



**KONYA ATIKSU ARITMA TESİSİNDE ANAEROBİK ÇÜRÜTME ÜNİTESİNİN
YAPAY ZEKA KULLANILARAK OPTİMİZASYONU**

Aliaa SALEH

YÜKSEK LİSANS TEZİ

Ağustos-2024

KONYA

Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Aliaa SALEH tarafından hazırlanan “Konya Atıksu Arıtma Tesisinde Anaerobik Çürütme Ünitesinin Yapay Zeka Kullanılarak Optimizasyonu” adlı tez çalışması 05/08/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Enerji Sistemleri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Serpil EDEBALI
Konya Teknik Üniversitesi

Danışman

Dr. Öğr. Üyesi Atıf Emre DEMET
Necmettin Erbakan Üniversitesi

Üye

Doç. Dr. Mehmet HACİBEYOĞLU
Necmettin Erbakan Üniversitesi

İmza

.....

.....

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

Bu tez çalışması tarafından nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Aliaa SALEH

05/08/2024

ÖZET
YÜKSEK LİSANS TEZİ

KONYA ATIKSU ARITMA TESİSİNDE ANAEROBİK ÇÜRÜTME ÜNİTESİNİN
YAPAY ZEKA KULLANILARAK OPTİMİZASYONU

Aliaa SALEH

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Enerji Sistemleri Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Atıf Emre Demet

2024, 67 Sayfa

Jüri

Danışman Dr. Öğr. Üyesi Atıf Emre DEMET
Doç. Dr. Mehmet HACİBEYOĞLU
Prof. Dr. Serpil EDEBALI

Metan üretiminin artırılması, atık su arıtma tesislerinin kendi kendine yeterliliğinin artırılmasında çok önemlidir ve anaerobik çürütme, enerji geri kazanım ünitesi olarak hizmet verdiği için sürdürülebilirlik faktörü olarak kabul edilmektedir. Barındırdığı çok sayıda faktör nedeniyle anaerobik çürütmenin doğasını anlamak ve kontrol etmek zordur. Yapay zekâ teknikleri, anaerobik çürütme sürecini doğası hakkında bilgi gerektirmeden kontrol etmeye olanak sağlar. Bu çalışmanın temel amacı, Türkiye’de bulunan Konya Atıksu Arıtma Tesisi’ndeki anaerobik çürütme ünitelerini modellemek için yapay sinir ağı metodolojisinin kullanımını incelemektir. Amaç, tesisin operasyonel parametrelerini ayarlayarak metan verimini ve hidrojen sülfid konsantrasyonunu optimize etmektir. Model, ardışık iki yıla ait gerçek veriler kullanılarak oluşturulmuştur. Metan verimi ve hidrojen sülfid çıkış olarak kullanılırken 11 parametre ölçülür ve giriş özellikleri olarak kullanılır. Çalışmada doğru bir model elde etmek için normalizasyon, Pearson korelasyon analizi ve farklı eğitim algoritmaları gibi teknikler kullanılmıştır. Ayrıca çalışma YSA modelini kullanarak girdi parametrelerinin çıktı parametreleri üzerindeki duyarlılığını analiz etmektedir. Metan üretimini maksimize ve hidrojen sülfidi minimize eden girdi parametrelerinin optimum değerlerini belirlemek için aynı zamanda genetik algoritmayı kullanmaktadır. Önerilen model hem eğitim hem de test setleri için ortalama kare hata (MSE) ve korelasyon katsayısı (R) kullanılarak değerlendirilmiştir. Sonuçlar MSE ve R değerlerinin sırasıyla 0.0048, 0.0077, 0.96 ve 0.94 olduğunu göstermektedir. Duyarlılık analizi, yoğunlaştırılmış çamurun pH seviyesinin her iki çıktı üzerinde de en büyük etkiye sahip olduğunu göstermektedir. Öte yandan, çamur akış hızı metan üzerinde en düşük etkiye sahipken, çürütücünün uçucu yağ asidi ise hidrojen sülfid üzerinde en düşük etkiye sahiptir. Dahası, çok sayıda optimum çözüm metan gazını en üst düzeye çıkarabilir ve hidrojen sülfidi en aza indirebilir. Metan verimi %27’ye kadar artırılabilir ve buna karşılık gelen hidrojen sülfid 350 ppm’dir.

Anahtar Kelimeler: Atıksu Arıtma Tesisi, Duyarlılık analizi, Genetik algoritma, Hidrojen sülfid, Metan, YSA.

ABSTRACT

MS THESIS

**OPTIMIZATION OF ANAEROBIC DIGESTION UNIT IN KONYA WASTEWATER
TREATMENT PLANT USING ARTIFICIAL INTELLIGENCE**

Aliaa SALEH

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF NECMETTIN
ERBAKAN UNIVERSITY**

**THE DEGREE OF MASTER OF SCIENCE
IN ENERGY SYSTEMS ENGINEERING**

Advisor: Assist. Prof. Atif Emre DEMET

2024, 67 Pages

Jury

Advisor: Assist. Prof. Dr. Atif Emre DEMET

Assoc Prof. Mehmet HACIBEYOĞLU

Prof. Dr. Serpil EDEBALI

The enhancement of methane production is crucial in increasing the self-sufficiency of wastewater treatment plants, and anaerobic digestion is considered the sustainability driver as it serves as the energy recovery unit. Understanding and controlling the nature of anaerobic digestion is challenging due to multiple factors involved. Artificial intelligence techniques provide a way to control the process of anaerobic digestion without requiring knowledge of its nature. The purpose of this study is to examine the use of artificial neural network methodology to model the units of anaerobic digestion in the Konya wastewater treatment plant located in Turkey. The goal is to optimize the methane yield and hydrogen sulfide concentration by adjusting the plant's operational parameters. The model is constructed using actual experimental data from two consecutive years, where 11 parameters are measured and used as input features and methane yield and hydrogen sulfide serve as output. The study uses normalization, Pearson correlation analysis, and different training algorithms to obtain an accurate model. Additionally, the study analyzes the sensitivity of input parameters on output parameters using the ANN model. It also utilizes the genetic algorithm to determine the optimal values of input parameters that maximize methane production and minimize hydrogen sulfide. The proposed model has been evaluated using the mean square error (MSE) and correlation coefficient (R) for both training and test sets. The results indicate that the MSE and R are 0.0048, 0.0077, 0.96, and 0.94 respectively. The sensitivity analysis shows that the pH level of thickened sludge has the greatest impact on both outputs. On the other hand, the sludge flow rate has the lowest impact on methane, while the volatile fatty acid of the digester has the lowest impact on hydrogen sulfide. Moreover, multiple optimal solutions can maximize methane gas and minimize hydrogen sulfide. Methane yield can be increased up to 27%, with corresponding hydrogen sulfide of 350 ppm.

Keywords: ANN, Genetic algorithm, Hydrogen sulfide, Methane, Sensitivity analysis, WWTP.

TEŐEKKÜR

Çalıőma sürecim boyunca, bu çalıőmaya yön veren verileri elde etmek için Konya Su ve Kanalizasyon İdaresi (KOSKİ) ile iletişime geçmeme katkıda bulunan ve yeni fikirler üretmemi sağlayarak çabalarımın yüksek kaliteli bir çalıőmayla karşılık bulması için ufkumu açmama yardımcı olan danışman hocam Dr. Öğr. Üyesi Atıf Emre Demet'e teşekkür ederim. Bize verileri ulaőtıran ve ham verileri sağlayan KOSKİ'ye, özellikle de verilerin aktarılması sürecini kolaylaőtıran ve hızlandıran KOSKİ'nin Genel Müdür Yardımcısı Yusuf Demet ve Arıtma Tesisleri Proje ve İnőaat Őube Müdürü Muhammed Ceylan'a, verilerin düzenlenmesini sağladıkları ve çalıőma için gerekli soruları özveriyle yanıtladıkları için Müh. Yusuf Kenan Ordu ve Müh. Cihat Uçar'a Őükranlarımı sunarım.

Aliaa SALEH
KONYA-2024

İÇİNDEKİLER

TEZ KABUL VE ONAYI	II
ÖZET	IV
ABSTRACT	V
TEŞEKKÜR	VI
İÇİNDEKİLER	VII
ŞEKİL TABLOSU	IX
ÇİZELGELER TABLOSU	X
1. GİRİŞ	1
1.1 Problemin Açıklanması	4
1.2 Çalışmanın Amacı ve Hedefleri	4
1.3 Çalışma Alanı	5
2. YAPAY ZEKAYA GENEL BAKIŞ	6
2.1 Yapay Sinir Ağı (YSA).....	7
2.2 Destek Vektör Makinesi (DVM)	8
2.3 Karar Ağacı	9
2.4 Bulanık Çıkarım Sistemi (BÇS).....	9
2.5 Temel Bileşen Analizi (TBA).....	10
2.6 Optimizasyon Algoritmaları.....	11
2.6.1 Genetik algoritma (GA)	12
2.6.2 Parçacık sürüsü optimizasyonu algoritması (PSO).....	12
3. AAT'DE ANAEROBİK ÇÜRÜTMEDE YAPAY ZEKA MODELLERİNİN UYGULAMALARI	13
3.1 Anaerobik Çürütmenin Proses Kararlılığının İzlenmesi Ve Biyogaz Veriminin Optimizasyonu	13
3.2 Mikrobiyal Topluluğun Aktivitesinin Artırılması.....	14
3.3 Arıza Tespiti	16
4. KAYNAK ARAŞTIRMASI	18
5. MATERYAL VE METODLAR	20
5.1 Çalışma Tesisi.....	20

5.2 Veri Toplama	22
5.3 Veri Ön İşleme.....	23
5.4 Pearson Analizi.....	24
5.5 Yapay Sinir Ağı Modeli (YSA).....	24
5.5.1 Veri ayırma.....	26
5.5.2 Ağ yapısı.....	26
5.5.3 Eğitim algoritması	28
5.6 YSA Modelinin Performans Değerlendirmesi	29
5.7 Duyarlılık Analizi.....	30
5.8 Optimum Koşulları Belirlemek İçin Genetik Algoritma (GA)	30
6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	32
6.1 Veri Ön İşleme ve Pearson Korelasyon Analizi Sonuçları.....	32
6.2 Yapay Sinir Ağı Modelinin Sonuçları	40
6.3 Duyarlılık Analizinin Sonuçları	47
6.4 GA Optimizasyon Sonuçları.....	51
7 SONUÇLAR VE ÖNERİLER.....	54
7.1 Sonuçlar.....	54
7.2 Öneriler.....	54
8. KAYNAKLAR	56

ŞEKİL TABLOSU

Şekil 2.1. Yapay zekâ, makine öğrenimi ve derin öğrenme teknolojileri arasındaki ilişkilerin şematik gösterimi.	6
Şekil 5.1. Konya Atıksu Arıtma tesisinin 2 boyutlu üstten görünüm şeması.	21
Şekil 5.2. Konya Kentsel Atıksu Arıtma Tesisi akım şeması.	22
Şekil 5.3. Gizli ve çıkış katmanları için sırasıyla Tansig ve Purelin aktivasyon fonksiyonları.	28
Şekil 6.1. Normalizasyondan sonra çamur yoğunlaştırma ünitesinin istatistiksel özeti için kutu grafiği.	35
Şekil 6.2. Normalizasyondan sonra çürütücü 1'in istatistiksel özeti için kutu grafiği.	36
Şekil 6.3. Normalizasyondan sonra çürütücü 2'in istatistiksel özeti için kutu grafiği.	37
Şekil 6.4. Normalizasyondan sonra çürütücü 3'in istatistiksel özeti için kutu grafiği.	38
Şekil 6.5. Normalizasyondan sonra çürütücü 4'in istatistiksel özeti için kutu grafiği.	39
Şekil 6.6. Metan verimi ve hidrojen sülfid konsantrasyonunun diğer değişkenlerle arasındaki Pearson korelasyon analizi sonuçları.	40
Şekil 6.7. Seçilen model için YSA yapılandırmasının basitleştirilmiş çizimi.	43
Şekil 6.8. Epoch 394 için seçilen YSA modelinin hedef ve çıktı değerleri arasındaki regresyon grafiği.	44
Şekil 6.9. Epoch394 için seçili ANN modeli için karşılık gelen örneklerle hata histogramı.	46
Şekil 6.10. MSE ve 398 epoch için en iyi performans.	50
Şekil 6.11. Gerçek ve model tahminli metan verimi verilerinin karşılaştırılması.	46
Şekil 6.12. Gerçek ve model tahminli H ₂ S verilerinin karşılaştırılması.	46
Şekil 6.13. Giriş özelliklerinin metan verimi üzerindeki göreceli öneminin dağılımı.	48
Şekil 6.14. Giriş özelliklerinin H ₂ S konsantrasyonu üzerindeki göreceli öneminin dağılımı.	49
Şekil 6.15. Giriş özelliklerinin metan verimi üzerindeki göreceli önem yüzdelerini gösteren pasta grafiği.	50
Şekil 6.16. H ₂ S konsantrasyonu üzerindeki girdi özelliklerinin göreceli önem yüzdelerini gösteren pasta grafiği.	50
Şekil 6.17. GA optimizasyonunu kullanarak metan ve hidrojen sülfid amaç fonksiyonları arasındaki Pareto optimal çözümleri.	52

ÇİZELGELER TABLOSU

Çizelge 5.1. Çamur yoğunlaştırma ve anaerobik çürütücü üniteleri için seçilen parametreleri. ..	23
Çizelge 6.1. Çamur yoğunlaştırma ünitesi özelliklerinin istatistiksel özeti.....	32
Çizelge 6.2. Çürütücü 1 özelliklerinin istatistiksel özeti.	32
Çizelge 6.3. Çürütücü 2 özelliklerinin istatistiksel özeti.	33
Çizelge 6.4. Çürütücü 3 özelliklerinin istatistiksel özeti.	33
Çizelge 6.5. Çürütücü 4 özelliklerinin istatistiksel özeti.	34
Çizelge 6.6. Tek gizli katmanlı LM eğitim yöntemini kullanan YSA yapısının performans sonuçları.....	41
Çizelge 6.7. İki gizli katmanlı LM eğitim yöntemini kullanan YSA yapısının performans sonuçları.....	41
Çizelge 6.8. Tek gizli katmanlı BR eğitim yöntemini kullanan YSA yapısının performans sonuçları.....	42
Çizelge 6.9. En iyi çıktılara karşılık gelen girdi özelliklerinin optimum çözümleri	53

1. GİRİŞ

Temiz Su ve Sanitasyon, Birleşmiş Milletler Sürdürülebilir Kalkınma Hedeflerinde (SKH) altıncı hedef olarak ilan edilmiştir. Temiz suya erişilebilirliğin bir insan hakkı olduğunu aynı zamanda sağlık, yoksulluğun ortadan kaldırılması ve gıda güvenliği için bir gereklilik olduğunu belirtmektedir. 2022 yılında 3,5 milyar insan güvenli bir şekilde yönetilen sanitasyondan yoksundu; sanitasyon ve atık su arıtımı ile ilgili programların bu amacın 2030 hedeflerine ulaşması için ilerlemenin beş kat hızlandırılması gerekecektir (Su ve Sanitasyon - Birleşmiş Milletler Sürdürülebilir Kalkınma). Nüfus artışı, ekonomik büyüme, kentleşme ve sanayileşme atık su tüketim oranını artıran başlıca etkenler olurken, iklim değişikliği, su kirliliği ve kötü su yönetimi de su kaynaklarında kıtlığa neden olan faktörlerdir (W. Lu vd., 2022; Teng vd., 2011). Dünya çapında her yıl 380 milyar m³ kentsel atık su üretilmektedir ve bu miktar Niagara Şelalesi'nden yılda geçen su hacminin beş katına eşittir. 2030 ve 2050 yıllarında atık su üretiminin sırasıyla %24 ve %51 oranında artması beklenmektedir (Qadir vd., 2020). Atık su, konut ve ticari faaliyetler, endüstriyel işlemler ve tarımsal kullanım nedeniyle fiziksel, kimyasal veya biyolojik özellikleri değişen kullanılmış suyun birleşiminden ortaya çıkar. Atık su %99,9 su ve %0,1 organik madde, mikroorganizmalar ve inorganik bileşiklerden oluşmaktadır. Arıtılmamış veya kötü arıtılmış atık su çevreyi, insan sağlığını, su kaynaklarını ve ekonomik büyümeyi tehlikeye atmaktadır. Bu nedenle, atık su arıtma tesisleri (AAT'ler), çevreyi ve halk sağlığını korumak için sıralı fiziksel, biyolojik ve/veya kimyasal arıtmalar yoluyla atık sudan kirletici, patojen ve besin yükünü gidermek ve azaltmak için bir su koruma aracı olarak hareket eder (Ehalt Macedo vd., 2022). Ayrıca atık su arıtımı, enerji ve besin maddelerini geri kazanma ve suyu yeniden kullanma kabiliyeti sayesinde döngüsel ekonomiyi güçlendirir (Obaideen vd., 2022). Evrensel olarak, üretilen atık suyun %11,4'ü AAT'lerde arıtıldıktan sonra yeniden kullanılmakta, %41,4'ü arıtıldıktan sonra serbest bırakılmakta ve %47,2'si ise AAT'lerde arıtılmadan çevreye deşarj edilmektedir (Ehalt Macedo vd., 2022).

Atık su, kanalizasyon şebekesi sisteminden gelir ve suyun deşarjı veya kullanımıyla ilgili düzenlenmiş standartlar karşılanana kadar kirleticilerden kurtulmak için AAT'lerde seri ünite işlemlerinden geçer. Ön ve birincil (fiziksel), ikincil (biyolojik) ve üçüncül (kimyasal) olmak üzere üç arıtma seviyesi vardır. Kaba fiziksel cisimleri ve kumları gidermek için ızgara ve kum tutucu içeren fiziksel arıtma ile başlar, daha sonra çökelebilen organik ve inorganik maddeler

çökeltme yoluyla, yüzen maddeler ("skum") ise sıyırma yoluyla uzaklaştırılır, ardından organik ve askıda katı maddelerin geleneksel aktif çamur yöntemi kullanılarak daha fazla parçalanması için biyolojik arıtma yapılır, bu yöntemde mikroorganizmalar havalandırma ve biyolojik olarak aktif katı maddelerin devridaimi yoluyla aktive edilir. Son olarak, biyolojik arıtmada giderilemeyenleri arıtmak için dezenfeksiyon veya kimyasal arıtma uygulanır. Gerekirse difüzyon membran teknolojisi veya ileri oksidasyon prosesleri gibi daha ileri arıtmalar da uygulanabilir (Newhart vd., 2019; Owonka vd., 2021). Anaerobik çürütme (AÇ), biyolojik olarak parçalanabilen maddenin oksijen yokluğunda mineralize olduğu biyolojik bir süreçtir. Stabilizasyon süreci, organik maddelerin metabolize olarak biyogaz olarak adlandırılan metan ve karbondioksit formundaki kararlı ürünlere dönüşmesiyle gerçekleşir (Mathur & Singh, 2022). Biyogaz ayrıca hidrojen sülfid, amonyak, su buharı, karbonmonoksit, uçucu organik bileşikler vb. gibi daha küçük yüzdelerde istenmeyen bileşiklerden oluşur (Bragança e., 2020). Birkaç farklı mikroorganizma türü arasında dört aşamada gerçekleşen son derece karmaşık ve hassas bir süreçtir: hidroliz, asidogenez, asetogenez ve metanogenez (van Lier vd., 2023). Anaerobik arıtma, kombine ısı ve güç üniteleri için kullanılacak metan üretirken çamur üretimini azaltmak için AAT'lerde ikincil arıtmada yer alır. Buna ek olarak, AÇ'den elde edilen biyogazın kullanılması fosil yakıtlara olan bağımlılığı azaltmakta ve CO₂ emisyonunu dengelemektedir. Daha az enerji yoğun olması ve patojenleri etkisiz hale getirme kabiliyetinin daha yüksek olması nedeniyle aerobik çürütmeye göre özel özelliklere sahiptir (Poh vd., 2016). Biyogaz yenilenebilir bir enerji kaynağıdır ve ısı, elektrik, biyoyakıt üretimi ve hidrojen üretimi gibi birçok uygulamada kullanılması nedeniyle küresel enerji krizinde önemli bir rol oynamıştır (Kabeyi & Olanrewaju, 2022).

Anaerobik çürütme işlemi sırasında, SO₄²⁻ gibi hem organik hem de inorganik sülfür dönüştürülür ve H₂S'ye indirgenir. Bu dönüşümler, organik karbonun disimilasyon yolu ile biyogaza dönüştürülmesi ile eş zamanlı olarak gerçekleşir. Anaerobik çürütmede H₂S oluşumu büyük ölçüde CH₄ üretimini etkileme potansiyeline de sahip olan sülfat indirgeyici bakterilerin faaliyetinden etkilenir (Vu vd., 2022). Sülfat indirgeyici bakteriler ve metanojenler arasında asetik asit gibi enerji kaynakları için bir rekabet vardır. Bu rekabet anaerobik çürütme sürecinin kararlılığını etkileyerek üretilen CH₄ miktarında düşüşe yol açabilir (J. L. Chen vd., 2014). Ayrıca, hidrojen sülfid biyogazdan uzaklaştırılması, ekipmana zarar verdiği için biyogaz endüstrisindeki en büyük zorluklardan biridir (J. W. Chen vd., 2023), gaz motorları özellikle

korozif etkiden etkilenir, bu da motor ömrünün kısalmasına, bakım maliyetlerinin artmasına ve biyogazın elektriğe dönüşümünün azalmasına neden olur (Arıman vd., 2021).

Modelleme, mühendislik tasarımı, simülasyon ve süreç dinamikleri gibi araştırma alanları, su, gıda ve enerjinin birbirine bağlı bağlantıları üzerindeki önemli etkileri nedeniyle daha fazla AAT'lere odaklanmaktadır (Palma-Heredia vd., 2022). Matematiksel modeller, anaerobik çürütme sırasında meydana gelen dinamik süreçlerin anlaşılması için bir fırsat sunmaktadır, sistemin kararlılığını ve kararsızlığını analiz etmenin yanı sıra geçici davranışını belirlemek için kullanılabilir güvenilir araçlardır. Üstelik bu modeller sistemin temel yönlerini tasvir eder, anlayışımızı geliştirir, hipotezleri doğrulamamızı sağlar ve nihayetinde deneysel yöntemlerle ilişkili maliyetleri, riskleri ve zamanı azaltır (Mathur & Singh, 2022) (Mendes vd., 2015). Yapay zekâ (YZ) ve veri madenciliği teknikleri, ilgili verileri inceleyerek anaerobik çürütme ve metan üretiminin verimliliğini artırmak için kullanılmaktadır. Analiz otomasyonu ve verilerde örüntü tespiti yoluyla, ilgili modeller oluşturulur. Daha sonra parametreler, optimizasyon sürecinin amacına ulaşmak için optimum operasyonel faktörleri belirlemek üzere farklı koşullar altında analiz edilir (Bao vd., 2023). İnsan beyninin sinir sisteminin benzetimi bu yaklaşım tarafından benimsenmiştir. Optimizasyon modelleri, belirli sınırlamalar dahilinde bir amaç fonksiyonunu tatmin eden en uygun çözümü seçme hedefine sahiptir (Gershman vd., 2015; Villarrubia vd., 2018). Yapay Sinir Ağı (YSA), Genetik Algoritma (GA), Bulanık Destek Vektör Makinesi (FSVM) ve Parçacık Sürü Optimizasyonu (PSO) dahil olmak üzere çeşitli yapay zekâ teknikleri vardır, bu yöntemler gerçek problemlerde optimum çözümler bulmak için de birleştirilebilir (Ardabili vd. 2018). YSA, maliyet optimizasyonunu artırabilecek ve tesisin atık su kalitesini belirleyebilecek AAT'lerin çalışmasını kontrol edebilir. YSA'nın öne çıkan ve pratik bir özelliği vardır; biyolojik sürecin arkasındaki teorik ve fiziksel bilgiyi incelemeye gerek kalmadan AAT çıkış suyunun özelliklerini tahmin etmek için giriş ve çıkış parametreleri arasındaki karmaşık doğrusal olmayanlığı keşfedebilir. AAT'nin performansını tahmin etmek için YSA modellemesinin yüksek doğruluğu, iyi kalitede geçmiş verilere sahip olmakla ilişkilidir (W.-Y. Chen vd., 2022).

1.1 Problemin Açıklanması

Dünya; nüfus artışı, sanayileşme, kentleşme ve su uygulamalarının yanlış kullanımı gibi çeşitli küresel nedenlerden dolayı atık su üretiminin artması gibi ciddi bir sorunla karşı karşıyadır. AAT'ler gibi atık su yönetim stratejileri etkili bir çözüm ortaya koymaktadır, ancak arıtma süreçleri sırasında yan ürün olarak büyük miktarda çamur üretilmektedir (Ahmad vd., 2017; Buonocore vd., 2018). Atık sudan kaynaklanan çamurun artması, bu çamuru arıtmak için gereken enerjinin artması anlamına gelir ve geleneksel katı bertaraf yöntemlerinin kullanılması durumunda yüksek maliyetlere neden olur. AAT'lerde yenilikçi yaklaşımların benimsenmesi ve yan ürünlerin verimli bir şekilde kullanılması olumlu sonuçlar doğurabilir. Enerji üretmek için kullanılacak biyogaz formundaki çamurun arıtılmasında alternatif bir enerji kaynağı bulunmuştur (Kougias & Angelidaki, 2018). Son yıllarda biyogaz üretim teknolojisi geliştirilmiştir, ancak yine de AAT'lerin enerji ihtiyacını karşılamak için enerji çıktıları açısından iyileştirme çalışması gerekmektedir. Çalışmada, atık su arıtma tesislerinde metan üretimini artırmaya ve anaerobik çürütmenin performansını yükseltirken aynı zamanda hidrojen sülfid konsantrasyonunu azaltmaya çaba gösterilmiştir. Bu bağlamda, yapay zekanın entegrasyonu, biyogaz üretiminin tüm potansiyelinden yararlanmak için anaerobik çürütmeyi optimize etmek için bir yenilik ortaya koymaktadır. Bu nedenle bu çalışma, yapay zekâ alanını kullanarak anaerobik çürütücünün optimum çalışma koşullarını ele almaktadır.

1.2 Çalışmanın Amacı ve Hedefleri

Bu çalışmada, atıksu arıtma tesislerinde anaerobik çürütme ünitesi için yapay zekâ tabanlı bir teknik geliştirilmiştir. Araştırmanın temel amacı, çamurun arıtılması sırasında anaerobik çürütmenin performansını artırmak için akıllı bir yol önermektir. Bu amaca dört ana hedefle ulaşılabilir:

1. YSA tekniğini kullanarak metan verimi ve hidrojen sülfid gazı için en iyi tahmin modelini oluşturmaktır.
2. Önerilen YSA modelini Ortalama Kare Hata (MSE) ve korelasyon katsayısı (R) metriklerini kullanarak değerlendirmektir.
3. Girdi parametrelerinin göreceli önemini ve bunların iki çıktı üzerindeki etkisini duyarlılık analizi kullanarak tanımlamak için metan ve hidrojen sülfid YSA modelini uygulamaktır.


4. Son olarak, YSA modelini bir amaç fonksiyonu olarak kullanmak ve aynı anda maksimum metan verimi ve minimum hidrojen sülfid konsantrasyonunu elde eden mümkün olan en iyi giriş parametresi ayarlarını belirlemek için genetik algoritmayı (GA) uygulamaktır.

1.3 Çalışma Alanı

Konya'nın Karatay ilçesinde bulunan Konya Atıksu Arıtma Tesisi (KAAT) bir vaka çalışması sahası olarak ele alındı. Saha, kentsel bir alanın eteklerinde yer almakta, günlük 200.000 m³ debi ile yaklaşık 1.000.000'a eşdeğer bir nüfusa hizmet vermekte, arıtılan su Devlet Su İşleri tarafından Konya ana tahliye kanalına verilmekte ve sulama için kullanılmaktadır. KAAT 2010 yılında inşa edilmiştir.

2. YAPAY ZEKAYA GENEL BAKIŞ

Yapay Zekâ (YZ), Makine Öğrenimi (MÖ) ve Derin Öğrenme (DÖ), insanların müdahalesi olmadan çalışan bir sistemi tanımlamak için birbirinin yerine kullanılabilen üç bilinen terimdir (Sarker, 2021). Şekil 2.1. YZ'de MÖ ve DÖ'nin alt kümelerini açıklamaktadır. Dördüncü Sanayi Devrimi'nin temel teknolojik ilerleme ayaklarından biri olan YZ, insanların davranışları gibi düşünebilen, işlev görebilen ve karar verebilen akıllı makineler geliştirmeyi amaçlayan bir bilgisayar bilimi dalıdır (Sarker vd., 2021). Makine öğrenimi, belirli davranışları tahmin eden veya tanıyan modeller oluşturmak üzere kalıpları ve eğilimleri keşfetmek için geçmiş veriler üzerinde gerçekleştirilebilen bir dizi istatistiksel araç veya yöntem kullanan bir daldır (Sarker vd., 2020), Bu esnada DÖ, insan beyninin verileri işleme şeklini taklit eden çok katmanlı sinir ağlarını kullanarak öğrenme yöntemlerini ve verilerden hesaplama süreçlerini de kullanır. DÖ 'nin MÖ'den farkı, ilkinin daha büyük miktarda veriyle başa çıkmada daha verimli olması ve test sırasında çalıştırılmasının daha kısa sürmesidir (Sarker, 2021). Genel olarak, YZ'nin ana hedefi, makinelerin veya bilgisayarların karar verme, tahmin ve problem çözme gibi bilişsel işlevleri yerine getirmesini sağlamaktır. Otomatik, akıllı ve zeki sistemler, çağımızın çok önemli bir teknolojik atılımı haline gelen yapay zekâ tabanlı modelleme kullanılarak inşa edilebilir. Bu teknolojinin, her süreci geliştirerek ve daha doğru, verimli ve hızlı hale getirerek her işletmenin geleceği üzerinde önemli bir etkiye sahip olması bekleniyor (Sarker, 2022).



Şekil 2.1. Yapay zekâ, makine öğrenimi ve derin öğrenme teknolojileri arasındaki ilişkilerin şematik gösterimi.

Verimli bir YZ modeli geliřtirmek, gerek dnya sorunlarının eřitlilięi nedeniyle kolay bir iř deęildir, ancak analitik, iřlevsel, etkileřimli, metinsel ve grsel dahil olmak zere uygun YZ modeli trn bilmek, verilen problemle bařa ıkma potansiyeline sahiptir. Ayrıca, genel olarak on farklı trde sınıflandırılabilir eřitli YZ modelleri kategorileri vardır: makine ęrenimi, derin ęrenme, veri madencilięi ve bilgi keřfi, bulanık mantık, optimizasyon ve arama, grsel veri madencilięi, vaka tabanlı akıl yrtme, kural tabanlı yaklařım, bilgi temsili ve akıl yrtme ve metin madencilięi (Sarker, 2022).

Ařaęıdaki kısımlarda, zellikle anaerobik rtme kullanılarak amur ynetiminde kullanılabilir en yaygın modeller aıklanmaktadır.

2.1 Yapay Sinir Aęı (YSA)

Yapay sinir aęı, derin ęrenme teknikleri iin kullanılan bařka bir terimdir; YSA'nın yapısı, gerek nronların bilgi aktarmak iin birbirleriyle iletiřim kurma řeklinden esinlenmiřtir (Saha vd., 2023). YSA, girdi, gizli ve ıktı katmanları olarak adlandırılan katmanlardan oluřur ve her katman, sinyalleri iřleyen ve bir sonrakine aktaran aęın yapı tařları olan dęmler (nronlar) adı verilen iřlem elemanlarını ierir (Mohseni-Dargah vd., 2022). Her bir aę, ister basit ister karmařık olsun, 6 ana bileřenden oluřur: girdiler, aęırlıklar, bias, toplama fonksiyonu, aktivasyon fonksiyonu ve ıktılar. Girdiler, dıř duyu sisteminden veya nceki nronlardan gelen bilgileri temsil eder. Aęırlıklar ve nyargılar, aęın davranıřını temsil eden katmanların ayarlanabilir parametreleridir ve bu parametreler belirli bir hedefi gerekleřtirmek iin sıralı ve denetimli bir řekilde bir ęrenme veya eęitim algoritması kullanılarak ayarlanabilir. Aęırlıklar dęme girmeden nce gelen verileri zayıflatabilen veya glendirebilen anahtarlar olarak aıklanabilir. Farklı girdi deęerleri sinaptik aęırlıklarla arpılır, daha sonra toplama fonksiyonu olarak adlandırılan fonksiyonu oluřturmak iin toplanır ve son olarak toplama deęeri, nronun veya aęın ıktı deęerini elde etmek iin aktivasyon fonksiyonunda (genellikle doęrusal olmayan) deęerlendirilir (Montesinos Lpez vd., 2022). Gizli katmanlardaki en uygun nron sayısı grevin karmařıklıęına baęlıdır ve deneme yanılma yoluyla elde edilebilir (Oloko-Oba vd., 2018). Bir Yapay Sinir Aęındaki (YSA) gizli nron sayısını artırmak, genellikle ęrenme performansını belirli bir noktaya kadar artırabilir. Ancak, ok fazla nron kullanılması, YSA'nın eęitim

verilerinde iyi performans gösterdiği ancak test verilerinde kötü performans gösterdiği aşırı uyuma yol açabilir. Bunun nedeni, nöron sayısı arttıkça modelin çok karmaşık hale gelmesidir. Tersine, çok az nöron kullanmak YSA'nın mekanizmayı doğru bir şekilde modelleme yeteneğini sınırlayabilir ve aşırı genellemeye yol açabilir (Andrade Cruz vd., 2022). Dğümler arasındaki bağlantı iki türe ayrılabilir: ileri beslemeli ağlar ve tekrarlayan ağlar. İleri beslemeli ağlarda çıktılar girdilere herhangi bir geri bildirim vermezken, girdiler ve çıktılar arasında geri bildirim olduğunda, ağ tekrarlayan sinir ağı olarak adlandırılır (Cheng & Zhao, 2019). YSA'daki öğrenme yeteneği, öğrenme yoluyla performansı arttığı için onu diğer geleneksel tekniklerden ayırır (SAZLI, 2006). YSA'nın eğitimi, ağırlıkların istenen çıktıya ulaşmak için ayarlandığı öğrenme süreci kullanılarak yapılır ve ağ oluşturulduktan sonra gerçekleştirilir, öğrenme süreci iki yaklaşımla sınıflandırılabilir: denetimli ve denetimsiz öğrenme (Alaloul & Qureshi, 2020). Ayrıca, YSA'da gradyan inişi, esnek geri yayılım, quasi-newton, eşlenik gradyan ve levenberg-marquardt olmak üzere beş grup eğitim algoritması kullanılabilir (Cömert & Kocamaz, 2017). Eğitim süreci sırasında veri kümesi üç gruba ayrılır: eğitim verileri, doğrulama verileri ve test verileri. Ağırlıklar, tüm verilerin çoğunluğunu oluşturan eğitim verileri kullanılarak değiştirilir. Modelin performansı hem doğrulama hem de test setleri kullanılarak değerlendirilir; doğrulama eğitim süreci sırasında, test ise modelin başarılı bir şekilde geliştirilmesinden sonra kullanılır (Mendes vd., 2015). Özetle, YSA girdileri alan ve çıktıları döndüren matematiksel bir işlemdir, parametreleri ölçülen verilere uydurmayı ve en iyi modeli seçmeyi kapsar. YSA'yı oluşturmak için üç ana şey gereklidir: geçmiş veriler, katmanların mimarisi ve en iyi eğitim algoritmasının seçilmesi.

2.2 Destek Vektör Makinesi (DVM)

DVM, sınıflandırma ve regresyon problemlerinde kullanılan güçlü bir denetimli makine öğrenimi tekniğidir (Kazemi vd., 2021). Karmaşık problemleri küçük veri kümeleriyle çözmek için özel bir özelliği vardır (Thakur & Ghosh, 2023). DVM, olası hiper düzlemler arasındaki maksimum marjı tahmin ederek çok boyutlu bir uzayda iki kategoriye ayıran en iyi hiper düzlemi bulmaya dayanır ve bu aynı zamanda verilen gruplar arasındaki maksimum mesafe anlamına gelir (Pink, 2016). Kernel, DVM algoritmaları tarafından kullanılan bir dizi matematiksel fonksiyondur. Amacı, girdi verilerini gerekli forma dönüştürmektir (Cristianini & Scholkopf, 2002). Radyal temel fonksiyonu, üstel radyal temel fonksiyonu, çok katmanlı perceptron

çekirdek fonksiyonu ve polinom kernel fonksiyonu dahil olmak üzere farklı DVM algoritmaları tarafından sıklıkla kullanılan çeşitli kernel fonksiyonları vardır (Liu & Lei, 2018). Optimum veri ayrımı için çekirdek fonksiyonları kullanmanın yanı sıra DVM, YSA'da kullanılan ampirik risk minimizasyonunun aksine yapısal risk minimizasyonu yoluyla aşırı uyumu önler (Guo vd., 2021).

2.3 Karar Ağacı

Denetimli öğrenmedeki en önemli algoritmalarından biri Karar Ağacıdır. İki tür ağaç mevcuttur: Regresyon Ağaçları ve Sınıflandırma Ağaçları. Bu iki ağaç türü, sırasıyla sürekli ve kategorik değişkenleri sınıflandırmaktan sorumludur (Y. Lu vd., 2022). Karar Ağacı, bir veri kümesini farklı alt gruplara veya düğümlere bölmek için ağaç benzeri bir akış şeması yapısı kullanan bir veri madenciliği yöntemidir (Yu vd., 2010). Karar ağacının akış şeması yapısı üç tür düğümden oluşur: kök, ara ve yaprak (Kim vd., 2001). Kök düğüm, hedef değişkenin tahmin edilmesinde kritik öneme sahiptir ve tüm kayıtları iki veya daha fazla alt gruba ayırır (Deepnarain vd., 2019). Ara düğüm, her bir bağımsız değişken için bir koşulu veya ikili bölme testini gösterir. Üst kenarı aracılığıyla bir üst düğüme ve alt kenarı aracılığıyla alt veya yaprak düğümlere bağlanır (Kim vd., 2001). Bir karar kombinasyonunun sonucu, bir karar ağacındaki yaprak düğümü ile temsil edilir. Yaprak düğümü, sınıflandırma ağaçları için kategorik sonuçları temsil ederken, regresyon ağaçları için sayısal sonuçlar temsil edilir. Oysa karar ağaçlarında hem kök hem de iç düğümlerden çıkan dallar mevcuttur. Bir dizi eğer-o zaman kuralı, karar ağaçları tarafından belirli bir popülasyonu kategorize etmek, genelleştirmek ve yeterince tahmin etmek için kullanılır. Bir veri kümesinde tanımlanmamış gözlemler olması durumunda, karar ağaçları kayıtları bağımsız dallar halinde sınıflandırır ve böylece araştırmada tüm veri kümesini kullanır. Karar ağaçları, büyük veri kümelerinin hem doğrusal hem de doğrusal olmayan ilişkilerini yorumlanması kolay görselleştirmelerle gösterebilir ve bu nedenle hem sürekli hem de kategorik hedef değişkenlerin tahmin doğruluğunu artırma eğilimindedir (Deepnarain vd., 2019).

2.4 Bulanık Çıkarım Sistemi (BÇS)

Bulanık çıkarım, bir ifadenin doğruluğunun doğru veya yanlış yerine kesinlik derecesi olarak ifade edildiği anlamına gelen bulanık mantık yaklaşımını kullanarak çıktılara değer

belirtmek için girdilerin değerlerinin bir dizi kurala göre yorumlandığı bir tekniktir (Kalogirou, 2014). Bulanık mantık, dilbilimsel dil ile muhakeme hesaplama sistemi arasında bağlantı kurarak bulanık kavramları anlaşılabilir bir biçime dönüştürür (Ramadan & Abou El-Ez, 2000). BÇS'in beş ana bloğu vardır: kural tabanı, veri tabanı, karar verme birimi, durulaştırma arayüzü ve bulanıklaştırma arayüzü (Tahmasebi & Hezarkhani, 2012). Sistemin giriş ve çıkış bulanık değişkenleri, bulanık kümeleri ve üyelik fonksiyonlarını oluşturmak için dilsel değerler kullanılarak tanımlanır. Bu, bilgi tabanı sistemlerinin yaklaşık muhakeme yapmasını sağlar (Jaafar vd., 2016) (Sadoughi & Arani, 2022). Bu sırada, giriş verilerinin ilgili bulanık kümelere ne ölçüde ait olduğunun belirlenmesi, bulanıklaştırma arayüz birimi işlemi sırasında üyelik fonksiyonları aracılığıyla gerçekleştirilir (Xu, 2010). Durulaştırma, birleştirilmiş bulanık kümenin sonucundan tek bir sayısal değer elde etmeyi içeren süreçtir. Bu adım, bulanık çıkarım sonuçlarını net bir çıktıya dönüştürmek için gereklidir. Esasen bulanıklaştırma, bulanık kümeden en uygun gevrek değeri seçen bir karar verme algoritması tarafından gerçekleştirilir (Fuchs & Masoum, 2023).

2.5 Temel Bileşen Analizi (TBA)

TBA, uyarlanabilir bir veri analizidir ve büyük veri kümelerinin karmaşıklığını anlaşılması kolay bir şekilde azaltmak için yaygın olarak kullanılan bir tekniktir, verilerin önemli bilgilerinin çoğunun korunmasını sağlar (Jolliffe & Cadima, 2016). Bu, orijinal değişkenlerin doğrusal olarak yeni kolektif değişkenlere dönüştürülmesiyle elde edilir ve veri kümesinin özelliklerine az sayıda "temel bileşen" hakimdir. TBA, denetimsiz bir makine öğrenimi tekniği olarak sınıflandırılır (Kitao, 2022). TBA, eksiksiz bir veri kümesinin doğrusal olarak ilişkisiz niteliklerden oluşan yeni bir uzaya dönüştürülmesine olanak tanır. Bu dönüşüm ortogonal dönüşüm yoluyla elde edilir. YBA işlemi, en yüksek özdeğere sahip özvektörün veri kümesi hakkında mümkün olan maksimum bilgiyi veya varyansı yakaladığı bir korelasyon matrisinin özdeğer ayrıştırmasını içerir. En bilgilendirici özvektörler veya temel bileşenler daha sonra bir alt küme olarak seçilir. Bu alt küme kullanılarak orijinal veri kümesi, her veri örneğinin daha küçük bir özellik vektörü ile temsil edildiği daha düşük boyutlu bir uzaya dönüştürülür (Dinç vd., 2014).

2.6 Optimizasyon Algoritmaları

Deterministik ve stokastik modeller, süreç modellemesinin iki ana kategorisidir. Bu kategorilerin her ikisi de kararlı durum ve dinamik modelleme olarak alt bölümlere ayrılabilir (Ramachandran vd., 2019). Matematiksel modelleme tabanlı algoritmaların çoğu deterministiktir, yani çok esnek olmayan belirli prosedürleri takip ederler. Bu tür algoritmalara örnek olarak gradyan tabanlı algoritmalar, doğrusal programlama ve dinamik programlama verilebilir (Siddique & Adeli, 2015). Bununla birlikte, bu algoritmalar fonksiyonlara ve türevlere dayanır ve tekdüze olmayan veya süreksiz problemleri etkili bir şekilde ele alma yetenekleri sınırlıdır. Buna karşılık, stokastik veya deterministik olmayan modeller, farklılaştırılabilir amaç fonksiyonları gerektirmeden birden fazla çözüm keşfetmelerini sağlayan doğal bir rastgelelik unsuruna sahiptir. Bu modeller, problemin birden fazla alanını aynı anda arayabildikleri için gerçek dünya problemlerini çözmeye çok uygundur (Ramachandran vd., 2019). Belirli hedefleri karşılamak için özelleştirilmiş, adım adım bir şekilde hesaplamalar veya yönergeler sunan yinelemeli prosedürlere optimizasyon problemleri için algoritmalar denir. Optimizasyon; performans, verimlilik ve kârın maksimize edilmesi ya da enerji tüketimi ve maliyetlerin minimize edilmesi gibi farklı alanlara uygulanabilir. Ancak, sınırlı zaman ve kaynaklarla karşı karşıya kalındığında, akıllı teknikler gereklidir. Anaerobik çürütme gibi doğrusal olmayan karmaşık sistemlerin üstesinden gelmek için bilgisayar simülasyonu önemli bir araç haline gelir (Ramachandran vd., 2019). Stokastik optimizasyon yaklaşımı sezgisel ve metasezgisel yöntemler olarak kategorize edilebilir (Nikolic, 2015). Deneme-yanılma süreci, sezgisel yöntemlerin çözüm bulmak için kullandığı yaklaşımdır. Gerçek dünya problemlerine olası her çözümü aramak, karmaşıklıkları nedeniyle çok zordur. Ancak, bu problemler için uygulanabilir ve kaliteli çözümler bulmak önemlidir. Sezgisel yöntemler en uygun çözümleri hızlı bir şekilde bulabilirken, birincil dezavantajı belirlenen çözümün en uygun çözüm olmayabilmesidir. Yapay sinir ağları sezgisel yöntemler kategorisine girer çünkü öğrenme ve tahmin hatalarını en aza indirmek için deneme yanılma yöntemini kullanırlar (Ramachandran vd., 2019). Metasezgisel ise ikinci nesil bir optimizasyon tekniğidir ve karmaşık problemlerin çözümü için uygundur. Doğal fenomenler, hem spesifik hem de rastgele olan metasezgisel kurallara ilham verir. Bu kurallar, arama ajanlarına arama alanını keşfetmelerinde yardımcı olur (Yang, 2012). Metasezgisel algoritmalar büyük ve karmaşık arama uzaylarını idare edebilir ve en iyi çözümü aramak için tasarlanmıştır. Bununla birlikte, ana sınırlamalarından biri, her zaman küresel optimumu

bulamayabilmeleridir. Algoritmanın rastgele doğası nedeniyle, en iyi çözümün bulunacağına garantisizdir (M. Almufti vd., 2023). Genetik algoritma, parçacık sürüsü optimizasyon algoritması, benzetimli tavlama ve değişken komşuluk araması metasezgisellerin ünlü örnekleridir (Rajwar vd., 2023).

2.6.1 Genetik algoritma (GA)

Genetik algoritma evrimsel algoritmalarından biridir, biyolojide bulunan doğal seçim ve evrim sürecini taklit eder. Algoritma, kromozom popülasyonu, uygunluk fonksiyonu ve kromozom operatörleri veya seçim, mutasyon ve çaprazlama gibi genetik operatörler dahil olmak üzere çeşitli bileşenlerden oluşur (Carr, 2014). Bir problem, genetik algoritmanın başlangıcında uygulanabilir bir çözüm kümesi ile temsil edilir. Popülasyon, genetik olarak kodlanmış belirli sayıda bireyden oluşur (FuRui vd., 2019). Kromozom terimi, ikili formatta bir diziden oluşan her bir çözümü temsil eder ve kromozomun her bir konumu (lokus), çözümün bir elemanını gösteren bir gen olarak adlandırılır. Bu genler genetik operatörler tarafından iteratif olarak değiştirilir. Amaç fonksiyonu veya uygunluk fonksiyonu, popülasyondaki kromozom değerlerini seçer ve en iyi çözümü tanımlar (Katoch vd., 2021), (Ramachandran vd., 2019). Problem genetik olarak kodlandıktan ve iyi çözümleri seçmek için uygunluk fonksiyonu ayarlandıktan sonra, birincil popülasyon ilk adım olarak rastgele seçilir ve önerilen çözümün uygunluk değerleri değerlendirilir, ardından süreç çapraz kombinasyon ve mutasyon için genetik operatörlerin kullanılmasını ve daha optimal çözümlere doğru kademeli olarak evrimleşmek için evrimsel alt prensibin uygulanmasını içerir. Nihayetinde, probleme en uygun çözüm, son nesil popülasyondan en iyi bireylerin kodunun çözülmesiyle belirlenebilir (FuRui vd., 2019).

2.6.2 Parçacık sürüsü optimizasyon algoritması (PSO)

Kuşların sürü oluşturması ve balıkların okullaşması gözlemleri PSO algoritmasının geliştirilmesine ilham vermiştir. Doğada bir grup kuş, yiyeceğe en yakın olan bir lideri takip eder. Kuşların bu davranışı, optimizasyon problemlerini ele almak için PSO'da olduğu gibi algoritmik bir sürece dönüştürülmüştür. PSO'da parçacık sürüsü doğadaki bir grup kuşu temsil eder ve her parçacık olası bir çözüme karşılık gelir (Qin, 2012). Bireysel ajanların (parçacıkların) yörüngesi, bir amaç fonksiyonunun uzayını aramak için PSO algoritması tarafından ayarlanır. Bir sürü parçacığının hareketi, bir stokastik bileşen ve bir deterministik bileşen olmak üzere iki

önemli bileşenden oluşur. Her parçacık mevcut küresel en iyi konuma ve kendi tarihsel en iyi konumuna doğru çekilirken aynı zamanda rastgele hareket etme eğilimindedir. Bir parçacık önceki konumlardan daha iyi bir nokta keşfederse, bu konumu yeni en iyi konum olarak belirleyecektir. Amaç, hedefte daha fazla gelişme olmayana kadar veya belirli sayıda iterasyondan sonra mevcut en iyi çözümler arasından küresel en iyiyi keşfetmektir (Yang, 2014).

3. AAT'DE ANAEROBİK ÇÜRÜTMEDE YAPAY ZEKA MODELLERİNİN UYGULAMALARI

3.1 Anaerobik Çürütmenin Proses Kararlılığının İzlenmesi Ve Biyogaz Veriminin Optimizasyonu

AÇ süreci oldukça karmaşıktır ve maksimum biyogaz veriminin elde edilmesi önemli ölçüde sürecin kararlılığıyla ilgilidir (Kasinath vd., 2021). Bu kararlılık, hammadde bileşimlerindeki değişimler, pH ve sıcaklıktaki dalgalanmalar gibi çeşitli nedenlerle kesintiye uğrayabilir; bu sonucunu mikrobiyal topluluğun faaliyetini ve biyolojik bozunma oranını etkiler (Yildirim & Ozkaya, 2023). AAT'lerdeki birçok AÇ reaktörünün kapatıldığı ve yapılan ankete göre proses karmaşıklığı, verimsiz yönetim, düşük biyogaz üretimi ve elektriğin ana nedenler olduğu bildirilmiştir (Deng vd., 2017a). Bu operasyonel sorunlar büyük ölçekli tesislerde ekonomik verimliliği azaltmaktadır, bu nedenle AÇ parametrelerini kontrol etmek ve uzun vadeli çalışmayı sağlamak istikrar ve verimliliği korumak için çok önemlidir. Yapay zeka tabanlı modeller, AÇ'nin sorunlarını çözebilir ve yerinde operasyonel kontrol sırasında sistemin performansını artırmak için yöntemler sağlayabilir (Yildirim & Ozkaya, 2023). Ayrıca, yapay zeka modelleri teori temelli modellerin zorluklarının üstesinden gelebilir ve sorunlu ve doğrusal olmayan biyoenerji sistemlerini tahmin edebilir (Z. Wang vd., 2022). Cheon ve arkadaşları, biyo-elektrokimyasal AÇ'nin performansını operasyonel parametreleri ve doğrusal olmayan ilişkileri ile tahmin ederek proses stabilitesini artırmak için beş yapay zeka modeli geliştirmiştir. Yazarlar, reaktörün metan verimini tahmin etmek için rastgele orman (RF), aşırı gradyan artırma (XGboost), destek vektör regresyonu (SVR), uzun kısa süreli bellek (LSTM) ve tekrarlayan sinir ağı (RNN) modellerine girdi parametreleri olarak pH, KOİ giderme verimliliği ve alkaliniteyi seçmiştir. Bulgular, RF ve SVR modellerinin kesin tahminler ürettiğini göstermiştir. Ayrıca çalışma, pH parametresinin stabilitenin izlenmesinde diğer parametrelere kıyasla daha etkili olduğunu göstermiştir (Cheon vd., 2022). Bir başka çalışmada, Sakiewicz ve arkadaşları AAT'de

teknolojik proses parametrelerinin biyogaz üretimi üzerindeki etkisini araştırmak için farklı yapılarda yapay sinir ağları geliştirmiş, YSA modelleri üç yıllık gerçek verileri işlemiş ve yazarlar atık su giriş hızı, devridaim çamur akışı, ham çamur akışı ve fermantasyon odasına konsantre çamur akışı, devridaim için temiz su akışı, yoğunlaştırıcıya yavaş çamur akışı ve filtre prese çamur akışı dahil olmak üzere tesis işletimi ile ilgili yedi parametreyi analiz etmişlerdir. Biyolojik oksijen ihtiyacı (BOİ), kimyasal oksijen ihtiyacı (KOİ), azot ve fosfor konsantrasyonları ve toplam askıda katı madde olmak üzere beş atık su parametresi de modele dahil edilmiştir. Ayrıca, modeli eğitmek için geri yayılım hatası ve eşlenik gradyan gibi birçok öğrenme algoritması kullanılmıştır. Sonuçlar, modellerin işletme parametrelerinin sistem performansı üzerindeki etkisini tahmin ettiğini ve optimizasyon için bir referans sağlayabileceğini göstermiştir (Sakiewicz vd., 2020). Operasyonel parametreler izlenebilir ve aynı zamanda yapay zeka algoritmaları kullanılarak verimlilik tahmin edilebilir, bu da biyogaz endüstrisi için daha düşük işletme maliyetleri ve daha fazla ekonomik sürdürülebilirlik sağlar. Sistem, potansiyel sorunları hızlı bir şekilde tespit edilerek proaktif önlemlerin alınmasına ve sorunların ortaya çıkmasının önlenmesine olanak tanıyabilir (Heo vd., 2021; Olakanmi vd., 2021) Üstelik Bao ve arkadaşları, metan gazı üretimini ve verimliliğini artırmak amacıyla anaerobik çamur çürütmede organik yükleme oranını ve hidrolik alıkonma süresini optimize etmek için bir yapay sinir ağı (YSA) modeli geliştirdikleri bir çalışma yürütmüştür. Veri kaynakları normalize edilmiş ve en iyi sonuçları elde etmek için pearson korelasyon analizi, çoklu regresyon analizi ve YSA kullanılarak analiz edilmiştir. Çalışmaya göre, YSA modeli OLR 1,26-1,46 kg/m³ gün ve HRT 26-30 gün arasında olduğunda çürütme verimliliğinde %0,5 ve gaz üretiminde %1,3 artış öngörmüştür. Bu durum, kurulan YSA modelinin uygulanabilir olduğunu ve çamur anaerobik çürütme verimliliğini ve gaz üretimini arttırmak için kullanılabileceğini göstermektedir (Bao vd., 2023).

3.2 Mikrobiyal Topluluğun Aktivitesinin Artırılması

Atık suyun biyolojik arıtımı, özellikle aktif çamur ve anaerobik çürütme gibi süreçlerde büyük ölçüde mikroorganizmalara dayanır. Mikrobiyomun aktivitesi ve kararlılığı, bu süreçlerin performansını ve sürdürülebilirliğini belirleyen çok önemli faktörlerdir. Mikrobiyomda bulunan farklı mikrop türleri, işlevleri ve aralarındaki etkileşimler gibi yüksek düzeyde karmaşıklık

nedeniyle, AÇ ve diğer biyolojik arıtma süreçlerinin performansını doğru bir şekilde düzenlemek ve tahmin etmek oldukça zor hale gelmektedir (Cai vd., 2021). AÇ'de mikrobiyal yönetim için üç yaklaşım kullanılabilir: geriye dönük yönetim, ileriye dönük yönetim ve proaktif yönetim (Carballa vd., 2015). Tüm olası aksaklıkları belirlemek, değerlendirmek ve süreç başarısızlığını önlemek için yaklaşımlar geliştirmek proaktif yönetimin özüdür. Sonuç olarak, mikrobiyomun proaktif yönetimi, süreç başarısızlığını önlemede ve sistem performansının istikrarını sürdürmede önemli bir potansiyele sahiptir (Stenuit & Agathos, 2015). Mikrobiyomları etkili bir şekilde yönetmek için erken yanıt veren mikrobiyal göstergeler gereklidir. Bu tür göstergeler, herhangi bir makroskopik performans sorunu ortaya çıkmadan önce mikrobiyal topluluklardaki değişiklikleri vurgulayarak sistem istikrarını sağlayabilir. Bu yönetim yaklaşımının geliştirilmesindeki en büyük zorluk, rutin mikrobiyom analizi ve sistem performansının izlenmesi için gereken kapsamlı deneysel çalışmadır. DNA dizileme verilerini anlamlı mikrobiyal örüntülere ve mikrobiyal ilişkili veri kümelerine dönüştürmek mümkün olsa da, mikrobiyom dinamikleri ve sistem işlevi sağlamlığı arasındaki ilişki hakkında deneylerden elde edilen bilgiler sınırlıdır (Cai vd., 2021). Yapay zeka modellerinin kullanımı, mikrobiyom sistemlerinin proaktif yönetimini kolaylaştırma potansiyeline sahiptir. Bu, mikrobiyom dinamiklerini ve operasyonel parametreleri girdi veri kümeleri olarak kullanarak çevresel stresin neden olduğu sistem performansındaki dalgalanmaları tahmin ederek elde edilir. Ayrıca, mikrobiyomlar ve performans dalgalanmaları arasındaki göreceli katsayıyı analiz ederek mikrobiyal göstergelerin erken işaretlerini belirlemek için yapay zeka modelleri kullanılabilir. Sistem işlevini doğrudan mikrobiyom yapılarından tahmin etmek için çeşitli algoritmalar geliştirilmiştir. Örneğin, reaktör performansını pH bozukluğundan çıkarmak mümkündür (Stenuit & Agathos, 2015). YSA modellerinin kullanılması, mikrobiyom dinamikleri ile performans değişiklikleri arasında bir bağlantı kurulmasına yardımcı olabilir. Bu bağlantı, reaktör performansındaki dalgalanmalar konusunda uyarıda bulunabilecek mikrobiyal göstergelerin erken tespitine olanak sağladığından son derece faydalıdır. Ayrıca bu yaklaşım, uç durumlar belirleyerek normal çalışma kapsamının tanımlanmasına yardımcı olabilir. YSA modelleri kullanılarak, en hassas parametrelerin ve bilinmeyen mikrobiyal göstergelerin tersine tanımlanması da mümkündür (Cai vd., 2021). İstenen belirli bir sistem işlevini tersten gerçekleştirebilecek mikrobiyomlar oluşturmak için yapay zeka modellerini kullanmak mümkündür. Bu yetenek, belirli mühendislik hedeflerini yerine getirmek için mikrobiyom

çeşitliliğinin, göreceli bolluğun ve gerekli etkileşimlerin tasarlanmasına olanak sağlayacaktır (Lawson vd., 2019). Metabolik süreçlerin karmaşık doğası nedeniyle, bazı mikrobiyal türler farklı biyoreaktör türlerinin işleyişini etkileme yeteneğine sahiptir. Sonuç olarak, yapılarındaki makroskopik değişikliklerle ilişkili olarak çeşitli mikrobiyal toplulukları incelemek için makine öğrenimi tekniklerini kullanma yönünde bir baskı olmuştur (Mathur & Singh, 2022).

3.3 Arıza Tespiti

Anaerobik çürütücülerin belirli bekleme sürelerinde yüksek hacimli atık sular gibi ağır koşullar altında düzgün çalışmasını sağlamak çok önemlidir. Bu tür proseslerin işletilmesi insan sağlığı ve çevre açısından patlama, yangın ve diğer kirlilik riskleri de dahil olmak üzere çeşitli riskler oluşturmaktadır. Örneğin, AÇ içinde bulunan çamurun hızlı bir şekilde çevreye salınması mümkün değildir. AÇ'nin boşaltılması ve yeniden doldurulması işlemi uzun süreler alabilir ve bu sırada tesis her zamanki gibi çalışamaz. Ayrıca, biyolojik toplulukla ilgili sorunlar nedeniyle AÇ reaktörünün arızalanması durumunda, reaktörün boşaltılması ve taze bir inokulum ile yeniden doldurulması gerekir. Bunun nedeni, reaktörün önemli miktarda organik madde ve çevresel biyolojik tehlike oluşturabilecek patojenik bakteriler, parazitler, mantarlar ve virüsler gibi zararlı mikroorganizmalar içerebilmesidir. Bu nedenle, süreç güvenliğini uygulamak ve çevresel riskleri önlemek için gelecekte arızalara ve feci sonuçlara yol açabilecek anormal koşulları tespit etmek çok önemlidir (Kazemi vd., 2021; Ritari vd., 2012). Bir hata tespit sistemi, sürecin normal çalışma koşullarından herhangi bir sapmasını veya anormalliğini belirlemeyi amaçlar, hata tespit sistemleri üç kategoriye sahiptir: model tabanlı, bilgi tabanlı ve veri odaklı (Sánchez-Fernández vd., 2018). Bilgi tabanlı hata tespit sistemleri, sistemin davranış doğasından ve operatörlerin insan deneyiminden çıkarılan bilgi ve kuralları kullanan sezgisel teknikler uygular (Kazemi vd., 2021; Sánchez-Fernández vd., 2018). Steyer ve arkadaşları, şarap damıtma tesislerinden gelen atık suyun arıtılması için kullanılan akışkan yataklı bir reaktörde köpüklenme, atık suda ani değişiklikler, boru tıkanıklıkları veya zayıf sıcaklık kontrolü gibi arızaların belirlenmesi ve teşhis edilmesi için kullanılacak bulanık mantık ve YSA'yı birleştiren hibrit bir model geliştirmiştir. pH, sıcaklık, devridaim akış hızı, giriş akış hızı ve gaz akış hızı gibi çevrimiçi alınan ölçümler, bir dizi özellik oluşturmak için bulanık mantıkla önceden işlenmiştir. Özellik vektörleri daha sonra sürecin durumunu gösteren bulanık kurallara dayalı olarak kategoriler halinde belirlenerek

YSA sürecin koşullarını kategorize etmek ve hatalı olanları belirtmek için kullanılmıştır (Steyer vd., 1997). Ancak bu tekniğin etkinliği büyük ölçüde operatör ve mühendisin bu metodolojiye dahil edilen uzmanlığına bağlıdır. Ek olarak, bu tür verileri süreç kayıtlarından elde etmek ve çıkarmak çoğu zaman zorlu bir iştir ve özellikle doğrusal olmayan özelliklere sahip son derece karmaşık süreçler için bazen ulaşılamaz olabilir (Kazemi vd., 2021). Aksine, veriye dayalı yöntemler matematiksel modellemeye veya insan deneyimi müdahalesine ihtiyaç duymadan tamamen önceki veri kayıtlarına dayanır (Kazemi vd., 2020). Bu yaklaşımın kullanımı son yıllarda, özellikle pratik durumlarda model ve bilgi edinmeyi içeren karmaşık endüstriyel prosedürlerde popülerlik kazanmış ve dağıtılmış kontrol sistemlerinin yaygın olarak kullanılması nedeniyle önemli miktarda veri toplanmıştır (Sánchez-Fernández vd., 2018). Arıza tespiti amacıyla temel bileşen analizi ve kısmi en küçük kareler kullanılabilir (Bakdi & Kouadri, 2017; Qin, 2012).

4. KAYNAK ARAŞTIRMASI


Son zamanlarda dünya genelinde kurulu biyogaz tesislerinin sayısı artmaktadır. Ancak Deng ve arkadaşları karmaşık süreçler nedeniyle birkaç anaerobik arıtma tesisinin kapatılmasının gerektiğini, bunun da tesis kontrolünü zorlaştırdığını ve düşük biyogaz üretimine yol açtığını buldu (Deng vd., 2017). De Clercq ve arkadaşları büyük ölçekte gıda atıklarından biyogaz üreten bir arıtma tesisinin düşük verimli biyogaz üretimi ve parçalanma yoğunluğu yaşadığını ortaya koyan bir çalışma gerçekleştirdi. Çalışma bunu zayıf süreç kontrolüne bağladı (De Clercq vd., 2016). Bu tür operasyonel sorunlar, biyogaz tesislerinin verimliliğinin ve ekonomik sürdürülebilirliğinin azalmasına yol açabilmektedir. Bu sorunlar nedeniyle kapanmaları önlemek ve uzun süreli çalışmayı sağlamak için süreç kontrolündeki eksikliklerin anında giderilmesi büyük önem taşımaktadır (Yıldırım & Ozkaya, 2023). Güvenilir ve uyarlanabilir bir enerji tedariki sağlamak için izleme ve kontrol sistemlerinin uygulanması gerekmektedir. Süreci izleyerek biyogaz üretim sürecine ilişkin kapsamlı bir anlayış kazanmak mümkündür. Bu, anaerobik çürütücülerdeki potansiyel sorunların kritik hale gelmeden önce erken belirlenmesine olanak tanır ve tesisin başarılı bir şekilde başlatılmasına veya yeniden başlatılmasına katkıda bulunur. (Cinar vd., 2021). Anaerobik çürütme verimliliği, operasyonel parametreler, çürütücü ve sistem türleri gibi faktörlere ve pH, sıcaklık ve organik asitler gibi büyüme faktörlerine bağlıdır. Organik yükleme hızının ve hidrolik bekletme süresinin kontrolü, anaerobik sindirimin verimliliğini ve gaz üretimini artırabilir (Bao vd., 2023). Verimliliği ve verimi artırmak için biyogaz üretiminin çeşitli alanlarında YSA'nın uygulanması, akademik literatürde büyük ilgi görmüştür. Chen ve arkadaşları, palmiye yağı değirmeni atık suyunda AÇ'in bir süreç modellemesini geliştirdiler. Yazarlar, giriş parametreleri olarak pH, sıcaklık ve devridaim oranının kullanıldığı ve çıkış parametreleri olarak metan verimi ve H₂S konsantrasyonunun kullanıldığı YSA ve yanıt yüzeyi metodolojisi (RSM) modelini oluşturmak için iki yıllık endüstriyel ölçekli tesis verilerini kullandılar. Performans ölçümleri, YSA ve RSM için belirleme katsayısının (R²) ve kök ortalama kare hatasının (RMSE) sırasıyla 0,9762 ve 0,8500 olduğunu gösterdi; bu arada yazarlar, en yüksek metan verimini elde etmek için giriş parametrelerinin uygun koşullarını belirlediler (J. W. Chen vd., 2023). Ayrıca Mafalda, anaerobik çürütme sırasında gaz üretimini ve Kimyasal Oksijen İhtiyacı (KOİ) giderim oranlarını tahmin etmek için YSA tekniklerinin kullanılması üzerine bir çalışma yürüttü. Çalışmada altı parametre kullanıldı. Modeli eğitmek ve doğrulamak için yazar, ilk verileri standartlaştırdı ve YSA ve Geri Yayılım

Sinir Ağı tekniklerini kullandı. Araştırmanın bulguları, anaerobik çürütme prosesinde gaz üretimi ve KOİ giderim oranlarının tahmin edilmesinde YSA yönteminin etkili olduğunu göstermiştir. Bu nedenle YSA, AÇ sırasında anahtar parametrelerin tahmin edilmesinde yararlı bir araç olarak düşünülebilir (Mafalda & Fernandes, 2014). Bu sırada P. Sakiewicz ve arkadaşları biyogaz-atık su arıtma sisteminin çalışmasını simüle etmek için yenilikçi bir yapay sinir ağı yöntemi önerdi. Yöntem, sistemin çıktısı ile sistemin çalışma parametreleri arasındaki ilişkiyi tahmin etmektedir. Sonuçlar, modelin işletim parametrelerinin sistem performansı üzerindeki etkisini tahmin edebildiğini ve sistem optimizasyonu için bir referans sağlayabildiğini göstermektedir. Ancak yazar, diğer modelleme yöntemleri ile YSA arasında karşılaştırmalı bir analiz yapmamış ve modelin uygulama kapsamını ve kararlılığını tam olarak tartışmamıştır (Sakiewicz vd., 2020). Yuchen Wu ve arkadaşları geri yayımlı bir sinir ağı kurarak anaerobik sindirimi optimize edecek bir model oluşturmak için bir genetik algoritma kullandı. Model, farklı sıcaklıklarda gaz üretimini tahmin etmek için kullanılabilir. Sonuçlar, modelin gerçek verilerle iyi bir uyum derecesine sahip olduğunu önemli pratik uygulama değerine sahip olduğunu göstermektedir. Ancak yazar, modelin pratik uygulamalardaki doğruluğunu etkileyecek kapsam ve sınırlamaları tam olarak tartışmamıştır (Wu vd., 2022). Mevcut literatüre göre, özellikle atık su arıtma tesisleri alanında biyogazdan H₂S'nin azaltılmasında yapay zekanın uygulanmasına ilişkin çalışma eksikliği bulunmaktadır. Strike ve arkadaşları yakıt hücrelerini daha güvenli ve daha verimli hale getirmek için yakıt hücrelerine uygulanacak, amonyak ve hidrojen sülfid dahil olmak üzere AÇ sürecinden biyogazda bulunan toksik eser bileşiklerin üretimini tahmin etmek, azaltmak, kontrol etmek, optimize etmek ve hatta önlemek için modeller geliştirdi (Strik vd., 2005). Zari ve arkadaşları sabit yataklı bir biyofiltrede hidrojen sülfid uzaklaştırılma verimliliğini tahmin etmek için bir model gerçekleştirdi. Model, deneysel verilere bağımlılığı azaltmak için Çoklu Doğrusal Regresyon ve Destek Vektör Makinesi gibi hem istatistiksel hem de akıllı tekniklerden yararlandı. Önerilen modeller, 0,98 ile 0,99 arasında değişen bir belirleme katsayısı ile H₂S giderme verimliliğini tahmin etme konusunda olağanüstü bir yetenek sergilemektedir ve Destek Vektör Makinesi, Çoklu Doğrusal Regresyon modeline kıyasla verilerle daha iyi bir uyum göstermektedir (Zarei vd., 2023).

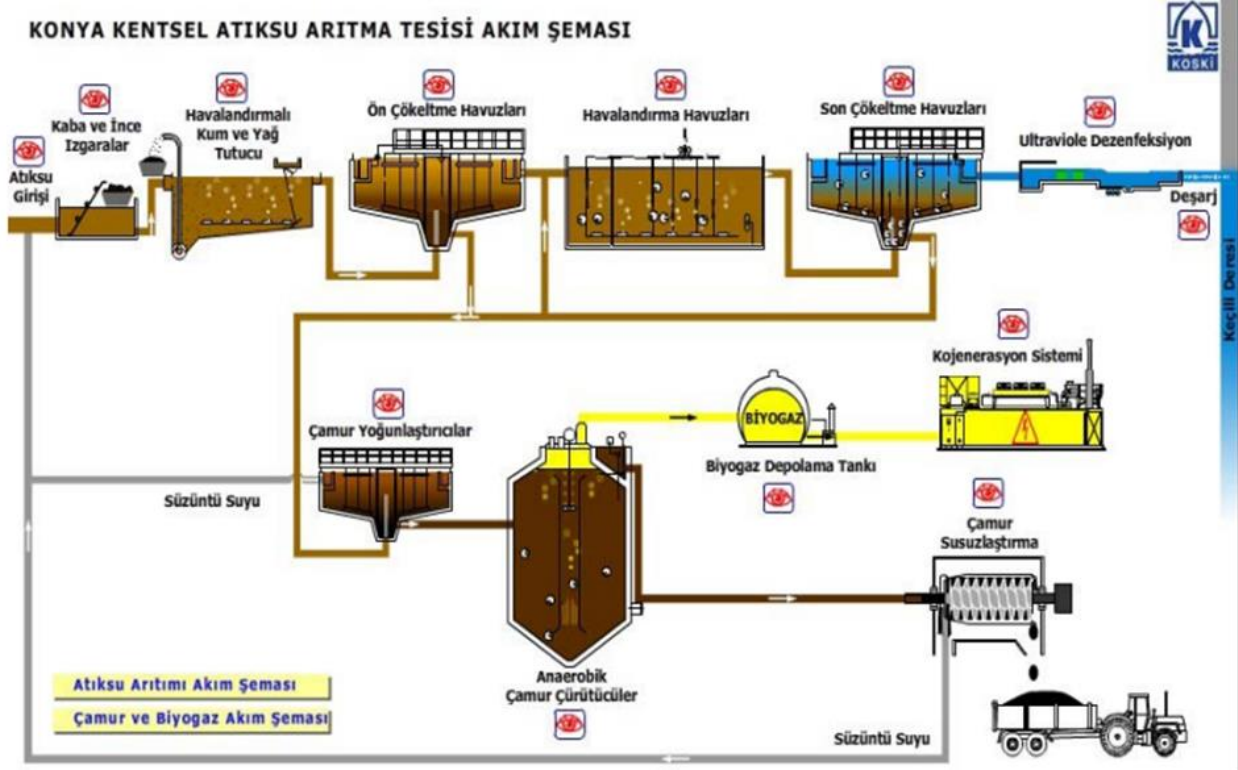
5. MATERYAL VE METODLAR

5.1 Çalışma Tesisi

Yapay sinir ağı modeli, Türkiye'nin Konya ilindeki Konya Atıksu Arıtma Tesisi'nden (KAAT) elde edilen verileri kullanmaktadır. Tesis, günde 200.000 m³ atık su arıtmak ve 1.000.000 eşdeğer nüfusa hizmet vermek üzere 2010 yılında kurulmuştur. KAAT ızgaraların ve kum tutucuların ön arıtmasını, 4 ön çökeltme havuzları, 8 havalandırma tankı, 8 son çökeltme havuzları bir UV dezenfeksiyon ünitesi, 4 çamur yoğunlaştırma ünitesi, 4 anaerobik çürütücü, 2 biyogaz deposu, bir kükürt giderme ünitesi, 3 gaz motoru, 1 çamur karıştırma tankı ve 4 çamur susuzlaştırma ünitesi içermektedir. KAAT'nin 2 boyutlu üstten görünüm şeması Şekil 5.1'de gösterilmektedir. Ön çökeltme havuzlarından gelen stabil olmayan çamur ve son çökeltme havuzlarından gelen kısmen stabil çamur, anaerobik çürütücülere girmeden önce çamurun ön işlemi olarak çamur yoğunlaştırma ünitelerine gönderilir. Her bir çürütücü 7.000 m³ hacme sahiptir ve çamur çürütücülerde katı bekletme süresi (SRT) olarak yaklaşık 20 gün kalır. Üretilen biyogaz, her biri 4.000 m³ hacme sahip gaz tutucularda depolanmakta, daha sonra biyogaz hem ısı hem de güç üretmek için gaz motorlarında yakılmadan önce kükürt giderme ünitesinde H₂S'den arındırılmaktadır. KAAT süreç akış diyagramı Şekil 5.2'de gösterilmektedir.



Şekil 5.1. Konya Atıksu Arıtma tesisinin 2 boyutlu üstten görünüm şeması.



Şekil 5.2. Konya Kentsel Atıksu Arıtma Tesisi akım şeması.

5.2 Veri Toplama

Gerçek veriler, çamur yoğunlaştırma ünitesi ve dört anaerobik çürütücünün her bir özelliği için toplam 731 veri ile günlük olarak art arda iki yıl boyunca KAAT'den alınmıştır. Çamur yoğunlaştırma ünitesi için veri seti şu parametreleri içerir: yoğunlaştırılmış çamurun pH'ı, yoğunlaştırılmış çamurun sıcaklığı, yoğunlaştırılmış çamurun uçucu katıları ve yoğunlaştırılmış çamurun toplam katıları. Aynı zamanda, her çürütücünün çamur akış hızı, çürütücünün pH'ı, çürütücünün sıcaklığı, toplam katılar, uçucu katılar, uçucu yağ asitleri, çürütücünün kalsiyum karbonat (CaCO_3) alkalinitesi ve çıkış metan verimi ve biyogazın hidrojen sülfid konsantrasyonu parametrelerini içeren parametreleri vardır. Çizelge 5.1.hem çamur yoğunlaştırma hem de anaerobik çürütücü üniteleri için seçilen parametreleri göstermektedir.

Çizelge 5.1. Çamur yoğunlaştırma ve anaerobik çürütücü üniteleri için seçilen parametreleri.

Çamur yoğunlaştırma ünitesinin parametreleri	Çamur çürütücü ünitesinin parametreleri
Çamurun pH'ı	Çamur akış hızı
Çamurun sıcaklığı	Çürütücünün pH'I
Çamurun uçucu katıları	Çürütücünün sıcaklığı
Çamurun toplam katıları	Toplam katılar
	Uçucu katılar
	Uçucu yağ asitleri
	CaCO ₃ alkalinitesi
	Çıkış metan verimi
	Biyogazın hidrojen sülfid konsantrasyonu

5.3 Veri Ön İşleme

Bu adımda, girdi ve çıktı parametreleri belirlenmiştir. Metan verimi ve H₂S konsantrasyonu hariç daha önce bahsedilen tüm parametreler girdi parametreleri olarak seçilirken, sonuncular çıktı parametreleridir. Verilerin modelleme için hazırlanması, kayıp veri tahmini, veri görselleştirme ve veri normalleştirme gibi çeşitli aşamaları içerir. Veri ön işleme, bilgisayarın verileri anlamasına yardımcı olur. Kayıp veri tahmini süreci sırasında, iki yıl boyunca seçilen parametreler için çok sayıda eksik değer olduğu keşfedilmiştir. Bu boşluklar hafta sonları, tatiller, arızalar ve bakımdan kaynaklanmaktadır. Veri eksikliği, araştırmanın istatistiksel gücünün azalmasına neden olabilir ve yanlış tahminler yapılmasına yol açabilir (Kang, 2013). Kayıp verilerle başa çıkmak için iki yaygın teknik vardır. Bunlardan ilki, analiz için gerekli değişkenlerden herhangi birinde bir veya daha fazla eksik değeri olan değerlerin çıkarılmasını içerir. Ancak bu, önemli ölçüde veri kaybına neden olarak sonuçları saptırabilir. İkincisi, kayıp değerler, kayıp verinin arkasındaki mekanizmayı en iyi şekilde temsil ettiğine inanılan tek bir değerle değiştirilmesini içerir (Papageorgiou vd., 2018). Eksik değerlerin yüzdesi %40'a ulaştı, bu sorunu gidermek için, parametrelerin son 7 veri noktası alınarak hareketli medyan tekniği kullanılarak her parametre için eksik veriler tahmin edildi. Ayrıca, parametrelerin değerlerinin farklı ölçekleri nedeniyle, değişkenler Denklem (1)'de gösterildiği gibi max-min normalizasyonu kullanılarak [0,1] aralığı arasında standartlaştırılmıştır. Normalizasyon, ağın performansını etkilediği ve aynı zamanda hesaplamaları hızlandırdığı için YSA'nın iyi sonuçlar elde etmesi için de çok önemlidir (Sola & Sevilla, 1997).

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Burada x' belirli bir parametre için veri kümesindeki her bir değerin normalleştirilmiş değeridir, x_{min} ve x_{max} sırasıyla parametre için minimum ve maksimum değerlerdir.

5.4 Pearson Analizi

Bu adımda, metan verimi ve H₂S konsantrasyonu ile diğer değişkenler arasındaki korelasyonun gücünü ve yönünü keşfetmek için Pearson korelasyon analizi kullanılır. Pearson korelasyonunun tanımlayıcı istatistiksel analizi, bir veri setinin değişkenler arasındaki doğrusal ilişkisini ölçer. 'r' katsayısının formülü Denklem (2)'de gösterilmektedir. Güçlü korelasyonun 1 veya -1'e yakın olduğu ve pozitif veya negatif işaretin değişkenler arasındaki yönü ifade ettiği r değeri -1 ile 1 aralığındadır, bu arada aralık arasındaki değer bir miktar korelasyon derecesini gösterir. Bununla birlikte, analiz sadece değişkenler arasındaki doğrusal ilişkiyi inceler, bu nedenle r'nin sıfıra eşit olması değişkenler arasında bir ilişki olmadığını göstermez, sadece doğrusal bir ilişki olmadığı anlamına gelir ve değişkenler arasında doğrusal olmayan bir ilişki olabilir (Bao vd., 2023).

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (2)$$

Burada r korelasyon katsayısı, x_i ve y_i sırasıyla x-değişkeni ve y-değişkeni değerleridir. \bar{x} ve \bar{y} sırasıyla x-değişkeni ve y-değişkeni değerleri için ortalamadır.

5.5 Yapay Sinir Ağı Modeli (YSA)

Derin öğrenme teknikleri yapay sinir ağları olarak da adlandırılır. Bir YSA'nın tasarımı, gerçek nöronların bilgi iletmek için birbirleriyle iletişim kurma şeklinden esinlenmiştir (Saha vd., 2023). YSA, girdi, gizli ve çıktı katmanları dahil olmak üzere farklı katmanlardan oluşur. Her katman, sinyallerin işlenmesinden ve bir sonraki katmana iletilmesinden sorumlu olan ve nöron olarak da bilinen düğümlerden oluşur. Bu düğümler ağın temel yapı taşlarıdır ve işleyişinde çok önemli bir rol oynarlar (Mohseni-Dargah vd., 2022). İster basit ister karmaşık olsun, herhangi bir ağın 6 temel unsuru girdiler, ağırlıklar, bias, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıları içerir. Dış duyu sisteminden veya önceki nöronlardan alınan veriler

girdilerdir. Ağın davranışını sergileyen katmanların ayarlanabilir parametreleri ise ağırlıklar ve yanlılıklardır. Bu parametreler, belirli bir hedefe ulaşmak için denetimli ve sıralı bir şekilde bir öğrenme veya eğitim algoritması kullanılarak ayarlanabilir. Ağırlıklar, düğüme girmeden önce gelen verileri zayıflatabilen veya güçlendirebilen anahtarlarla karşılaştırılabilir. Sinaptik ağırlıklar çeşitli giriş değerlerini çarparak toplama fonksiyonunun oluşmasını sağlar. Toplama fonksiyonu daha sonra bu değerleri bir araya getirerek toplam bir değer oluşturur. Bu toplam değer daha sonra tipik olarak doğrusal olmayan bir karakteristiğe sahip olan bir aktivasyon fonksiyonuna beslenir. Son olarak, aktivasyon fonksiyonu bir nöronun veya ağın çıktı değerini üretmek için bu toplam değeri değerlendirir (Montesinos López vd., 2022). YSA'nın düğümündeki aktivasyon fonksiyonunun formülü Denklem (3)'te ifade edilmiştir.

$$y_i = f \left(\sum_{j=1}^n w_{ij}x_j + b_i \right) \quad (3)$$

Burada y ve x sırasıyla düğümün çıkış ve giriş değerleridir, w ve b ağırlıkları ve yanlılığı temsil eder. i ve j ise sırasıyla önceki ve mevcut katmanları göstermektedir. f fonksiyonu katmanın aktivasyon fonksiyonunu ifade eder.

Tek bir nöronu modellemek için farklı aktivasyon fonksiyonları uygulanabilir. Log-sigmoid, tan-sigmoid ve doğrusal transfer fonksiyonları en sık kullanılan üç aktivasyon fonksiyonudur. Örüntü tanıma görevleri için bir sinir ağı oluştururken, sigmoid çıkış nöronları en uygun seçimdir. Öte yandan, fonksiyon uydurma görevleri için doğrusal fonksiyonlu çıkış nöronlarının kullanılması tavsiye edilir. Yapay sinir ağı, giriş değişkeni ile çıkış değişkeni arasındaki doğrusal olmayan bağlantıları anlamak için doğrusal olmayan bir giriş fonksiyonu gerektirir (W.-Y. Chen vd., 2022). Bu çalışmada, YSA modeli, optimizasyon problemi için en iyi koşulları belirlemenin yanı sıra modelin doğruluğunu artıracak ve dolayısıyla daha iyi sonuçlar elde edebilecek mümkün olduğunca çok veriye sahip olmak için dört yerine tek bir nihai modele sahip olmak üzere dört çürütücünün tüm verilerine sahip tek bir çürütücü olduğu varsayımına dayanarak oluşturulmuştur, dolayısıyla model toplam 2924 veri içermektedir.


5.5.1 Veri ayırma

Veri kümesi, eğitim süreci sırasında eğitim verileri, doğrulama verileri ve test verileri olmak üzere üç gruba ayrılır. Ağırlıklar, tüm veri kümesinin çoğunluğunu oluşturan eğitim verileri kullanılarak ayarlanır. Modelin performansını değerlendirmek için hem doğrulama hem de test setleri kullanılır; doğrulama eğitim sürecinde, test ise başarılı model geliştirmenin ardından kullanılır (Mendes vd., 2015). Optimal bir YSA modeli oluşturmak, eksik veya aşırı uyuma maruz kalabileceği için zordur. Bir modelin yetersiz uyum göstermesi, çok basit olduğu ve veriler arasındaki ilişkileri etkili bir şekilde tanımlayamadığı anlamına gelir. Öte yandan, bir model aşırı derecede karmaşık olduğunda ve yalnızca eğitim verilerini hafızaya aldığı anda, aşırı uyuma yol açar. Bu da modelin iyi genelleme yapamamasıyla sonuçlanır (Bejani & Ghatee, 2021). Aşırı uyum, bir modelin eğitim setinde çok iyi performans göstermesine, ancak test setinde kötü performans göstermesine neden olabilir. Bunun nedeni, aşırı uyum sağlayan bir modelin eğitim sırasında öğrendiklerinden farklı olabilecek test setindeki belirli bilgi parçalarını işleyemeyebilmesidir (Ying, 2019). YSA modelinin öğrenme sürecinde genellikle eğitim seti ve doğrulama seti oranının %70 ve %30, bazen de %80 ve %20 seviyelerinde tutulduğu gözlemlenmektedir (Bao vd., 2023). Bu çalışma için eğitim, doğrulama ve test veri kümeleri için sırasıyla %70, %15 ve %15 oranları seçilmiştir. Her bir özellik için toplam veri noktası sayısı 2924'tür ve seçilen oranlara göre, eğitim, doğrulama ve test veri kümeleri için sırasıyla 2047, 438 ve 438 veri noktası vardır. Bayesian Regülasyonu yöntemi gibi öğrenme sürecinde sadece eğitim ve test veri setlerini alan eğitim algoritmaları vardır ve bu durumda eğitim seti 2485 veri noktasına sahipken test seti 438 noktaya sahiptir.

5.5.2 Ağ yapısı

Bir sinir ağının yapısını veya topolojisini belirlemek, tasarımının hayati bir yönüdür ve ilgili her gizli katman için uygun sayıda gizli katmana ve gizli nöronlara karar vermeyi içerir. Bu karar, sinir ağının performansının belirlenmesinde önemli bir rol oynamaktadır. Bununla birlikte, YSA yapısının belirlenmesi süreci hala karmaşık ve zorlu bir problemdir (Rachmatullah vd., 2021). YSA'nın yapısı 4 unsur seçilerek oluşturulur. Bunlar arasında gizli katman sayısı, girdi, gizli ve çıktı katmanlarındaki nöron sayısı, her katmanda kullanılan aktivasyon fonksiyonunun türü ve YSA modelini eğitmek için kullanılan eğitim algoritması yer almaktadır (W.-Y. Chen vd., 2022). Aşırı uyum ve yetersiz uyum, verilere uygun olmayan bir topoloji kullanmanın başlıca

sonuçlarıdır (Rachmatullah vd., 2021). Bir YSA için en iyi mimarinin belirlenmesi genellikle farklı mimarilerin karşılaştırıldığı bir deneme-yanılma sürecini içerir. Yüksek tahmin değerine sahip bir YSA modeli oluşturmak için gereken nöron veya gizli katman sayısını kesin olarak belirlemek mümkün değildir (W.-Y. Chen vd., 2022). Ayrıca, araştırmalara göre, optimum performans için gereken gizli katmanlardaki nöron sayısı, verilen görevin karmaşıklığına göre değişmektedir (Oloko-Oba vd., 2018). Daha fazla gizli nöron eklemek YSA'nın öğrenme performansını bir dereceye kadar artırabilir. Ancak, çok fazla nöron varsa, model aşırı uyum sağlayabilir. Bunun nedeni, nöron sayısı arttıkça modelin daha karmaşık hale gelmesidir. Öte yandan, çok az nöron varsa, YSA'nın mekanizmayı doğru bir şekilde temsil etme kapasitesi sınırlı olabilir ve bu da aşırı genellemeye yol açabilir (Andrade Cruz vd., 2022). Bu analizde girdi katmanı, yoğunlaştırılmış çamurun pH'ı, yoğunlaştırılmış çamurun sıcaklığı, yoğunlaştırılmış çamurun uçucu katıları, yoğunlaştırılmış çamurun toplam katıları, çürütücünün çamur akış hızı, çürütücünün pH'ı, çürütücünün sıcaklığı, toplam katılar, uçucu katılar, uçucu yağ asitleri, çürütücünün kalsiyum karbonat (CaCO_3) alkalinitesi gibi 11 girdi parametresinin değerlerini temsil etmektedir. Çıkış katmanı metan verimini ve hidrojen sülfid konsantrasyonunu temsil ederken, gizli katmanlar ve ilgili nöronlar bir deneme-yanılma süreci ile seçilir. Bir YSA'nın mimarisini oluşturmak için süreç bir gizli katman varsayarak başlar. Daha sonra nöron sayısı değiştirilir ve hata oranları eğitim, doğrulama ve test setleri için ortalama karesel hata (MSE) kullanılarak hesaplanır. En düşük hata oranına sahip konfigürasyon seçilir. Bu çalışmada, tek bir eğitim algoritması kullanılarak bir gizli katman ve iki gizli katman için nöron sayısı 10 ila 20 arasında değiştirilmiştir. Giriş katmanında 11 nöron vardır, çünkü seçilen 11 giriş özelliği vardır ve çıkış katmanında iki nöron vardır, çünkü iki çıkış özelliği vardır. Ortalama karesel hata (MSE) buna göre kaydedilmiştir. Ayrıca, başka bir eğitim algoritması ile bir katman için nöron sayısı da incelenmiştir. Gizli katman için aktivasyon fonksiyonu tansig iken çıkış katmanı için purelin seçilmiştir. Şekil 5.3, Tansig ve purelin aktivasyon fonksiyonlarının grafiksel gösterimini göstermektedir.



Şekil 5.3. Gizli ve çıkış katmanları için sırasıyla Tansig ve Purelin aktivasyon fonksiyonları.

5.5.3 Eğitim algoritması

Ağ modelinin performansı sadece nöron ve katman sayılarından değil, aynı zamanda eğitim algoritmasının yönteminden de etkilenir. Sinir ağlarının eğitimi sırasında, ileri besleme süreci ve geri yayılma süreci olmak üzere iki ana süreç söz konusudur. İleri besleme süreci, girdinin sinir ağına, özellikle de gizli katmana ve ardından tüm ağırlıkların rastgele atandığı çıktı katmanına yayılmasını içerir. Önyargı ve aktivasyon fonksiyonları bir tahmin değeri sağlamak için kullanılır. Buna karşılık, geriye yayılma aşaması başlatılır ve bu sayede ağırlıklar, tahmin edilen değer ile eğitim verilerinden elde edilen ağ girdisinin deneysel değeri arasındaki hatayı en aza indirecek şekilde ayarlanır. Bunu başarmak için belirli bir geri yayılım eğitim algoritması seti kullanılır (W.-Y. Chen vd., 2022; Lee vd., 2020). YSA'nın eğitimi sırasında epoch, batch size ve iterasyon olmak üzere üç terim oldukça önemlidir. Eğitim veri kümesi üzerinden tam bir geçiş Epoch olarak adlandırılır. Amacı, modelin tüm veri kümesini kaç kez gözden geçirdiğini takip etmektir. Epok sayısı önemli olabileceğinden, genellikle birden fazla küçük partiye bölünürler ve modelin eğitim sürecini bitirmeden önce tüm eğitim setini kaç kez inceleyeceğini tanımlar. Ağ üzerinden bir ileri ve geri geçişte kullanılan örnek sayısı, grup büyüklüğü tarafından belirlenir. Son olarak, eğitim sürecinin ilerlemesi, bir epogu tamamlamak için gereken yığın sayısı ile ölçülür ve buna iterasyon adı verilir (Dönemler, Toplu Boyut, Yinelemeler- Neden Önemlidirler). Bu analiz için, hem bir hem de iki katman için öğrenme sürecini yürütmek üzere Levenberg-Marquardt (LM) geri yayılım algoritması seçilmiştir. Ayrıca nöron sayısı 10'dan 20'ye değiştirilen tek katman için Bayesian Regülasyonu (BR) geri yayılım algoritması kullanılmıştır.

Her iki algoritmanın performansı karşılaştırıldıktan sonra, YSA modelini temsil etmek için daha iyi performans gösteren seçilmiştir. LM algoritması optimizasyon amacıyla yaygın olarak kullanılmaktadır. Çeşitli doğrusal olmayan, gerçek değerli fonksiyonların karelerinin toplamı ile temsil edilen çok değişkenli bir fonksiyonun yerel minimumunu tanımlayan iteratif bir yöntemdir. LM, doğrusal olmayan en küçük kare problemlerini çözmek için popülerlik kazanmıştır ve veri uydurma problemleri için birçok alanda yaygın olarak kullanılmaktadır. LM eğri uydurma tekniği iki minimizasyon yöntemini birleştirir: gradyan iniş yöntemi ve Gauss-Newton yöntemi (Sapna, 2012). Geleneksel yöntemleri takip eden geri yayılım algoritmaları yerel bir minimuma yakınsamaya eğilimlidir ve bu da eğitim süreci sonuçlarının istikrarsızlığına neden olabilir. Öte yandan, LM algoritmasının yerel yakınsamadan etkilenme olasılığı daha düşüktür, bu da onu geri yayılım ağlarında öğrenme ve eğitim için daha iyi bir yaklaşım haline getirir (Zhou vd., 2018). Bununla birlikte, Bayesian Regülasyonu sinir ağları, yapay sinir ağının pratik ve basit bir biçimini sunar. Esnek olma özelliğine sahiptirler, bu da onları aşırı eğitime veya aşırı uyuma daha az duyarlı hale getirir. Ayrıca, minimum tekrarlı hesaplamalarla güvenilir bir model belirleyebilirler. Bayesian Regülasyonu, sinir ağlarının eğitiminde aşırı uyumu önlemek için kullanılır, böylece ağın iyi genelleme yapmasını sağlar (Handayani vd., 2018). LM bir doğrulama seti alırken BR almaz.

5.6 YSA Modelinin Performans Değerlendirmesi

Yapay sinir ağı modelinin konfigürasyonu, doğruluğuna bağlı olarak seçilir. Bu nedenle, doğruluğunu ve güvenilirliğini belirlemek için modeli değerlendirmek ve doğrulamak çok önemli hale gelmektedir. YSA modelinin tahmin doğruluğunu değerlendirmek için kök ortalama kare hatası (RMSE), ortalama kare hatası (MSE), yüzde hata (PE) ve belirleme katsayısı (R-kare), korelasyon katsayısı (R) dahil olmak üzere birçok performans ölçütü kullanılır. Bu çalışmada, modelin doğruluğunu değerlendirmek için MSE ve R metrikleri benimsenmiştir. Denklem (4) MSE formülünü ifade etmektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2 \quad (4)$$

Burada t_i ve y_i sırasıyla gerçek gözlem ve tahmin edilen değerleri göstermektedir. n test veri kümesindeki gözlem noktalarının sayısıdır. MSE, bir YSA modelinin doğruluğunu değerlendirmek için çok önemlidir. Tahmin edilen ve tahmin edilen değerler arasındaki farkı ölçer ve daha düşük bir değer doğru bir uyumu gösterir. R-değeri, regresyon çizgisine uyan verilerin yakınlığını değerlendirir ve 1'e yakın bir değer daha iyi bir uyumu gösterir.

5.7 Duyarlılık Analizi

Duyarlılık analizi yapmanın amacı, modelin girdi faktörlerini değiştirmek ve modelin sonuçlarında ortaya çıkan değişiklikleri analiz etmektir. Duyarlılık analizi, girdi değişkenlerinin her birinin ağ üzerindeki etki derecesini netleştirmek için yöntemler sunar. Göreceli önem (RI), girdi değişkenlerinin çıktı değişkenlerinin tahminine katkısını tanımlamak için kullanılan bir terimdir. YSA modellerinin duyarlılık analizini değerlendirmek için Garson algoritması, bağlantı ağırlıkları algoritması ve kısmi türevlerin kullanımı gibi çeşitli teknikler mevcuttur (Agwu vd., 2020). Bu çalışmada, duyarlılık analizi yapmak için Garson'un algoritması seçilmiştir. Garson algoritması, girdi-gizli katman ve gizli katman-çıkış katmanının ağırlıklarını hesaplayarak belirli faktörlerin göreceli önemini belirlemek için kullanılabilir. Göreceli katkıyı elde etmek için her bir gizli nöronun katkısı, her bir giriş nöronunun katkısı toplanarak normalleştirilir. Her bir girdi nöronunun göreceli katkısı daha sonra tüm gizli nöronlar arasında toplanır ve göreceli özellik önem puanını belirlemek için bir yüzdeye dönüştürülür (Kumar & Ravi). Göreceli katkının ifadesi denklem (5)'te gösterilmiştir.

$$E_j = \frac{\sum_{t=1}^{t=N_h} (|W_{jt}^{ih}| / \sum_{k=1}^{k=N_i} |W_{kt}^{ih}|) \times |W_{tn}^{ho}|}{\sum_{k=1}^{N_i} \{ \sum_{t=1}^{t=N_h} (|W_{jt}^{ih}| / \sum_{k=1}^{k=N_i} |W_{kt}^{ih}|) \times |W_{tn}^{ho}| \}} \quad (5)$$

Burada E_j girdi değişkeninin göreceli önemi, W ağırlık katsayısı ve N nöron sayısıdır. Alt simgeler k , t ve n sırasıyla giriş, gizli ve çıkış nöronlarını ifade ederken, üst simgeler i , h ve o sırasıyla giriş, gizli ve çıkış katmanlarıdır.

5.8 Optimum Koşulları Belirlemek İçin Genetik Algoritma (GA)

Genetik algoritma, evrimsel algoritmalarından biri olarak sınıflandırılır. Biyolojide görülen doğal seçim ve evrim sürecini taklit eder. Algoritma, kromozom popülasyonu, uygunluk fonksiyonu ve genetik operatörler veya kromozom operatörleri gibi farklı bileşenlerden oluşur.

Genetik operatörler mutasyon, seçim ve çaprazlamayı içerir (Carr, 2014). Süreçteki ilk adım, problemi genetik olarak kodlamak ve iyi çözümleri seçmek için uygunluk fonksiyonunu tanımlamaktır. Bu yapıldıktan sonra, bir başlangıç popülasyonu rastgele seçilir ve önerilen her çözümün uygunluk değerleri değerlendirilir. Ardından, çapraz kombinasyon ve mutasyon gibi genetik operatörler kullanılır ve kademeli olarak daha optimal çözümlere doğru ilerlemek için evrimsel alt ilke uygulanır. Son olarak, son nesil popülasyondan en iyi bireylerin kodunu çözerek, problemin en uygun çözümü belirlenebilir (FuRui vd., 2019). Bu çalışmada, YSA modeli GA için bir uygunluk fonksiyonu olarak kullanılmış olup, modelin ilk çıktısı maksimize edilmesi gereken ilk amaç fonksiyonu olarak tanımlanan metan verimi, ikinci çıktısı ise minimize edilmesi gereken ikinci amaç fonksiyonu olarak tanımlanan hidrojen sülfid gazıdır. GA'nın optimum çözümü, daha önce bahsedilen amaç fonksiyonlarını sağlayan girdi değişkenlerinin optimum koşullarının belirlenmesidir.

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

6.1 Veri Ön İşleme ve Pearson Korelasyon Analizi Sonuçları

Konya Atıksu Arıtma Tesisi'ndeki (KAAT) 4 çürütücü ve bunların çamur yoğunlaştırma ünitesine ait veriler iki yıl üst üste toplanmıştır. Bu çalışmada canlı kod, istatistiksel ve makine öğrenimi araçları ve görselleştirme araçları içeren MATLAB R2023b yazılımından yararlanılmıştır. Yazılım, özellikle yapay sinir ağı aracı olmak üzere derin öğrenme uygulamasını kullanarak bir tahmin modeli oluşturmak amacıyla kapsamlı verileri incelemek, seçmek, hazırlamak, görüntülemek ve uygun bir veri setine dönüştürmek için kullanılmıştır. Verilerin toplanmasından sonra, verileri incelemek ve anlamak için verilerin ön işleme ve görselleştirme görevleri gerçekleştirilmiştir. Ön işleme adımı eksik verilerin doldurulmasını ve normalleştirmeyi içerir. Çizelge 6.1, Çizelge 6.2, Çizelge 6.3 ve Çizelge 6.4 sırasıyla çamur yoğunlaştırma ünitesi, çürütücü 1, çürütücü 2, çürütücü 3 ve çürütücü 4'ün istatistiksel özetini göstermektedir. Tablolardaki minimum, medyan ve maksimum değerler ham verileri temsil etmektedir. Son sütun, eksik veriler göz ardı edilip yerine yenileri konulduktan sonraki standart sapmayı göstermektedir.

Çizelge 6.1. Çamur yoğunlaştırma ünitesi özelliklerinin istatistiksel özeti.

Parametre	Min	Medyan	Max	Standart sapma	
				Kayıp veri tahmin etmeden	Kayıp verilerin tahminyle
pH	5.73	6.52	8.02	0.28	0.25
Sıcaklık °C	2.4	19.5	36	3.50	3.52
Toplam Katı Madde mg/L	16990	34410	93410	8716.40	8014.66
Uçucu Katı Madde mg/L	2760	24670	47000	5902	5334

Çizelge 6.2. Çürütücü 1 özelliklerinin istatistiksel özeti.

Parametre	Min	Medyan	Max	Standart sapma	
				Kayıp veri tahmin etmeden	Kayıp verilerin tahminyle
Çamur akış hızı m ³ /saat	0.6	14	244	16.41	14.52
Çürütücü pH	7.28	7.77	8.7	0.17	0.16
Çürütücü sıcaklığı °C	20	37	43	2.58	2.19

Toplam Katı Madde mg/L	1980	24300	40200	4593.16	3821.26
Uçucu Katı Madde mg/L	15	14700	22700	2491.14	1899.89
Uçucu Yağ Asidi	17	115	3406	282.64	177.71
Alkalinite	101	3325	38880	2177.10	1858.91
Metan m ³ /gün	9.66	126.96	663	42.48	34.97
H ₂ S ppm	900	3300	5050	935.28	962.18

Çizelge 6.3. Çürütücü 2 özelliklerinin istatistiksel özeti.

Parametre	Min	Medyan	Max	Standart sapma	
				Kayıp veri tahmin etmeden	Kayıp verilerin tahminyle
Çamur akış hızı m ³ /saat	0.6	13.5	244	35.98	31.95
Çürütücü pH	6.23	7.81	8.49	0.23	0.19
Çürütücü sıcaklığı °C	13.2	39	44	2.67	2.39
Toplam Katı Madde mg/L	15810	24895	35350	3738.72	3217.33
Uçucu Katı Madde mg/L	10110	15130	25100	2083.61	1704.86
Uçucu Yağ Asidi	25	110	1398	147.41	NaN
Alkalinite	166	3414.5	4278	520	474.32
Metan m ³ /gün	9.66	120.9	663	44.49	36.67
H ₂ S ppm	910	3285	5050	929.81	948.86

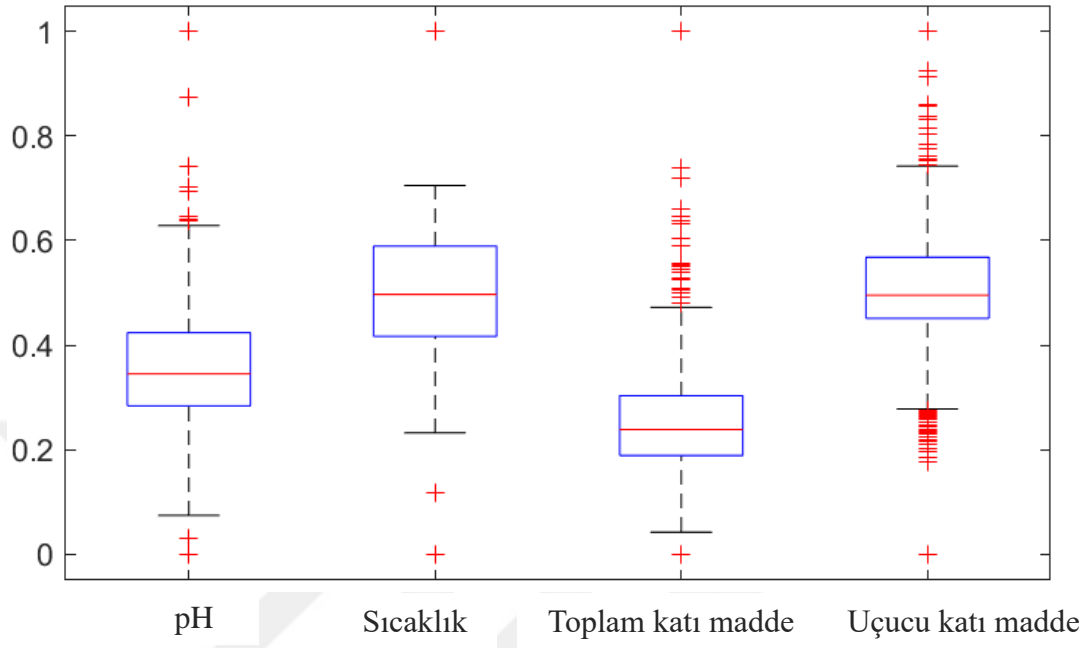
Çizelge 6.4. Çürütücü 3 özelliklerinin istatistiksel özeti.

Parametre	Min	Medyan	Max	Standart sapma	
				Kayıp veri tahmin etmeden	Kayıp verilerin tahminyle
Çamur akış hızı m ³ /h	0.6	12.5	222	15.25	13.54
Çürütücü pH	6.9	7.81	8.66	0.18	0.17
Çürütücü sıcaklığı °C	19	39	44	2.71	2.55
Toplam Katı Madde mg/L	2281	23320	35760	3962.84	3256.74
Uçucu Katı Madde mg/L	10730	13970	174340	9883.10	6090
Uçucu Yağ Asidi	18	115	3522	306.59	191.21
Alkalinite	165	3332	4168	453.51	418.41
Metan m ³ /day	0.6	15.96	206.7	63.53	60.31
H ₂ S ppm	390	3300	5050	907.65	917.31


Çizelge 6.5. Çürütücü 4 özelliklerinin istatistiksel özeti.

Parametre	Min	Medyan	Max	Standart sapma	
				Kayıp veri tahmin etmeden	Kayıp verilerin tahminyle
Çamur akış hızı m ³ /saat	2	13.9	253	15.63	13.85
Çürütücü pH	7.25	7.85	8.52	0.16	0.15
Çürütücü sıcaklığı °C	20.7	38	44	2.14	1.74
Toplam Katı Madde mg/L	16760	24650	42970	4076.22	3524.82
Uçucu Katı Madde mg/L	10300	14950	20870	1812.34	1575
Uçucu Yağ Asidi	15	120	3360	411.77	272.35
Alkalinite	115	3430	4166	476.12	422.16
Metan m ³ /gün	8.97	120.6	219.42	36.22	31.81
H ₂ S ppm	350	3300	5050	943.59	944.44


Şekil 6.1 ila 6.5 sırasıyla yoğunlaştırma ünitesi ve dört çürütücü için normalleştirme sonrası verilerin kutu grafiği diyagramını göstermektedir. Verileri 0 ve 1 aralığında dönüştürmek için normalleştirme yöntemi olarak min-max yöntemi seçilmiştir. Kutu ve bıyık grafiği olarak da bilinen kutu grafiği, sayısal verileri çeyreklere göre temsil etmek için kullanılan istatistiksel bir araçtır. Üst ve alt çeyreklerin yayılımını gösteren bıyıkları veya ondan uzanan çizgileri olan bir kutudan oluşur. Kutu grafikleri, bir veri kümesindeki varyasyon aralığını göstermek için kullanışlıdır (Wongburi & Park, 2021). Pearson korelasyon analizine gelince, tipik olarak, istatistiklerle uğraşırken, r'nin büyüklüğü aşağıdaki kategorilere ayrılır: 0.8-1.0 arasında değişen bir korelasyon çok güçlü olarak kabul edilir; 0.6-0.79 güçlü olarak kabul edilir; 0.4-0.59 orta olarak kabul edilir; 0.2-0.39 zayıf olarak kabul edilir ve 0.0-0.19 çok zayıf bir korelasyona sahip olduğu veya hiç korelasyon olmadığı kabul edilir (Selvanathan vd., n.d.). Şekil 6.6, dört çürütücünden gelen tüm verilerin tek bir çürütücü olarak derlenmesinden sonra değişkenler arasındaki ilişkinin gücünü göstermektedir. Pearson korelasyon analizi sonuçlarına göre, çıkış metan verimi ile H₂S arasında diğer özelliklerle çok zayıf bir güç vardır veya hiç korelasyon yoktur. Yani aralarında doğrusal bir ilişki olmadığı gibi doğrusal olmayan bir ilişkiye de sahip olabilirler. Bu, YSA tekniği kullanılarak keşfedilebilir. Ayrıca, uçucu katılar toplam katıların bir parçası olduğundan, yoğunlaştırma ünitesindeki ve çürütücülerdeki çamur için toplam katılar ve uçucu katılar arasında yalnızca güçlü bir korelasyon bulunmaktadır.




Şekil 6.1. Normalizasyondan sonra çamur yoğunlaştırma ünitesinin istatistiksel özeti için kutu grafiği.




Şekil 6.2 Normalizasyondan sonra çürütücü l'in istatistiksel özeti için kutu grafiği.




Şekil 6.3. Normalizasyondan sonra çürütücü 2'in istatistiksel özeti için kutu grafiği.



Şekil 6.4. Normalizasyondan sonra çürütücü 3'in istatistiksel özeti için kutu grafiği.



Şekil 6.5. Normalizasyondan sonra çürütücü 4'in istatistiksel özeti için kutu grafiği.



Şekil 6.6. Metan verimi ve hidrojen sülfid konsantrasyonunun diğer değişkenlerle arasındaki Pearson korelasyon analizi sonuçları.

6.2 Yapay Sinir Ağı Modelinin Sonuçları

YSA'nın tahmininin doğruluğu esas olarak modelin yerleşik konfigürasyonuna ve benimsenen eğitim yöntemine bağlıdır. Bu çalışmadaki YSA modelinde giriş katmanı için 11, çıkış katmanı için ise iki nöron bulunmaktadır. Gizli katman için deneme yanılma süreci, gizli katmanların doğasını seçmenin yolu olmuştur. Çizelge 6.6, Levenberg-Marquardt (LM) algoritması kullanılarak eğitilmiş tek gizli katmana sahip çeşitli YSA yapılarının performansını göstermektedir. Kod her yürütüldüğünde, veriler gruplara bölündüğü ve her grup rastgele

karıştırıldığı için farklı sonuçlar üretir. Bu nedenle, programın beş kez çalıştırılmasıyla elde edilen ortalama sonuçlar aşağıda verilmiştir.

Çizelge 6.6. Tek gizli katmanlı LM eğitim yöntemini kullanan YSA yapısının performans sonuçları.

YSA Yapısı	Eğitim R	Doğrulama R	Test R	Eğitim MSE	Doğrulama MSE	Test MSE
11-10-2	0.94568	0.9328	0.93252	0.00744	0.0092	0.00922
11-11-2	0.93774	0.92638	0.92724	0.00848	0.01006	0.00988
11-12-2	0.94768	0.94074	0.92172	0.00712	0.00812	0.01114
11-13-2	0.94652	0.93776	0.92842	0.00732	0.0087	0.00968
11-14-2	0.93174	0.92564	0.92046	0.00924	0.0102	0.01086
11-15-2	0.95022	0.93468	0.92438	0.00686	0.0088	0.0105
11-16-2	0.93646	0.92272	0.90636	0.1899	0.18612	0.1903
11-17-2	0.94638	0.93812	0.93834	0.00732	0.00852	0.0086
11-18-2	0.94876	0.93748	0.92956	0.00704	0.0086	0.00956
11-19-2	0.9465	0.92868	0.92252	0.00734	0.0098	0.01066
11-20-2	0.94896	0.93738	0.93086	0.00696	0.00868	0.00944

İlk katmanında 10 nöron bulunan LM eğitim algoritmasını kullanan iki gizli katmanlı farklı YSA yapılarının performansı Çizelge 6.8'de gösterilmektedir.

Çizelge 6.7. İki gizli katmanlı LM eğitim yöntemini kullanan YSA yapısının performans sonuçları.

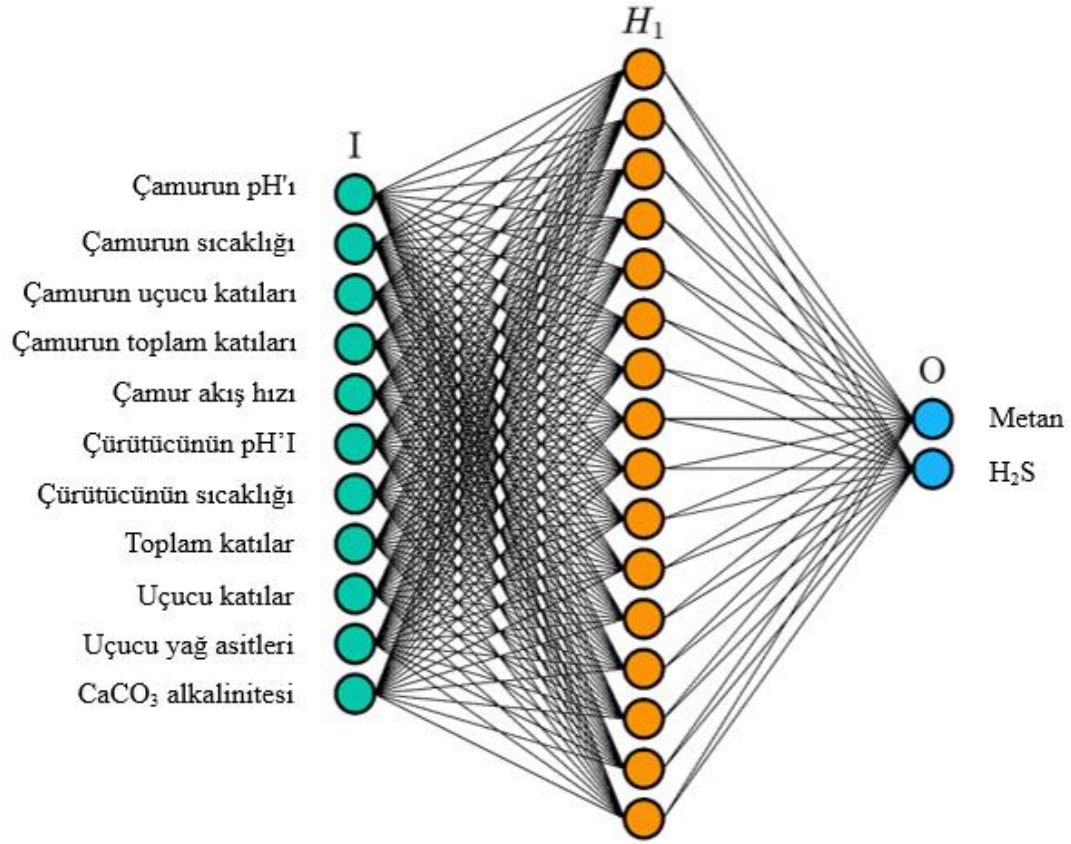
YSA Yapısı	Eğitim R	Doğrulama R	Test R
11-10-1-2	0.930144	0.92138	0.917524
11-10-2-2	0.940016	0.935158	0.927178
11-10-3-2	0.939798	0.932364	0.922994
11-10-4-2	0.938298	0.927404	0.896394
11-10-5-2	0.939242	0.93466	0.92362
11-10-6-2	0.94205	0.928314	0.922184
11-10-7-2	0.930694	0.917928	0.911486
11-10-8-2	0.937076	0.927122	0.922068
11-10-9-2	0.936042	0.927118	0.911882
11-10-10-2	0.940984	0.92925	0.923218

Çizelge 6.8, Bayesian Regülasyonu (BR) algoritmasını kullanan tek gizli katman eğitimiyle çeşitli YSA yapılarının performansını göstermektedir.

Çizelge 6.8. Tek gizli katmanlı BR eğitim yöntemini kullanan YSA yapısının performans sonuçları.

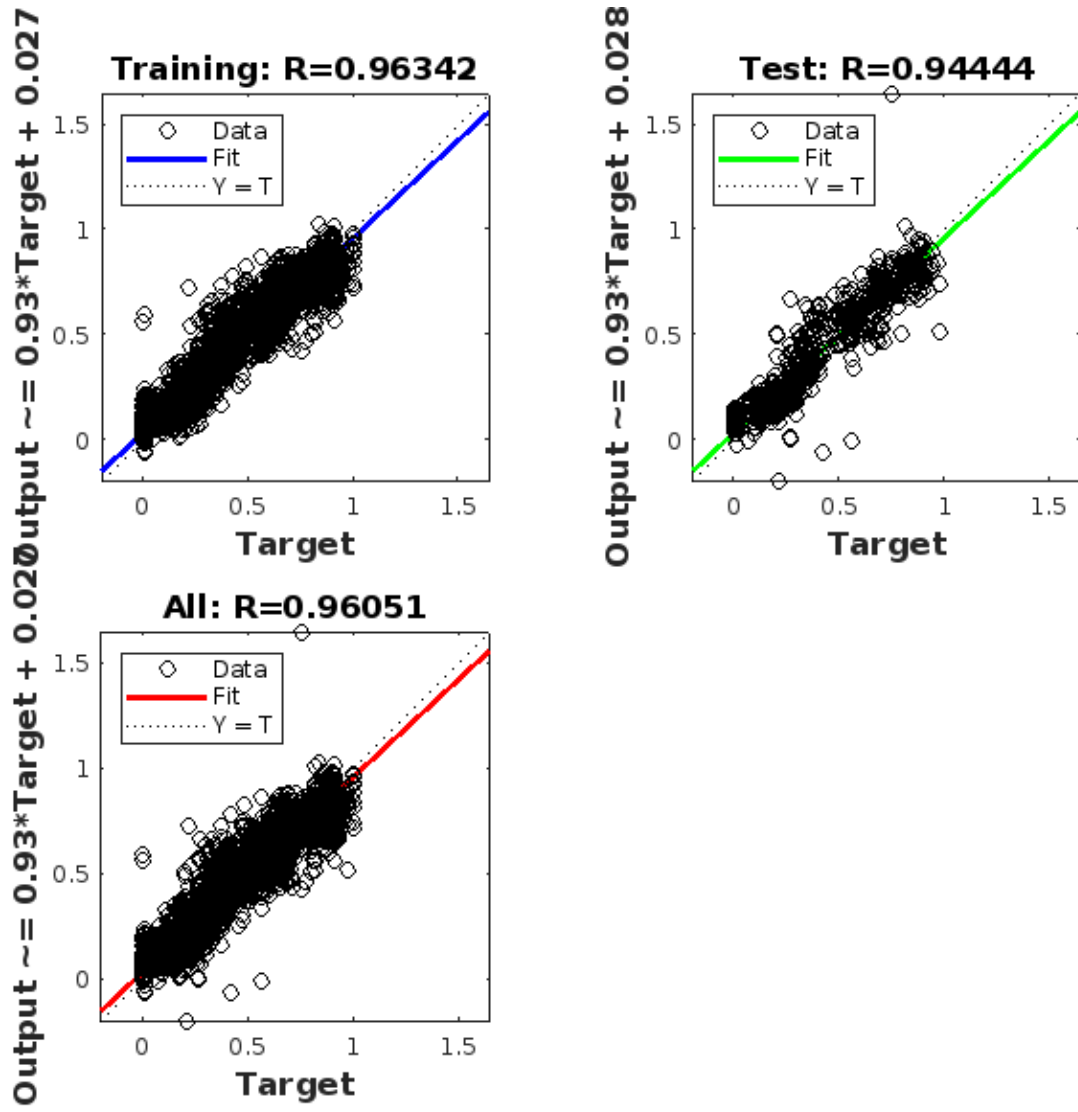
YSA Yapısı	Eğitim R	Test R	Eğitim MSE	Test MSE
11-10-2	0.95664	0.93628	0.00602	0.00858
11-11-2	0.95742	0.93122	0.00588	0.00952
11-12-2	0.95938	0.89998	0.00558	0.01508
11-13-2	0.96118	0.93962	0.00536	0.0082
11-14-2	0.96266	0.92322	0.00516	0.01088
11-15-2	0.96312	0.93624	0.0051	0.00906
11-16-2	0.96446	0.9447	0.00488	0.00778
11-17-2	0.96484	0.93924	0.00484	0.00856
11-18-2	0.9666	0.93374	0.00464	0.00932
11-19-2	0.96776	0.91292	0.00446	0.0127
11-20-2	0.96766	0.93358	0.00446	0.00944

Çizelge 6.6 ve Çizelge 6.7, katmanların ve bunlara karşılık gelen nöronların sayısını değiştirerek performans ölçümlerinin niceliksel sonuçlarını göstermektedir. Modelin performansının değerlendirilmesi, MSE'ye ve Levenberg-Marquardt eğitim yöntemini kullanan eğitim, doğrulama ve test setleri için korelasyon katsayısına göre yapılır. Önerilen YSA mimarileri genel olarak iyi performansa sahiptir ve varyansları düşüktür. Bir gizli katman için, 11-15-2 (15 nöron) mimarisi, R değeri ve MSE için 0,95022 ve 0,00686 ile eğitim seti için en iyi performansı gösterirken; 11-12-2 ve 11-12-2 yapısı sırasıyla doğrulama ve test için en iyi performansı göstermiştir. İki gizli katman ve aynı eğitim algoritması için, 11-10-6-2 konfigürasyonu (ilk gizli katman için 10 nöron ve ikinci gizli katman için 6 nöron) eğitim seti için en iyi performansı gösterirken; 11-10-2-2, doğrulama ve test kümeleri için sırasıyla en iyi performansa sahiptir. Çalışma sırasında, Bayesian Regülasyonu yönteminin eğitim algoritmasının kullanılmasının LM'ye göre daha iyi performans ortaya koyduğu tespit edilmiştir. Gizli katman için eğitime yönelik R değeri 0,95 ile 0,96 arasında yer almıştır. 11-16-2 konfigürasyonu 0,9447 puanla test seti için en iyi performansı gösterirken; 11-20-2 konfigürasyonu 0,96776 puanla eğitim seti için en iyi performansı göstermiştir. Ancak eğitim seti için 11-16-2 konfigürasyonunun performansı, 11-20-2 konfigürasyonundan önemli ölçüde farklı olmadığından, çalışma için benimsenen model olarak 11-16-2 konfigürasyonu seçilmiştir. Daha sonraki analizler bu modele dayanarak yapılmıştır. Şekil 6.7, YSA modelinin benimsenen yapısının bir çizimini göstermektedir.




Şekil 6.7. Seçilen model için YSA yapılandırmasının basitleştirilmiş çizimi.

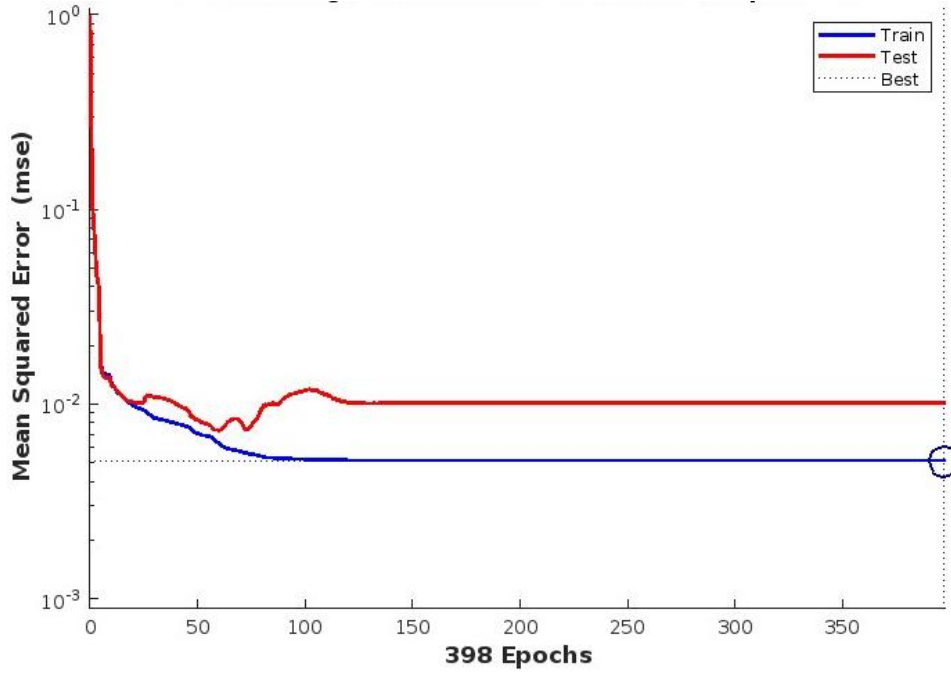
Şekil 6.8, modelin hedef (gerçek tahmini değerler) ile çıktı (seçilen modelden tahmin edilen değerler) arasındaki regresyon grafiğini göstermektedir. Aşağıdaki şekillerin sonuçlarının 394. döneme ait sonuçları ifade ettiğini belirtmekte fayda vardır. Şekil 6.11 ve 6.12, YSA modelinden tahmin edilen veriler ile metan verimi ve hidrojen sülfid konsantrasyonunun iki çıktısı için gerçek tahmin edilen veriler arasındaki farkları göstermektedir.




Şekil 6.8. Epoch 394 için seçilen YSA modelinin hedef ve çıktı değerleri arasındaki regresyon grafiği.




Şekil 6.9. 394 epoch için seçili ANN modeli için karşılık gelen örneklerle hata histogramı.



Şekil 6.10. MSE ve 398 epoch için en iyi performans.




Şekil 6.11. Gerçek ve model tahminli metan verimi verilerinin karşılaştırılması.




Şekil 6.12. Gerçek ve model tahminli H₂S verilerinin karşılaştırılması.

6.3 Duyarlılık Analizinin Sonuları

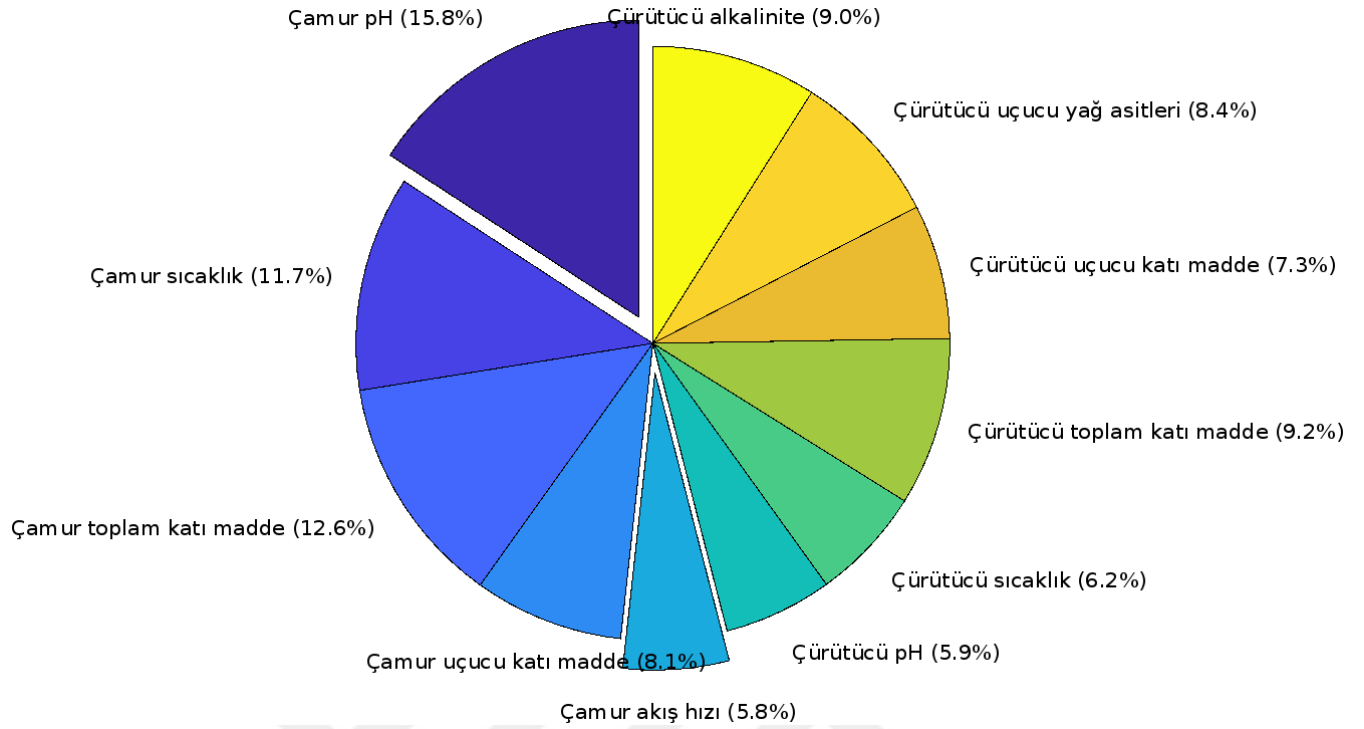
Artık YSA modeli geliřtirildiđine gre ıktıyı tahmin etmekten bařka amalar iin de kullanılabilir. Bu amalardan biri, duyarlılık analizi yoluyla yapılabilecek girdi zelliklerinin ıktı deđiřkenleri zerindeki etkisini incelemektir. Her girdi deđiřkeninin metan verimi ve hidrojen slfit konsantrasyonu zerindeki greceli neminin incelemek iin Garson yntemi uygulanmıřtır. đrenme sreci sırasında eđitim verileri dnemlere ve gruplara blnr. Sonu olarak program her alıřtırıldıđında farklı sonular retmektedir. Bunu hesaba katmak iin duyarlılık analizi 40 kez yapılarak sonular kaydedilmiřtir. Őekil 6.13 ve 6.14, bir kutu grafiđi kullanarak, sırasıyla metan verimi ve hidrojen slfit konsantrasyonu zerindeki her girdi deđiřkeninin greceli neminin istatistiksel zetini gstermektedir. Bu izim, 40 program alıřması sırasında kaydedilen greceli nemin dađılımını ve aykırı deđerlerini sergilemek iin kullanılmıřtır. Her deđiřkenin neminin belirlemek iin aykırı deđerler ıkarılarak ortalama hesaplanmıřtır. İki pasta grafik, Őekil 6.15 ve Őekil 6.16, sırasıyla hem metan hem de hidrojen slfitdeki her bir zelliđin ortalama nem yzdesini gstermektedir.




Şekil 6.13. Giriş özelliklerinin metan verimi üzerindeki göreceli öneminin dağılımı.



Şekil 6.14. Giriş özelliklerinin H₂S konsantrasyonu üzerindeki göreceli öneminin dağılımı.



Şekil 6.15. Giriş özelliklerinin metan verimi üzerindeki göreceli önem yüzdelerini gösteren pasta grafiği.



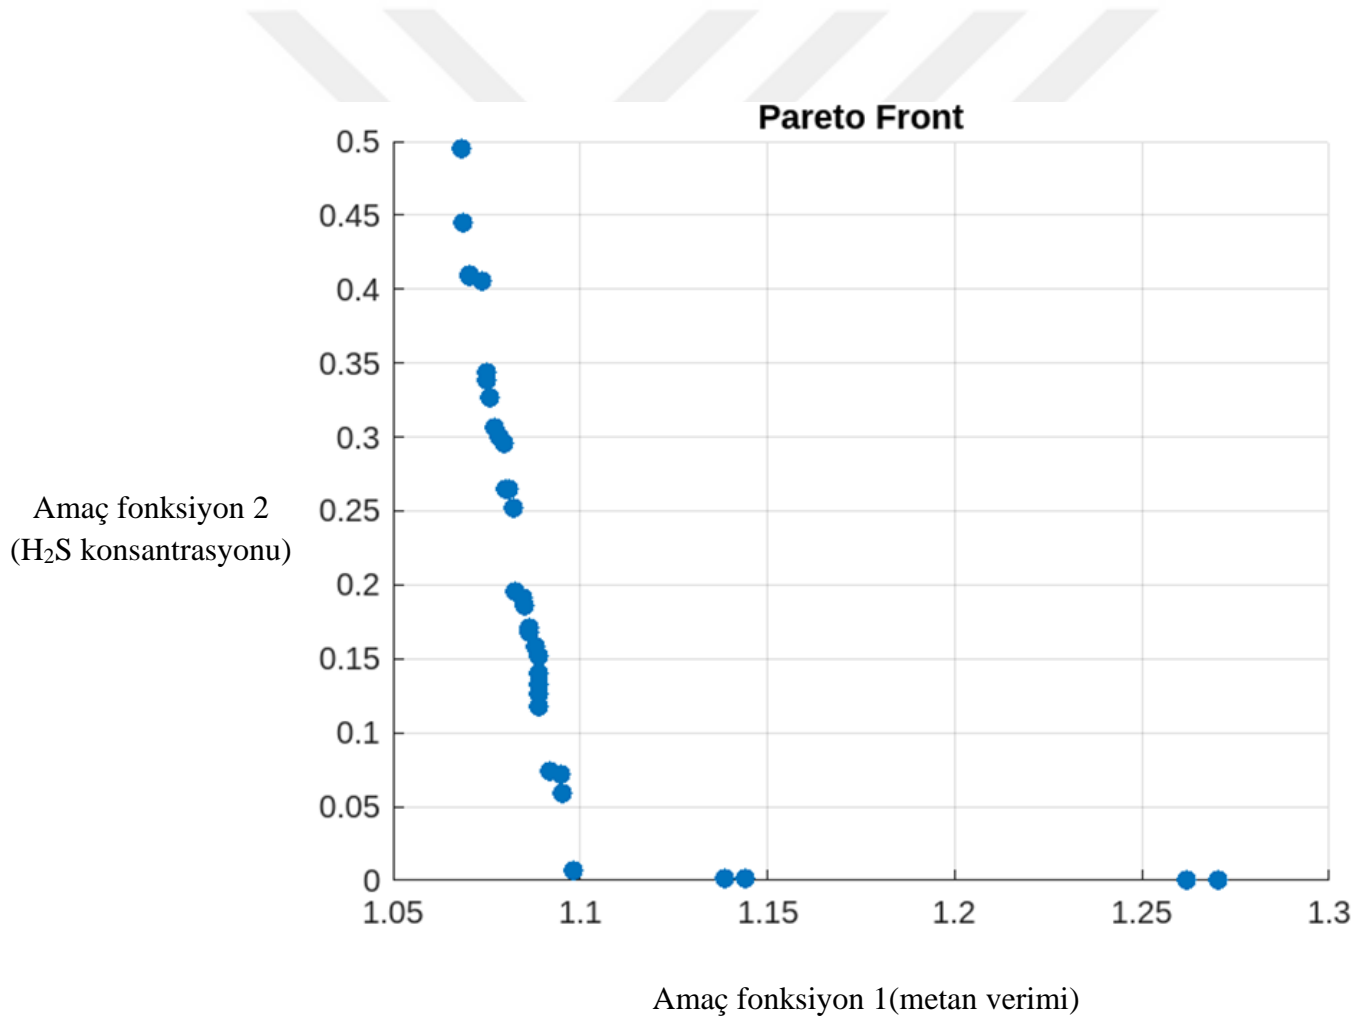
Şekil 6.16. H₂S konsantrasyonu üzerindeki girdi özelliklerinin göreceli önem yüzdelerini gösteren pasta grafiği.

Metan verimi açısından, giriş parametrelerinin gücü şu şekildedir: Çamur pH > Çamur toplam katıları > Çamur sıcaklığı > Çürütücü toplam katıları > Çürütücü alkalinitesi > Çürütücü uçucu yağ asitleri > Çamur uçucu katıları > Çürütücü uçucu katıları > Çürütücü sıcaklığı > Çürütücü pH > Çamur akış hızı. Garson'un araştırması, yoğunlaştırılmış çamurun pH seviyesinin metan verimi üzerinde en önemli etkiye sahip olduğunu ve tahmini göreceli önemin %15,81 olduğunu göstermektedir. Öte yandan, çamurun çürütücüye giren akış hızı %5,8 bağıl önem ile en düşük etkiye sahiptir. Hidrojen sülfid konsantrasyonları üzerinde %15 bağıl önemle en büyük etkiye çamur pH'ının sahip olduğu, çürütücü uçucu yağ asidinin ise %6,4 ile en düşük etkiye sahip olduğu bulunmuştur. İlginç bir şekilde, hem metan verimi hem de hidrojen sülfid üzerindeki çamur pH'ı, çamur sıcaklığı ve çamur toplam katı maddeleri dahil en büyük etki faktörleri aynıdır ve bu da optimizasyon sürecini daha zorlu hale getirir.

6.4 GA Optimizasyon Sonuçları

YSA modelinin bir diğer kullanımı, çıktı özelliklerinin optimal koşullarını yerine getirmek için giriş özelliklerinin değerlerinin seçilmesine yönelik optimizasyondur. Bu durumda metan verimini maksimuma çıkarmak ve hidrojen sülfid konsantrasyonunu en aza indirmek gerekir. Bu nedenle bu çalışmada çok amaçlı fonksiyonlar problemi analiz edilmektedir. Sorun üç adımda çözülmüştür. İlk olarak her bir çıktı için YSA modelinin formülü Denklem (3) kullanılarak çıkarılmıştır. YSA modelleri parametrik olmayan regresyon modelleridir; bu, tahminlerin, eğitim verilerinden tahmin edilen katsayılara sahip geleneksel regresyon modelleri gibi belirli bir parametre grubuna dayanmadığı anlamına gelir. Bu da tahminlerin yorumlanmasını daha da zorlaştırmaktadır. Çalışmada her katman için Denklem (3) kullanılarak, her çıktıya ait formül oluşturulmuştur. Bu, girdi katmanı ile gizli katman arasındaki ve ayrıca gizli katman ile çıktı katmanı arasındaki ağırlıkların ve önyargıların matrislere çıkarılmasını içermektedir. Daha sonra denklemlerin çıkarılması için Tansig ve Purlin'in aktivasyon fonksiyonları kullanılmıştır. İkinci olarak her denklem bir uygunluk fonksiyonu olarak değerlendirilmiştir. Metan verimi denklemi maksimize edilen amaç fonksiyonudur ve hidrojen sülfid denklemi minimuma indirilmiştir. Son olarak optimal çözümleri çözmek için genetik algoritma kullanılmıştır. Popülasyon büyüklüğü ve maksimum nesil büyüklüğü sırasıyla 200 ve 50 olarak ayarlanmıştır. Şekil 6.17, metan verimi ve hidrojen sülfid konsantrasyonundan oluşan iki amaç fonksiyonu arasındaki optimizasyona yönelik Pareto optimal çözümünü göstermektedir. Metanı maksimuma çıkarmak ve hidrojen

sülfiti minimuma indirmek için birçok optimal çözümün elde edilebileceğini göstermiştir. Aynı zamanda metan verimindeki artışın, gerçek verilerden elde edilen günlük 842 m³'lük maksimum noktadan %27'a ulaşabileceğini de gösterebilmektedir. Ancak hidrojen sülfid için hidrojen sülfidin konsantrasyonları yaklaşık 350 ila 2700 ppm arasında değişir. Çizelge 6.9, metanı maksimuma çıkarmak ve hidrojen sülfidi minimuma indirmek için girdi değişkenlerinin optimal çözümlerinin en iyi altı setini özetlemektedir. Sıfır ile bir aralığında normalizasyon yapıldığı dikkate alınarak optimal çözümler hesaplanmış, dolayısıyla nihai çözümleri elde etmek için denormalizasyon adımı uygulanmıştır.



Şekil 6.17. GA optimizasyonunu kullanarak metan ve hidrojen sülfid amaç fonksiyonları arasındaki Pareto optimal çözümleri.

Çizelge 6.9 En iyi çıktılara karşılık gelen girdi özelliklerinin optimum çözümleri

Giriş Değişkenleri	CH₄'teki artış yüzdesi	H₂S- ppm
6.4, 8.6, 52961, 29070, 167, 8.4, 25.5, 31800, 20725, 3343, 24140	27	350.5
6.2, 8.7, 49774, 24208, 157, 8.5, 24.5, 32575, 22747, 3242, 24632.5	26.18	352.4
7.5, 32, 65731, 34144, 75.6, 7.3, 22.2, 41125.5, 32422, 1125.7, 19098.8	14.4	354.7
7.5, 34, 65379.1, 36891.2, 68.2, 7.3, 21.9, 38998.1, 32352.3, 1094.1, 18141	9.8	382.4
7.5, 35.8, 65563, 37612, 65.2, 7.6, 21.9, 38518.5, 32805.5, 1096.6, 18102.2	9.5	627.8
7.5, 34.4, 65394.4, 37430.9, 66.9, 7.3, 21.9, 39067.8, 31811.9, 1095.2, 17985.9	9.2	699.2

7 SONUÇLAR VE ÖNERİLER

7.1 Sonuçlar

Bu çalışma, yapay zeka tekniklerini kullanarak, Konya Atıksu Arıtma Tesisi'ndeki anaerobik çürütme ünitesinin performansını başarıyla artırmıştır. Çalışma, bir yapay sinir ağı modeli için eğitim algoritması olarak Bayesian Regülasyonu kullanılmasıyla Levenberg-Marquardt kullanımına kıyasla en güvenilir ve doğrusu olduğunu ortaya koymuştur. Daha sonra YSA modelinden, metan verimi ve hidrojen sülfid gazları üzerindeki çeşitli faktörlerin etkisini belirlemek için yararlanılmıştır ve duyarlılık analizi kullanılarak, çürütme ünitesine girmeden önce yoğunlaştırılmış çamurun pH seviyesinin, göreceli olarak her iki gaz üzerinde en büyük etkiye sahip olduğu saptanmıştır. Önemi sırasıyla %15,8 ve %15'tir. Çalışma aynı zamanda metan verimini optimize ederken hidrojen sülfid konsantrasyonunu azaltmanın zorlu bir iş olduğunu, çünkü metanı etkileyen faktörlerin aynı zamanda hidrojen sülfidi de etkilediğini tespit etmiştir. GA tekniğinden yararlanarak optimizasyon problemini çözmek için amaç fonksiyonları olarak iki çıkışlı YSA modeli kullanılmıştır. Bu teknik ile metan verimi ve hidrojen sülfid konsantrasyonunun en iyi değerlerini elde etmek için girdi özellikleri ölçülmüştür. Sonuçlar, 350 ppm'de daha düşük hidrojen sülfid konsantrasyonlarına ulaşılırken metan üretiminin yaklaşık %27 artırılabilirliğini işaret etmektedir. Çalışma, yapay zeka tekniklerinin uygulanmasının döngüsel ekonomiyi nasıl artırabileceğini ve KAAT'ın ekonomik refahını nasıl koruyabileceğini göstermektedir. Daha fazla iyileştirme için yapay zekanın mekanik modellerle entegre edilmesi, anaerobik sindirimin karmaşık yapısının anlaşılmasının potansiyel faydalarını artırabilir.

7.2 Öneriler

Yapay Zeka modelleri, AÇ alanında geleneksel modellere göre çeşitli çözümler sunsa da birçok sınırlama ve zorluk dikkate alınmalıdır. Yapay zeka tabanlı modelleri eğitmek için büyük veri kümeleri gereklidir. Ancak bazı durumlarda modeli etkili bir şekilde eğitmek için yeterli verinin bulunmaması ve aynı zamanda seçilen değişkenler için aynı zaman aralığını elde etmekte zorluk yaşanması kuvvetle muhtemeldir (Luca vd., 2022). Yapay zeka modeli yalnızca girdiler ve çıktılar arasında bir eşleştirme ilişkisi sağlar ve üzerinde çalışılan sorun hakkında herhangi bir mekanizma bilgisi sunma yeteneğinden yoksundur. Bu ayırt edici özellik, yapay zeka modellerini geleneksel modellerden ayırmaktadır (Y. Wang vd., 2023). Bu geleneksel matematiksel modeller,

altta yatan mekanizmaları açıklar ancak yapay zeka modellerinin girdileri ve çıktıları arasındaki karmaşık doğrusal olmayan ilişkileri tanımlamada zorluklarla karşılaşır. Bu nedenle, bir kara kutu yapay zeka modelini beyaz kutulu geleneksel bir matematik modeliyle entegre etmek, bu miktarı önemli ölçüde azaltabilir. İhtiyaç duyulan verilerin toplanması ve değerli sonuçlar elde etme sürecinin basitleştirilmesi yaklaşımı (K. Li vd., 2022), AÇ'nin karmaşık ilişkilerini daha iyi anlamak için umut verici bir araç olabilir. Dahası, yapay zeka modellerinin yorumlanması, nöronlar, gizli katmanlar, ağırlıklar ve önyargılar gibi parametrelerinde fiziksel önem bulunmaması nedeniyle genellikle düşüktür ve bu da yorumlanabilirliklerinde bir sınırlamaya neden olur (Jawad vd., 2021). Eğitim, parametreleri optimize etme ve zayıf yorumlanabilirlik gibi zorlukların üstesinden gelmek için yapay zeka teknikleri üzerine daha fazla teorik araştırma yapılması gerekmektedir. Bu sırada, yapay sinir ağları için en uygun ağ mimarisinin belirlenmesi henüz standartlaştırılmamıştır ve çoğu zaman eldeki spesifik soruna bağlıdır. Şu anda deneme yanılma en geçerli yaklaşım olmaya devam etmektedir, ancak bu bazen aşırı uyum veya yetersiz uyum sorunlarına yol açabilir (Y. Wang vd., 2023). Yapay zekada transfer öğrenimi olarak bilinen bir süreç vardır; bu, eğitilen modellerin farklı eğitim verileriyle tekrar kullanılabilmesi anlamına gelir ve bir özetleyicinin operasyonel parametrelerinin orijinal modelinkilerle aynı hızda olmaması durumunda, bunun dikkate alınması önemlidir. Bir anaerobik çürütme sistemi üzerinde eğitilmiş modellerin başka bir çürütücüye doğrudan aktarılması mümkün olmayabilir (Rutland vd., 2023). Ayrıca, biyogaz tesislerinin izleme sistemlerinin, altyapılarının doğru tahminler için gerekli veri talebini karşılayıp karşılayamayacağını belirlemek amacıyla değerlendirilmesi büyük önem taşımaktadır. Bu değerlendirme, yapay zeka teknolojilerinin AÇ operasyonlarında uygulanmasının fizibilitesinin belirlenmesinde hayati öneme sahiptir (C. Li vd., 2022).

8. KAYNAKLAR

- Agwu, O. E., Akpabio, J. U., & Dosunmu, A. (2020). Artificial neural network model for predicting the density of oil-based muds in high-temperature, high-pressure wells. *Journal of Petroleum Exploration and Production Technology*, 10(3), 1081–1095. <https://doi.org/10.1007/s13202-019-00802-6>
- Ahmad, T., Ahmad, K., & Alam, M. (2017). Sludge quantification at water treatment plant and its management scenario. *Environmental Monitoring and Assessment*, 189(9), 453. <https://doi.org/10.1007/s10661-017-6166-1>
- Alaloul, W. S., & Qureshi, A. H. (2020). Data Processing Using Artificial Neural Networks. In D. G. Harkut (Ed.), *Dynamic Data Assimilation*. IntechOpen. <https://doi.org/10.5772/intechopen.91935>
- Andrade Cruz, I., Chuenchart, W., Long, F., Surendra, K. C., Renata Santos Andrade, L., Bilal, M., Liu, H., Tavares Figueiredo, R., Khanal, S. K., & Fernando Romanholo Ferreira, L. (2022). Application of machine learning in anaerobic digestion: Perspectives and challenges. *Bioresource Technology*, 345, 126433. <https://doi.org/10.1016/J.BIORTECH.2021.126433>
- Arıman, S., Koyuncu, S., & Metropolitan Municipality, K. (2021). *Removal of Hydrogen Sulde in Biogas From Wastewater Treatment Sludge by Real Scale Biotrickling Filtration Desulfurization Process*. <https://doi.org/10.21203/rs.3.rs-696411/v1>
- Bakdi, A., & Kouadri, A. (2017). A new adaptive PCA based thresholding scheme for fault detection in complex systems. *Chemometrics and Intelligent Laboratory Systems*, 162, 83–93. <https://doi.org/10.1016/J.CHEMOLAB.2017.01.013>
- Bao, Y., Koutavarapu, R., & Lee, T.-G. (2023). Derivation of Optimal Operation Factors of Anaerobic Digesters through Artificial Neural Network Technology. *Systems*, 11(7). <https://doi.org/10.3390/systems11070375>
- Bejani, M. M., & Ghatee, M. (2021). A systematic review on overfitting control in shallow and deep neural networks. *Artificial Intelligence Review*, 54(8), 6391–6438. <https://doi.org/10.1007/s10462-021-09975-1>
- Bragança, I., Sánchez-Soberón, F., Pantuzza, G. F., Alves, A., & Ratola, N. (2020). Impurities in biogas: Analytical strategies, occurrence, effects and removal technologies. *Biomass and Bioenergy*, 143, 105878. <https://doi.org/10.1016/J.BIOMBIOE.2020.105878>

- Buonocore, E., Mellino, S., De Angelis, G., Liu, G., & Ulgiati, S. (2018). Life cycle assessment indicators of urban wastewater and sewage sludge treatment. *Ecological Indicators*, *94*, 13–23. <https://doi.org/10.1016/J.ECOLIND.2016.04.047>
- Cai, W., Long, F., Wang, Y., Liu, H., & Guo, K. (2021). Enhancement of microbiome management by machine learning for biological wastewater treatment. *Microbial Biotechnology*, *14*(1), 59–62. <https://doi.org/https://doi.org/10.1111/1751-7915.13707>
- Carballa, M., Regueiro, L., & Lema, J. M. (2015). Microbial management of anaerobic digestion: exploiting the microbiome-functionality nexus. *Current Opinion in Biotechnology*, *33*, 103–111. <https://doi.org/10.1016/J.COPBIO.2015.01.008>
- Carr, J. (2014). *An Introduction to Genetic Algorithms*. <https://api.semanticscholar.org/CorpusID:20274694>
- Chen, J. L., Ortiz, R., Steele, T. W. J., & Stuckey, D. C. (2014). Toxicants inhibiting anaerobic digestion: A review. *Biotechnology Advances*, *32*(8), 1523–1534. <https://doi.org/10.1016/J.BIOTECHADV.2014.10.005>
- Chen, J. W., Chan, Y. J., Arumugasamy, S. K., & Yazdi, S. K. (2023). Process modelling and optimisation of methane yield from palm oil mill effluent using response surface methodology and artificial neural network. *Journal of Water Process Engineering*, *52*, 103493. <https://doi.org/10.1016/J.JWPE.2023.103493>
- Chen, W.-Y., Chan, Y. J., Lim, J. W., Liew, C. S., Mohamad, M., Ho, C.-D., Usman, A., Lisak, G., Hara, H., & Tan, W.-N. (2022). Artificial Neural Network (ANN) Modelling for Biogas Production in Pre-Commercialized Integrated Anaerobic-Aerobic Bioreactors (IAAB). *Water*, *14*(9). <https://doi.org/10.3390/w14091410>
- Cheng, F., & Zhao, J. (2019). A novel process monitoring approach based on Feature Points Distance Dynamic Autoencoder. *Computer Aided Chemical Engineering*, *46*, 757–762. <https://doi.org/10.1016/B978-0-12-818634-3.50127-2>
- Cheon, A., Sung, J., Jun, H., Jang, H., Kim, M., & Park, J. (2022). Application of Various Machine Learning Models for Process Stability of Bio-Electrochemical Anaerobic Digestion. *Processes*, *10*(1). <https://doi.org/10.3390/pr10010158>
- Cinar, S., Cinar, S. O., Wiczorek, N., Soho, I., & Kuchta, K. (2021). Integration of Artificial Intelligence into Biogas Plant Operation. *Processes*, *9*(1). <https://doi.org/10.3390/pr9010085>
- CÖMERT, Z., & KOCAMAZ, A. (2017). A Study of Artificial Neural Network Training Algorithms for Classification of Cardiotocography Signals. *Bitlis Eren University Journal of Science and Technology*, *7*(2), 93–103. <https://doi.org/10.17678/beuscitech.338085>

- Cristianini, N., & Scholkopf, B. (2002). Support Vector Machines and Kernel Methods: The New Generation of Learning Machines. *AI Magazine*, 23(3), 31. <https://doi.org/10.1609/aimag.v23i3.1655>
- De Clercq, D., Wen, Z., Fan, F., & Caicedo, L. (2016). Biomethane production potential from restaurant food waste in megacities and project level-bottlenecks: A case study in Beijing. *Renewable and Sustainable Energy Reviews*, 59, 1676–1685. <https://doi.org/10.1016/J.RSER.2015.12.323>
- Deepnarain, N., Nasr, M., Kumari, S., Stenström, T. A., Reddy, P., Pillay, K., & Bux, F. (2019). Decision tree for identification and prediction of filamentous bulking at full-scale activated sludge wastewater treatment plant. *Process Safety and Environmental Protection*, 126, 25–34. <https://doi.org/10.1016/J.PSEP.2019.02.023>
- Deng, L., Liu, Y., Zheng, D., Wang, L., Pu, X., Song, L., Wang, Z., Lei, Y., Chen, Z., & Long, Y. (2017a). Application and development of biogas technology for the treatment of waste in China. *Renewable and Sustainable Energy Reviews*, 70, 845–851. <https://doi.org/10.1016/J.RSER.2016.11.265>
- Deng, L., Liu, Y., Zheng, D., Wang, L., Pu, X., Song, L., Wang, Z., Lei, Y., Chen, Z., & Long, Y. (2017b). Application and development of biogas technology for the treatment of waste in China. *Renewable and Sustainable Energy Reviews*, 70, 845–851. <https://doi.org/10.1016/J.RSER.2016.11.265>
- Dinç, İ., Sigdel, M., Dinç, S., Sigdel, M. S., Pusey, M. L., & Aygün, R. S. (2014). Evaluation of normalization and PCA on the performance of classifiers for protein crystallization images. *IEEE SOUTHEASTCON 2014*, 1–6. <https://doi.org/10.1109/SECON.2014.6950744>
- Dönemler, Toplu Boyut, Yinelemeler - Neden Önemlidirler.* (n.d.). Retrieved July 21, 2024, from <https://www.sabrepc.com/blog/Deep-Learning-and-AI/EPOCHS-Batch-Size-Iterations>
- Ehalt Macedo, H., Lehner, B., Nicell, J., Grill, G., Li, J., Limtong, A., & Shakya, R. (2022). Distribution and characteristics of wastewater treatment plants within the global river network. *Earth System Science Data*, 14(2), 559–577. <https://doi.org/10.5194/essd-14-559-2022>
- Fuchs, E. F., & Masoum, M. A. S. (2023). Optimal placement and sizing of shunt capacitor banks in the presence of harmonics. *Power Quality in Power Systems, Electrical Machines, and Power-Electronic Drives*, 1017–1085. <https://doi.org/10.1016/B978-0-12-817856-0.00011-X>
- FuRui, Al-Absi, M. A., & Lee, H. J. (2019). Introduce a Specific Process of Genetic Algorithm through an Example. *2019 International Conference on Information and Communication*

- Gershman, S. J., Horvitz, E. J., & Tenenbaum, J. B. (2015). Computational rationality: A converging paradigm for intelligence in brains, minds, and machines. *Science*, 349(6245), 273–278. <https://doi.org/10.1126/science.aac6076>
- Guo, H. nan, Wu, S. biao, Tian, Y. jie, Zhang, J., & Liu, H. tao. (2021). Application of machine learning methods for the prediction of organic solid waste treatment and recycling processes: A review. *Bioresource Technology*, 319, 124114. <https://doi.org/10.1016/J.BIORTECH.2020.124114>
- Handayani, A. N., Lathifah, N., Herwanto, H. W., Andrie Asmara, R., & Arai, K. (2018). Neural Network Bayesian Regularization Backpropagation to Solve Inverse Kinematics on Planar Manipulator. *2018 Joint 7th International Conference on Informatics, Electronics & Vision (ICIEV) and 2018 2nd International Conference on Imaging, Vision & Pattern Recognition (IcIVPR)*, 99–104. <https://doi.org/10.1109/ICIEV.2018.8640958>
- Heo, S. K., Nam, K. J., Tariq, S., Lim, J. Y., Park, J., & Yoo, C. K. (2021). A hybrid machine learning–based multi-objective supervisory control strategy of a full-scale wastewater treatment for cost-effective and sustainable operation under varying influent conditions. *Journal of Cleaner Production*, 291, 125853. <https://doi.org/10.1016/J.JCLEPRO.2021.125853>
- Jaafar, J., Danyaro, K. U., & Liew, M. S. (2016). Web Intelligence: A Fuzzy Knowledge-Based Framework for the Enhancement of Querying and Accessing Web Data. In I. R. Management Association (Ed.), *Big Data: Concepts, Methodologies, Tools, and Applications* (pp. 711–733). IGI Global. <https://doi.org/10.4018/978-1-4666-9840-6.ch033>
- Jawad, J., Hawari, A. H., & Javaid Zaidi, S. (2021). Artificial neural network modeling of wastewater treatment and desalination using membrane processes: A review. *Chemical Engineering Journal*, 419, 129540. <https://doi.org/10.1016/J.CEJ.2021.129540>
- Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. In *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* (Vol. 374, Issue 2065). Royal Society of London. <https://doi.org/10.1098/rsta.2015.0202>
- Kabeyi, M. J. B., & Olanrewaju, O. A. (2022). Biogas Production and Applications in the Sustainable Energy Transition. *Journal of Energy*, 2022, 8750221. <https://doi.org/10.1155/2022/8750221>
- Kalogirou, S. A. (2014). Designing and Modeling Solar Energy Systems. *Solar Energy Engineering*, 583–699. <https://doi.org/10.1016/B978-0-12-397270-5.00011-X>

- Kang, H. (2013). The prevention and handling of the missing data. *Korean Journal of Anesthesiology*, 64(5), 402–406. <https://doi.org/10.4097/kjae.2013.64.5.402>
- Kasinath, A., Fudala-Ksiazek, S., Szopinska, M., Bylinski, H., Artichowicz, W., Remiszewska-Skwarek, A., & Luczkiewicz, A. (2021). Biomass in biogas production: Pretreatment and codigestion. *Renewable and Sustainable Energy Reviews*, 150, 111509. <https://doi.org/10.1016/J.RSER.2021.111509>
- Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, 80(5), 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>
- Kazemi, P., Bengoa, C., Steyer, J. P., & Giralt, J. (2021). Data-driven techniques for fault detection in anaerobic digestion process. *Process Safety and Environmental Protection*, 146, 905–915. <https://doi.org/10.1016/J.PSEP.2020.12.016>
- Kazemi, P., Giralt, J., Bengoa, C., Masoumian, A., & Steyer, J.-P. (2020). Fault detection and diagnosis in water resource recovery facilities using incremental PCA. *Water Science and Technology*, 82(12), 2711–2724. <https://doi.org/10.2166/wst.2020.368>
- Kim, J. W., Lee, B. H., Shaw, M. J., Chang, H.-L., & Nelson, M. (2001). Application of Decision-Tree Induction Techniques to Personalized Advertisements on Internet Storefronts. *International Journal of Electronic Commerce*, 5(3), 45–62. <http://www.jstor.org/stable/27750981>
- Kitao, A. (2022). Principal Component Analysis and Related Methods for Investigating the Dynamics of Biological Macromolecules. *J*, 5(2), 298–317. <https://doi.org/10.3390/j5020021>
- Kougias, P. G., & Angelidaki, I. (2018). Biogas and its opportunities—A review. *Frontiers of Environmental Science & Engineering*, 12(3), 14. <https://doi.org/10.1007/s11783-018-1037-8>
- Kumar, S., & Ravi, V. (n.d.). Explainable Deep Belief Network based Auto encoder using novel Extended Garson Algorithm. *Institute for Development and Research in Banking Technology (IDRBT)*.
- Lawson, C. E., Harcombe, W. R., Hatzenpichler, R., Lindemann, S. R., Löffler, F. E., O'Malley, M. A., García Martín, H., Pflieger, B. F., Raskin, L., Venturelli, O. S., Weissbrodt, D. G., Noguera, D. R., & McMahon, K. D. (2019). Common principles and best practices for engineering microbiomes. *Nature Reviews Microbiology*, 17(12), 725–741. <https://doi.org/10.1038/s41579-019-0255-9>

- Lee, D.-H., Kim, Y.-T., & Lee, S.-R. (2020). Shallow Landslide Susceptibility Models Based on Artificial Neural Networks Considering the Factor Selection Method and Various Non-Linear Activation Functions. *Remote Sensing*, *12*(7). <https://doi.org/10.3390/rs12071194>
- Li, C., He, P., Peng, W., Lü, F., Du, R., & Zhang, H. (2022). Exploring available input variables for machine learning models to predict biogas production in industrial-scale biogas plants treating food waste. *Journal of Cleaner Production*, *380*, 135074. <https://doi.org/10.1016/J.JCLEPRO.2022.135074>
- Li, K., Duan, H., Liu, L., Qiu, R., van den Akker, B., Ni, B.-J., Chen, T., Yin, H., Yuan, Z., & Ye, L. (2022). An Integrated First Principal and Deep Learning Approach for Modeling Nitrous Oxide Emissions from Wastewater Treatment Plants. *Environmental Science & Technology*, *56*(4), 2816–2826. <https://doi.org/10.1021/acs.est.1c05020>
- Liu, L., & Lei, Y. (2018). An accurate ecological footprint analysis and prediction for Beijing based on SVM model. *Ecological Informatics*, *44*, 33–42. <https://doi.org/10.1016/J.ECOINF.2018.01.003>
- Lu, W., Sarkar, A., Hou, M., Liu, W., Guo, X., Zhao, K., & Zhao, M. (2022). The Impacts of Urbanization to Improve Agriculture Water Use Efficiency_ An Empirical Analysis Based on Spatial Perspective of Panel Data of 30 Provinces of China. *Land*, *11*(1). <https://doi.org/10.3390/land11010080>
- Lu, Y., Ye, T., & Zheng, J. (2022). Decision Tree Algorithm in Machine Learning. *2022 IEEE International Conference on Advances in Electrical Engineering and Computer Applications (AEECA)*, 1014–1017. <https://doi.org/10.1109/AEECA55500.2022.9918857>
- Luca, A. R., Ursuleanu, T. F., Gheorghe, L., Grigorovici, R., Iancu, S., Hlusneac, M., & Grigorovici, A. (2022). Impact of quality, type and volume of data used by deep learning models in the analysis of medical images. *Informatics in Medicine Unlocked*, *29*, 100911. <https://doi.org/10.1016/J.IMU.2022.100911>
- M. Almufti, S., Ahmad Shaban, A., Ismael Ali, R., & A. Dela Fuente, J. (2023). Overview of Metaheuristic Algorithms. *Polaris Global Journal of Scholarly Research and Trends*, *2*(2), 10–32. <https://doi.org/10.58429/pgjsrt.v2n2a144>
- Mafalda, L., & Fernandes, S. (2014). *Modeling Anaerobic Digestion with Artificial Neural Networks*.
- Mathur, P., & Singh, S. (2022). Analyze mathematical model for optimization of anaerobic digestion for treatment of waste water. *Materials Today: Proceedings*, *62*, 5575–5582. <https://doi.org/10.1016/J.MATPR.2022.04.606>

- Mendes, C., da Silva Magalhes, R., Esquerre, K., & Queiroz, L. M. (2015). Artificial Neural Network Modeling for Predicting Organic Matter in a Full-Scale Up-Flow Anaerobic Sludge Blanket (UASB) Reactor. *Environmental Modeling & Assessment*, 20(6), 625–635. <https://doi.org/10.1007/s10666-015-9450-x>
- Mohseni-Dargah, M., Falahati, Z., Dabirmanesh, B., Nasrollahi, P., & Khajeh, K. (2022). Machine learning in surface plasmon resonance for environmental monitoring. *Artificial Intelligence and Data Science in Environmental Sensing*, 269–298. <https://doi.org/10.1016/B978-0-323-90508-4.00012-5>
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of Artificial Neural Networks and Deep Learning. In O. A. Montesinos López, A. Montesinos López, & J. Crossa (Eds.), *Multivariate Statistical Machine Learning Methods for Genomic Prediction* (pp. 379–425). Springer International Publishing. https://doi.org/10.1007/978-3-030-89010-0_10
- Newhart, K. B., Holloway, R. W., Hering, A. S., & Cath, T. Y. (2019). Data-driven performance analyses of wastewater treatment plants: A review. *Water Research*, 157, 498–513. <https://doi.org/10.1016/J.WATRES.2019.03.030>
- Nikolic, K. P. (2015). Stochastic Search Algorithms for Identification, Optimization, and Training of Artificial Neural Networks. *Advances in Artificial Neural Systems*, 2015, 931379. <https://doi.org/10.1155/2015/931379>
- Obaideen, K., Shehata, N., Sayed, E. T., Abdelkareem, M. A., Mahmoud, M. S., & Olabi, A. G. (2022). The role of wastewater treatment in achieving sustainable development goals (SDGs) and sustainability guideline. *Energy Nexus*, 7, 100112. <https://doi.org/10.1016/J.NEXUS.2022.100112>
- Olakanmi, O. O., Nnoli, K. P., Odeyemi, K. O., & Benyeogor, M. S. (2021). Enhanced Secure Process Control and Data Routing for Multi-plant Biogas Production System in IoT Environment: A Practical Approach to Securing Smart Bio-energy Infrastructure. *2021 International Symposium on Networks, Computers and Communications (ISNCC)*, 1–5. <https://doi.org/10.1109/ISNCC52172.2021.9615644>
- Oloko-Oba, M. I., Taiwo, A. E., Ajala, S. O., Solomon, B. O., & Betiku, E. (2018). Performance evaluation of three different-shaped bio-digesters for biogas production and optimization by artificial neural network integrated with genetic algorithm. *Sustainable Energy Technologies and Assessments*, 26, 116–124. <https://doi.org/10.1016/J.SETA.2017.10.006>
- Owhonka, A., Fubara, E. F., & Justice, O. B. (2021). Wastewater Quality- It's Impact on the Environment and Human Physiology: A Review. *International Journal of Advance Research and Innovation*, 9(4), 43–58. <https://doi.org/10.51976/ijari.942107>

- Palma-Heredia, D., Verdaguer, M., Puig, V., Poch, M., & Cugueró-Escofet, M. À. (2022). Comparison of Optimisation Algorithms for Centralised Anaerobic Co-Digestion in a Real River Basin Case Study in Catalonia. *Sensors*, 22(5). <https://doi.org/10.3390/s22051857>
- Papageorgiou, G., Grant, S. W., Takkenberg, J. J. M., & Mokhles, M. M. (2018). Statistical primer: how to deal with missing data in scientific research?†. *Interactive CardioVascular and Thoracic Surgery*, 27(2), 153–158. <https://doi.org/10.1093/icvts/ivy102>
- Pink, C. M. (2016). Forensic Ancestry Assessment Using Cranial Nonmetric Traits Traditionally Applied to Biological Distance Studies. *Biological Distance Analysis: Forensic and Bioarchaeological Perspectives*, 213–230. <https://doi.org/10.1016/B978-0-12-801966-5.00011-1>
- Poh, P. E., Gouwanda, D., Mohan, Y., Gopalai, A. A., & Tan, H. M. (2016). Optimization of Wastewater Anaerobic Digestion Using Mechanistic and Meta-heuristic Methods: Current Limitations and Future Opportunities. *Water Conservation Science and Engineering*, 1(1), 1–20. <https://doi.org/10.1007/s41101-016-0001-3>
- Qadir, M., Drechsel, P., Jiménez Cisneros, B., Kim, Y., Pramanik, A., Mehta, P., & Olaniyan, O. (2020). Global and regional potential of wastewater as a water, nutrient and energy source. *Natural Resources Forum*, 44(1), 40–51. <https://doi.org/https://doi.org/10.1111/1477-8947.12187>
- Qin, S. J. (2012). Survey on data-driven industrial process monitoring and diagnosis. *Annual Reviews in Control*, 36(2), 220–234. <https://doi.org/10.1016/J.ARCONTROL.2012.09.004>
- Rachmatullah, M. I. C., Santoso, J., & Surendro, K. (2021). Determining the number of hidden layer and hidden neuron of neural network for wind speed prediction. *PeerJ Computer Science*, 7, 1–19. <https://doi.org/10.7717/PEERJ-CS.724>
- Rajwar, K., Deep, K., & Das, S. (2023). An exhaustive review of the metaheuristic algorithms for search and optimization: taxonomy, applications, and open challenges. *Artificial Intelligence Review*, 56(11), 13187–13257. <https://doi.org/10.1007/s10462-023-10470-y>
- Ramachandran, A., Rustum, R., & Adeloye, A. J. (2019). Review of Anaerobic Digestion Modeling and Optimization Using Nature-Inspired Techniques. *Processes*, 7(12). <https://doi.org/10.3390/pr7120953>
- Ramadan, M. Z., & Abou El-Ez, S. R. S. (2000). DEVELOPMENT OF A GENETIC ALGORITHM BASED ON FUZZY LOGIC SETS FOR SOLVING FACILITY LAYOUT PROBLEMS. *Current Advances in Mechanical Design and Production VII*, 571–578. <https://doi.org/10.1016/B978-008043711-8/50058-1>

- Ritari, J., Koskinen, K., Hultman, J., Kurola, J. M., Kymäläinen, M., Romantschuk, M., Paulin, L., & Auvinen, P. (2012). Molecular analysis of meso- and thermophilic microbiota associated with anaerobic biowaste degradation. *BMC Microbiology*, *12*(1), 121. <https://doi.org/10.1186/1471-2180-12-121>
- Rutland, H., You, J., Liu, H., Bull, L., & Reynolds, D. (2023). A Systematic Review of Machine-Learning Solutions in Anaerobic Digestion. *Bioengineering*, *10*(12). <https://doi.org/10.3390/bioengineering10121410>
- Sadoughi, F., & Arani, L. A. (2022). Intelligent computer systems for multiple sclerosis diagnosis. *Augmenting Neurological Disorder Prediction and Rehabilitation Using Artificial Intelligence*, 75–105. <https://doi.org/10.1016/B978-0-323-90037-9.00001-1>
- Saha, N., Swetapadma, A., & Mondal, M. (2023). A Brief Review on Artificial Neural Network: Network Structures and Applications. *2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS)*, *1*, 1974–1979. <https://doi.org/10.1109/ICACCS57279.2023.10112753>
- Sakiewicz, P., Piotrowski, K., Ober, J., & Karwot, J. (2020). Innovative artificial neural network approach for integrated biogas – wastewater treatment system modelling: Effect of plant operating parameters on process intensification. *Renewable and Sustainable Energy Reviews*, *124*, 109784. <https://doi.org/10.1016/J.RSER.2020.109784>
- Sánchez-Fernández, A., Baldán, F. J., Sainz-Palmero, G. I., Benítez, J. M., & Fuente, M. J. (2018). Fault detection based on time series modeling and multivariate statistical process control. *Chemometrics and Intelligent Laboratory Systems*, *182*, 57–69. <https://doi.org/10.1016/J.CHEMOLAB.2018.08.003>
- Sapna, S. (2012). *Backpropagation Learning Algorithm Based on Levenberg Marquardt Algorithm*. 393–398. <https://doi.org/10.5121/csit.2012.2438>
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, *2*(6), 420. <https://doi.org/10.1007/s42979-021-00815-1>
- Sarker, I. H. (2022). AI-Based Modeling: Techniques, Applications and Research Issues Towards Automation, Intelligent and Smart Systems. *SN Computer Science*, *3*(2), 158. <https://doi.org/10.1007/s42979-022-01043-x>
- Sarker, I. H., Furhad, M. H., & Nowrozy, R. (2021). AI-Driven Cybersecurity: An Overview, Security Intelligence Modeling and Research Directions. *SN Computer Science*, *2*(3), 173. <https://doi.org/10.1007/s42979-021-00557-0>

- Sarker, I. H., Kayes, A. S. M., Badsha, S., Alqahtani, H., Watters, P., & Ng, A. (2020). Cybersecurity data science: an overview from machine learning perspective. *Journal of Big Data*, 7(1), 41. <https://doi.org/10.1186/s40537-020-00318-5>
- SAZLI, M. H. (2006). A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 50(01). https://doi.org/10.1501/commua1-2_0000000026
- Selvanathan, M., Jayabalan, N., & Hussain, N. (n.d.). *Employee Productivity in Malaysian Private Higher Educational Institutions*. <https://doi.org/10.48080/jae.v17i3.50>
- Şenocak, D. (2020). Açık ve uzaktan öğrenme ortamlarında yapay zekâ: Sunduğu fırsatlar ve yarattığı endişeler. *Açıköğretim Uygulamaları ve Araştırmaları Dergisi*, 6(3), 56–78.
- Siddique, N., & Adeli, H. (2015). Nature Inspired Computing: An Overview and Some Future Directions. *Cognitive Computation*, 7(6), 706–714. <https://doi.org/10.1007/s12559-015-9370-8>
- Sina Faizollahzadeh Ardabili Bahman Najafi, S. S. B. M. B. R. C. D., & Chau, K. (2018). Computational intelligence approach for modeling hydrogen production: a review. *Engineering Applications of Computational Fluid Mechanics*, 12(1), 438–458. <https://doi.org/10.1080/19942060.2018.1452296>
- Sola, J., & Sevilla, J. (1997). Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on Nuclear Science*, 44(3), 1464–1468. <https://doi.org/10.1109/23.589532>
- Stenuit, B., & Agathos, S. N. (2015). Deciphering microbial community robustness through synthetic ecology and molecular systems synecology. *Current Opinion in Biotechnology*, 33(1), 305–317. <https://doi.org/10.1016/J.COPBIO.2015.03.012>
- Steyer, J.-P., Rolland, D., Bouvier, J.-C., & Moletta, R. (1997). Hybrid fuzzy neural network for diagnosis - application to the anaerobic treatment of wine distillery wastewater in a fluidized bed reactor. *Water Science and Technology*, 36(6–7), 209–217. <https://doi.org/10.2166/wst.1997.0593>
- Strik, D. P. B. T. B., Domnanovich, A. M., Zani, L., Braun, R., & Holubar, P. (2005). Prediction of trace compounds in biogas from anaerobic digestion using the MATLAB Neural Network Toolbox. *Environmental Modelling & Software*, 20(6), 803–810. <https://doi.org/10.1016/J.ENVSOFT.2004.09.006>
- Su ve Sanitasyon - Birleşmiş Milletler Sürdürülebilir Kalkınma*. (n.d.). Retrieved July 21, 2024, from <https://www.un.org/sustainabledevelopment/water-and-sanitation/>

- Tahmasebi, P., & Hezarkhani, A. (2012). A hybrid neural networks-fuzzy logic-genetic algorithm for grade estimation. *Computers & Geosciences*, 42, 18–27. <https://doi.org/10.1016/J.CAGEO.2012.02.004>
- Teng, Y., Yang, J., Zuo, R., & Wang, J. (2011). Impact of urbanization and industrialization upon surface water quality: A pilot study of Panzhuhua mining town. *Journal of Earth Science*, 22(5), 658–668. <https://doi.org/10.1007/s12583-011-0217-2>
- Thakur, S., & Ghosh, S. (2023). Recent advances in transcriptomic biomarker detection for cancer. *Transcriptome Profiling: Progress and Prospects*, 453–478. <https://doi.org/10.1016/B978-0-323-91810-7.00007-8>
- van Lier, J., Mahmoud, N., & Zeeman, G. (2023). Anaerobic wastewater treatment. In *Biological Wastewater Treatment: Principles, Modelling, and Design*. https://doi.org/10.2166/9781789060362_0701
- Villarrubia, G., De Paz, J. F., Chamoso, P., & la Prieta, F. De. (2018). Artificial neural networks used in optimization problems. *Neurocomputing*, 272, 10–16. <https://doi.org/10.1016/J.NEUCOM.2017.04.075>
- Vu, H. P., Nguyen, L. N., Wang, Q., Ngo, H. H., Liu, Q., Zhang, X., & Nghiem, L. D. (2022). Hydrogen sulphide management in anaerobic digestion: A critical review on input control, process regulation, and post-treatment. *Bioresource Technology*, 346, 126634. <https://doi.org/10.1016/J.BIORTECH.2021.126634>
- Wang, Y., Cheng, Y., Liu, H., Guo, Q., Dai, C., Zhao, M., & Liu, D. (2023). A Review on Applications of Artificial Intelligence in Wastewater Treatment. *Sustainability*, 15(18). <https://doi.org/10.3390/su151813557>
- Wang, Z., Peng, X., Xia, A., Shah, A. A., Huang, Y., Zhu, X., Zhu, X., & Liao, Q. (2022). The role of machine learning to boost the bioenergy and biofuels conversion. *Bioresource Technology*, 343, 126099. <https://doi.org/10.1016/J.BIORTECH.2021.126099>
- Wongburi, P., & Park, J. K. (2021). Big Data Analytics from a Wastewater Treatment Plant. *Sustainability*, 13(22). <https://doi.org/10.3390/su132212383>
- Wu, Y., Zhang, G., Zhang, Y., & Wang, B. (2022). Design of Biogas Production Prediction Model Based on Improved BP Neural Network and Genetic Algorithm. *Journal of Physics: Conference Series*, 2401(1), 12076. <https://doi.org/10.1088/1742-6596/2401/1/012076>
- Xu, B. (2010). Grading of cotton by color measurement. *Colour Measurement: Principles, Advances and Industrial Applications*, 253–278. <https://doi.org/10.1533/9780857090195.2.253>

- Yang, X.-S. (2012). Nature-Inspired Metaheuristic Algorithms: Success and New Challenges. *Journal of Computer Engineering and Information Technology*, 01(01). <https://doi.org/10.4172/2324-9307.1000e101>
- Yang, X.-S. (2014). Particle Swarm Optimization. *Nature-Inspired Optimization Algorithms*, 99–110. <https://doi.org/10.1016/B978-0-12-416743-8.00007-5>
- Yildirim, O., & Ozkaya, B. (2023a). Prediction of biogas production of industrial scale anaerobic digestion plant by machine learning algorithms. *Chemosphere*, 335, 138976. <https://doi.org/10.1016/J.CHEMOSPHERE.2023.138976>
- Yildirim, O., & Ozkaya, B. (2023b). Prediction of biogas production of industrial scale anaerobic digestion plant by machine learning algorithms. *Chemosphere*, 335, 138976. <https://doi.org/10.1016/J.CHEMOSPHERE.2023.138976>
- Ying, X. (2019). An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, 1168(2). <https://doi.org/10.1088/1742-6596/1168/2/022022>
- Yu, Z., Haghghat, F., Fung, B. C. M., & Yoshino, H. (2010). A decision tree method for building energy demand modeling. *Energy and Buildings*, 42(10), 1637–1646. <https://doi.org/10.1016/J.ENBUILD.2010.04.006>
- Zarei, M., Bayati, M. R., Ebrahimi-Nik, M., Rohani, A., & Hejazi, B. (2023). Modelling the removal efficiency of hydrogen sulfide from biogas in a biofilter using multiple linear regression and support vector machines. *Journal of Cleaner Production*, 404, 136965. <https://doi.org/10.1016/J.JCLEPRO.2023.136965>
- Zhou, R., Wu, D., Fang, L., Xu, A., & Lou, X. (2018). A Levenberg–Marquardt Backpropagation Neural Network for Predicting Forest Growing Stock Based on the Least-Squares Equation Fitting Parameters. *Forests*, 9(12). <https://doi.org/10.3390/f9120757>