liao W, Liu H, 2020, Prediction of anaerobic digestion performance and identification of critical operational parameters using machine learning algorithms, *Bioresource Technology*, 298, 122495.
- Wang X, Lu X, Li F, Yang G, 2014, Effects of temperature and carbon-nitrogen (C/N) ratio on the performance of anaerobic co-digestion of dairy manure, chicken manure and rice straw: Focusing on ammonia inhibition, *PLOS ONE*, 9(5), e97265.
- Yalcinkaya S, Yucel O, 2025, Enhancing biogas production from municipal wastewater sludge and grease trap waste: Explainable machine learning models for prediction and parameter identification, *Fuel*, 391, 134787.
- Yetilmezsoy K, Karakaya K, Bahramian M, Abdul-Wahab S A, Goncaloglu B I, 2021, Black-, gray-, and white-box modeling of biogas production rate from a real-scale anaerobic sludge digestion system in a biological and advanced biological treatment plant, *Neural Computing and Applications*, 33(21), 11043–11066.
- Yıldırım Ö, Ozkaya B, 2023, Prediction of biogas production of industrial scale anaerobic digestion plant by machine learning algorithms, *Chemosphere*, 335, 138976.
- Youlian Z, Cheng H, 2011, A study on the Levenberg–Marquardt algorithm in training artificial neural networks, In *Proceedings of the 2011 Third International Conference on Measuring Technology and Mechatronics Automation (ICMTMA)*, 1–4.
- Zador A M, 2019, A critique of pure learning: What artificial neural networks can learn from animal brains, *Nature Communications*, 10, 3770.
- Zhang X, Yang Y, Wang D, 2023, Embodied carbon accounting through spatial-temporal embodied carbon models, *arXiv preprint*, arXiv:2312.06364.
- Zhang Y, Yang Q, 2023, Information criteria for model selection, *Wiley Interdisciplinary Reviews: Computational Statistics*, 15(2), e1607.
- Zhang Y, Jing Z, Feng Y, Chen S, Li Y, et al., 2023, Using automated machine learning techniques to explore key factors in anaerobic digestion, *Chemical Engineering Journal*, 475, 146069.

- Zhang C, Su H, Baeyens J, Tan T, 2014, Reviewing the anaerobic digestion of food waste for biogas production, Renewable and Sustainable Energy Reviews, 38, 383–392.
- Zou J, Lü F, Chen L, Zhang H, He P, 2024, Machine learning for enhancing prediction of biogas production and building a VFA/ALK soft sensor in full-scale dry anaerobic digestion of kitchen food waste, Journal of Environmental Management, 371, 123190.

İnternet Kaynakları

- 1) <https://www.veribilimiokulu.com/yapay-sinir-aglari/> 25.11.2024
- 2) <https://www.veribilimiokulu.com/yapay-sinir-aglari/wp-content/uploads/2018/08/ileri-beslemeli-yapay-sinir-ag1.png> 27.11.2024
- 3) <https://www.veribilimiokulu.com/yapay-sinir-aglari/wp-content/uploads/2018/08/yapay-sinir-aglari.jpg.webp> 29.11.2024
- 4) <https://www.veribilimiokulu.com/yapay-sinir-aglari/> 29.11.2024
- 5) https://ch.mathworks.com/help/deeplearning/referencelist.html?type=function&s_tid=CRUX_topnav 02.12.2024
- 6) <https://altacaenerji.com/biyogaz/uretim/> 04.05.2025
- 7) <https://armatec.com.tr> 06.05.2025