



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

**KENTSEL ATIKSU ARITMA TESİSİ VERİMİNİN YAPAY
SİNİR AĞI İLE MODELLEMESİ: KONYA İLİ ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

Ülkü SERTKAN AYDIN

DANIŞMAN

Dr. Öğretim Üyesi Gamze SÖNMEZ

AKSARAY, 2024

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 212301408 numaralı Yüksek Lisans öğrencisi Ülkü SERTKAN AYDIN tarafından hazırlanan “**KENTSEL ATIKSU ARITMA TESİSİ VERİMİNİN YAPAY SİNİR AĞI İLE MODELLEMESİ: KONYA İLİ ÖRNEĞİ**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Çevre Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğretim Üyesi Gamze SÖNMEZ

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Dr. Öğr. Üyesi Ebru KOÇAK

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Doç. Dr. Fatma KUNT

Necmettin Erbakan Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.....

Tez Savunma Tarihi: 25/06/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Mehmet Ali HINIS

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinalliğini ve her türlü intihalden uzak olduğunu beyan ederim.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

Ülkü SERTKAN AYDIN

TEŞEKKÜR

Yüksek Lisans öğrenimimin her aşamasında çok değerli bilgi ve tecrübelerini benimle paylaşan, tezimin her aşamasında rehberliğini esirgemeyen saygıdeğer tez danışmanım Dr. Öğretim Üyesi Gamze Sönmez'e,

Bu süreçte hep desteklerini hissettiğim, bilgilerinden istifade ettiğim Doç. Dr. Gülden Gök, Doç. Dr. Oğuzhan Gök, Dr. Öğretim Üyesi Ebru KOÇAK'a,

Araştırmam süresince bilgi paylaşımında bulunan KOSKİ Genel Müdürlüğüne, Arıtma Tesisleri Dairesi Başkanlığı Atıksu Arıtma Tesisleri Şube Müdürü Çağrı ŞAHİN ve mesai arkadaşlarına,

Varlığı bana güç veren değerli aileme, eşim Halil ve oğlum Mert' e bana inançları ve destekleri için,

Teşekkür ederim.

Ülkü SERTKAN AYDIN
AKSARAY, 2024

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET	iv
ABSTRACT	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	4
2.1 Temel Bilgileri	4
2.1.1 Atıksu.....	4
2.1.2 Atıksu parametreleri	6
2.1.3 Atıksuların arıtımı.....	8
2.2 Yapay Sinir Ağları Hakkında Genel Bilgi	10
2.2.1 Yapay sinir hücresi ve yapay sinir ağlarının yapısı	11
2.2.2 Yapay sinir ağlarının elemanları.....	14
2.2.3 Yapay sinir ağlarının özellikleri	15
2.2.4 Yapay sinir ağlarının çalışma prensibi	16
2.3 Yapay Sinir Ağının Sınıflandırılması.....	17
2.4 Yapay Sinir Ağlarında Öğrenme Stratejileri	17
2.4.1 Çok katmanlı algılayıcı (Öğretmenli öğrenme) (ÇKA).....	17
2.4.2 LVQ Modeli (Destekleyici öğrenme).....	18
2.4.3 Adaptif rezonans teori (ART) ağları (Öğretmensiz öğrenme).....	18
2.5 Yapay Sinir Ağları Kullanım Alanları	19
2.6 Yapay Sinir Ağı Kullanımının Avantaj ve Dezavantajları.....	19
2.7 Yapay Sinir Ağları ile Çevre Konusunda Yapılan Bazı Örnek Çalışmalar	20
2.8 Atıksu Arıtma Tesisi Veriminin Yapay Sinir Ağları ile Modellenmesi.....	22
3. MATERYAL VE YÖNTEM.....	23
3.1 Konya İli Hakkında Genel Bilgi.....	23
3.2 Konya Atıksu Arıtma Tesisi Hakkında Genel Bilgi.....	23
3.2.1 Ön arıtma ünitesi.....	25
3.2.2 Ön çökeltme ünitesi	27
3.2.3 Havalandırma Havuzu Ünitesi.....	28
3.2.4 Son çökeltme havuzları ünitesi.....	29
3.2.5 Çıkış kanalı	31
3.2.6 Çamur yoğunlaştırma havuzları ünitesi	32
3.2.7 Çamur çürütme ünitesi.....	33
3.2.8 Çamur susuzlaştırma ünitesi	34
3.2.9 Biyogaz saflaştırma ve kojenerasyon ünitesi.....	34
3.2.10 Isı kazanları.....	35
3.2.11 Atıksu geri kazanım ünitesi (Mor şebeke).....	35
3.3 Çalışılan Parametreler	36
3.4 Veri Toplama.....	37
3.5 Seçilen Yapay Sinir Ağları Modeli Hakkında Bilgi.....	37
3.6 Modelin Çalıştırılması ve Veri Setlerinin Uyumu	41
4. ARAŞTIRMA BULGULARI	43

4.1 Yapay Sinir Ağları Model Oluşturulması ve Model Sonuçları	43
4.1.1 Biyokimyasal oksijen ihtiyacı değeri tahmini için YSA modeli oluşturulması ve model sonuçları.....	43
4.1.2 Kimyasal oksijen ihtiyacı değeri tahmini için YSA modeli oluşturulması ve model sonuçları.....	72
4.1.3 Askıda katı madde değeri tahmini YSA modeli oluşturulması ve model sonuçları	102
5. SONUÇ VE ÖNERİLER.....	132
5.1 Bulguların Özeti	132
KAYNAKLAR	136
ÖZGEÇMİŞ.....	140



YÜKSEK LİSANS TEZİ

KENTSEL ATIKSU ARITMA TESİSİ VERİMİNİN YAPAY SİNİR AĞI İLE MODELLEMESİ: KONYA ÖRNEĞİ

Ülkü SERTKAN AYDIN

Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
Çevre Mühendisliği Anabilim Dalı

Danışman: Dr. Öğretim Üyesi Gamze SÖNMEZ

ÖZET

İklim krizi ile birlikte doğal kaynaklarımızın etkin ve verimli kullanılmasının gerektiği dünya gündeminde konuşulmaya başlanmıştır. Bu süreçte karşı karşıya kaldığımız kuraklık gerçeği de atıksuların yeniden kullanımı için uygun teknolojilerin geliştirilmesini gündeme getirmiştir. Mevcut atıksu arıtma tesislerinde çıkış suyu parametre değerlerinin önceden tahmin edilebilir olması, çıkış suyunun alıcı ortam üzerinde yaratacağı potansiyel zararlı etkilerinin önlenmesini ve proses yönetiminin etkinliğinin artmasını sağlayacaktır. Bu amaçla gelişen bilgisayar teknolojileri arasında yer alan yapay sinir ağları gibi yöntemlerle kentsel atıksu arıtma tesislerinin performanslarının tahmin edilmesine yönelik çalışmalar yapılmaktadır. Bu tez çalışmasında, Konya Su ve Kanalizasyon İdaresi (KOSKİ) Genel Müdürlüğünden temin edilen Konya Kentsel Atıksu Arıtma Tesisi 2021-2022 yılı giriş suyu pH, sıcaklık, iletkenlik, BOİ, KOİ, AKM parametreleri değerlerinden faydalanılarak, çıkış suyu BOİ, AKM, KOİ parametrelerinin değerleri MATLAB(2023b) programı Yapay Sinir Ağı (YSA) modülü Neural Net Fitting sinir ağı aracı ile modellenerek tahmin edilmiştir. Veri setindeki değerlerin dağılımının belirli bir aralıkta tutularak (0-1 aralığı) modelin daha etkin çalışmasının sağlanması amacıyla ham verilere normaizasyon işlemi uygulanmış olup, normalizasyon sonrasında elde edilen veri setinin %70'i eğitim, %15'i test, %15'i doğrulama olarak kullanılmıştır. Levenberg-Marquardt (LM) öğrenme algoritması kullanılarak yapılan modellemede nöron sayısı, giriş verisi sayısı, gizli katman sayısı değiştirilerek en iyi öğrenme algoritması bulunmaya çalışılmıştır. BOİ değerinin tahmini için; 1. senaryoda oluşturulan [3 20 1] ağ yapısında eğitim veri setinde $R^2=1$ değerleri ile öğrenmeyi gerçekleştirdiği, tüm veri setleri dikkate alındığında modelin genel performansının $MSE=0,0194$, $R^2=0,7271$ olduğu, 2. senaryo kapsamında yapılan çalışmaya ait gizli katman nöron sayısı 8 olarak belirlenen [6 8 1] ağ yapısında modelin genel performansının $MSE=0,014$, $R^2=0,7522$ olduğu görülmüştür.

Anahtar Kelimeler: Atıksu, Yapay Sinir Ağı, Yeniden Kullanım.

Haziran, 2024; 140 sayfa

M.Sc. THESIS

URBAN WASTEWATER TREATMENT PLANT EFFICIENCY MODELING WITH ARTIFICIAL NEURAL NETWORK: KONYA EXAMPLE

Ülkü SERTKAN AYDIN

**Aksaray University
Graduate School of Natural and Applied Sciences
Department of Environmental Engineering**

Supervisor: Assist. Prof. Gamze SÖNMEZ

ABSTRACT

With the climate crisis, the necessity of using our natural resources efficiently and effectively has become a topic of global discussion. The reality of drought we are facing has brought the development of suitable technologies for the reuse of wastewater to the forefront. Predicting the parameter values of the effluent from existing wastewater treatment plants in advance will help prevent the potential harmful effects of the effluent on the receiving environment and increase the efficiency of process management. For this purpose, studies are being conducted to predict the performance of urban wastewater treatment plants using methods such as artificial neural networks, which are among the advanced computer technologies. In this thesis, the values of the influent water parameters pH, temperature, conductivity, BOD, COD, and TSS for the Konya Urban Wastewater Treatment Plant for the years 2021-2022, provided by the Konya Water and Sewerage Administration (KOSKI) General Directorate, were used to predict the values of the effluent water parameters BOD, TSS, and COD. These predictions were made using the Neural Net Fitting neural network tool of the Artificial Neural Network (ANN) module in the MATLAB(2023b) program. To ensure the model works more effectively, normalization was applied to the raw data to keep the values within a specific range (0-1). After normalization, 70% of the dataset was used for training, 15% for testing, and 15% for validation. The best learning algorithm was sought by varying the number of neurons, the number of input data, and the number of hidden layers in the modeling performed using the Levenberg-Marquardt (LM) learning algorithm. For estimation of BOD value; In the [3 20 1] network structure created in the 1st scenario, learning was achieved with $R^2 = 1$ values in the training data set, and considering all data sets, the overall performance of the model was $MSE = 0.0194$, $R^2 = 0.7271$. It was observed that the overall performance of the model in the [6 8 1] network structure, where the number of hidden layer neurons was determined as 8, was $MSE = 0.014$, $R^2 = 0.7522$.

Keywords: Wastewater, Artificial Neural Network, Reuse.

June 2024; 140 pages

ŞEKİLLER DİZİNİ

Şekil 2.1. Atıksu arıtım yöntemleri.....	10
Şekil 2.2. İnsan sinir hücresi.....	12
Şekil 2.3. Yapay sinir ağları katmanları.....	13
Şekil 2.4. Yapay sinir hücresinin elemanları.....	14
Şekil 3.1. Konya il haritası.....	23
Şekil 3.2. Konya Kentsel Atıksu Arıtma Tesisi fotoğrafları.....	24
Şekil 3.3. Konya Kentsel Atıksu Arıtma Tesisi iş akış şeması.....	25
Şekil 3.4. Ön arıtma ünitesi vaziyet planı.....	26
Şekil 3.5. Ön arıtma ünitesi fotoğrafı.....	26
Şekil 3.6. Ön çökeltme ünitesi vaziyet planı.....	27
Şekil 3.7. Havalandırma havuzu ünitesi vaziyet planı.....	29
Şekil 3.8. Havalandırma havuzu.....	29
Şekil 3.9. Son çökeltme ünitesi vaziyet planı.....	30
Şekil 3.10. Son çökeltme havuzları.....	30
Şekil 3.11. Çıkış kanalları.....	31
Şekil 3.12. U.V. kanalları.....	31
Şekil 3.13. Çamur yoğunlaştırma havuzları ünitesi vaziyet planı ve iş akışı.....	32
Şekil 3.14. Çamur yoğunlaştırma havuzları.....	32
Şekil 3.15. Çamur Çürütme Ünitesi vaziyet planı ve iş akışı.....	33
Şekil 3.16. Biyogaz saflaştırma ve kojenerasyon ünitesi vaziyet planı.....	34
Şekil 3.17. Desülfürizasyon ve enerji geri kazanım ünitesi.....	35
Şekil 3.18. Atıksu geri kazanım ünitesi (Mor Şebeke) vaziyet planı.....	36
Şekil 3.19. Araç kutusu menüsünden erişim.....	38
Şekil 3.20. Komut penceresinden erişim.....	39
Şekil 3.21. Eğitim algoritması seçim ekranı.....	40
Şekil 3.22. Kullanılan YSA yapısı.....	40
Şekil 3.23. YSA veri giriş ekranı.....	42
Şekil 4.1. BOİ AAT giriş ve çıkış değerlerinin grafiksel gösterimi.....	44
Şekil 4.2. İlk senaryo BOİ değeri tahmininde [3 8 1] ağ diyagramı ve eğitim sonuçları.....	45
Şekil 4.3. İlk senaryo BOİ değeri tahmininde [3 8 1] ağ yapısında A) performans ve B) hata grafikleri.....	46
Şekil 4.4. İlk senaryo BOİ değeri tahmininde [3 10 1] ağ diyagramı ve eğitim sonuçları.....	47
Şekil 4.5. İlk senaryo BOİ değeri tahmininde [3 10 1] ağ yapısında A) performans ve B) hata grafikleri.....	48
Şekil 4.6. İlk senaryo BOİ değeri tahmininde [3 15 1] ağ diyagramı ve eğitim sonuçları.....	49
Şekil 4.7. İlk senaryo BOİ değeri tahmininde [3 15 1] ağ yapısında A) performans ve B) hata grafikleri.....	50
Şekil 4.8. İlk senaryo BOİ değeri tahmininde [3 20 1] ağ diyagramı ve eğitim sonuçları.....	51
Şekil 4.9. İlk senaryo BOİ değeri tahmininde [3 20 1] ağ yapısında A) performans ve B) hata grafikleri.....	52
Şekil 4.10. İlk senaryo BOİ değeri tahmininde [3 30 1] ağ diyagramı ve eğitim sonuçları.....	53

Şekil 4.11. İlk senaryo BOİ değeri tahmininde [3 30 1] ağ yapısında A) performans ve B) hata grafikleri.	54
Şekil 4.12. İlk senaryo BOİ değeri tahmininde [3 50 1] ağ diyagramı ve eğitim sonuçları.	55
Şekil 4.13. İlk senaryo BOİ değeri tahmininde [3 50 1] ağ yapısında A) performans ve B) hata grafikleri.	56
Şekil 4.14. BOİ değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.	57
Şekil 4.15. BOİ değeri ilk senaryo için en iyi tahmini yapan ağ yapısı [3 20 1] sonuç karşılaştırma grafiği.	58
Şekil 4.16. İkinci senaryo BOİ değeri tahmininde [6 8 1] ağ diyagramı ve eğitim sonuçları.	59
Şekil 4.17. İkinci senaryo BOİ değeri tahmininde [6 8 1] ağ yapısında A) performans ve B) hata grafikleri.	60
Şekil 4.18. İkinci senaryo BOİ değeri tahmininde [6 10 1] ağ diyagramı ve eğitim sonuçları.	61
Şekil 4.19. İkinci senaryo BOİ değeri tahmininde [6 10 1] ağ yapısında A) performans ve B) hata grafikleri.	62
Şekil 4.20. İkinci senaryo BOİ değeri tahmininde [6 15 1] ağ diyagramı ve eğitim sonuçları.	63
Şekil 4.21. İkinci senaryo BOİ değeri tahmininde [6 15 1] ağ yapısında A) performans ve B) hata grafikleri.	64
Şekil 4.22. İkinci senaryo BOİ değeri tahmininde [6 20 1] ağ diyagramı ve eğitim sonuçları.	65
Şekil 4.23. İkinci senaryo BOİ değeri tahmininde [6 20 1] ağ yapısında A) performans ve B) hata grafikleri.	66
Şekil 4.24. İkinci senaryo BOİ değeri tahmininde [6 30 1] ağ diyagramı ve eğitim sonuçları.	67
Şekil 4.25. İkinci senaryo BOİ değeri tahmininde [6 30 1] ağ yapısında A) performans ve B) hata grafikleri.	68
Şekil 4.26. İkinci senaryo BOİ değeri tahmininde [6 50 1] ağ diyagramı ve eğitim sonuçları.	69
Şekil 4.27. İkinci senaryo BOİ değeri tahmininde [6 50 1] ağ yapısında A) performans ve B) hata grafikleri.	70
Şekil 4.28. BOİ değeri 2. senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.	71
Şekil 4.29. BOİ değeri 2. senaryo için en iyi tahmini yapan ağ yapısı [6 8 1] sonuç karşılaştırma grafiği.	72
Şekil 4.30. KOİ AAT giriş ve çıkış değerlerinin grafiksel gösterimi.	73
Şekil 4.31. İlk senaryo KOİ değeri tahmininde [3 8 1] ağ diyagramı ve eğitim sonuçları.	74
Şekil 4.32. İlk senaryo KOİ değeri tahmininde [3 8 1] ağ yapısında A) performans ve B) hata grafikleri.	75
Şekil 4.33. İlk senaryo KOİ değeri tahmininde [3 10 1] ağ diyagramı ve eğitim sonuçları.	76
Şekil 4.34. İlk senaryo KOİ değeri tahmininde [3 10 1] ağ yapısında A) performans ve B) hata grafikleri.	77
Şekil 4.35. İlk senaryo KOİ değeri tahmininde [3 15 1] ağ diyagramı ve eğitim sonuçları.	78

Şekil 4.36. İlk senaryo KOİ değeri tahmininde [3 15 1] ağ yapısında A) performans ve B) hata grafikleri.	79
Şekil 4.37. İlk senaryo KOİ değeri tahmininde [3 20 1] ağ diyagramı ve eğitim sonuçları.	80
Şekil 4.38. İlk senaryo KOİ değeri tahmininde [3 20 1] ağ yapısında A) performans ve B) hata grafikleri.	81
Şekil 4.39. İlk senaryo KOİ değeri tahmininde [3 30 1] ağ diyagramı ve eğitim sonuçları.	82
Şekil 4.40. İlk senaryo KOİ değeri tahmininde [3 30 1] ağ yapısında A) performans ve B) hata grafikleri.	83
Şekil 4.41. İlk senaryo KOİ değeri tahmininde [3 50 1] ağ diyagramı ve eğitim sonuçları.	84
Şekil 4.42. İlk senaryo KOİ değeri tahmininde [3 50 1] ağ yapısında A) performans ve B) hata grafikleri.	85
Şekil 4.43. KOİ değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.	86
Şekil 4.44. KOİ değeri ilk senaryo için en iyi tahmini yapan ağ yapısı [3 50 1] sonuç karşılaştırma grafiği.	87
Şekil 4.45. İkinci senaryo KOİ değeri tahmininde [5 8 1] ağ diyagramı ve eğitim sonuçları.	88
Şekil 4.46. İkinci senaryo KOİ değeri tahmininde [5 8 1] ağ yapısında A) performans ve B) hata grafikleri.	89
Şekil 4.47. İkinci senaryo KOİ değeri tahmininde [5 10 1] ağ diyagramı ve eğitim sonuçları.	90
Şekil 4.48. İkinci senaryo KOİ değeri tahmininde [5 10 1] ağ yapısında A) performans ve B) hata grafikleri.	91
Şekil 4.49. İkinci senaryo KOİ değeri tahmininde [5 15 1] ağ diyagramı ve eğitim sonuçları.	92
Şekil 4.50. İkinci senaryo KOİ değeri tahmininde [5 15 1] ağ yapısında A) performans ve B) hata grafikleri.	93
Şekil 4.51. İkinci senaryo KOİ değeri tahmininde [5 20 1] ağ diyagramı ve eğitim sonuçları.	94
Şekil 4.52. İkinci senaryo KOİ değeri tahmininde [5 20 1] ağ yapısında A) performans ve B) hata grafikleri.	95
Şekil 4.53. İkinci senaryo KOİ değeri tahmininde [5 30 1] ağ diyagramı ve eğitim sonuçları.	96
Şekil 4.54. İkinci senaryo KOİ değeri tahmininde [5 30 1] ağ yapısında A) performans ve B) hata grafikleri.	97
Şekil 4.55. İkinci senaryo KOİ değeri tahmininde [5 50 1] ağ diyagramı ve eğitim sonuçları.	98
Şekil 4.56. İkinci senaryo KOİ değeri tahmininde [5 50 1] ağ yapısında A) performans ve B) hata grafikleri.	99
Şekil 4.57. KOİ değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.	101
Şekil 4.58. KOİ değeri 2. senaryo için en iyi tahmini yapan ağ yapısı [5 30 1] sonuç karşılaştırma grafiği.	101
Şekil 4.59. AKM AAT giriş ve çıkış değerlerinin grafiksel gösterimi.	102
Şekil 4.60. İlk senaryo AKM değeri tahmininde [3 8 1] ağ diyagramı ve eğitim sonuçları.	104

Şekil 4.61. İlk senaryo AKM değeri tahmininde [3 8 1] ağ yapısında A) performans ve B) hata grafikleri.	105
Şekil 4.62. İlk senaryo AKM değeri tahmininde [3 10 1] ağ diyagramı ve eğitim sonuçları.	106
Şekil 4.63. İlk senaryo AKM değeri tahmininde [3 10 1] ağ yapısında A) performans ve B) hata grafikleri.	107
Şekil 4.64. İlk senaryo AKM değeri tahmininde [3 15 1] ağ diyagramı ve eğitim sonuçları.	108
Şekil 4.65. İlk senaryo AKM değeri tahmininde [3 15 1] ağ yapısında A) performans ve B) hata grafikleri.	109
Şekil 4.66. İlk senaryo AKM değeri tahmininde [3 20 1] ağ diyagramı ve eğitim sonuçları.	110
Şekil 4.67. İlk senaryo AKM değeri tahmininde [3 20 1] ağ yapısında A) performans ve B) hata grafikleri.	111
Şekil 4.68. İlk senaryo AKM değeri tahmininde [3 30 1] ağ diyagramı ve eğitim sonuçları.	112
Şekil 4.69. İlk senaryo AKM değeri tahmininde [3 30 1] ağ yapısında A) performans ve B) hata grafikleri.	113
Şekil 4.70. İlk senaryo AKM değeri tahmininde [3 50 1] ağ diyagramı ve eğitim sonuçları.	114
Şekil 4.71. İlk senaryo AKM değeri tahmininde [3 50 1] ağ yapısında A) performans ve B) hata grafikleri.	115
Şekil 4.72. AKM değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.	116
Şekil 4.73. AKM değeri ilk senaryo için en iyi tahmini yapan ağ yapısı ([3 50 1]) sonuç karşılaştırma grafiği.	117
Şekil 4.74. İkinci senaryo AKM değeri tahmininde [5 8 1] ağ diyagramı ve eğitim sonuçları.	118
Şekil 4.75. İkinci senaryo AKM değeri tahmininde [5 8 1] ağ yapısında A) performans ve B) hata grafikleri.	119
Şekil 4.76. İkinci senaryo AKM değeri tahmininde [5 10 1] ağ diyagramı ve eğitim sonuçları.	120
Şekil 4.77. İkinci senaryo AKM değeri tahmininde [5 10 1] ağ yapısında A) performans ve B) hata grafikleri.	121
Şekil 4.78. İkinci senaryo AKM değeri tahmininde [5 15 1] ağ diyagramı ve eğitim sonuçları.	122
Şekil 4.79. İkinci senaryo AKM değeri tahmininde [5 15 1] ağ yapısında A) performans ve B) hata grafikleri.	123
Şekil 4.80. İkinci senaryo AKM değeri tahmininde [5 20 1] ağ diyagramı ve eğitim sonuçları.	124
Şekil 4.81. İkinci senaryo AKM değeri tahmininde [5 20 1] ağ yapısında A) performans ve B) hata grafikleri.	125
Şekil 4.82. İkinci senaryo AKM değeri tahmininde [5 30 1] ağ diyagramı ve eğitim sonuçları.	126
Şekil 4.83. İkinci senaryo AKM değeri tahmininde [5 30 1] ağ yapısında A) performans ve B) hata grafikleri.	127
Şekil 4.84. İkinci senaryo AKM değeri tahmininde [5 50 1] ağ diyagramı ve eğitim sonuçları.	128
Şekil 4.85. İkinci senaryo AKM değeri tahmininde [5 50 1] ağ yapısında A) performans ve B) hata grafikleri.	129

Şekil 4.86. AKM değeri 2. senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.	131
Şekil 4.87. AKM değeri 2. senaryo için en iyi tahmini yapan ağ yapısı ([5 30 1]) sonuç karşılaştırma grafiği.	131



ÇİZELGELER DİZİNİ

Çizelge 2.1. Evsel atıksuyun fiziksel, kimyasal ve biyolojik bileşenleri (Metcalf, ...)	5
Çizelge 2.2. Evsel/Kentsel Atıksu Bileşimi (Metcalf & Eddy, 2003).	6
Çizelge 3.1. Çalışılan parametreler ve modelde kullanım Şekilleri (Senaryo 1).	36
Çizelge 3.2. Çalışılan parametreler ve modelde kullanım şekilleri (Senaryo 2).	37
Çizelge 4.1. BOİ tahmini 1. senaryo performans karşılaştırma tablosu.	57
Çizelge 4.2. BOİ tahmini 2. senaryo performans karşılaştırma tablosu.	71
Çizelge 4.3. KOİ tahmini 1. senaryo performans karşılaştırma tablosu.	86
Çizelge 4.4. KOİ tahmini 2. senaryo performans karşılaştırma tablosu.	100
Çizelge 4.5. AKM tahmini 1. senaryo performans karşılaştırma tablosu.	116
Çizelge 4.6. AKM tahmini 2. senaryo karşılaştırma tablosu.	130
Çizelge 5.1. YSA ağ yapıları karşılaştırma tablosu.	133

SİMGELER VE KISALTMALAR

AAT	Atıksu Arıtma Tesisi
AKM	Askıda Katı Madde
ART	Adaptif Rezonans Teori
BOİ	Biyokimyasal Oksijen İhtiyacı
ÇKA	Çok Katmanlı Algılayıcı
KAAY	Kentsel Atıksu Arıtımı Yönetmeliği
KOİ	Kimyasal Oksijen İhtiyacı
KOSKİ	Konya Su ve Kanalizasyon İdaresi
LM	Levenberg Marquardt
LVQ	Linear Vektör Quanuzation
MSE	Mean Squared Error
NET	Network
R²	Korelasyon Katsayısı
SKKY	Su Kirliliği Kontrolü Yönetmeliği
TKM	Toplam Katı Madde
TN	Toplam Azot
TP	Toplam Fosfor
YSA	Yapay Sinir Ağı

1. GİRİŞ

Tüm Dünyada ve ülkemizde son yıllarda görülen iklim değişikliği ve ekolojik ayak izinin etkileri, doğal ve yenilenebilir kaynakların etkin kullanımını iyi ve verimli bir şekilde kullanılması zorunluluğunu ortaya koymaktadır. Kentlerde yaşayan nüfus dünya da nüfusun yarısından fazlası Türkiye de ise yaklaşık olarak % 90'ıdır. Nüfusun büyük bir kısmının kentlerde yaşaması kullanılan altyapı tesislerini daha da önemli bir hale getirmiştir (Üçüncü, 2019). Öte yandan, nüfus artışı ve sanayileşmenin beraberinde getirdiği aşırı atıksu üretimi ve alıcı ortamların kirlenmesi, günümüzde insan hayatını doğrudan ve dolaylı olarak tehdit eden sorunlardan biridir." Atıksuları uzaklaştırmadan önce arıtma zorunluluğu, doğadaki ekolojik dengeyi olumsuz yönde etkileyebilecek bu durumu önlemek için ortaya çıkmıştır. Atık suyun bu kirleticilerden arındırılarak tekrar alıcı ortamlara verilmesi için kurulan atıksu arıtma tesislerinde, yönetimi zor bir arıtma süreci mevcuttur.

Proses kontrolünde kullanılan bazı kirlilik ölçme işlemlerinin uzun sürmesi, yüksek maliyet ve zaman zaman bu sonuçların acil değerlendirilme ihtiyacı, atıksu arıtma tesisi (AAT) yöneticisinin karar vermede yardımcı olacak ek bilgi sistemlerine ihtiyaç duymasına neden olmaktadır. Tesis yöneticisinin prosesi etkin yönetmesi ve düzenleyici müdahalelerde bulunabilmesi için, bilgi sistemlerinde kayıtlı geçmiş tesis giriş ve çıkış parametreleri arasındaki ilişkinin modellenmesi ve karşılaşılan giriş kontrol parametre değerlerine göre muhtemel çıkış parametrelerinin tahmin edilmesi destek olacaktır (Öztemel ve Dügenci, 2016).

Evsel atıksu arıtma tesislerinin işletilmesinde lineer olmayan ve zamanla değişen birçok değişkenin göz önünde bulundurulması gerekmektedir. Bu değişkenlerden bazıları yerinde ölçülebilmesine rağmen bazı değişkenlerin laboratuvarlarda ölçülmesi gerekmektedir. Bu sebeplerden dolayı, bu tesislerin işletilmesinde bir sorunla karşılaşıldığında bu sorunların aşılması çok kolay olmamakta ve sorunun aşılmasında yardımcı olacak araçlara gereksinim duyulmaktadır (Çınar ve Yılmaz, 2005).

AAT'nin işleyişini kontrol etmenin ve performanslarını değerlendirmenin karmaşık ve uygun maliyetli bir yolu model geliştirmedir (Hassen and Asmare, 2019). Yapay Sinir Ağları (YSA) karşılaşılan problemlere çözüm üretmek için insan beyninin bilgiyi

işleme sistemini taklit ederek geliştirilmiş bilgisayar yazılımlarıdır. Yapay sinir ağları bilgiyi öğrenerek hafızaya alır ve öğrendiklerini yeni bilgiler üretecek biçimde genellemeler yapar. Yapay sinir ağları değişkenler arasındaki ilişkileri ortaya koyabilirler. YSA'nın atıksu arıtımında başarılı bir şekilde sistemi modelleyebildiği görülmüştür (Erdem, 2021). Atıksuların arıtımında deneysel çalışmaların çok fazla yapılması hem maliyeti hem de harcanan zamanı arttıracaktır. YSA analizi çevre mühendisliğinin ilgilendiği deneysel çalışmaların analizinde kullanılabilecek, ekonomik ve faydalı bir yöntemdir. YSA metoduyla girdi ve çıktılar tanımlanarak çıkış değerlerinin tahmini çevre mühendisliğinde verilerin analizinde sağlanabilmektedir. Yapılan çalışmaların analizinde YSA modelleri kullanılarak verimli sonuçlara ulaşılabilir. Farklı parametrelerin ilişkilerini denklemlerle ifade edilmediğimizde YSA ile sonuç aramak mantıklı olacaktır. Bu işlemler düzenli olarak hazırlanmış verilerle ve doğru yapılmış ölçümlerle yapılabilir (Açıkalın, 2007). Bilgi işlem yeteneklerinin gelişmesiyle basitliği ve tahmin doğruluğu nedeniyle, atık su arıtma sürecini modellemek için makine öğreniminin, özellikle YSA'nın kullanılması, gerçekleştirilebilecek umut verici bir alternatif haline gelmiştir.

Yapay sinir ağı modelleri, girdi ve çıktı arasındaki karmaşık örüntüleri ve ilişkileri tespit etmek için bir dizi doğrusal olmayan denklem kullanır, bu nedenle tahmin, simülasyon ve sınıflandırma gibi alanlarda uygulanabilir (Bekkari ve Zedduri, 2018).

Kentlerde atıksu arıtma tesislerinde karşılaşılan en önemli çevresel sorun; arıtma tesisi çıkış suyunun alıcı ortam üzerinde yaratacağı olumsuz etkilerdir. Bu olumsuz etkilerin en az düzeyde tutulmasını sağlamak için sistem arızalarını zamanında tespit etmek ve uygun önlemleri almak tesisin arıtma işlemini kontrol için önemlidir. Bu tez çalışması ile YSA Modelleri aracılığıyla Konya İli Kentsel Atıksu Arıtma tesisinin giriş suyu verilerini kullanarak, ölçülen çıkış suyu değerlerine en yakın verileri veren optimum algoritma araştırılmıştır. MATLAB programı kullanılarak yapılan çalışmada Konya Kentsel Atıksu Arıtma Tesisinin 2021-2022 yılı giriş suyu parametreleri (pH, sıcaklık, iletkenlik, BOİ, KOİ, AKM) kullanılarak çıkış suyu BOİ, KOİ, AKM parametrelerinin değerleri tahmin edilmiştir. Bu hedefin belirlenmesinde, atıksu arıtım tesislerinin çalışması esnasında meydana gelen, ani değişim ve müdahale gerektiren durumların önceden tahmin edilebilir olmasının çevresel risklerin önlenmesindeki önemi etken olmuştur.

Mevcut durumda AAT giriş ve çıkış suyu analizleri ölçüm ve deneysel yöntemler kullanılarak gerçekleştirilmektedir. Ancak bu durum analizlerin standartlara uygun olarak yapılması gerekliliği nedeniyle zaman kaybı ve maliyet problemini karşımıza çıkarmaktadır. Uygun bir model yöntemi ile gerçek ölçüm verilerine en yakın sonuçların elde edilebilir olması önemli sorunlarda erken müdahale şansı ve zaten yüksek işletme maliyeti bulunan tesislerde işletme veriminin artmasına imkân sağlayacaktır. Çalışma sonrasında elde edilen uygun yöntemin benzer ölçekteki diğer tesislerde de kullanılabilir olması amaçlanmaktadır.



2. LİTERATÜR ÖZETİ

2.1 Temel Bilgileri

2.1.1 Atıksu

Su Kirliliği Kontrolü Yönetmeliğine (SKKY) göre; Evsel, endüstriyel, tarımsal ve diğer kullanımlar sonucunda kirlenmiş veya özellikleri kısmen veya tamamen değişmiş sular ile maden ocakları ve cevher hazırlama tesislerinden kaynaklanan sular ve yapılaşmış kaplamalı ve kaplamasız şehir bölgelerinden cadde, otopark ve benzeri alanlardan yağışların yüzey veya yüzeyaltı akışa dönüşmesi sonucunda gelen sular atıksu olarak nitelendirilmektedir (SKKY, 2004).

Çepni (2017), çalışmasında endüstriyel ve evsel atıksuların su kaynaklarının büyük olduğu, ekolojik dengenin bozulmasını engellemek için atıksuların arıtılarak uzaklaştırılmasının gerektiği ve yerleşim bölgelerine bu amaçla evsel ve endüstriyel atıksu arıtma tesislerinin kurulduğunu belirtmiştir.

Atıksu arıtma tesislerinde arıtımı amaçlanan atıksular aşağıda belirtilen şekil’de sınıflandırılabilir

Evsel atıksular: Kentsel Atıksu Arıtımı Yönetmeliğinde (KAAY) evsel atıksu yaygın olarak yerleşim bölgelerinden ve çoğunlukla evsel faaliyetler ile insanların günlük yaşam faaliyetlerinin yer aldığı okul, hastane, otel gibi hizmet sektörlerinden kaynaklanan atıksular şeklinde tanımlanmaktadır. İklimler, insanların yaşam şekilleri ve alışkanlıkları atıksu karakterizasyonunu etkilemektedir. Evsel atıksular askıda, kolloidal ve çözünmüş halde organik ve inorganik maddeler içerir. Kanalizasyona sanayi atıksularının da verilmesi, sistemdeki evsel atıksu özelliklerini büyük oranda değiştirecektir. Günlük kullanılan su miktarlarına bağlı olarak da konsantrasyonlar da değişir. Evsel atıksuların karakterizasyonunu içeriğindeki fiziksel, kimyasal ve biyolojik bileşenler de değiştirmektedir (Sinan, 2010). Evsel atıksu bileşenleri Çizelge 2.1’de görülmektedir.

Çizelge 2.1. Evsel atıksuyun fiziksel, kimyasal ve biyolojik bileşenleri (Metcalf, 2003).

Fiziksel Özellikler	Kimyasal Bileşenler			Biyolojik Bileşenler
	Organikler	İnorganikler	Gazlar	
Katı maddeler Sıcaklık Renk Koku	Karbonhidratlar Yağ ve Gres Pestisitler Fenoller Proteinler Yüzey aktif maddeler	pH Azot Fosfor Alkalinite Klorürler Ağır metaller Sülfür Toksik bileşenler	Metan Oksijen Hidrojen sülfür	Canlı hücreler Bitkiler Tek hücreliler Virüsler

Kentsel atıksular: Kentsel Atıksu Arıtımı Yönetmeliğinde (KAAY), evsel atıksu ya da evsel atıksuyun endüstriyel atıksu ve/veya yağmur suyu ile karışımının kentsel atıksuyu tanımladığı belirtilmektedir. Nas (2017), kentlerde atıksular genellikle evsel atıksulardan meydana gelmektedir. , Ayrıca, yağmur suları, yeraltına sızan sular, ticarî veya sanayi atıksuları da evsel atıksulara karışmaktadır (Nas, 2017). Atıksu Çizelge 2.2’de verilen evsel/kentsel atıksu bileşimi konsantrasyonlarına bağlı olarak sınıflandırılır.

Sanayilerden kaynaklanan atıksu: Ticari ya da endüstriyel faaliyetin yürütüldüğü işletmelerden, evsel atıksu ve yağmur suyu dışında deşarj edilen atıksular sanayilerden kaynaklanan atıksu olarak nitelendirilmektedir (KAAY, 2006).

Çizelge 2.2. Evsel/Kentsel Atıksu Bileşimi (Metcalf & Eddy, 2003).

Parametre	Birim	Zayıf	Orta	Güçlü
Toplam Katı Madde	mg/L	350	720	1200
Çözünmüş Katı Madde	mg/L	250	500	850
Askıda Katı Madde	mg/L	100	220	350
Çökebilir Katı Madde	ml/L	5	10	20
BOİ ₅	mg/L	110	220	400
KOİ	mg/L	250	500	1000
Toplam Azot	mg/L	20	40	85
Organik Azot	mg/L	8	15	35
Amonyak	mg/L	12	25	50
Nitrit	mg/L	0	0	0
Nitrat	mg/L	0	0	0
Toplam Fosfor	mg/L	4	8	15
Organik Fosfor	mg/L	1	3	5
İnorganik Fosfor	mg/L	3	5	10
Sülfat	mg/L	20	30	50
Alkalinite (CaCO ₃)	mg/L	50	100	200
Yağ.Gres	mg/L	50	100	150
Toplam Koliform	EMS/100 mL	106.107	107.108	107.1

Tekrar kullanımı mümkün olmayan kirletici içeriği yüksek atıksuyu fiziksel, biyolojik ve kimyasal yöntemler ile içerdiği kirletici miktarını ilgili mevzuatların izin verdiği seviyeye getirerek alıcı ortama vereceği zararı önlemek ve su döngüsüne yeniden kazandırmak atıksu arıtımının amacıdır. Atıksuların özelliklerini; fiziksel, kimyasal ve biyolojik olmak üzere üç grupta inceleyebiliriz;

- . Fiziksel Özellikleri: Sıcaklık, koku, Renk, iletkenlik, bulanıklık, tuzluluk ve katı maddeler,
- . Kimyasal Özellikleri: Metaller, inorganik ve organik maddeler
- . Biyolojik Özellikleri: Mikroorganizmalar (bakteriler, virüsler, mantarlar) (Selvi, 2019).

2.1.2 Atıksu parametreleri

Bu çalışmada arıtma tesisleri performansının değerlendirilmesinde pH, biyokimyasal oksijen ihtiyacı (BOİ), kimyasal oksijen ihtiyacı (KOİ), askıda katı madde (AKM), sıcaklık, iletkenlik parametreleri tesis performansı takibi için seçilmiş olup, bu parametrelere ilişkin temel bilgiler aşağıda verilmiştir.

pH: suyun asidik veya bazik olma durumunu belirtmektedir. Su içerisindeki hidrojen iyonu konsantrasyonu 10 tabanına göre negatif logaritması pH olarak tanımlanmaktadır. pH değeri 7 olan sular nötr sulardır. Bazik sularda $pH > 7$ dir. Nötr sularda H^+ ve OH^- iyonları denge halindedir. Suda H^+ iyonu konsantrasyonunun artması halinde su asidik karakter kazanırken tam tersi durumda ise su bazik özellik kazanır. pH değerleri 0.14 arasında değişim göstermektedir (Aras, 2020).

Biyokimyasal oksijen ihtiyacı (BOİ): Nas (2017), çalışmasında biyokimyasal oksijen ihtiyacını belirli şartlar altında ($20^{\circ}C$ 'de t gün veya azot oluşumu ile veya azot oluşumu engellenmeksizin), sudaki organik ve/veya inorganik maddelerin biyolojik oksidasyonu sonucu sarf edilen çözünmüş oksijenin konsantrasyonu olarak tanımlamıştır. Biyokimyasal oksijen ihtiyacı, mg/L veya g/m^3 birimleri ile ifade edilebilir.

Biyokimyasal oksidasyon, su içinde bir yanma olayı olup, bu yanma esnasında suda çözünmüş (erimiş) oksijen kullanılır. Sudaki organik madde miktarının fazla olması fazla oksijen tüketimine neden olur (URL-3).

Kimyasal oksijen ihtiyacı (KOİ): kimyasal olarak oksitlenebilen organik maddelerin oksijen ihtiyacını ifade eder. KOİ ölçümü asit ortamda kuvvetli bir kimyasal oksitleyici (potasyum dikromat gibi) vasıtasıyla yapılır. Kimyasal oksijen ihtiyacının biyolojik oksijen ihtiyacından daha fazla olmasının nedeni kimyasal olarak oksitlenebilecek bileşiklerin biyolojik olarak oksitlenebileceklerden daha çok olmasıdır. Tasfiye edilmemiş atıksular için $BOİ_5/KOİ = 0,4-0,8$ (ortalama 0,65) alınabilir (URL-3).

Askıda katı madde (AKM): Özen (2018), askıda katı maddeyi, atıksuyun ve alıcı ortamın bulanıklaşmasına sebep olan, atıksu içerisinde çözünmeyip, kendi ağırlığından dolayı çökebilen ve askıda kalan küçük tane çaplı organik ve inorganik katı maddeler şeklinde açıklamıştır.

Sinan (2010), çalışmasında askıda katı maddelerin; suların çeşitli amaçlar için kullanılmasını direkt etkilediği, doğal sularda ışık geçirgenliğini azaltıp dip birikintilerine yol açarak ya da doğrudan zarar vererek su canlılarını etkilediği, kanallarda ve arıtma sistemlerinde önlem alınması ihtiyacını ortaya koyduğu ve bu

özellikleri ile AKM'nin atık sularda önemli bir parametre olduğu hususlarına değinmiştir.

Toplam Azot (TN): atıksulardaki en önemli kirletici, organik bileşiklerden sonra azot bileşikleridir (10-40 mg civarında). İnsanların besin yoluyla aldığı ve çoğunlukla üre olarak atıksuya karışan proteinler evsel atıksuda bulunan önemli azot kaynaklarıdır (Samsunlu, 2006).

Toplam Fosfor (TP): evsel atıksular 2-10 mg/L civarında toplam fosfor içermekte olup, fosforun genel formları ortofosfat, polifosfat ve organik fosfatın toplamından oluşur. Endüstriyel ve evsel atıksuların yanında tarımsal faaliyetler de alıcı ortamda mevcut fosforun kaynaklarıdır. Fiziksel, kimyasal ve biyolojik metotlarla fosfor giderimi yapılabilir (Samsunlu, 2006).

Sıcaklık: mevsimlere göre değişkenlik gösteren atıksudaki tüm reaksiyonlar için reaksiyonu ve mikroorganizmaların çalışmasını etkileyen ve mikroorganizmalarca gerçekleşen fiziksel bir parametredir (Özen, 2018).

2.1.3 Atıksuların arıtımı

Günümüzde artan nüfus ve refah seviyeleri beraberinde mal ve hizmet talebindeki artış nedeniyle bu talebi karşılamak için tüketilen su miktarları da artmaktadır. Çeşitli kullanımlar sonucu tüketilen bu suların arıtılmadan alıcı ortamlara bırakılması birçok olumsuz çevresel şartların oluşmasına neden olmaktadır (Güner, 2017). Ayrıca su kaynaklarının korunması ve sürdürülebilir bir su yönetimi için atıksuların arıtılması önemlidir (Nas, 2017).

Atıksu arıtma sistemlerinin planlanması, tasarlanması ve işletilmesi oldukça kapsamlı ve karmaşık bir konudur. Bu konu, politik, sosyal ve teknik unsurların birlikte dikkate alınmalıdır. Deşarj standartlarının sağlanmasının yanı sıra, iyi bir atıksu arıtma ve uzaklaştırma sistemi ile birçok olumsuz çevresel etkinin önlenmesi hedeflenir. Bu çevresel olumsuzluklar genellikle şunlardır:

- Gürültü kirliliği ve koku problemi,
- Fiziksel, kimyasal ve biyolojik atıklarla su kaynaklarının kirlenmesi,

- Su ekosisteminin zarar görmesi,
- Deşarj sonrası alıcı su ortamı kalitesinin bozulması,
- Doğal suların yararlı kullanımının azalması,
- Arıtılmamış atıksuların tarım arazilerinde kullanımı dolayısıyla hastalıkların yayılması,
- Arazilerin değer kaybetmesi gibi riskler olarak sıralanabilir (URL-1).

Güner (2017), atıksuların arıtılmasının, doğal kaynakların korunması, sürdürülebilir şekilde yönetilmesi ve verimli şekilde değerlendirilmesinde önemli olduğunu, bu kapsamda atıksu arıtma tesislerinin atıksuları arıtarak, alıcı ortamın fiziksel, kimyasal, biyolojik ve ekolojik özelliklerine olumsuz etki etmeyecek duruma getirilmesi ile tekrar doğal döngüye dahil edilmelerine imkân sağladıklarını ifade etmiştir.


Atıksu karakterizasyonu atıksuların bertarafında, ihtiyaca uygun arıtma sistemi tasarımı ve bu tesislerin verimli şekilde işletilmesi açısından oldukça önemlidir. Etkin bir atıksu arıtımının uygulanması ve çamur yönetimine çözümler geliştirilmesi açısından arıtma tesisleri giriş ve çıkış atıksuları ile çamur karakteristiklerinin takibi, yeni arıtma teknolojilerinin geliştirilmesi, oldukça önemlidir (Çepni, 2017).

Su Kirliliği Kontrolü Yönetmeliğinde (SKKY), atıksu arıtımı, suların çeşitli kullanımlar sonucunda atıksu haline dönüşerek yitirdikleri fiziksel, kimyasal ve bakteriyolojik özelliklerinin bir kısmını veya tamamını tekrar kazandırabilmek ve/veya boşaldıkları alıcı ortamın doğal fiziksel, kimyasal, bakteriyolojik ve ekolojik özelliklerini değiştirmeyecek hale getirebilmek için uygulanan fiziksel, kimyasal ve biyolojik arıtma işlemlerinin birini veya birkaçını ifade etmektedir.

Güner (2017), atık su arıtımında kullanılan yöntemleri birincil, ikincil ve ileri arıtma yöntemleri olarak sınıflandırmış ve birincil arıtmanın ızgara, yağ sıyrıcı paletler ve benzeri fiziksel arıtma üniteleri ile bir kimyasal veya bakteri kullanmadan atık sudaki yüzen ve çökebilen katı maddelerin uzaklaştırılması, ikincil arıtmanın kimyasal ve/veya biyolojik arıtma ünitelerinden oluştuğunu ve kimyasal arıtmada atık suyun

hızlı ve yavaş karıştırma üniteler ile çeşitli kimyasallar eklenerek kirleticilerin kimyasal reaksiyona girerek çökmesi ile arıtmanın gerçekleştiğini, ikincil arıtmada giderilmeyen kirleticilerinde ileri arıtma ile giderildiğini belirtmiştir.

Nas (2017), çalışmasında da belirttiği üzere; yerleşim yerinin nüfusuna ve alıcı ortam standartlarına bağlı olarak basit bir ön arıtmadan başlanarak, birincil, ikincil ve üçüncül arıtma proseslerinden seçim yapılmaktadır. Ülkemizde yaygın kullanılan arıtma prosesleri Şekil 2.1’de görüleceği üzere; ilk arıtma (ızgara, kum ve yağ tutucu), birincil arıtma (çökeltme havuzu), ikincil arıtma (aktif çamur prosesi) şeklindedir. Hassas alanlara deşarjlarda ise üçüncül arıtma (biyolojik nütrient giderimi) prosesleri uygulanmaktadır. Arıtılmış atıksuyun yeniden kullanımı hedeflendiğinde ise son çökeltme havuzu çıkış suyuna filtrasyon ve dezenfeksiyon (UV, klorlama) uygulamaları yapılmaktadır.



Şekil 2.1. Atıksu arıtım yöntemleri.

2.2 Yapay Sinir Ağları Hakkında Genel Bilgi

Makine öğrenmesi; bilgisayar sistemleri ile veri analizi yaparak gerekli algoritma ve formüllerin kullanılmasıyla bir şeyler öğrenilmesidir. Daha sonraki zaman ya da zamanlar için çalışılan olay hakkında karar verecek düzeye ulaşılmasına makine

öğrenmesi denir (Öztemel, 2012). Çakır (2020), çalışmasında Yapay Sinir Ağları hakkında şu bilgileri vermiştir; YSA örnek verileri kullanılarak genel yargılar veya sonuçlar üretmeye çalışan makine öğrenmesi alanında geliştirilmiş bir yapay zeka uygulamasıdır. Kullanıcıların, bilgisayar ortamında yapay sinir ağına yalnızca eldeki örnekleri verip başka bilgi verilmeden bu örnekler ile sonuçlara göre ağı öğrenme işlemini gerçekleştirmesini, öğrenmeyi gerçekleştirdikten sonra da hiç görmediği örnekleri kullanarak YSA'nın öğrendiği bilgilerle sonuca ulaştığına değinmiştir.

Yapay Sinir Ağları (YSA) canlılardaki sinir hücrelerinin ve ağlarının matematiksel olarak modellenmesi ile oluşturulmuş yapılardır. Günümüzde bu yapılar, karar verme, sınıflandırma, tahminde bulunma, kontrol gibi birçok alanda kullanılmaktadır (Temür, 2013).

Bu ağlara olan ilgi oluşturulacak olan ağı yapısının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağı davranışlarını açıklayamamasına rağmen her geçen gün artmaktadır. Özellikle yapay sinir ağları, sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında en güçlü teknikler arasında sayılabilirler. Günlük hayatımızda, veri madenciliği, optik karakter taşıma, optimum rota belirleme, parmak izi tanıma, malzeme analizi, iş çizelgelemesi ve kalite kontrol, tıbbi analizler gibi birçok alanda göreceğimiz başarılı örneklerine rastlamak mümkündür (Öztemel, 2012).


2.2.1 Yapay sinir hücresi ve yapay sinir ağlarının yapısı

Beyin, sahip olduğu büyük sinir ağları ile bilişsel, algısal ve kontrol görevlerinde başarılı olabilmektedir. Beyin, hesaplama açısından zorlayıcı algısal eylemleri ve kontrol faaliyetlerini gerçekleştirebilir. Beynin avantajı, geniş paralellikten etkili bir şekilde yararlanması, son derece paralel hesaplama yapısına sahip olması ve belirsiz bilgi işleme yeteneğidir. İnsan beyni, birbirine bağlı on milyardan fazla nöronun bir koleksiyonudur. Her nöron, bilgi almak, işlemek ve iletmek için biyokimyasal reaksiyonları kullanan bir hücredir. Beyindeki sinir ağlarını matematiksel modellerinin genellemesi olarak Yapay sinir ağları geliştirilmiştir (Abraham, 2005).

Biyolojik sinir ağlarının yapısını ve işlevlerini taklit etmek için geliştirilen modellere yapay sinir ağı denir. Yapay sinir ağının temeli matematiksel fonksiyon olan yapay nörondur (Krenker vd., 2011).

Son yıllarda yapay sinir ağları (YSA'lar), bilim insanları ve mühendisler arasında büyük bir ilgi uyandırmıştır. YSA'lar, öğrenme ve hatırlama yeteneklerine sahiptirler. Bunlar, insan beyninin temel işlevleridir. Bu hayranlığın ana nedeni, YSA'ların 'biyolojik' esin kaynağına sahip olmasıdır. Karmaşık ve gürültülü bilgilerle karşılaştıklarında karar verme ve sonuç çıkarma yetenekleri, beynin aktivitelerini taklit etme yeteneğine sahiptirler (Raol ve Mankame, 1996).


Gelişen bilgisayar teknolojileri ile kullanımı artan yapay zeka teknikleri arasında YSA da yer almaktadır. YSA insanların doğayı araştırma ve taklit etme çabalarının en son ürünlerinden biridir. YSA basit biyolojik sinir hücrelerinin çalışma şeklini simule etmek için tasarlanmış programlardır (Öztemel, 2012). Şekil 2.2’de İnsan sinir hücresi verilmiştir.



Şekil 2.2. İnsan sinir hücresi.

İnsan sinir hücresi, hücre çekirdeğini içeren soma (şişkin hücre gövdesi), dendritler (hücre gövdesine bağlı uzun, tüy benzeri filamentler, karmaşık dallanmış "dendritik ağaç" şeklinde) ve tek bir akson (soma uzunluğunun binlerce katı olabilen, özel, ekstra uzun, dallanmış hücresel filament) içerir. Sinir uyarıları, hücrenin aksonu boyunca hızla ilerler ve sinaps adı verilen özel bir bağlantı üzerinden komşu bir nörona iletilir, bu komşu nöron onu tüy benzeri dendritleriyle alır. Her bireysel nöron bu şekilde diğer

nöronlarla binlerce bağlantı kurabilir, bu da tipik bir beyine 100 trilyonun üzerinde sinaps (bazı tahminlere göre 1.000 trilyona kadar) verir. İşlevsel olarak ilişkili nöronlar birbirine bağlanarak sinir ağları (nöral ağlar veya topluluklar olarak da bilinir) oluşturur. Ancak, nöronlar arasındaki bağlantılar statik değildir, zamanla değişir. İki nöron arasında ne kadar çok sinyal gönderilirse, bağlantı o kadar güçlenir (teknik olarak, post.sinaptik nöronun tepkisinin genliği artar) ve böylece her yeni deneyim ve hatırlanan her olay veya bilgiyle beyin fiziksel yapısını hafifçe yeniden düzenler (Zhang, 2019). Benzer şekilde yapay sinir hücreleri de dışarıdan gelen bilgileri bir toplama fonksiyonu ile toplar ve aktivasyon fonksiyonundan geçirerek çıktı olarak üretip ağırlık bağlantılarının üzerinden diğer hücelere (proses elemanlarına) gönderir (Öztemel, 2012). Bunlar Şekil 2.3’de belirtildiği üzere; girdi katmanı, ara katmanlar ve çıktı katmanıdır.




Şekil 2.3. Yapay sinir ağları katmanları.

Öztemel (2012), çalışmasında YSA çalışma prensibinin bilgilerin ağa girdi katmanından iletilmesiyle başladığını, bilgilerin ara katmanda işlendikten sonra çıktı katmanına gönderildiğini belirtmiştir. Ağa gelen bilgilerin ağırlık değerleri kullanılarak çıktıya dönüştürülmesi süreci bilgi işleme olarak tanımlanmakta olup, doğru çıktıları üretebilmesi için ağırlıkların doğru değerlendirilmesinin önemli olduğu ve bu işleme ağı eğitilmesi denildiğinden de bahsetmiştir. Ayrıca, ağı eğitilmesi sürecinde her örnek ağa gösterildiğinde ağı öğrenme kuralına göre ağırlıkların değiştiği ve en iyi sonuç elde edilene kadar bu işlemin devam ettiği, sonrasında ağa

iletilen test verilerine de ağı doğru çıktıları vermesi ile ağı eğitilmiş kabul edileceğini anlatmıştır.

2.2.2 Yapay sinir ağlarının elemanları

Bir yapay sinir hücresinde beş bölüm vardır. Bunlar; girdiler ($X_1, X_2, X_3, \dots$), ağırlıklar ($W_1, W_2, W_3, \dots$), birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktıdır (Y) (Haykin, 1999). Bu bölümler Şekil 2.4’de verilmiştir.



Şekil 2.4. Yapay sinir hücresinin elemanları.

Girdiler: Girdi katmanını dışarıdan gelen bilgileri toplayan katmandır. Girdi katmanında girdi sayısı kadar sinir hücresi bulunur. Bu katmanda girdiler çoğunlukla bir işleme tabi tutulmadan diğer katmana geçer. Girdi katmanından gelen bilgiler ara katmanlara geldiğinde bilgi işleme yapılır (Çakır, 2020).

Ağırlıklar: Yapay sinir hücresine gelen bilgiler girdiler üzerinden çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlığıyla çarpılarak çekirdeğe iletilir. Bu sayede girdilerin üretilen çıktı üzerindeki etkisi ayarlanabilmektedir.

Toplama Fonksiyonu: Girdiler ile ağırlıkların çarpılması ile Network(NET) girdi değeri bulunur. Girdiler ve ağırlıklar çarpıldıktan sonra NET değerinin hesaplanmasında birkaç yöntem kullanılabilir. Aşağıda örnek olarak verilmiş olan formül (2.1) toplamının kullanıldığı formüldür (Çakır, 2020).

$$NET = \sum_{i=1}^n X_i * W_i \quad (2.1)$$

Aktivasyon fonksiyonu: Önceki katmandaki tüm girdilerin ağırlıklı toplamını alan ve daha sonra genellikle doğrusal olmayan bir çıkış değeri üreten ve bir sonraki katmana geçiren bir fonksiyondur (Öztemel, 2012). Çakır (2020), aktivasyon fonksiyonu çeşitlerini aşağıdaki şekilde belirtmiştir.

- Sigmoid(Logsig) fonksiyonu
- Hiperbolik tanjant (Tansig) fonksiyonu
- Doğrusal (Pürelin) fonksiyonu
- Doğrusal pozitif (Poslin) fonksiyonu
- Adım (Step veya Heavisite) fonksiyonu
- Rampa fonksiyonu
- Gaussion fonksiyonu
- Satlin ve Satlins fonksiyonları
- Hardlim ve Hardlims fonksiyonları

Çıktılar: Bu katman ara katmanda işlenen ve bilgiye dönüşen verinin son geçiş katmanı olup, çıkış katmanından oluşan veri başka bir hücreye girdi olacak veya direkt bilgi olarak çıkacaktır (Çakır, 2020).

2.2.3 Yapay sinir ağlarının özellikleri

YSA' nın karmaşık problemleri çözebilmesi için; öğrenme, genelleme, uyarlanabilirlik, hata toleransı, donanım ve hız, analiz ve tasarım kolaylığı özelliklerine sahip olması gerekir. Bu özelliklerin açıklaması aşağıda verilmiştir.

Öğrenme: Çetin (2014), çalışmasında YSA'nın temel işlevinin bilgisayarların öğrenmesini sağlamak olduğu, böylece benzer durumlar karşısında benzer cevaplar verebileceğini, bunda nöronlar arasında doğru bağlantılar kurulması ve bu bağlantılara uygun ağırlık değerlerinin atanması ile mümkün olabileceği, ağırlıklara başlangıç değeri olarak genellikle rastgele değerler atandığı ve seçilen öğrenme algoritmasına ve hata değerine bağlı olarak ağırlıkların yenilenerek öğrenme işleminin gerçekleştirildiğini ifade etmiştir.

Genelleme: Öztemel (2003), genelleme özelliğinin, eğitim sırasında kullanılan sayısal bilgilerden eşleştirmeyi betimleyen kaba özelliklerin çıkarılarak eğitim sırasında verilmeyen giriş değerleri için de anlamlı sonuçlar üretilebilmesi olarak ifade etmiştir.

Uyarlanabilirlik: Subaşı (2010), çalışmasında uyarlanabilirlik hususunda; belirli bir problemi çözmek için eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda YSA etkin olarak kullanılır, demiştir.

Hata Toleransı: YSA sistemleri klasik hesaplama yöntemlerinin aksine hata toleransına sahiptir. Paralel doğaları nedeniyle bilgi tek bir noktada saklanmayıp sisteme dağıtılmıştır. YSA'nın bazı nöronlarının bozulması ve çalışamaz hale düşmesi halinde performansın düşmesine rağmen ağ çalışmaya devam eder (Çetin, 2014).

Donanım ve Hız: YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda istenilir (Subaşı, 2010).

Analiz ve tasarım kolaylığı: YSA'ların temel işlem elemanı olan yapay nöron modeli, hemen hemen bütün YSA yapılarında aynıdır. Bundan dolayı, standart yapay nöron modeli tasarlandıktan sonra farklı YSA modelleri için kullanılabilir (Çetin, 2014; Temür, 2013).

2.2.4 Yapay sinir ağlarının çalışma prensibi

Önceleri sadece hesap yapabilirken ya da veri aktarımı gerçekleştirirken kullanılan bilgisayarlar ile şimdi büyük verileri özetleyen ve onları kullanarak olaylar hakkında yorumlar yapabilen, olaylar arasındaki ilişkiyi çözümleyen işlemler yapabilmektedirler. Bu özellikleriyle yaşamımızın vazgeçilmez bir parçası haline gelmişlerdir. YSA insan beyninin bilgi işleme mekanizmasını stimüle ederek, çeşitli problemlere çözüm getirmek amacıyla oluşturulmuş bilgisayar yazılımlarıdır. Öğrenme, hafızaya alma ve öğrendiklerini yeni bilgiler üretecek biçimde genelleme, değişkenler arasındaki ilişkileri ortaya koyma yeteneklerine sahip YSA insan beyni gibi biyolojik bir sinir ağının benzetimiyle oluşturulmuştur (Erdem, 2021).

Bir YSA'yı eğitmek ve sonuç üretmesini sağlamak için bazı adımların gerçekleştirilmesi gerekmektedir. Adımlardan birinin atlandığı durumda ağ istenen sonucu vermez. Bu nedenle aşağıdaki adımların çok iyi belirlenmesi ve uygun ağ yapısının kurulması gerekmektedir (Çakır, 2020).

- Verilerin ağa sunulması ve ağ yapısının belirlenmesi
- Gizli nöron sayısının belirlenmesi
- Birleşme ve aktivasyon fonksiyonlarının seçilmesi
- Durdurma kriterlerinin belirlenmesi
- Modeller için performans ölçütleri
- Modeller için hata azaltma yöntemleri

2.3 Yapay Sinir Ağının Sınıflandırılması

Yapay sinir ağları, yapılarına göre, aşağıda belirtildiği üzere ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar (URL-2).

1. İleri Beslemeli Ağlar: Bu ağlarda, aktarılan bilgilerin sadece ileri doğru girişten çıkışa doğru bir hareketi söz konusudur. Bir katmandaki nöronlar sadece kendinden sonra gelen katmana gider, sonrasında çıkış katmanına geçer, dışarıdan gelen bilgilere giriş katmanındayken herhangi bir değişiklik yapmadan bir sonraki katmana aktarır.
2. Geri Beslemeli Yapay Sinir Ağları: Çakır (2020), geri beslemeli ağların ileri beslemeli ağlar gibi yalnız kendinden sonraki katmana bilgi vermeyip, bir nöronun kendi katmanındaki veya kendinden önceki katmandaki nörona da girdi olarak bağlanabildiğini söylemiştir.

2.4 Yapay Sinir Ağlarında Öğrenme Stratejileri

2.4.1 Çok katmanlı algılayıcı (Öğretmenli öğrenme) (ÇKA)

Yapay sinir ağının öğrenebilmesi için girdi-çıkı değerleri tam olarak sisteme öğretilir. Sistem aldığı girdiler ile sonucunda oluşturması gereken çıktılar hakkında bilgi sahibi olur. Girdi ve çıktılar arasındaki ilişkiler böylelikle belirlenmiş olur. Bu öğrenme ile

ağın olayı öğrenmesinde bir öğretmen etkisi yer alır. Ağa verilen girdiler için ağın elde etmesi gereken çıktılar sayısal olarak bellidir (Ataseven, 2013; Çakır, 2020).

Bir yapay sinir ağının öğrenmesini istediğimiz olayların girdi ve çıktılar arasında doğrusal olmayan ilişkiler varsa bu durumda uygulanacak modellerden biri de Çok Katmanlı Algılayıcı modeldir. ÇKA modeli yapay sinir ağlarına olan ilgiyi çok hızlı bir şekilde arttırmış ve yapay sinir ağları tarihinde yeni bir dönemin başlamasına neden olmuştur (Öztemel, 2012).

2.4.2 LVQ Modeli (Destekleyici öğrenme)

Yapay sinir ağına hem girdi değerlerini hem de girdi değerlerine bağlı üretilecek çıktı değerleri verilerek uygulanan model Öğretmenli öğrenme modelidir. Bazen ağa çıktının ne olduğunu vermek mümkün olmamaktadır; ancak ağın üretmiş olduğu çıktının doğru veya yanlış olduğu belirtilebilmektedir. Doğrusal vektör parçalama modeli diyebileceğimiz LVQ (Linear Vektör Quanzation) modeli destekleyici öğrenme olarak da belirlenen bu yöntemi kullanan modellerin bir tanesidir (Öztemel 2012; Açıkalın, 2007).

2.4.3 Adaptif rezonans teori (ART) ağları (Öğretmensiz öğrenme)

Öztemel (2012) ve Açıkalın (2007) çalışmalarında ART ağlarını şöyle ifade etmişlerdir; ART ağlarının temeli öğretmensiz öğrenmeye dayalıdır. Gerçek zamanlı çalışabilmeleri ve çevrimiçi (on-line) öğrenebilmeleri bu ağların en önemli özellikleridir. ART ağları yeni durumlara adapte olabilmekte çok güçlüdürler. Bunu gerçekleştirmek için bir taraftan öğrenirken bir taraftan da unutabilmektedirler. Bir ART ağı, gösterim katmanı (F1) ve kategori katmanı (F2) olmak üzere iki katmandan oluşmaktadır. Bunların yanında, ağa sunulan girdilerin sınıflandırılmaması durumunda yeni bir kategori oluşturmaya yardım eden oryantasyon modülü vardır. F1 katmanı girdinin özelliklerini gösterirken F2 katmanı kategorileri (ayrıştırılmış sınıfları) göstermektedir. Bu iki katman birbirlerine UDH ile bağlanmaktadırlar. Girdi bilgileri F1 katmanından alınır ve sınıflandırma ise F2 katmanında yapılır.

2.5 Yapay Sinir Ağları Kullanım Alanları

Yapay sinir ağları tıp, mühendislik, sağlık, savunma, ticaret, güvenlik vs. çok farklı alanlarda başarı ile uygulanmaya devam etmektedir (Anderson, 1995). Öztemel (2003), yaptığı çalışmada yapay sinir ağları kullanım alanları hakkında şu hususları belirtmiştir; Yapay sinir ağı sınıflandırma, tahmin, teşhis, kontrol, veri ilişkilendirme, veri filtreleme, yorumlama gibi alanlarda kullanılmaktadır. Hangi problem için hangi ağın daha uygun olduğunu belirlemek için ağların özellikleri ile problemlerin özelliklerini karşılaştırmak gerekir (Öztemel, 2003). Matematiksel bir model veya algoritma oluşturulamadığı durumlarda bile, yapay sinir ağlarının kullanımı oldukça yaygın ve faydalıdır (Nabiyev, 2016).

2.6 Yapay Sinir Ağı Kullanımının Avantaj ve Dezavantajları

Çakır (2020), yapay sinir ağlarının avantajlı ya da güçlü yönlerini aşağıda belirtildiği şekilde sıralamıştır.

- YSA yaşanan gerçek problemlerin birçoğunun çözümünde kullanılır.
- Doğrusal veya doğrusal olmayan çoklu giriş ve çoklu çıkışlı sistemleri kolayca modelleyebilir.
- Hem kategorik hem de sürekli verilerle kullanılabilir.
- Geleneksel yöntemlerden farklı olarak bilgiyi işler ve değişkenlerin dönüşümlerini otomatik olarak yapabilir.
- Geniş bir kullanım alanı bulunmaktadır.
- Ağ, daha önce hiç görmediği örnekler üzerinden bilgi üretebilir.
- Eksik, gürültülü veya hatalı veri setlerinde dahi kullanılabilir.
- Ağın sahip olduğu ağırlık değerleri ne kadar doğru belirlenirse, ağın performansı da o kadar yüksek olur. Bilgi ağı, geri kalan parçalara dağıtıldığından, bir ağırlık kaybolduğunda bile ağın çalışmasını etkilemez.
- Gözlem sayısı az olduğunda bile diğer modellere göre iyi sonuçlar verir.
- YSA'lar, özellikle doğrusal olmayan zaman serilerinin tahmininde gösterdiği başarıyla zaman serilerinin tahmini için yaygın bir şekilde kullanılmıştır. YSA'lar, hem doğrusal hem de doğrusal olmayan modelleme yaparak tahmin yapabilir ve bu nedenle diğer modelleme yöntemlerine göre daha esnektir.

Çakır (2020), YSA'nın zayıf veya dezavantajlı tarafları da şu şekilde sıralamıştır.

- Güvenilir sonuçlar elde etmek için yeterli miktarda veri gereklidir.
- Her giriş ve çıkış değişkeni arasındaki ilişkilerin tam olarak bilinmesi mümkün değildir, bu nedenle her Yapay Sinir Ağı modeli, içindeki ilişkiler için bir kara kutudur. Kara kutunun içinde YSA'nın nasıl çözüm ürettiği hala merak konusudur.
- Algoritmalar, kısa bir süre sonra yerel bir çözüme ulaşabilir.
- Yapay Sinir Ağları, sözel nitelikteki verileri işleyemez; sadece nümerik verilerle çalışabilir.
- Ağın eğitiminin tamamlanması için belirli bir kriter bulunmamaktadır; bu nedenle kabul edilebilir bir hata seviyesine ulaşıldığında eğitim sonlandırılır, ancak bu, en iyi sonucun elde edildiği anlamına gelmez.
- Ağın nasıl oluşturulacağına dair net kurallar yoktur.
- Yapay Sinir Ağları, kabul edilebilir çözümler üretebilir ancak kesin en iyi çözümü garanti etmez; bu nedenle probleme uygun ağ yapısının dikkatlice belirlenmesi gerekir.
- Ağın parametre değerleri, tecrübeyle belirlenebilecek belirli bir sayıya sahip değildir.
- Girdiler, genellikle 0 ile 1 arasına ölçeklenmelidir.

2.7 Yapay Sinir Ağları ile Çevre Konusunda Yapılan Bazı Örnek Çalışmalar

Kapucu (2019), yüksek lisans tez çalışmasında, bazı meteorolojik veriler kullanılarak güneş ışıının şiddetinin modellenmesinde en uygun YSA modelinin geliştirilmesinde kullanılabilecek parametrelerin ortaya çıkarılmasını ve optimizasyonu araştırmıştır. Çalışma ile bağımsız değişkenlerden (bağıl nem, hava sıcaklığı, atmosferik basınç, birikmiş günlük toplam yağış ile ölçüm zamanı gibi) faydalanılarak güneş ışıının şiddetini modelleyebilen ve tahmin edebilen bir YSA geliştirilmiştir.

Kunt (2007), yüksek lisans tez çalışmasında, Konya ili örneğinde YSA modelleri ile hava kirliliğinin tahmininde, bazı meteorolojik parametreleri kullanarak SO₂ konsantrasyonunu tahmin etmiş ve yapay sinir ağlarının hava kirliliği modellenmesinde oldukça başarılı sonuçlar verdiğini belirtmiştir.

Çimen Mesutoğlu (2020), doktora tezi çalışmasında, öncelikli mikro kirleticilerden olan benzenin Orhaneli Çayında 12 ay boyunca izlemesini yapmış ve sonrasında yapay sinir ağları ile yapmış olduğu modelleme ile YSA tabanlı modellerin yüzeysel sulardaki benzen konsantrasyonlarının tahmin edilmesinde kullanılabileceği sonucuna ulaşmıştır.

Açıkalın (2007), yüksek lisans tez çalışmasında, atıksu arıtma tesisi kirlilik parametrelerinden biyolojik oksijen ihtiyacı, kimyasal oksijen ihtiyacı ve askıda katı madde çıkış değerlerini tahmin etmek için Yapay Sinir Ağları metodu kullanarak Adapazarı Kentsel Atıksu Arıtma Tesis verilerinden oluşturulan modellerden ÇKA modelin gerçek verilere oldukça iyi bir sonuçla uyum sağladığı sonucuna ulaşmıştır.

Hassen ve Asmare (2019), çalışmalarında bira fabrikası atıksu arıtma tesisinin yapay sinir ağları kullanılarak tahmine dayalı performans modellemesini yapmıştır. Çalışma endüstriyel AAT'lerden gelen ham giriş ve arıtılmış atık su kalitesi verileri arasındaki ilişkinin doğrusal olmayışını ve karmaşıklığını yakalamak için sinir ağları kullanmanın etkinliğini göstermiştir. Sonuç olarak YSA modellerinin, AAT performansını tahmin etmek için potansiyel olarak kullanılabileceğini ve böylece tesisin kontrolü ve izlenmesi için iyi bir destekleyici araç sağlayabileceği görülmüştür.

Aras (2020), Bolu İli Örneğinde Atık Su Arıtma Tesis Modellemesi ve Performans Parametreleri Değerlendirilmesi konusunda yaptığı çalışmasında Bolu Belediyesi Merkezi Atık Su Arıtma Tesisinden elde edilen veriler için yapılan istatistiksel yöntemler sonucunda verilerin güvenilir olduğunu, Konvolüsyonel Sinir Ağı modelinin, atık su arıtma tesislerinin modellemesinde başarılı olduğunu görmüştür.

Çepni (2017), yılında yapılan yüksek lisans tez çalışmasında, istatistiksel metotlar yardımıyla, 2009-2013 yılları arasında Buski Doğu ve Batı Atıksu Arıtma Tesislerinden, kompozit olarak alınan numunelerde ölçülen pH, iletkenlik ($\mu\text{S}/\text{cm}$), BOI_5 (mg/L), KOI (mg/L), AKM (mg/L), TN (mg/L), TP (mg/L) değerleri kullanılarak, arıtma tesislerinin mevsimlere ve yıllara göre performanslarını değerlendirmiştir.

Alkay (2016), yılında yapılan yüksek lisans tez çalışmasında, Kocaeli 42 Evler ile Kullar Atıksu Arıtma Tesislerinin tesis giriş verileri ile atıksu arıtma tesis işletme

simülasyonunu yapay sinir ağı ile yapılmış ve tesis işletmeye alınmadan arıtma tesisinin performansı incelenmiş ve iki tesisin tek arazide birleştirilip yeniden projelendirilmesinin optimum çözüm olduğu sonucuna varmıştır.

Tümer ve Edebalı (2019), MATLAB yazılımındaki yapay sinir ağı kullanarak Konya atıksu arıtma tesisinin modellenmesi konusunda yaptıkları çalışmada ölçülen ve tahmin edilen çıktı değişkenleri arasındaki maksimum korelasyon katsayısının (R) 3-3-1 YSA yapısıyla 0,99'a kadar ulaştığını göstermiştir. YSA'nın atıksu arıtma tesisini anlamak ve taklit etmek için verimli bir analiz ve tanı koyma yardımı sağladığı ve arıtma tesisi işletmecileri ve yöneticiler için önemli bir performans değerlendirme aracı olarak kullanıldığı sonucuna varılmıştır.

2.8 Atıksu Arıtma Tesisi Veriminin Yapay Sinir Ağları ile Modellenmesi

Çınar ve Yılmaz (2005), Yapay sinir ağlarının atıksu arıtma tesisi işletilmesine uygulanması hakkındaki çalışmalarında şu hususları ifade etmişlerdir; Atıksu arıtma süreçleri, tesise gelen atık su akış hızı, konsantrasyonu ve bileşimindeki büyük farklılıklar nedeniyle doğal olarak değişkendir. Kentleşme ve sanayinin artmasıyla birlikte atıksu oluşumu da artmaktadır, bu da daha etkin ve verimli çalışan arıtma tesislerine olan ihtiyacı artırmaktadır. Ancak, birçok atıksu arıtma tesisi, tasarım ve işletme hataları nedeniyle tam verimle çalışmamaktadır. Mevcut tesisler, mevzuat tarafından zorunlu kılınan deşarj standartlarını sağlayamayabilir veya işletme maliyetleri yüksek olabilir. Bu durum, iyileştirme ve optimizasyon ihtiyacını doğurmakta ve dolayısıyla atıksu arıtım tesislerinde modelleme çalışmalarının önemi artmaktadır. Arıtım tesisleri gibi karmaşık prosesler, modelleme çalışmalarında yer alan akıllı yöntemler ile modellenebilmektedir. Tesisin geçmiş işletim verilerinden yararlanılarak bulanık mantık ve istatistiksel süreç kontrolü kullanılmaktadır. Ancak örneklerden öğrenebilen YSA'nın karşılaşılan birçok ek sorun için daha iyi çözüm seçenekleri sunduğu yapılan çalışmalarda görülmüştür (Erdem, 2021).

3. MATERİYAL VE YÖNTEM

3.1 Konya İli Hakkında Genel Bilgi

Konya ili, İç Anadolu Bölgesi'nin güneyinde yer almaktadır. Konya'nın 31 ilçesi bulunmaktadır. Türkiye İstatistik Kurumu 2022 yılı adrese dayalı nüfus kayıt verilerine göre nüfusu 2.296.347 kişidir. Yüzölçümü 41.001 kilometrekaredir. Konya da karasal iklim hâkimdir. Konya coğrafi olarak 36°41" ve 39°16' kuzey enlemleri ile 31°14' ve 34°26' doğu boylamları arasında yer alır. Yüz ölçümü bakımından Türkiye'nin en büyük yüz ölçümüne sahip olan ildir. Şekil 3.1'de Konya il haritası verilmiştir (Anonim, 2023).



Şekil 3.1. Konya il haritası.

3.2 Konya Atıksu Arıtma Tesisi Hakkında Genel Bilgi

Konya Kentsel Atık Su Arıtma tesisi Karatay İlçesi Tatlıcak Mevkiinde bulunmaktadır. KOSKİ Genel Müdürlüğünden alınan bilgilere göre mevcut durumda 110.000 m² yüz ölçümüne sahip sahada 1.000.000 kişi eşdeğer nüfus ve 200.000 m³ /gün atık su debisi ile çalışmakta olup, 2030 yılı 1.600.000 kişi eşdeğer nüfus ve 300.000 m³ /gün kapasiteye göre tasarlanmıştır. İleri biyolojik arıtma + UV dezenfeksiyon yöntemleriyle çalışmaktadır. Atıksu Arıtma Tesisi çıkışında arıtılmış

sular Konya Ana Tahliye Kanalına verilmektedir. Tesis Çevre, Şehircilik ve İklim Değişikliği Bakanlığı sürekli atıksu izleme sistemleri ile takip edilmektedir.


Ayrıca tesiste atıksuyun arıtımı sırasında oluşan çamurların çürütülmesi sonucu ortaya çıkan biyogaz kullanılarak elektrik ve ısı enerjisi üretimi yapılmaktadır. 2500 kWh elektrik üretilmektedir. Tesiste oluşan stabilize arıtma çamurları tarım arazilerinde kullanılmaktadır.

Arıtılmış atıksuların yeniden kullanımı için 150 m³/h kapasiteli uygulama projesi ile yeşil alan sulamasında uygulamalar yapılmaktadır. Bu uygulama sayesinde, üretilen yaklaşık 385.000 m³/sezon geri kazanılmış atıksu ile her yıl sulama sezonunda 3.216.000 m² yeşil alan sulaması gerçekleştirilmektedir.

Artan Nüfus ve kentleşme oranlarına paralel olarak Konya atıksu arıtma tesisinin de kapasitesinin artırılması gerekmektedir. 2040 yılında 2.409.592 kişi ve 400.000 m³ /gün debiye hizmet verecek ikinci kademe atıksu arıtma tesisi planlanmıştır. Planlanan tesiste Arıtılmış Atıksudan Tarımsal Sulama Suyu Üretim Tesisi Ünitesi 'de yer almaktadır. Konya atıksu arıtma tesisi genel görünümü Şekil 3.2'de, tesis iş akım şeması Şekil 3.3'de verilmiştir.



Şekil 3.2. Konya Kentsel Atıksu Arıtma Tesisi fotoğrafları.




Şekil 3.3. Konya Kentsel Atıksu Arıtma Tesisi iş akış şeması.

Konya Kentsel Atıksu Arıtma Tesisi genel olarak ön arıtma, ön çökeltme, havalandırma havuzu, son çökeltme havuzları, çamur yoğunlaştırma, çamur susuzlaştırma, çamur çürütme, çıkış yapısı, biyogaz saflaştırma ve kojenerasyon, mor şebeke ünitelerinden oluşmaktadır. Belirtilen üniteler hakkında detaylı bilgi aşağıda verilmiştir.

3.2.1 Ön arıtma ünitesi

Ön Arıtma Ünitesi (Şekil 3.5) işletmede 6.250 m² alanda (6.250 m² açık alan) yer almaktadır. Şekil 3.4’de ön arıtma ünitesi vaziyet planı verilmiştir.



Şekil 3.4. Ön arıtma ünitesi vaziyet planı.



Şekil 3.5. Ön arıtma ünitesi fotoğrafı.

Ön arıtma ünitesinde yer alan bölümler aşağıdaki gibidir:

Atıksu girişi: Konya Şehrinden kaynaklanan atıksular atıksu arıtma tesisine 3000 mm’lik beton borulardan giriş yapar.

Giriş kaba ızgara: Atıksular giriş pompalarının korunması amacıyla 40 mm aralıklı giriş kaba ızgaradan geçirilerek, sudan uzaklaştırılırlar.

Bu ünite de ön arıtmadan çıkan atıksuyun içerisindeki çökebi len katı maddeler belli bir bekletme süresi sonunda graviteli olarak çöktürme işle mi gerçekleştirilir. Ön çökeltme ünitesinde yer alan bölümler aşağıdaki gibidir:

Ön çökeltme dağıtım yapısı: Ön arıtmadan geçen atıksuyun ön çökeltme havuzlarına dağıldığı kısımdır.


Ön Çökeltme Havuzları: 4 Adet 5400 m³ hacme sahip ön çökeltme havuzu vardır. Ön çökeltme havuzlarının amacı çökebi len katı maddelerin çökmesini sağlamaktır. Çöken katı maddeler sonucu havuzun alt kısmında oluşan çamur, çamur yoğunlaştırma dağıtım yapısına gönderilirken, havuzun üst tarafından savaklanan atıksu havalandırma havuzu dağıtım yapısına gönderilir.

Havalandırma Havuzu Dağıtım Yapısı: Ön Çökeltme havuzunun üst tarafından savaklanan atıksular biyolojik olarak arıtmaya girmeden önce dağıtım yapısından geçer. Aynı zamanda havalandırma havuzu dağıtım yapısına, son çökeltme havuzunun alt tarafından toplanan çamur da gönderilir.

Çamur Yoğunlaştırma Dağıtım Yapısı: Ön Çökeltme havuzlarının ve son çökeltme havuzlarının alt kısımlarından toplanan çamurlar, çamur yoğunlaştırma dağıtım yapısına gönderilir.

3.2.3 Havalandırma Havuzu Ünitesi

Havalandırma Havuzları Ünitesi (Şekil 3.8) işletmede 28.820 m² alanda (28.430 m² açık alan ve 390 m² kapalı alan) yer almaktadır. Bu ünite de Ön çökeltme havuzlarından çıkan atıksuyun biyolojik olarak arıtımı gerçekleştirilir. Üniteye ait vaziyet planı Şekil 3.7’de verilmiştir.




Şekil 3.7. Havalandırma havuzu ünitesi vaziyet planı.



Şekil 3.8. Havalandırma havuzu.

3.2.4 Son çökeltme havuzları ünitesi

Son Çökeltme Havuzları Ünitesi (Şekil 3.10) işletmede 27954 m² alanda (27.440 m² açık alan ve 514 m² kapalı alan) yer almaktadır. Bu ünite de havalandırma havuzlarından gelen karışık sıvıdaki çamurlar belli bir bekletme süresi sonunda çökerek üst tarafından çıkış suyu haline gelir, alt taraftan alınan çamurun bir kısmı geri devrettirilirken fazla olan kısmı ise çamur yoğunlaştırma dağıtım yapısına gönderilir. Üniteye ait vaziyet planı Şekil 3.9’da verilmiştir.



Şekil 3.9. Son çökeltme ünitesi vaziyet planı.



Şekil 3.10. Son çökeltme havuzları.

Son çökeltme havuzları ünitesinde yer alan aşamalar aşağıdaki gibidir:

Son çökeltme havuzları dağıtım yapısı: Havalandırma havuzlarından gelen karışık sıvı son çökeltme havuzlarına dağılması için son çökeltme havuzları dağıtım yapısına gelir.

Son çökeltme havuzları: Toplam hacmi 51.650 m³ olan 8 adet son çökeltme havuzlarına gelen karışık sıvı içerisindeki bakteri topluluklarının çökmesi için belli bir süre bekletildikten sonra üstte kalan su çıkış suyu haline gelirken alt tarafta toplanan bakteri toplulukları, bakteri popülasyonunun devamı için havalandırma havuzları dağıtım yapısına gönderilir.

3.2.5 Çıkış kanalı

Çıkış Kanalı: Son çökeltme havuzlarından çıkan arıtılmış atıksular çıkış kanalına gelir. Bu kısımda arıtılmış atıksuyun debisi, pH'sı, iletkenliği, sıcaklığı ölçülür. Şekil 3.11'de çıkış kanalları verilmiştir.

U.V. Bypass Kanalı: Çıkışa kanalından geçen arıtılmış atıksular U.V. ünitesinde sorun olması durumunda U.V. bypass kanalına gönderilir.

U.V. Kanalı: Arıtılmış atıksuları dezenfekte edebilmek için U.V. kanalından geçirilir. Şekil 3.12'de U.V. kanalları verilmiştir.



Şekil 3.11. Çıkış kanalları.



Şekil 3.12. U.V. kanalları.

3.2.6 Çamur yoğunlaştırma havuzları ünitesi

Çamur yoğunlaştırma Havuzları Ünitesi (Şekil 3.13) işletmede 3950 m² alanda (3803 m² açık alan ve 147 m² kapalı alan) yer almaktadır. Şekil 3.14 de görülen bu ünite ön çökeltmeden ve son çökeltmeden toplanan çamurları daha yoğun hale getirmek için kullanılır.



Şekil 3.13. Çamur yoğunlaştırma havuzları ünitesi vaziyet planı ve iş akışı.



Şekil 3.14. Çamur yoğunlaştırma havuzları.


Çamur yoğunlaştırma havuzları vaziyet planı Şekil 3.13’de verilmiş olup, ünitesi aşağıdaki bölümlerden oluşur:

Çamur Yoğunlaştırma Dağıtım Yapısı: Ön çökeltme ve son çökeltme havuzlarından toplanan çamurlar çamur yoğunlaştırma havuzlarına dağılması için çamur yoğunlaştırma dağıtım yapısına gelir.

Çamur Yoğunlaştırma Havuzları: Toplam hacmi 5542 m³ olan 4 adet çamur yoğunlaştırma havuzuna gelen çamurlar belli bir bekletme süresi sonunda daha yoğun hale gelerek fiziksel çamur çürütücülere beslenecek özellikteki bir çamura dönüşür. Alt taraftan toplanan yoğunlaşmış çamur çürütücüye beslenirken, havuzun üst tarafındaki savak kısmından oluşan yoğunlaşmamış kısım ise giriş yapısına gönderilir.

3.2.7 Çamur çürütme ünitesi

Çamur Çürütme Ünitesi işletmede 3262 m² alanda (3134 m² açık alan ve 128 m² kapalı alan) yer almaktadır. Üniteye ait vaziyet planı Şekil 3.15 de yer almaktadır. Bu üniteye çamur yoğunlaştırma havuzlarından gelen yoğunlaşmış çamurlar stabil hale getirilirler. Çamur çürütücüler toplam 28.000 m³ hacminde 4 adet çamur çürütme tankında çamur yoğunlaştırma ünitesinden gelen yoğunlaşmış çamurlar belli bir bekletme süresi sonunda ve 36 °C sıcaklıkta çürütme işlemini gerçekleştirirler. Bu işlem sırasında ortaya çıkan biyogaz desülfürizasyon ünitesine, çürümüş çamur ise çamur susuzlaştırma ünitesine gönderilir.



Şekil 3.15. Çamur Çürütme Ünitesi vaziyet planı ve iş akışı.

3.2.8 Çamur susuzlaştırma ünitesi

Çamur susuzlaştırma Ünitesi işletmede 470 m² alanda (açık alan yok) yer almaktadır. Bu ünite de çamur çürütücülerden çıkan çürümüş çamur katı madde oranı arttırılarak sıvı halden katı hale getirilir. Çamur çürütücülerden çıkan çürümüş çamurun katı madde oranını yaklaşık % 2,5'den % 25'e çıkarmak için 4 adet santrifüj dekantör kullanılmaktadır. Çürümüş çamur santrifüj dekantörlere girerken polielektrolit çözeltisi hazırlama haznesinde hazırlanan katyonik polielektrolit ile karışırlar. Böylece çürümüş çamur içerisindeki katı maddeler bir araya gelerek katı madde ayırımına yardımcı olur.

3.2.9 Biyogaz saflaştırma ve kojenerasyon ünitesi

Biyogaz saflaştırma ve Kojenerasyon ünitesi işletmede 412 m²'si kapalı olmak üzere toplam 2670 m² alanda yer almaktadır (Şekil 3.17). Bu ünite de çamur çürütücülerden elde edilen biyogaz sırasıyla desülfürizasyon, rutubet giderimi, gaz balonları ve gaz motorlarına giderek elektrik enerjisi geri kazanımı veya ısı kazanlarında ısıtma amaçlı uygulanmaktadır. Ünite vaziyet planı Şekil 3.16 da yer almaktadır.



Şekil 3.16. Biyogaz saflaştırma ve kojenerasyon ünitesi vaziyet planı.

Çamur çürütücülerde oluşan biyogaz içerisindeki H₂S'in biyolojik olarak giderimi sağlanmaktadır. Daha sonra rutubet giderimi aşamasında biyogaz içerisinde oluşan su buharını uzaklaştırmaktır. Biyogazın içerisindeki safsızlıklar giderildikten sonra elde edilen gaz balonlarında depolanır. Toplam 8.000 m³ kapasiteli 2 adet gaz balonu mevcuttur. Enerji geri kazanımı için gaz motorlarında biyogaz elektriğe ve ısıya çevrilir. Toplam 2.500 kWh kapasiteli sadece biyogaz ile çalışan 3 adet gaz motoru mevcuttur.




Şekil 3.17. Desülfürizasyon ve enerji geri kazanım ünitesi.

3.2.10 Isı kazanları

Anaerobik çamur için ısıtma ihtiyacında kullanılan ekipmandır. Biyogaz veya doğalgaz ile çalışabilir. Toplam 4000 kW gücünde 2 adet ısı kazanı bulunmaktadır.

3.2.11 Atıksu geri kazanım ünitesi (Mor şebeke)

Atıksu Geri Kazanım Ünitesi 500 m² geri kazanılmış atıksu deposu ile birlikte toplam 820 m² kapalı alana sahiptir. Arıtılmış atıksu deposuna gelen arıtılmış atıksular bir pompa vasıtasıyla basınçlı kum filtrelerine geçerken ön klorlama ve koagülasyon işlemlerinden geçmektedir. Filtrelerden çıkan geri kazanılmış atıksuya önce U.V. sonra son klorlama işlemi uygulanarak geri kazanılmış atıksu deposuna gönderilir. Şekil 3.18’de atıksu geri kazanım ünitesi (mor Şebeke) vaziyet planı verilmiştir.



Şekil 3.18. Atıksu geri kazanım ünitesi (Mor Şebeke) vaziyet planı.

3.3 Çalışılan Parametreler

Bu çalışma ile Konya Su ve Kanalizasyon İdaresi (KOSKİ) Genel Müdürlüğünden temin edilen Konya Kentsel Atıksu Arıtma Tesisi 2021-2022 yılı giriş suyunda deneysel olarak tespit edilen pH, sıcaklık, iletkenlik, BOİ, KOİ, AKM parametreleri değerlerinden faydalanılarak, çıkış suyu BOİ, KOİ ve AKM parametrelerinin değerleri MATLAB (R2023b) programı YSA modeli kullanılarak iki farklı senaryo ile tahmin edilmiştir. Çalışılan parametrelerin ağ yapısında kullanım şekilleri Çizelge 3.1 ve Çizelge 3.2’de gösterilmiştir.

Çizelge 3.1. Çalışılan parametreler ve modelde kullanım Şekilleri (Senaryo 1).

Girdiler	Çıktı
AKM	AKM
İletkenlik	
Sıcaklık	

Girdiler	Çıktı
KOİ	KOİ
Sıcaklık	
İletkenlik	

Girdiler	Çıktı
BOİ	BOİ
Sıcaklık	
İletkenlik	

Çizelge 3.2. Çalışılan parametreler ve modelde kullanım şekilleri (Senaryo 2).

Girdiler	Çıktı
pH	AKM
Sıcaklık	
İletkenlik	
AKM	
KOİ	

Girdiler	Çıktı
pH	KOİ
Sıcaklık	
İletkenlik	
AKM	
KOİ	

Girdiler	Çıktı
pH	BOİ
Sıcaklık	
İletkenlik	
AKM	
KOİ	
BOİ	

3.4 Veri Toplama

Bu çalışma ile KOSKİ Genel Müdürlüğü Konya Kentsel Atıksu Arıtma Tesisi 2021-2022 yılı giriş ve çıkış suyunda deneysel verilerle tespit edilen pH, sıcaklık, iletkenlik, BOİ, KOİ, AKM parametreleri değerlerinden faydalanılmıştır. Gerçek sistemden elde edilen ölçüm değerleri YSA modelinde kullanılabilecek yapıya sahip olmadıklarından çalışmada kullanılabilmesi için normalizasyon işlemine tabi tutulmuştur.

3.5 Seçilen Yapay Sinir Ağları Modeli Hakkında Bilgi

Çakır (2020), Yapay sinir ağları, MATLAB kodları ve MATLAB toolbox çözümleri kitabında; YSA'ların örneklerden öğrenen ve bu öğrendiklerini daha önce görmediği örneklere uygulayan bir yapıda olduğu, ağın sadece kendine verilen örnekler için öğrenme gerçekleştirdiği, eğitildiği örnek türleri dışında herhangi bir konuya tekrar eğitilmeden cevap veremediği, ağa yeni girdiler sunulduğunda önce bunlarla da eğitimin tamamlanmasının gerektiği, verilerin ağa sunulmasında genel kabul görmüş bir kuralın olmadığı, verinin ağa nasıl sunulacağının eğitim algoritmasına bağlı olduğu, bazı algoritmalarda veriler bütün hâlinde ağa tanıtılırken, bazı algoritmalar için ise veri tanıtımının değişken setleri hâlinde yapıldığı, veri sayısı hakkında da genel bir kuralın olmadığı ancak ağa uygun sayıda verinin sunulmasının öğrenmenin iyi bir şekilde gerçekleşmesi için gerekli olduğu hususlarını ifade etmiştir.


Kapucu (2019), çalışmasın da YSA kullanımı ile istatistiksel yöntemlerin karşılaştırıldığı çalışmalardan özellikle YSA'nın modelleme anlamında eğri

uydurmada başarılı olduğundan bahsetmiştir. Diğer taraftan YSA'nın, pek çok yazılım geliştirme ekosistemleri ya da programlama dilleri için özel olarak geliştirilmiş yazılım kütüphaneleri kullanılarak oluşturulabildiği ve MATLAB programının, YSA oluşturmak amacıyla sık kullanılan ekosistemlerden biri olduğunun ve MATLAB'da YSA oluşturmak için YSA araç kutuları kullanıldığını belirtmiştir.


YSA model geliştirme sürecinde aşağıda belirtilen aşamalar dikkate alınmıştır;

- Veri toplama ve veri setlerinin normalizasyonu
- Ağın dizaynı (verilerin kullanım oranları, gizli katman sayısı, gizli katmanda yer alan nöron sayısı, eğitim algoritması vs.)
- Ağın eğitimi,
- Test edilmesi ve uygun algoritmanın onaylanması

Bu çalışmada MATLAB (R2023b) programı uygulamalar bölümünden Neural Network Start araç kutusu menüsünde yer alan Neural Net Fitting sekmesi kullanılarak YSA topolojisi oluşturulmuştur. Şekil 3.19'da gösterilen sinir ağları başlatma aracı (*nnstart*) arayüzü ile Neural Net Fitting sinir ağı aracına ulaşılarak ağ yapısı belirlenmiştir. Aynı zamanda MATLAB komut penceresinden de *nnstart* komutunun çalıştırılmasıyla da araç kutusuna ulaşılabilir (Şekil 3.20).



Şekil 3.19. Araç kutusu menüsünden erişim.




Şekil 3.20. Komut penceresinden erişim.

Hangi değişkenlerin giriş hangilerinin çıkış değişkenleri olacağı, verilerin ne kadarlık kısmının eğitim ne kadarlık kısmının test ve doğrulama için kullanılacağı verilerin ağa sunulma aşamasında belirlenmiştir. Ağın oluşturulması aşamasında program tarafından %70'i eğitim verisi, %15'i test verisi, %15'i ise doğrulama verisi olarak seçilmekte olup, en uygun algoritma için bu değerler değiştirilebilmektedir. Çalışmada, YSA modelinde, birleştirme fonksiyonu olarak toplama fonksiyonu kullanılmış, aktivasyon fonksiyonu olarak Hiperbolik Tanjant Sigmoid fonksiyonu kullanılmıştır. Sigmoid fonksiyonun özelliğinden dolayı, veriler ağa verilmeden önce 0-1 arasında normalize edilmelidir (Okkan vd., 2018).


Eğitim algoritması olarak Levenberg-Marquardt (LM) algoritması kullanılmıştır (Şekil 3.21). Sidal ve Altun (2003), Atık Su Arıtma Tesislerinde Biyokimyasal Oksijen

İhtiyacının Yapay Sinir Ağı ve Regresyon Analiziyle Tahmin Edilmesi çalışmalarında LM algoritması hakkında, YSA ile birlikte ileri beslemeli geriye yayımlı algoritmalar arasında kullanılmakta olduğu, özellikle az sayıda veri noktası veya daha az eğitim verisi ile çalışılan durumlarda çeşitli uygulamalarda başarılı bir şekilde kullanıldığı ancak, geniş veri kümeleri veya çok büyük YSA modelleri gibi durumlarda, daha büyük ve daha hızlı algoritmalara ihtiyaç duyulabileceği hususlarını ifade etmiştir.



Şekil 3.21. Eğitim algoritması seçim ekranı.

Normalize edilen veriler 1 giriş katmanı, 1 gizli katman ve 1 çıkış katmanından oluşan ağ yapısında, giriş veri sayısı ve gizli katmandaki nöron sayıları değiştirilerek eğitime tabi tutulmuştur. Şekil 3.22’de bu çalışmada kullanılan YSA yapısının genel özellikleri belirtilmiştir.



Şekil 3.22. Kullanılan YSA yapısı.

3.6 Modelin Çalıştırılması ve Veri Setlerinin Uyumu

Güçlü (2007), tam ölçekli kentsel atıksu arıtma tesislerinin bilgisayar programı kullanılarak modellenmesi ve arıtma performanslarının incelenmesi konulu doktora tezinde, yapay sinir ağlarının en belirgin özelliklerinden olan doğrusal olmama özelliğini anlamlı hale getiren yaklaşımın, verilerin normalizasyon işlemine tabi tutulmasının olduğunu, elde edilen ölçüm değerlerinin YSA modelinde kullanılabilecek yapıya sahip olmaması nedeniyle verilerin normalizasyon işlemi ile girdi setindeki her bir parametrenin modelin tahmin işlemine eşit ölçüde katkıda bulunmasını sağlayabilecek duruma dönüştüğünü söylemiştir.

Aksu vd. (2019), YSA uygulamalarında verilerin nasıl yönetildiği ve işlendiğinin önemli olduğundan, bu bağlamda normalizasyonun veri yönetiminde, verinin yorumlanmasında ve anlamlı hale gelmesinde kritik rol aldığından bahsetmişlerdir.

Literatürde birçok veri normalizasyon çeşidi vardır (Yavuz ve Deveci, 2013).


1. İstatiksel veya Z.Score Normalizasyonu
2. Min.Max Normalizasyonu
3. Medyan Normalizasyonu
4. Sigmoid Normalizasyonu
5. D_Min_Max Normalizasyonu

Bu çalışmada genellikle YSA modelinde giriş ve çıkış değerlerinin 0–1 aralığında normalize edilmesi tercih edildiğinden veri setindeki parametreler Denklem 3.1 kullanılarak normalize edilmiştir.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

Burada; X_{norm} : X verisinin normalize edilmiş şeklini, X:gerçek değer, X_{min} : veri grubunun minimum değerini, X_{max} :veri grubundaki maksimum değeri ifade etmektedir.

Normalize edilen giriş ve çıkış değerleri YSA modeline tanıtılarak ağı eğitimi süreci başlatılmıştır. Şekil 3.23’de YSA veri girişi ekranı görüntüsü verilmiştir.



Şekil 3.23. YSA veri giriş ekranı.

Eğitim ve test esnasında normalize edilmiş giriş ve çıkış değerlerinin kullanılması aşamasından sonra, sonuçlarının yorumlanabilmesi için veriler ters normalize işlemine tabi tutulmak suretiyle orijinal değerlerine çevrilmiştir. Veriler son aşamada denormalize işlemi Denklem 3.2 kullanılarak yapılmıştır.

$$X_{\text{denorm}} = X_{\text{test}} * (X_{\text{max}} - X_{\text{min}}) + X_{\text{min}} \quad (3.2)$$

4. ARAŞTIRMA BULGULARI

4.1 Yapay Sinir Ağları Model Oluşturulması ve Model Sonuçları

4.1.1 Biyokimyasal oksijen ihtiyacı değeri tahmini için YSA modeli oluşturulması ve model sonuçları


Bu çalışma ile KOSKİ Genel Müdürlüğü Konya Kentsel Atıksu Arıtma Tesisi 2021-2022 yılı giriş ve çıkış suyunda deneysel verilerle tespit edilen pH, sıcaklık, iletkenlik, BOİ, KOİ, AKM parametreleri değerlerinden faydalanılarak çıkış BOİ değerinin tahmin edilmesi için MATLAB (R2023b) programı Neural Net Fitting sinir ağı aracı ile en uygun algoritma bulunmaya çalışılmıştır. Gerçek sistemden elde edilen ölçüm değerleri (Şekil 4.1) YSA modelinde kullanılabilmek için min.max normalizasyon yöntemi ile normalize edilmiştir. 2021-2022 yılı periyotunda atıksu arıtma tesisi çıkış suyu BOİ değerinin tahmini için veri seçiminde BOİ değerlerinin ölçümünün yapıldığı günlere ait 35 adet ölçüm verisi kullanılmıştır. Verilerin, test verisi olarak %15'i, doğrulama verisi olarak %15'i, eğitim verisi olarak %70'i kullanılmıştır. İki farklı senaryo ile model oluşturularak en uygun algoritmaya ulaşılmaya çalışılmıştır. 1. Senaryoda 3 parametreye (BOİ, sıcaklık, iletkenlik) ait, 2. Senaryoda 6 parametreye (BOİ, sıcaklık, iletkenlik, pH, KOİ, AKM) ait AAT giriş suyu ölçüm değerleri ve BOİ çıkış suyu ölçüm değerleri kullanılmıştır. Her iki senaryo için de 1 gizli katman kullanılmış ve gizli katmanda bulunan nöron sayıları sırasıyla 8- 10- 15- 20- 30- 50 olarak seçilmiştir. 1 parametreye (BOİ) ait çıkış suyu değerleri tahmin edilmeye çalışılmıştır. Eğitim algoritması olarak ileri beslemeli geriye yayımlı Levenberg-Marquardt (LM) algoritması kullanılmıştır. Model sonuçlarının değerlendirilmesinde, ortalama karesel hata (Mean Squared Error, MSE) ve korelasyon katsayısı hata göstergeleri olarak kullanılmıştır.

Kullanılan uyum katsayısı değeri (R) ve hata karelerinin ortalaması (Mean Squared Error – MSE) sinir ağının tahmin performansının ölçütü olarak yaygın kullanılan ölçütlerdir. Kullanılan uyum katsayısı değeri (R) 0 ile 1 arasında değişmektedir (Kapucu, 2019).

Selvi (2019), kentsel atıksu arıtma tesisi biyokimyasal oksijen ihtiyacının (BOİ) makina öğrenmesi yöntemleri ile tahmin edilmesi konulu yüksek lisans çalışmasında;


MSE (Mean Squared Error) değerinin modelinin tahmin ettiği sonuçlar ile gerçek veriler arasındaki uzaklığın bulunmasında kullanılan bir ölçü olduğundan ve MSE değerin 0 olmasının modelin hatasız çalıştığı anlamına geldiğinden bahsetmektedir.

BOİ AAT giriş ve çıkış değerlerinin grafiksel gösterimi Şekil 4.1 de verilmiştir.




Şekil 4.1. BOİ AAT giriş ve çıkış değerlerinin grafiksel gösterimi.


İlk senaryoda veri seti olarak BOİ, sıcaklık ve iletkenlik parametreleri Atıksu Arıtma Tesisi giriş suyu ölçüm değerleri, BOİ çıkış suyu ölçüm değerleri kullanılmıştır. Oluşturulan model ile sinir ağı eğitilerek en iyi tahmine ulaşmak hedeflenmiştir. Şekil 4.2, Şekil 4.4 Şekil 4.6, Şekil 4.7, Şekil 4.10, Şekil 4.12 de ağ diyagramı ve eğitim sonuçları, Şekil 4.3, Şekil 4.5, Şekil 4.7, Şekil 4.9, Şekil 4.11, Şekil 4.13’de gizli katmanda bulunan nöron sayılarına göre performans ve hata grafikleri verilmiştir.




Şekil 4.2. İlk senaryo BOİ değeri tahmininde [3 8 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.3. İlk senaryo BOİ değeri tahmininde [3 8 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.4. İlk senaryo BOİ değeri tahmininde [3 10 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.5. İlk senaryo BOİ değeri tahmininde [3 10 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.6. İlk senaryo BOİ değeri tahmininde [3 15 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.7. İlk senaryo BOİ değeri tahmininde [3 15 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.8. İlk senaryo BOİ değeri tahmininde [3 20 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.9. İlk senaryo BOİ değeri tahmininde [3 20 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.10. İlk senaryo BOİ değeri tahmininde [3 30 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.11. İlk senaryo BOİ değeri tahmininde [3 30 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.12. İlk senaryo BOİ değeri tahmininde [3 50 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.13. İlk senaryo BOİ değeri tahmininde [3 50 1] ağ yapısında A) performans ve B) hata grafikleri.


Seçilen ağ modellerinin eğitilmesi sonucunda yukarıda grafiksel olarak belirtilen sonuçlara ulaşılmıştır. Çizelge 4.1 de BOİ tahmini için oluşturulan 1. senaryo için YSA modellerinin üretmiş oldukları performans ölçütleri karşılaştırması verilmiştir. BOİ değerinin tahmini için [3 20 1] ağ topolojisi ile yapılan çalışmanın eğitim veri setinde $R^2=1$ değerleri ile mükemmel öğrenmeyi gerçekleştirdiği ve gizli katman nöron

sayılarına bakıldığında diğerlerine kıyasla da en yüksek değere ulaştığı, tüm veri setleri dikkate alındığında modelin genel performansının $R^2=0,7271$ olduğu görülmüştür. Nöron sayısı arttıkça eğitim veri setinde öğrenme artmakla birlikte bu durum test ve doğrulama değerleri için paralellik oluşturmamıştır.

Çizelge 4.1. BOİ tahmini 1. senaryo performans karşılaştırma tablosu.


		Nöron Sayısı					
		8	10	15	20	30	50
BOİ Senaryo 1	MSE	0,0352	0,0258	0,0270	0,0194	0,0238	0,0253
	Training (R^2)	0,4709	0,6511	0,9392	1,0000	0,8847	0,9926
	Validation (R^2)	0,0054	0,2285	0,6323	0,5486	0,2791	0,6940
	Test (R^2)	0,1766	0,1007	0,0430	0,1477	0,3723	0,6900
	All (R^2)	0,3821	0,5436	0,5567	0,7271	0,6101	0,6456

BOİ parametresi için 1. Senaryo kapsamında yapılan çalışmaya ait gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırmasının grafiği Şekil 4.14’de verilmiştir. Grafikte de görüldüğü üzere MSE=0,0194, $R^2=0,7271$ değerleri ile en iyi performansın [3 20 1] ağ topolojisi ile sağlandığı belirlenmiştir.





Şekil 4.14. BOİ değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.

Belirlenen YSA’nın eğitilmesi sonrasında model tarafından tahmin edilen değerlerle gerçek ölçüm değerlerinin karşılaştırması Şekil 4.15’de verilmiştir. Ölçülen ve tahmin edilen değerlerin büyük ölçüde uyduğu görülmüştür.




Şekil 4.15. BOİ değeri ilk senaryo için en iyi tahmini yapan ağ yapısı [3 20 1] sonuç karşılaştırma grafiği.



İkinci senaryoda veri seti olarak BOİ, sıcaklık ve iletkenlik parametrelerine ilave olarak pH, KOİ, AKM parametreleri Atıksu Arıtma Tesisi giriş suyu ölçüm değerleri giriş, BOİ çıkış suyu ölçüm değerleri çıkış değeri olarak belirlenmiştir. Oluşturulan model ile YSA eğitilerek en iyi tahmine ulaşmak hedeflenmiştir. Şekil 4.16, Şekil 4.18, Şekil 4.20, Şekil 4.22, Şekil 4.24, Şekil 4.26'de ağ diyagramı ve eğitim sonuçları, Şekil 4.17, Şekil 4.19, Şekil 4.21, Şekil 4.23, Şekil 4.25, Şekil 4.27'de gizli katmanda bulunan nöron sayılarına göre performans ve hata grafikleri verilmiştir.




Şekil 4.16. İkinci senaryo BOİ değeri tahmininde [6 8 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.17. İkinci senaryo BOİ değeri tahmininde [6 8 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.18. İkinci senaryo BOİ değeri tahmininde [6 10 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.19. İkinci senaryo BOİ değeri tahmininde [6 10 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.20. İkinci senaryo BOİ değeri tahmininde [6 15 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.21. İkinci senaryo BOİ değeri tahmininde [6 15 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.22. İkinci senaryo BOİ değeri tahmininde [6 20 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.23. İkinci senaryo BOİ değeri tahmininde [6 20 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.24. İkinci senaryo BOİ değeri tahmininde [6 30 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.25. İkinci senaryo BOİ değeri tahmininde [6 30 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.26. İkinci senaryo BOİ değeri tahmininde [6 50 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.27. İkinci senaryo BOİ değeri tahmininde [6 50 1] ağ yapısında A) performans ve B) hata grafikleri.


Seçilen ağ modellerinin eğitilmesi sonucunda yukarıda grafiksel olarak belirtilen sonuçlara ulaşılmıştır. Çizelge 4.2’de BOİ tahmini için oluşturulan 2. senaryo için YSA modellerinin üretmiş oldukları performans ölçütleri karşılaştırması verilmiştir. Çizelge 4.2.’de görüldüğü üzere Training R^2 değerlerine bakıldığında, gizli katmanda bulunan nöron sayısı artışı ile ağın öğrenme performansının doğru orantılı olmadığı,

[6 10 1] ağ topolojisi ile yapılan çalışmanın eğitim veri setinde $R^2=1$ değerleri ile öğrenmeyi gerçekleştirdiği ve gizli katman nöron sayılarına bakıldığında diğerlerine kıyasla da en yüksek değere ulaştığı, ancak tüm veri setleri dikkate alındığında modelin genel performansının aynı şekilde devam etmediği, [6 8 1] topolojisindeki ağın ise tüm unsurları değerlendirildiğinde $R^2=0,7522$ değerleriyle diğer alternatiflere göre en uygun model olduğu belirlenmiştir.

Çizelge 4.2. BOİ tahmini 2. senaryo performans karşılaştırma tablosu.


		Nöron Sayısı					
		8	10	15	20	30	50
BOİ Senaryo 2	MSE	0,014	0,0217	0,0197	0,0219	0,0256	0,0247
	Training (R^2)	0,9732	1,0000	0,9990	0,9923	0,8605	0,7449
	Validation (R^2)	0,2196	0,0002	0,0645	0,4397	0,1650	0,8341
	Test (R^2)	0,3881	0,2586	0,3977	0,1014	0,5594	0,5571
	All (R^2)	0,7522	0,7202	0,7322	0,6930	0,6253	0,6829

BOİ parametresi için 2. senaryo kapsamında yapılan çalışmaya ait gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırmasının grafiği Şekil 4.28’de verilmiştir. Grafikte de görüldüğü üzere MSE=0,014, $R^2=0,7522$ değerleri ile en iyi performansın [6 8 1] ağ topolojisi ile sağlandığı belirlenmiştir.



Şekil 4.28. BOİ değeri 2. senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.

Belirlenen YSA’nın eğitilmesi sonrasında model tarafından tahmin edilen değerlerle gerçek ölçüm değerlerinin karşılaştırması Şekil 4.29’da verilmiştir. Ölçülen ve tahmin edilen değerlerin büyük ölçüde uyduğu görülmüştür.




Şekil 4.29. BOİ değeri 2. senaryo için en iyi tahmini yapan ağ yapısı [6 8 1] sonuç karşılaştırma grafiği.

4.1.2 Kimyasal oksijen ihtiyacı değeri tahmini için YSA modeli oluşturulması ve model sonuçları

Bu çalışma ile KOSKİ Genel Müdürlüğü Konya Kentsel Atıksu Arıtma Tesisi 2021-2022 yılı giriş ve çıkış suyunda deneysel verilerle tespit edilen pH, sıcaklık, iletkenlik, KOİ, AKM parametreleri değerlerinden faydalanılarak çıkış KOİ değerinin tahmin edilmesi için MATLAB (R2023b) programı Neural Net Fitting sinir ağı aracı ile en uygun algoritma bulunmaya çalışılmıştır. Gerçek sistemden elde edilen ölçüm değerleri (Şekil 4.30) YSA modelinde kullanılabilmek için min-max normalizasyon yöntemi ile normalize edilmiştir. Modele dahil edilen her bir parametre için 180 adet ölçüm verisinin, test verisi olarak %15'i, doğrulama verisi olarak %15'i, eğitim verisi olarak %70'i kullanılmıştır. İki farklı senaryo ile model oluşturularak en uygun algoritmaya ulaşılmaya çalışılmıştır. 1. Senaryoda 3 parametreye (KOİ, sıcaklık, iletkenlik) ait, 2. Senaryoda 5 parametreye (Sıcaklık, iletkenlik, pH, KOİ, AKM) ait AAT giriş suyu ölçüm değerleri ve KOİ çıkış suyu ölçüm değerleri kullanılmıştır. Her iki senaryo için de 1 gizli katman kullanılmış ve gizli katmanda bulunan nöron sayıları sırasıyla 8- 10- 15- 20- 30- 50 olarak seçilmiştir. KOİ çıkış suyu değerleri tahmin edilmeye çalışılmıştır. Eğitim algoritması olarak ileri beslemeli geriye yayımlı Levenberg-Marquardt (LM) algoritması kullanılmıştır. Model sonuçlarının



değerlendirilmesinde, ortalama karesel hata (Mean Squared Error, MSE) ve korelasyon katsayısı hata göstergeleri olarak kullanılmıştır.

KOİ AAT giriş ve çıkış değerlerinin grafiksel gösterimi Şekil 4.30’da verilmiştir.




Şekil 4.30. KOİ AAT giriş ve çıkış değerlerinin grafiksel gösterimi.


İlk senaryoda veri seti olarak KOİ, sıcaklık ve iletkenlik parametreleri Atıksu Arıtma Tesisi giriş suyu ölçüm değerleri giriş, KOİ çıkış suyu ölçüm değerleri çıkış değeri olarak belirlenmiştir. Oluşturulan model ile sinir ağı eğitilerek en iyi tahmine ulaşmak hedeflenmiştir. Şekil 4.31, Şekil 4.33, Şekil 4.35, Şekil 4.37, Şekil 4.39, Şekil 4.41’de ağ diyagramı ve eğitim sonuçları, Şekil 4.32, Şekil 4.34, Şekil 4.36, Şekil 4.38, Şekil 4.40, Şekil 4.42’de gizli katmanda bulunan nöron sayılarına göre performans ve hata grafikleri verilmiştir.




Şekil 4.31. İlk senaryo KOİ değeri tahmininde [3 8 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.32. İlk senaryo KOİ değeri tahmininde [3 8 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.33. İlk senaryo KOİ değeri tahmininde [3 10 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.34. İlk senaryo KOİ değeri tahmininde [3 10 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.35. İlk senaryo KOİ değeri tahmininde [3 15 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.36. İlk senaryo KOİ değeri tahmininde [3 15 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.37. İlk senaryo KOİ değeri tahmininde [3 20 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.38. İlk senaryo KOİ değeri tahmininde [3 20 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.39. İlk senaryo KOİ değeri tahmininde [3 30 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.40. İlk senaryo KOİ değeri tahmininde [3 30 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.41. İlk senaryo KOİ değeri tahmininde [3 50 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.42. İlk senaryo KOİ değeri tahmininde [3 50 1] ağ yapısında A) performans ve B) hata grafikleri.


Seçilen ağ modellerinin eğitilmesi sonucunda yukarıda grafiksel olarak belirtilen sonuçlara ulaşılmıştır. Çizelge 4.3’de KOİ tahmini için oluşturulan 1. senaryo için YSA modellerinin üretmiş oldukları performans ölçütleri karşılaştırması verilmiştir. KOİ değerinin tahmini için [3 50 1] ağ topolojisi ile yapılan çalışmanın eğitim veri setinde $R^2=0,5195$ değerleri ile öğrenmeyi gerçekleştirdiği ve gizli katman nöron

sayılarına bakıldığında diğerlerine kıyasla daha iyi bir değere ulaştığı, tüm veri setleri dikkate alındığında modelin genel performansının $R^2=0,3660$ olduğu görülmüştür. Nöron sayısı arttıkça eğitim veri setinde öğrenme artmakla birlikte bu durum test ve doğrulama değerleri için paralellik oluşturmamıştır.

Çizelge 4.3. KOİ tahmini 1. senaryo performans karşılaştırma tablosu.


		Nöron Sayısı					
		8	10	15	20	30	50
KOİ Senaryo 1	MSE	0,0459	0,049	0,0462	0,0424	0,0452	0,038
	Training (R^2)	0,2635	0,2890	0,3136	0,3760	0,4255	0,5195
	Validation (R^2)	0,2529	0,0480	0,1414	0,2229	0,1038	0,1992
	Test (R^2)	0,0948	0,0181	0,0450	0,1364	0,0103	0,0377
	All (R^2)	0,2254	0,1815	0,2260	0,2984	0,2743	0,3660

KOİ parametresi için 1. Senaryo kapsamında yapılan çalışmaya ait gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırmasının grafiği Şekil 4.44’ de verilmiştir. Grafikte de görüldüğü üzere $MSE=0,038$, $R^2=0,3660$ değerleri ile diğer alternatiflere göre en iyi performansın [3 50 1] ağ topolojisi ile sağlandığı belirlenmiştir. Daha iyi sonuçlara ulaşabilmek için ağ gizli katman sayısı artırılarak YSA modeli oluşturulması için çalışma yapılabileceği düşünülmektedir.





Şekil 4.43. KOİ değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.

Belirlenen YSA'nın eğitilmesi sonrasında model tarafından tahmin edilen değerlerle gerçek ölçüm değerlerinin karşılaştırması Şekil 4.46'da verilmiştir.




Şekil 4.44. KOİ değeri ilk senaryo için en iyi tahmini yapan ağ yapısı [3 50 1] sonuç karşılaştırma grafiği.



İkinci senaryoda veri seti olarak KOİ, sıcaklık ve iletkenlik parametrelerine ilave olarak pH, AKM parametreleri Atıksu Arıtma Tesisi giriş suyu ölçüm değerleri giriş, KOİ çıkış suyu ölçüm değerleri çıkış değeri olarak belirlenmiştir. Oluşturulan model ile YSA eğitilerek en iyi tahmine ulaşmak hedeflenmiştir. Şekil 4.45, Şekil 4.47, Şekil 4.49, Şekil 4.51, Şekil 4.53, Şekil 4.55'de ağ diyagramı ve eğitim sonuçları, Şekil 4.46, Şekil 4.48, Şekil 4.50, Şekil 4.52, Şekil 4.54, Şekil 4.56'de gizli katmanda bulunan nöron sayılarına göre performans ve hata grafikleri verilmiştir.




Şekil 4.45. İkinci senaryo KOİ değeri tahmininde [5 8 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.46. İkinci senaryo KOİ değeri tahmininde [5 8 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.47. İkinci senaryo KOİ değeri tahmininde [5 10 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.48. İkinci senaryo KOİ değeri tahmininde [510 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.49. İkinci senaryo KOİ değeri tahmininde [5 15 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.50. İkinci senaryo KOİ değeri tahmininde [5 15 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.51. İkinci senaryo KOİ değeri tahmininde [5 20 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.52. İkinci senaryo KOİ değeri tahmininde [5 20 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.53. İkinci senaryo KOİ değeri tahmininde [5 30 1] ağ diyagramı ve eğitim sonuçları.



Şekil 4.54. İkinci senaryo KOİ değeri tahmininde [5 30 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.55. İkinci senaryo KOİ değeri tahmininde [5 50 1] ağ diyagramı ve eğitim sonuçları.




Şekil 4.56. İkinci senaryo KOİ değeri tahmininde [5 50 1] ağ yapısında A) performans ve B) hata grafikleri.

Seilen ađ modellerinin eđitilmesi sonucunda yukarıda grafiksel olarak belirtilen sonuçlara ulaşılmıştır. izelge 4.4’de KOİ tahmini iin oluřturulan 2. senaryo iin YSA modellerinin retmiř oldukları performans ltleri karřılařtırması verilmiřtir. KOİ deđerinin tahmini iin [5 30 1] ađ topoloji ile yapılan alıřmanın eđitim veri setinde $R^2=0,7312$ deđerleri ile đrenmeyi gerekleřtirdiđi ve gizli katman nron sayılarına bakıldıđında diđerlerine kıyasla daha iyi bir deđere ulařtıđı, tm veri setleri dikkate alındıđında modelin genel performansının $R^2=0,6048$ olduđu grlmřtir. Nron sayısı arttıkk eđitim veri setinde đrenme artmakla birlikte bu durum test ve dođrulama deđerleri iin paralellik oluřturmamıştır.

izelge 4.4. KOİ tahmini 2. senaryo performans karřılařtırma tablosu.


		Nron Sayısı					
		8	10	15	20	30	50
KOİ Senaryo 2	MSE	0,0463	0,0453	0,0446	0,042	0,0397	0,0418
	Training (R^2)	0,2877	0,2954	0,3421	0,4019	0,7312	0,4512
	Validation (R^2)	0,1325	0,1253	0,1691	0,1796	0,0580	0,0007
	Test (R^2)	0,0724	0,1084	0,0725	0,0197	0,1323	0,1381
	All (R^2)	0,2241	0,2390	0,2523	0,2922	0,3658	0,3053

KOİ parametresi iin 2. Senaryo kapsamında yapılan alıřmaya ait gizli katman nron sayısına gre MSE, R^2 deđerleri karřılařtırmasının grafiđi řekil 4.57’de verilmiřtir. Grafikte de grldđ zere MSE=0,0397, $R^2=0,3658$ deđerleri ile diđer alternatiflere gre en iyi performansın [5 30 1] ađ topolojisi ile sađlandıđı belirlenmiřtir. Daha iyi sonuçlara ulařabilmek iin ađ gizli katman sayısı artırılarak YSA modeli oluřturulması iin alıřma yapılabilceđi dřnlmektedir.



Şekil 4.57. KOİ değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.


Belirlenen YSA'nın eğitilmesi sonrasında model tarafından tahmin edilen değerlerle gerçek ölçüm değerlerinin karşılaştırması Şekil 4.58'de verilmiştir.



Şekil 4.58. KOİ değeri 2. senaryo için en iyi tahmini yapan ağ yapısı [5 30 1] sonuç karşılaştırma grafiği.

4.1.3 Askıda katı madde değeri tahmini YSA modeli oluşturulması ve model sonuçları



Bu çalışma ile KOSKİ Genel Müdürlüğü Konya Kentsel Atıksu Arıtma Tesisi 2021-2022 yılı giriş ve çıkış suyunda deneysel verilerle tespit edilen pH, sıcaklık, iletkenlik, KOİ, AKM parametreleri değerlerinden faydalanılarak çıkış AKM değerinin tahmin edilmesi için MATLAB (R2023b) programı Neural Net Fitting sinir ağı aracı ile en uygun algoritma bulunmaya çalışılmıştır. Gerçek sistemden elde edilen ölçüm değerleri (Şekil 4.59) YSA modelinde kullanılabilmek için min-max normalizasyon yöntemi ile normalize edilmiştir. Modele dahil edilen her bir parametre için 180 adet ölçüm verisinin, test verisi olarak %15'i, doğrulama verisi olarak %15'i, eğitim verisi olarak %70'i kullanılmıştır. İki farklı senaryo ile model oluşturularak en uygun algoritmaya ulaşılmaya çalışılmıştır. 1. Senaryoda 3 parametreye (AKM, sıcaklık, iletkenlik) ait, 2. Senaryoda 5 parametreye (Sıcaklık, iletkenlik, pH, KOİ, AKM) ait AAT giriş suyu ölçüm değerleri ve AKM çıkış suyu ölçüm değerleri kullanılmıştır. Her iki senaryo için de 1 gizli katman kullanılmış ve gizli katmanda bulunan nöron sayıları sırasıyla 8- 10- 15- 20- 30- 50 olarak seçilmiştir. AKM çıkış suyu değerleri tahmin edilmeye çalışılmıştır. Eğitim algoritması olarak ileri beslemeli geriye yayımlı Levenberg-Marquardt (LM) algoritması kullanılmıştır. Model sonuçlarının değerlendirilmesinde, ortalama karesel hata (Mean Squared Error, MSE), korelasyon katsayısı hata göstergeleri olarak kullanılmıştır.




Şekil 4.59. AKM AAT giriş ve çıkış değerlerinin grafiksel gösterimi.

İlk senaryoda veri seti olarak AKM, sıcaklık ve iletkenlik parametreleri Atıksu Arıtma Tesisi giriş suyu ölçüm değerleri giriş, AKM çıkış suyu ölçüm değerleri çıkış değeri olarak belirlenmiştir. Oluşturulan model ile sinir ağı eğitilerek en iyi tahmine ulaşmak hedeflenmiştir. Şekil 4.60, Şekil 4.62, Şekil 4.64, Şekil 4.66, Şekil 4.68, Şekil 4.70’de ağ diyagramı ve eğitim sonuçları, Şekil 4.61, Şekil 4.63, Şekil 4.65, Şekil 4.67, Şekil 4.69, Şekil 4.71’de gizli katmanda bulunan nöron sayılarına göre performans ve hata grafikleri verilmiştir.








Şekil 4.60. İlk senaryo AKM değeri tahmininde [3 8 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.61. İlk senaryo AKM değeri tahmininde [3 8 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.62. İlk senaryo AKM değeri tahmininde [3 10 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.63. İlk senaryo AKM değeri tahmininde [3 10 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.64. İlk senaryo AKM değeri tahmininde [3 15 1] ağ diyagramı ve eğitim sonuçları.




Şekil 4.65. İlk senaryo AKM değeri tahmininde [3 15 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.66. İlk senaryo AKM değeri tahmininde [3 20 1] ağ diyagramı ve eğitim sonuçları.



A)



B)




Şekil 4.67. İlk senaryo AKM değeri tahmininde [3 20 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.68. İlk senaryo AKM değeri tahmininde [3 30 1] ağ diyagramı ve eğitim sonuçları.



A)




B)



Şekil 4.69. İlk senaryo AKM değeri tahmininde [3 30 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.70. İlk senaryo AKM değeri tahmininde [3 50 1] ağ diyagramı ve eğitim sonuçları.




Şekil 4.71. İlk senaryo AKM değeri tahmininde [3 50 1] ağ yapısında A) performans ve B) hata grafikleri.

Yukarıda belirtilen ağ modellerinin eğitilmesi sonucunda Çizelge 4.5’de belirtilen karşılaştırma verilerine ulaşılmıştır. AKM değerinin tahmini için [3 50 1] ağ topolojisi ile yapılan çalışmanın eğitim veri setinde $R^2=0,5782$ değerleri ile öğrenmeyi gerçekleştirdiği ve gizli katman nöron sayılarına bakıldığında diğerlerine kıyasla daha iyi bir değere ulaştığı, tüm veri setleri dikkate alındığında modelin genel performansının $R^2=0,2501$ olduğu görülmüştür. Nöron sayısı arttıkça eğitim veri setinde öğrenme artmakla birlikte bu durum test ve doğrulama değerleri için paralellik oluşturmamıştır.

Çizelge 4.5. AKM tahmini 1. senaryo performans karşılaştırma tablosu.


		Nöron Sayısı					
		8	10	15	20	30	50
AKM Senaryo 1	MSE	0,0444	0,0444	0,042	0,0424	0,0423	0,0393
	Training (R2)	0,2117	0,2881	0,3559	0,2890	0,3314	0,5782
	Validation (R2)	0,0678	0,0056	0,2017	0,0012	0,0481	0,1215
	Test (R2)	0,0000	0,0002	0,2272	0,0021	0,0003	0,0156
	All (R2)	0,1131	0,1261	0,1760	0,1579	0,1720	0,2501

AKM parametresi için 1. Senaryo kapsamında yapılan çalışmaya ait gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırmasının grafiği Şekil 4.72’de verilmiştir. Grafikte de görüldüğü üzere $MSE=0,0393$, $R^2=0,2501$ değerleri ile diğer alternatiflere göre en iyi performansın [3 50 1] ağ topolojisi ile sağlandığı belirlenmiştir. Daha iyi sonuçlara ulaşabilmek için farklı ağ yapılarıyla çalışma yapılabileceği düşünülmektedir.





Şekil 4.72. AKM değeri ilk senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.

Belirlenen YSA'nın eğitilmesi sonrasında model tarafından tahmin edilen değerlerle gerçek ölçüm değerlerinin karşılaştırması Şekil 4.73'de verilmiştir.




Şekil 4.73. AKM değeri ilk senaryo için en iyi tahmini yapan ağ yapısı ([3 50 1]) sonuç karşılaştırma grafiği.



İkinci senaryoda veri seti olarak AKM, sıcaklık ve iletkenlik parametrelerine ilave olarak pH, KOİ parametreleri Atıksu Arıtma Tesisi giriş suyu ölçüm değerleri giriş, AKM çıkış suyu ölçüm değerleri çıkış değeri olarak belirlenmiştir. Oluşturulan model ile YSA eğitilerek en iyi tahmine ulaşmak hedeflenmiştir. Şekil 4.74, Şekil 4.76, Şekil 4.78, Şekil 4.80, Şekil 4.82, Şekil 4.84'de ağ diyagramı ve eğitim sonuçları, Şekil 4.75, Şekil 4.77, Şekil 4.79, Şekil 4.81, Şekil 4.83, Şekil 4.85'de gizli katmanda bulunan nöron sayılarına göre performans ve hata grafikleri verilmiştir.




Şekil 4.74. İkinci senaryo AKM değeri tahmininde [5 8 1] ağ diyagramı ve eğitim sonuçları.





Şekil 4.75. İkinci senaryo AKM değeri tahmininde [5 8 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.76. İkinci senaryo AKM değeri tahmininde [5 10 1] ağ diyagramı ve eğitim sonuçları.




Şekil 4.77. İkinci senaryo AKM değeri tahmininde [5 10 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.78. İkinci senaryo AKM değeri tahmininde [5 15 1] ağ diyagramı ve eğitim sonuçları.



A)




B)





Şekil 4.79. İkinci senaryo AKM değeri tahmininde [5 15 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.80. İkinci senaryo AKM değeri tahmininde [5 20 1] ağ diyagramı ve eğitim sonuçları.




Şekil 4.81. İkinci senaryo AKM değeri tahmininde [5 20 1] ağ yapısında A) performans ve B) hata grafikleri.




Şekil 4.82. İkinci senaryo AKM değeri tahmininde [5 30 1] ağ diyagramı ve eğitim sonuçları.



A)




B)



Şekil 4.83. İkinci senaryo AKM değeri tahmininde [5 30 1] ağ yapısında A) performans ve B) hata grafikleri.



Şekil 4.84. İkinci senaryo AKM değeri tahmininde [5 50 1] ağ diyagramı ve eğitim sonuçları.




Şekil 4.85. İkinci senaryo AKM değeri tahmininde [5 50 1] ağ yapısında A) performans ve B) hata grafikleri.

Seilen ađ modellerinin eđitilmesi sonucunda yukarıda grafiksel olarak belirtilen sonuçlara ulaşılmıştır. izelge 4.6’da KOİ tahmini iin oluřturulan 2. senaryo iin YSA modellerinin retmiř oldukları performans ltleri karřılařtırması verilmiştir. AKM deđerinin tahmini iin [5 50 1] ađ topoloji ile yapılan alıřmanın eđitim veri setinde $R^2=0,5782$ deđerleri ile đrenmeyi gerekleřtirdiđi ve gizli katman nron sayılarına bakıldıđında diđerlerine kıyasla daha iyi bir deđere ulařtıđı, tm veri setleri dikkate alındıđında modelin genel performansının $R^2=0,2501$ olduđu grlmřtr. Nron sayısı arttıkk eđitim veri setinde đrenme artmakla birlikte bu durum test ve dođrulama deđerleri iin paralellik oluřturmamıştır, deđerli bir geliřme sađlanamamıştır.

izelge 4.6. AKM tahmini 2. senaryo karřılařtırma tablosu.


		Nron Sayısı					
		8	10	15	20	30	50
AKM Senaryo 1	MSE	0,0444	0,0438	0,0409	0,04	0,0414	0,0371
	Training (R^2)	0,1469	0,2133	0,3559	0,2890	0,3314	0,5782
	Validation (R^2)	0,0289	0,0811	0,2017	0,0012	0,0481	0,1215
	Test (R^2)	0,0474	0,0001	0,2272	0,0021	0,0003	0,0156
	All (R^2)	0,1031	0,1192	0,1760	0,1579	0,1720	0,2501

AKM parametresi iin 2. senaryo kapsamında yapılan alıřmaya ait gizli katman nron sayısına gre MSE, R^2 deđerleri karřılařtırmasının grafiđi řekil 4.86’da verilmiştir. Grafikte de grldđ zere $MSE=0,0371$, $R^2=0,2501$ deđerleri ile diđer alternatiflere gre en iyi performansın [5 50 1] ađ topolojisi ile sađlandıđı belirlenmiştir. Daha iyi sonuçlara ulařabilmek iin farklı ađ yapılarında YSA modeli oluřturulması iin alıřma yapılabileceđi dřnlmektedir.



Şekil 4.86. AKM değeri 2. senaryo için gizli katman nöron sayısına göre MSE, R^2 değerleri karşılaştırması.

Belirlenen YSA'nın eğitilmesi sonrasında model tarafından tahmin edilen değerlerle gerçek ölçüm değerlerinin karşılaştırması Şekil 4.87'de verilmiştir.



Şekil 4.87. AKM değeri 2. senaryo için en iyi tahmini yapan ağ yapısı [5 30 1] sonuç karşılaştırma grafiği.

5. SONUÇ VE ÖNERİLER

5.1 Bulguların Özeti

MATLAB programı kullanılarak yapılan bu araştırmada Konya Kentsel Atıksu Arıtma Tesisinin 2021- 2022 yılı giriş suyu parametreleri (pH, sıcaklık, iletkenlik, BOİ, KOİ, AKM) kullanılarak çıkış suyu BOİ, KOİ, AKM parametrelerinin değerleri tahmin edilmiştir.

Sidal ve Altun (2003), atık su arıtma tesislerinde biyokimyasal oksijen ihtiyacının yapay sinir ağı ve regresyon analiziyle tahmin edilmesi konusunda yapmış oldukları çalışmada LM algoritması hakkında, YSA ile birlikte ileri beslemeli geriye yayımlı algoritmalar arasında kullanıldığı, başarılı bir şekilde çeşitli uygulamalarda kullanıldığı, özellikle daha az eğitim verisi ile çalışılan veya az sayıda veri noktası olan durumlarda etkili olabildiği bilgilerini paylaşmıştır. Diğer taraftan, geniş veri kümeleri veya çok büyük YSA modelleri gibi durumlarda, daha büyük ve daha hızlı algoritmalara ihtiyaç duyulabileceği belirtilmiştir.

Bu açıklamalardan hareketle çalışmada, YSA modeli oluşturulurken eğitim algoritması olarak Levenberg-Marquardt (LM) algoritması kullanılmıştır. Kentsel Atıksu Arıtma Tesisi çıkış suyu kirletici parametrelerinin en iyi şekilde tahmin edilebileceği YSA modeline ulaşmak için iki farklı senaryo denenmiştir. 1. Senaryoda 3 parametreye (BOİ, sıcaklık, iletkenlik) ait, 2. Senaryoda BOİ için 6 (BOİ, sıcaklık, iletkenlik, pH, KOİ, AKM) , AKM ve KOİ için 5 parametreye (Sıcaklık, iletkenlik, pH, KOİ, AKM) ait AAT giriş suyu ölçüm değerleri, araştırılan parametreye ait çıkış suyu ölçüm değerleri kullanılmıştır. Her iki senaryo için de 1 gizli katman kullanılmış ve gizli katmanda bulunan nöron sayıları sırasıyla 8-10-15-20-30-50 olarak seçilmiştir. Araştırılan parametreye ait çıkış suyu değerleri tahmin edilmeye çalışılmıştır.

Model sonuçlarının değerlendirilmesinde, ortalama karesel hata (Mean Squared Error, MSE), korelasyon katsayısı (R^2) hata göstergeleri olarak kullanılmıştır.

BOİ, KOİ, AKM parametre değerlerinin tahmini için oluşturulan ağlar içerisinde en iyi sonucu verenlere ait MSE ve R^2 değerleri karşılaştırma tablosu Çizelge 5.1’de verilmiştir.

Çizelge 5.1. YSA ağ yapıları karşılaştırma tablosu.

		BOİ	KOİ	AKM
1. Senaryo	Nöron Sayısı	20	50	50
	MSE	0,0194	0,038	0,0393
	Training (R^2)	1,0000	0,5195	0,5782
	Validation(R^2)	0,5486	0,1992	0,1215
	Test(R^2)	0,1477	0,0377	0,0156
	All(R^2)	0,7271	0,3660	0,2501
		BOİ	KOİ	AKM
2. Senaryo	Nöron Sayısı	8	30	50
	MSE	0,014	0,0397	0,0371
	Training(R^2)	0,9732	0,7312	0,5782
	Validation(R^2)	0,2196	0,0580	0,1215
	Test(R^2)	0,3881	0,1323	0,0156
	All(R^2)	0,7522	0,3658	0,2501

Bu kapsamda;

BOİ değerinin tahmini için yapılan çalışmada;

- İlk senaryoda [3 20 1] ağ topolojisine sahip modelde en iyi sonuca ulaşıldığı
- İkinci senaryoda [6 8 1] ağ topolojisine sahip modelde en iyi sonuca ulaşıldığı

görülmüştür. Yapılan çalışma sonrasında BOİ değerlerinin tahmininde 1. senaryo ve 2. senaryo için LM öğrenme algoritmasıyla oluşturulan YSA modelinin kullanılabilir olduğu görülmektedir.

KOİ değerinin tahmini için yapılan çalışmada;

- İlk senaryoda [3 50 1] ağ topolojisine sahip modelde en iyi sonuca ulaşıldığı
- İkinci senaryoda [6 30 1] ağ topolojisine sahip modelde en iyi sonuca ulaşıldığı

görülmüştür. KOİ değerlerinin tahmininde YSA modelinde yüksek nöron sayılarında eğitim verilerinde öğrenmenin iyi seviyelere ulaştığı belirlenmiştir.

AKM deęerinin tahmini iin yapılan alıřmada;

- İlk senaryoda [3 50 1] aę topolojisine sahip modelde en iyi sonuca ulařıldıęı
- İkinci senaryoda [6 50 1] aę topolojisine sahip modelde en iyi sonuca ulařıldıęı

görölmüřtür. AKM deęerlerinin tahmininde YSA modelinde yüksek nöron sayılarında eęitim verilerinde öęrenmenin iyi seviyelere ulařtıęı, her iki senaryo iinde benzer sonuçlar elde edildięi belirlenmiřtir.

Bu alıřma ile oluřturulan YSA yapısında en iyi aę yapısının BOİ ıkıř suyu deęeri tahmininde kullanılan LM öęrenme algoritması ile gerekleřtirilen [6 8 1] aę olduęu, bu durumun LM öęrenme algoritması özellięiyle uyuruęu görölmüřtür.

KOİ ve AKM deęerlerinin tahmini iin oluřturulan aę yapılarında gizli katmanda yer alan nöron sayılarının artırılmasında yüksek nöron sayılarında öęrenmenin daha iyi olduęu görölmekle birlikte model performansında kayda deęer bir düzelme saęlanamamıřtır. Modelin daha ok ezberlemeye yönel-dięi düşünölmektedir.

Bu alıřmada seilen senaryolar sonrasında, giriř verisi eřidinin artması ile hata oranının düřtüęü ve öęrenmenin artabildięi gözlenmiřtir. 1. Senaryo tahmin alıřmasında R^2 deęerleri, BOİ All(R^2) 0,7271, KOİ All(R^2) 0,3660, AKM All(R^2) 0,2501 iken 2. Senaryo tahmin alıřmada R^2 deęerleri, BOİ All (R^2) 0,7522, KOİ All(R^2) 0,358, AKM All(R^2) 0,2501 řeklinde deęiřmiřtir.

Dięer taraftan, yüksek performanslı YSA modellerinin oluřturulabilmesi iin giriř veri setlerinin eřitlilięinin önemli olduęu, uygun katman ve nöron sayısının seimi ile en iyi öęrenmenin gerekleřebileceęi ve veri setlerindeki verilere ait deęerlerin AAT özelinde ardıřık ve süreklilięi olan on-line ölçüm sonuçlarından oluřmasının model performansının daha iyi ortaya konmasına yardımcı olacaęı kanaati oluřmuřtur.

Ayrıca, ok farklı faktörlerden etkilenebilen giriř veri setlerinden faydalanılarak oluřturulacak YSA modellerinde gizli katman sayısı artırılarak model performansında artış olup olmadıęı kontrol edilebilir.

Çalışmanın Kentsel Atıksu Arıtma Tesislerinin proses kontrollerinin ve performanslarının belirlenmesinde yapay sinir ağları gibi yapay zeka yöntemleriyle yapılması konusunda literatüre katkı sağlayacağı düşünülmektedir.



KAYNAKLAR

- Açıklan, S., 2007. Atıksu arıtma tesisi veriminin yapay sinir ağları ile tahmin edilmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Abraham, A., 2005. Artificial neural networks. Handbook of measuring system design, Oklahoma State University, USA.
- Aksu G., Güzeller C.O., Eser M.T., 2019 . The effect of the normalization method used in different sample sizes on the success of artificial neural network model, International Journal of Assessment Tools in Education, Vol. 6, No. 2, 170–192.
- Alkay, T., 2016. Kocaeli kentsel atıksu arıtma tesislerinin yapay sinir ağları ile modellenmesi ve entegre tesis tasarımı, Yüksek Lisans Tezi, Yalova Üniversitesi Fen Bilimleri Enstitüsü, Yalova.
- Anderson, J. A., 1995. An Introduction to Neural Networks, The MIT Press, Massachusetts.
- Aras, E., 2020. Atık Su arıtma tesisi modellemesi ve performans parametreleri değerlendirilmesi: Bolu İli Örneği, Yüksek Lisans Tezi, Bolu Abant İzzet Baysal Üniversitesi Lisansüstü Eğitim Enstitüsü, Bolu.
- Ataseven, B., 2023. Yapay Sinir Ağları ile Öngörü Modellemesi. Öneri,10(39),101.115.
- Bekkari, N. ve Zedduri, A., 2018. Using artificial neural network for predicting and controlling the effluent chemical oxygen demand in wastewater treatment plant , Management of Environmental Quality: An International Journal Vol. 30 No. 3, pp. 593.608.
- Çakır, F.S., 2020. Yapay sinir ağları,MATLAB kodları ve MATLAB toolbox çözümleri, Nobel Akademik Yayıncılık Da. Tic. Ltd. Şti.
- Çepni, A.G., 2017. Bursa ili kentsel atıksu arıtma tesisleri performanslarının istatistiksel olarak değerlendirilmesi, Yüksek Lisans Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.
- Çetin, O., 2014. Yapay Sinir Ağlarının Uyarlanabilir Donanımsal Yapılarda Gerçeklenmesi, Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Çınar, Ö. ve Yılmaz, A.S., 2005. Yapay sinir ağlarının atıksu arıtma tesisi işletilmesine uygulanması: Bir örnek çalışma, KSÜ. Fen ve Mühendislik Dergisi 8(2), 48.49.
- Çimen Mesutoğlu, Ö., 2020. Yüzeysel Sularda Benzen Mikrokirleticisinin Tespiti ve Modellemesi: Orhaneli Çayı Örneği, Yüksek Lisans Tezi, Aksaray Üniversitesi Fen Bilimleri Enstitüsü, Aksaray.

- Damar Y., 2009. Tekstil endüstrisi atıksularının ardışık kesikli biyoreaktör ile arıtılması ve modellenmesi, Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Güçlü D., 2007. Tam ölçekli kentsel atıksu arıtma tesislerinin bilgisayar programı kullanılarak modellenmesi ve arıtma performanslarının incelenmesi, Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Erdem, F., 2021. Atıksulardan Zn gideriminin yapay sinir ağı (YSA) ile modellenmesi, Avrupa Bilim ve Teknoloji Dergisi Özel Sayı 24, 335.342.
- Güner, E. D., 2018. Biyolojik atıksu arıtma tesisi çevresel risk analizi, Pamukkale Univ Muh Bilim Derg, 24(3), 476.480.
- Haykin, S., 1999. Neural Networks. A Comprehensive Foundation, Prentice Hall, 2. Edition, New Jersey.
- Kapucu, A. N., 2019. Çevresel ölçüm değerlerinin yapay sinir ağlarıyla modellenmesinde çözüm yöntemine ilişkin parametrelerin optimizasyonu, Yüksek Lisans Tezi, Muğla Sıtkı Koçman Üniversitesi, Fen Bilimleri Enstitüsü, Muğla.
- Konya Çevre, Şehircilik ve İklim Değişikliği İl Müdürlüğü, 2023. Konya İli 2022 Yılı Çevre Durum Raporu, Konya.
- Konya Su Ve Kanalizasyon İdaresi Genel Müdürlüğü.
- Krenker, A., Beşter, J., ve Kos, A., 2011. Introduction to the artificial neural networks. Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech, 1.18.
- Kunt, F., 2007. Hava Kirliliğinin Yapay Sinir Ağları Yöntemi ile Modellenmesi ve Tahmini, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Metcalf & Eddy, 2003. “.Wastewater Engineering: Treatment and Reuse”, New York, United States, Water Environment Federation.
- Nabiyev, V., 2016. Yapay zeka, 5. Baskı, Seçkin Yayıncılık, Ankara.
- Hassen, E. ve Asmare, A., 2019. Predictive performance modeling of Habesha brewery wastewater treatment plant using artificial neural networks, Chemistry International 5(1), 2019, 87.96.
- Nas, B., 2017. Atıksu arıtma tesislerinde işletme sorunları ve çözümleri, Çevre ve Şehircilik Bakanlığı, Ankara.

- Okkan, U. Serbeş Z. A., ve Gedik N., 2018. MATLAB ile Levenberg-Marquardt algoritması tabanlı YSA uygulaması: Aylık yağış-akış modellemesi, DÜMF MD, c. 9, Sy. 1, 351–362, 2018.
- Özen, S. B., 2018. KASKİ atık su arıtma verilerinin yapay sinir ağları ve bulanık mantık yöntemleri ile tahmin edilmesi, Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- Öztemel, E. ve Düğenci, M., 2016. Atıksu arıtma tesis kontrolde yapay sinir ağı ile kirlilik parametre tahmini, I SEM2016, 3rd International Symposium on Environment and Morality, Alanya, Bildiriler Kitabı, 512.517.
- Öztemel E., 2012. Yapay Sinir Ağları İstanbul: Papatya Yayıncılık Eğitim.
- Öztemel E., 2003. Yapay Sinir Ağları İstanbul: Papatya Yayıncılık Eğitim.
- Raol, J. R., ve Mankame, S. S., 1996. Artificial neural networks. Resonance, 1(2), 47.54.
- Samsunlu A., 1997. Çevre Mühendisliği Kimyası, SAM Çevre Teknolojileri Yayınları, 4. Baskı.
- Samsunlu A., 2006. Atıksuların Arıtılması, Birsan Yayınevi.
- Selvi, E., 2019. Kentsel atıksu arıtma tesisi biyolojik oksijen ihtiyacının (BOİ₅) makina öğrenmesi yöntemleri ile tahmin edilmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Sidal, F. ve Altun, Y., 2003. Atık su arıtma tesislerinde biyokimyasal oksijen ihtiyacının yapay sinir ağı ve regresyon analiziyle tahmin edilmesi, Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 13(4), 2934.2944.
- Sinan, R. K., 2010. Evsel atıksu arıtma tesislerinde ön arıtım ve biyolojik arıtım çıkış parametrelerinin YSA ile tahmini, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Subaşı, H., 2010. Yapay sinir ağları ile atıksu arıtma tesisi performansının modellenmesi, Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Çevre Mühendisliği Ana Bilim Dalı, Adana.
- T.C. Resmi Gazete, 25687 sayılı Su Kirliliği Kontrolü Yönetmeliği.
- T.C. Resmi Gazete, 26047 sayılı Kentsel Atıksu Arıtımı Yönetmeliği.
- Tümer, E. A. ve Edebali, S., 2015. An artificial neural network model for wastewater treatment plant of Konya, intelligent systems and applications in engineering.

Temür, G., 2013. Yapay sinir ağlarının otomatik olarak FPGA çipine uygulanması için denetleyici tasarım aracı, Yüksek Lisans, Düzce Üniversitesi, Elektrik Eğitim Anabilim Dalı, Düzce.

Üçüncü, O., 2019. Atıksu arıtımı, atıksu deşarjı ve su kirliliği: Trabzon İli Örneği, Türk Hidrolik Dergisi, 3, 2.

Yavuz, S. ve Deveci M., 2013. İstatiksel normalizasyon tekniklerinin yapay sinir ağına performansına etkisi, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı 40 167.187.

Zhang, J., 2019. Basic neural units of the brain: neurons, synapses and action potential. arXiv preprint arXiv:1906.01703.

URL-1 <<https://l24.im/KL2a>>, Erişim tarihi: 03.03.2024.

URL-2 <<https://l24.im/acLKg>>, Erişim tarihi:18.10.2023.

URL-3 <<https://l24.im/MLFXw4x>>, Erişim tarihi:18.10.2023.

ÖZGEÇMİŞ

Adı ve Soyadı : Ülkü SERTKAN AYDIN

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Selçuk Üniversitesi, Çevre Mühendisliği Bölümü,
1994-1998

Yüksek Lisans : Aksaray Üniversitesi, Çevre Mühendisliği Anabilim
Dalı, 2021-

MESLEKİ DENEYİM VE ÖDÜLLERİ

1. DSİ 12. Bölge Müdürlüğü, Su Analizi Laboratuvarı / Yaz Stajı
2. İller Bankası A.Ş. Konya Bölge Müdürlüğü/ Yaz Stajı
3. Çevre Şehircilik ve İklim Değişikliği Konya İl Müdürlüğü/ Çevre Mühendisi
4. Çevre Şehircilik ve İklim Değişikliği Konya İl Müdürlüğü/ Şube Müdürü

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Kongrelerde Sunulan Makaleler

1. Sertkan Aydın Ü., ve Sönmez G., 2023. Urban wastewater treatment plant efficiency modeling with artificial neural network: Konya example, International Symposium for Environmental Science and Engineering Research (ISESER),Konya, Proceeding Book of ISESER 2023, 136-142.