

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

HİDROLİK MODELLEME: ATIKSU ARITMA TESİSİ (AAT) ÖRNEKLERİ

DOKTORA TEZİ

Hussein Y.H. ALNAJJAR

**AĞUSTOS 2023
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

HİDROLİK MODELLEME: ATIKSU ARITMA TESİSİ (AAT) ÖRNEKLERİ

Hussein Y.H. ALNAJJAR

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
“DOKTOR (İNŞAAT MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 27 / 07 / 2023

Tezin Savunma Tarihi : 11 / 08 / 2023

Tez Danışmanı : Dr. Öğr.Üyesi Osman ÜÇÜNCÜ
ORCID : - - -

Trabzon 2023

ÖNSÖZ

Bu çalışma Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü inşaat Mühendisliği Anabilim Dalı'nda Doktora Tezi olarak hazırlanmıştır.

Öncelikle, bu çalışmanın başlangıcından sonuna kadar her aşamasında bana destek olan, karşılaştığım tüm güçlüklerde teknik bilgisi ve bana duyduğu güvenle önümü açan ve motive eden tez danışmanım Sayın Dr.Öğr.Üyesi OSMAN ÜÇÜNCÜ'e teşekkür etmek isterim. Kendisini tanıştığımız ilk günden beri sergilediği çalışma prensibi ve insani duruşu ile hayatım boyunca örnek almaktan gurur duyacağım.

Tez çalışmalarımın başlangıcında uygulama örneğini gerçekleştirmek üzere tesis bulabilmek için bana yardımcı olan, ricam üzerine yoğun iş programı arasında bana vakit ayıran ve tesis ziyaretlerinde çok büyük yardım eden SASKİ Genel Müdürü Dr. Bahattin YANIK'a tüm desteği ve içten tavrı için çok teşekkür ederim. Bu Dr Tez çalışmasında veri temini ve bilgi paylaşımı konusunda bana kapılarını sonuna kadar açan ve bu akademik çalışmaya katkısı büyük olan SASKİ çalışanlarına da iş birlikçi tavırlarından ötürü teşekkür ederim

Son olarak, bugüne kadar özveri ile beni yetiştiren ve bu süreçte de yalnız bırakmayan, manevi desteğini her zaman hissettiğim aileme sonsuz teşekkürlerimi sunarım.

Hussein ALNAJJAR

Trabzon 2023

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Hidrolik Modelleme: Atıksu Arıtma Tesisi (AAT) Örnekleri” başlıklı bu doktora çalışmasını baştan sona kadar danışmanım Dr. Öğr.Üyesi Osman ÜÇÜNCÜ’nün sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 11/08/2023.

Hussein ALNAJJAR

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Amaç ve Kapsam	3
1.3. Literatür Taraması	4
1.4. Araştırılan Atıksu Parametreleri Tanımlanması.....	13
1.5. Atıksu Arıtma Tesislerinin Üniteleri.....	18
2. YAPILAN ÇALIŞMALAR	20
2.1. Çalışma Alanı ve Veriler.....	20
2.1.2. Tesis Tanıtımı.....	22
2.2. Samsun Doğu AAT’nde Yapılan Analizler	23
2.3. Çalışmada Kullanılan Yöntemler	24
2.3.1. Normal Model (MATLAB APPDESİGNER).....	24
2.3.2. Bulanık Mantık.....	27
2.3.3. Yapay Sinir Ağı.....	45
2.3.4. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS).....	79
2.4. Veri Seti.....	87
2.4.1. Modellerin Giriş Parametrelerinin Belirlenmesi	97
2.4.2. Veri Gruplarının Analizi	98
2.4.3. Çalışmada Kullanılan Değerlendirme Kriterleri	98
3. BULGULAR	100

3.1.	Bulanık Mantık ile Parametreler Tahmini.....	100
3.1.1.	Değerlendirme.....	109
3.2.	Yapay Sinir Ağı ile Parametrelere Tahmini.....	110
3.2.1.	YSA'ı Değerlendirmesi.....	123
3.3.	Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Parametrelere Tahmini	124
3.3.1.	Değerlendirme.....	137
3.4.	MATLAB APP DESIGNER.....	138
4.	TARTIŞMA	144
5.	SONUÇLAR	151
6.	ÖNERİLER	154
7.	KAYNAKLAR.....	155
8.	EKLER.....	161
	ÖZGEÇMİŞ.....	163

ÖZET

HİDROLİK MODELLEME: ATIKSU ARITMA TESİSİ (AAT) ÖRNEKLERİ

Hussein ALNAJJAR

Karadeniz Teknik Üniversitesi

Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr.Üyesi Osman ÜÇÜNCÜ

2023, 163 Sayfa

Atıksu arıtma tesislerini (AAT) planlanması, boyutlandırılmasında ve yönetirken kirlilik parametrelerinden olan BOİ, TN, TP, AKM ve pH miktarlarına dikkat etmek çok önemlidir. Bu kirlilik parametrelerinin kullanılması ile AAT boyutlandırması, işletme esnasında düzenlenmesi ve ölçülmesi yardımıyla AAT’de atıksuyun kirliletiçi miktarlarının kontrol altında tutulmasını sağlar. Bununla birlikte, bu parametreleri yerinde ölçmek ve analitik bulgular elde etmek çok zaman ve çaba gerektirmektedir. Sonuç olarak, kirlilik parametrelerinin elde olmaması ve yerinde ölçümü çok masraflı olması nedeniyle bu çalışmanın önemi ortaya çıkmaktadır. Kirlilik parametrelerinin yapay zekâ modelleri kullanılarak tesis yönetimine çok büyük katkı sağlamaktadır. Bu Dr Tez çalışmasında, Samsun İli “Doğu İleri Biyolojik AAT” atıksu giriş havuzu ve çıkış havuzunda kirlilik parametrelerinden BOİ, TN, TP, AKM ve pH ölçüm sonuçları 2014-2018 yılları arası alınmıştır. Bu doğrultuda MMS, OKH, KOKH, OMYH ve R^2 kullanılarak karşılaştırmalı analizler yapılmıştır. Dört bağımsız teknik -APPDESIGNER, bulanık mantık, yapay sinir ağları ve ANFIS-birleştirilmiştir. Oluşturulan modeller karşılaştırıldığında en yüksek belirleme katsayısına sahip olan ANFIS modeli en iyi model olarak ortaya çıkmıştır.

Anahtar Kelimeler: Bulanık mantık, SASKİ, AAT, yapay sinir ağları, ANFIS, biyolojik oksijen ihtiyacı, toplam azot, toplam fosfor, toplam askıda katı madde.

PhD Thesis

SUMMARY

HYDRAULIC MODELING: WASTEWATER TREATMENT PLANT EXAMPLES

HUSSEIN ALNAJJAR

Karadeniz Technical University

The Graduate School of Natural and Applied Sciences

Civil Engineering Graduate Program

Supervisor: Dr. Öğr.Üyesi Osman ÜÇÜNCÜ

2023, 163 Pages

The pollutant criteria of BOD, TN, TP, TSS, and pH must be taken into consideration while developing, sizing, and maintaining wastewater treatment facilities (WWTPs). By using these pollution parameters, WWTP sizing, regulation and measurement during operation, the pollutant amounts of wastewater in the WWTP can be kept under control. However, it takes a lot of time and effort to measure these parameters on-site and to obtain analytical findings. As a result, pollution parameters are not available and in-situ measurement is very costly, hence the importance of this study. It makes a great contribution to facility management by using artificial intelligence models of pollution parameters. In this thesis study, the measurement results of BOD, TN, TP, TSS and pH from pollution parameters in the wastewater inlet pond and outlet pond of Samsun Province "East Advanced Biological WWTP" were taken between 2014-2018. Accordingly, comparative analyses were made using MAD, MSE, RMSE, MAPE and R^2 . Four independent techniques -APPDESIGNER, fuzzy logic, artificial neural networks and ANFIS- were combined. When the models were compared, the ANFIS model with the highest coefficient of determination emerged as the best model.

Keywords: Fuzzy logic, neural networks, ANFIS, WWTP, biological oxygen demand, total nitrogen, total phosphorus, total suspended solids.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Bir atıksu arıtımı ve arıtma kademeleri.....	19
Şekil 2. Samsun İli “Doğu ileri biyolojik AAT’si”nin konumu.....	20
Şekil 3. Samsun İli Doğu ileri biyolojik AAT’ye ait bir hava fotoğrafı.....	21
Şekil 4. a) Birincil arıtma, b) ikincil arıtma ve c) model sonuçları özeti için “APP DESIGNER” modelinin arayüzü görünümü.	25
Şekil 5. Boolean ve bulanık mantıkta mantıksal değerler aralığı: (a) Boole mantığı;(b) çok değerli mantık.	29
Şekil 6. X ’in net ve bulanık alt kümesinin temsili	32
Şekil 7. Bulanık küme işlemleri	36
Şekil 8. Mamdani bulanık çıkarımın temel yapısı.....	39
Şekil 9. Tipik bir yapay sinir ağının gösterimi	46
Şekil 10. Nöron diyagramı gösterilişi.....	48
Şekil 11. Bir nöronun aktivasyon fonksiyonları.....	49
Şekil 12. Tek katmanlı iki girişli algılayıcı	50
Şekil 13. Algılayıcılarda doğrusal ayrılabilirlik: (a) iki girdili algılayıcı; (b) üç girdili algılayıcı	51
Şekil 14. İki gizli katmana sahip çok katmanlı algılayıcı.....	54
Şekil 15. Momentum ve uyarlanabilir öğrenme oranı ile öğrenme.....	60
Şekil 16. Tek katmanlı n-nöron Hopfield ağı.....	61
Şekil 17. Doymuş doğrusal aktivasyon fonksiyonu	62
Şekil 18. BAM işlemi: (a) ileri yön; (b) geriye doğru yön.....	67
Şekil 19. Bir sinir ağında Hebbian öğrenme.....	70
Şekil 20. Kohonen modelinde a) (1, 0) ve b) (0,1) özellik eşleme.....	74
Şekil 21. Kohonen ağının yapısı.....	75
Şekil 22. X ve w_j Vektörleri arasındaki benzerlik ölçüsü Öklid mesafesi	76
Şekil 23. Dikdörtgen komşuluk işlevi	78
Şekil 24. Uyarlamalı Sinirsel Bulanık Çıkarım Sistem Yapısı (ANFİS).	80

Şekil 25.	ANFIS test adımının akış şeması ((Alnajjar ve Üçüncü, 2022)).....	86
Şekil 26.	Samsun Doğu İleri Biyolojik AAT Sahasında Hava Sıcaklık değişimi.....	89
Şekil 27.	Samsun Doğu İleri Biyolojik AAT giriş havuzu ÇO (mg/L) ölçümlerizamana bağlı değişimi.....	89
Şekil 28.	Samsun Doğu İleri Biyolojik AAT giriş havuzu Biyo-fosfor havuzları (anaerobik)-HRT ölçümlerinin zamana bağlı değişimi	90
Şekil 29.	Samsun Doğu İleri Biyolojik AAT giriş havuzu Havalandırma havuzları (Anoksik-Oksik)-HRT (Sa) ölçümlerinin zamana bağlı değişimi	90
Şekil 30.	Samsun Doğu İleri Biyolojik AAT giriş havuzu Son çökeltim havuzları HRT (Sa) ölçümlerinin zamana bağlı değişimi.....	91
Şekil 31.	Samsun Doğu İleri Biyolojik AAT giriş havuzu iletkenlik ölçümlerinin zamana bağlı değişimi.....	91
Şekil 32.	Samsun Doğu İleri Biyolojik AAT giriş havuzu debi ölçümlerin zamana bağlı değişimi.....	92
Şekil 33.	Samsun Doğu İleri Biyolojik AAT giriş havuzu pH (-) ölçümlerin zamana bağlı değişimi.....	92
Şekil 34.	Samsun Doğu İleri Biyolojik AAT giriş havuzu BOİ ölçümlerin zamana bağlı değişimi.....	93
Şekil 35.	Samsun Doğu İleri Biyolojik AAT giriş havuzu TN ölçümlerin zamana bağlı değişimi.....	93
Şekil 36.	Samsun Doğu İleri Biyolojik AAT giriş havuzu TP ölçümlerin zamana bağlı değişimi.....	94
Şekil 37.	Samsun Doğu İleri Biyolojik AAT giriş havuzu AKM ölçümlerin zamana bağlı değişimi.....	94
Şekil 38.	Samsun Doğu İleri Biyolojik AAT çıkışı BOİ ölçümlerin zamana bağlı Değişimi	95
Şekil 39.	Samsun Doğu İleri Biyolojik AAT çıkış TN ölçümlerin zamana bağlı değişimi	95
Şekil 40.	Samsun Doğu İleri Biyolojik AAT çıkış TP ölçümlerin zamana bağlı değişimi..	96
Şekil 41.	Samsun Doğu İleri Biyolojik AAT çıkış AKM ölçümlerin zamana bağlı değişimi	96

Şekil 42.	Samsun Doğu İleri Biyolojik AAT çıkış pH (-) ölçümlerin zamana bağlı değişimi	97
Şekil 43.	Doğu İleri Biyolojik AAT için bulanık kontrol yapısı	101
Şekil 44.	Sürecin girdi değişkenleri için MF'ler	102
Şekil 45.	BOİ, TN, TP ve AKM çıkış değişkenleri proses parametreleri için MF'ler.....	102
Şekil 46.	FIS kurallarına bir örnek	105
Şekil 47.	Doğu İleri Biyolojik AAT süreci için FL kontrol sonuçları.....	106
Şekil 48.	Girdi değişkenlerinin BOİ, TN, TP ve AKM üzerindeki etkisinin yüzeysel veri analizi.....	108
Şekil 49.	Samsun Doğu İleri Biyolojik AAT için Kullanılan YSA Yapısı	115
Şekil 50.	Programdaki sinir ağı eğitim arayüzü	117
Şekil 51.	YSA modeli için gerçek verilerin ve tahmin edilen değerlerin dağılımı (Eniyi performans için regresyon grafiği)	119
Şekil 52.	BOİ, TN, TP, AKM ve pH için gerçek ve tahmin edilen yüzde azalma değerlerinin dağılımını gösteren grafiği.....	120
Şekil 53.	MLP ağ eğitim performansı.	122
Şekil 54.	Program çıktı olarak RBF ağ eğitim performansı.	122
Şekil 55.	YSA modelinin sıfır hata alması için hata histogramı	123
Şekil 56.	ANFIS çıktı tahmini için şematik gösterim.....	125
Şekil 57.	Durulaştırılmış sonuçlar elde etmek için kural görüntü ekranı.	127
Şekil 58.	Giriş ve çıkış yanıtı ANFIS kuralı gösterimi.	129
Şekil 59.	Farklı girdi çıktıların çıktılar üzerindeki etkileri için 3B yüzey sunumu.....	131
Şekil 60.	En iyi seçilmiş modeller olan ANFIS ve YSA kullanılarak ölçülen ve tahmin edilen atıksu çıktıların dağılım grafikleri.	133
Şekil 61.	ANFIS ve YSA kullanılarak tahmin edilen ve gözlemlenen atıksu çıkışları.	135
Şekil 62.	Birincil arıtma için “APP DESIGNER” modelinin arayüzü, ikinci arıtma için “APP DESIGNER” modelinin arayüzü ve sonuç özeti arayüzü.	138
Şekil 63.	Parametreler için deneysel ve tahmin edilen yüzde azalma değerlerinin dağılım	142
Şekil 64.	Tahmin edilen giderim veriminin değerleri ile gözlemlenen (ölçülen) değerler arasındaki değişimi.	147

TABLOLAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Evsel atıksuyun fiziksel, kimyasal, biyolojik ve bakteriyolojik parametreleri	14
Tablo 2. AAT İşletme parametreleri.....	23
Tablo 3. Bulanık mantıkta çitlerin temsili	34
Tablo 4. Biyolojik ve yapay sinir ağlarındaki terimlerin karşılaştırılması	47
Tablo 5. Atıksu Arıtımında girdi ve çıktı değişkenlerin istatistiksel özellikleri.	88
Tablo 6. Giriş değişkenlerine karşılık gelen Gauss-MF'lerinin parametreleri.	103
Tablo 7. SKKY ve çıkış değişkenlerine bağlı Gauss-MF parametreleri (Resmî Gazete Tarihi: 31.12.2004 Resmi Gazete Numarası: 25687).	104
Tablo 8. AAT'den elde edilen sonuçların bir özeti.....	111
Tablo 9. YSA Modeli çıktı tahmin performansı.....	118
Tablo 10. Çeşitli ANFIS ve YSA modellerinin eğitim ve test aşamaları için performans değerleri	137
Tablo 11. “APP DESIGNER” Model'den elde edilen sonuçların özeti	140
Tablo 12. Çıktı parametrelerinin tahmin modeli için performans istatistik değerleri	143
Tablo 13. Tüm modellerden en iyi değerleri.	144

SEMBOLLER DİZİNİ

A_2O	: İleri Biyolojik Arıtma Üniteleri
AAT	: Atıksu Arıtma Tesisi
AN	: Amonyak Azotu
ANFIS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
ARIMA	: Otoregresif Entegre Hareketli Ortalama
ASM	: aktif çamur modeli
b	: Genişlik
BOİ	: Biyolojik Oksijen İhtiyacı
CO_2	: Karbon Dioksit
ÇKM	: Çözünmüş Katı Madde
ÇO	: Çözünmüş Oksijen
D	: Çapı
DDD	: Derin Deniz Deşarjı
e(p)	: Hata
$f_A(x)$	: Karakteristik Fonksiyonu
FFNN	: İleri Beslemeli Sinir Ağı
FIS	: Bulanık Çıkarım Sistemi
FLS	: Bulanık Mantık Sistemleri
GLM	: Genelleştirilmiş Lineer Model
GUI	: Grafik kullanıcı arabiriminizin
H	: Derinlik
H_2S	: Hidrojen Sülfid
H_2SO_4	: Sülfürik Asit
HRT	: Hidrolik Bekletme Süresi
KHOK	: Karesel Hatanın Ortalama Karekökü
KOİ	: Kimyasal Oksijen İhtiyacı
LASSO	: Düşük Mutlak Büzülme Ve Seçim Operatörü
L	: Litre

$M_A(x)$	: Üyelik Fonksiyonu
MF	: Üyelik Fonksiyonu
MLP	: Çok Katmanlı Bir Algılayıcı
MLP-BP	: Geri Yayılım Algoritmasına Sahip Çok Katmanlı Bir Algılayıcı Sinir Ağı
MMS	: Medyan Mutlak Sapma
NaOCl	: Sodyum Hipoklorit
N	: Veri Sayısını
NaOH	: Sodyum Hidroksit
N_g	: Azot
NH_3	: Amonyak
NH_4-N	: Amonyum Nitrojen
NO_2-N	: Nitrit Nitrojen
NO_3-N	: Nitrat Nitrojen
O ve G	: Yağ ve Gres
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hata
P	: Basınç
P_g	: Fosfor
PO_4^{3-}	: Fosfat İyonu
Q	: Debi
R^2	: Belirleme Katsayısı
RBF	: Radyal Tabanlı Fonksiyon Ağı
Sa	: Saat
Sn	: Saniye
SASKİ	: Samsun Su ve Kanalizasyon İdaresi
SKKY	: Su Kirliliği Kontrol Yönetmeliği
SVM	: Destek Vektör Makinesi
SVR	: Destek Vektör Regresyonu
T	: Sıcaklık
TAKM	: Toplam Askıda Katı Madde

TK	: Toplam Katılar
TKN	: Toplam Kjeldahl Azotu
TN	: Toplam Azot
TP	: Toplam Fosfor
UV	: Ultraviyole
V	: Hacim
Vd.	: Ve diğ�erler
$Y(p)$	: Ger�ek �ıktı
$Y_d(p)$	: İstenen �ıktı
YSA	: Yapay Sinir Ağıları
YZ	: Yapay Zekâ
W_A	: Singletonların Ağırlıklı Ortalamasını
Q	: Debi
$x_{g�zlenen}$	: Parametre Değ�erinin G�zlenmiř Değ�erini;
$\bar{x}_{g�zlenen}$	: Parametre Değ�erinin Ortalamasını
x_{tahmin}	: Parametre Değ�erinin Modellenmiř Değ�erini;
$\bar{x}_{tahmin}$	: Parametre Değ�er: İnin Ortalamasını Temsil Etmektedir.
η	: Arıtma verimliliğ�i
η_1	: Birincil arıtma verimliliğ�i
η_2	: İkincil arıtma verimliliğ�i

1. GENEL BİLGİLER

1.1. Giriş

Nüfus ve endüstri ve sanayi artışına bağlı olarak içme ve kullanma suyu tüketimlerinde artışlar meydana gelmektedir. Buna karşılık her yıl atıksu miktarları da artması nedeniyle atıksu arıtımı giderek çok daha fazla önemli bir hale gelmektedir. Sonuç olarak, evsel ve endüstriyel arıtılmamış ham atıksu en ciddi çevresel kirleticilerden biri olmaktadır. Bununla birlikte, atıksu arıtma süreci son derece karmaşık ve pahalıdır. AAT arıtma mekanizmasının anlaşılması ve işletim açısından da zordur. AAT'lerini matematiksel bir model ve simülasyon/benzeşim ile dayalı olarak daha hızlı ve ekonomik boyutlandırma ve işletmeye yardımcı olunabilmektedir (Alnajjar ve Üçüncü, 2022, 2023). Başka bir deyişle AAT'lerinin işletiminde bir dizi bilinmeyen kirlilik parametrelerin değişkenliklerinden etkilenmektedir. Bunlar, atıksuyun fiziksel, kimyasal ve biyolojik arıtma süreçlerindeki mekanizmalarını içermektedir. Sonuç olarak, AAT'da arıtma verimliliğini tahmin etmek için doğru sonuçlar veren düşük maliyetli program teknikler geliştirilmelidir. Bu nedenle, atıksu arıtma sistemlerinin kararlılığını (iyi arıtma yapılabilmesi) artırmak için bir bilgisayar işletim sistemi geliştirilebilmektedir (Niu vd., 2020). Büyük miktarda kirlilik parametre verileriyle başa çıkma ve tahmin etme zorluklarıyla artık tüm dünyada kullanılan Yapay Zekâ modelleri hızla ilerlemekte ve artış göstermektedir. Yapay Zekâ uygulaması, bilgiyi artırma ve iletişim kurma ihtiyacı, gelişmekte olan teknolojilerde yapay zekâ alanını daha yaygın hale getirmiştir. Genel olarak yapay zekânın (YZ) geliştirmesi ile YZ, insanoğlu düşünme süreçlerini modelleyerek karmaşık doğrusal olmayan atıksu arıtma süreçlerini modelleyebilen geleneksel süreç kontrol yöntemlerine göre belirgin avantajlara sahiptir (Alnajjar ve Üçüncü, 2021). Yapay zekâ teknolojilerine dayalı iyileştirilmiş süreç kontrol algoritmaları, artan çevresel ve ekonomik kaygıların bir olarak büyük ilgi görmüştür. Diğer yandan mühendislikteki son gelişmeler, bulanık mantık, genetik algoritmalar ve sinir ağları gibi farklı kolay hesaplama tekniklerinde var olan bazı fikirleri ve paradigmaları entegre eden hibrit kontrol stratejilerinin, atıksu kalitesini geliştirmiş kontrolünü sağlayabileceğini göstermektedir.

Olası planlayıcı eylemlerinin etkisini simüle etmek için bu modelleri kullanarak, süreçlerdeki herhangi bir değişikliğe hızla yanıt vermek ve tesisin düzgün çalışmasını, arıtma kalitesini artıran yeni bir çalışma seviyesine taşıyabilecek bir operasyonel strateji tasarlamak mümkündür. Bununla atıksu arıtımında, aynı zamanda AAT'nin işletilmesinde ve tasarım maliyetlerinde bir azalmalar sağlamaktadır.

Ayrıca, YZ modelleri, daha önce görülmemiş girdilerle sunulduğunda bir çıktı üretmek için girdi-çıkıtı ilişkisini genelleştirme yeteneğine sahiptir. Bu, uygun şekilde kalibre edilmiş ve onaylanmış mekanik modellerle mümkün olabilse de mekanik modeller o kadar çok veri gerektirir ki, bunların etkin kalibrasyonu ve doğrulanması imkânsız değilse de her zaman zordur. Ayrıca mekanik modeller için model tanımlama ile ilişkili belirsizlik de vardır, yani fonksiyonel ilişkinin tam şekli bilinmemektedir ve bu nedenle bilinmeyen ilişki için matematiksel ifade ne olursa olsun, sadece bir tahmin olmaya mahkumdur. YZ teknikleri ise veriye dayalı tekniklerdir ve modellenen ilişkinin matematiksel biçimini belirtme zorunluluğu yoktur.

Yaygın olarak kullanılan yapay zekâ araçları ve teknikleri arasında, her ikisi de karmaşık Çevresel sistemler için modellerin geliştirilmesinde önemli bir rol oynayan Bulanık Mantık sistemleri (FLS) ve yapay sinir ağları (YSA) bulunmaktadır (Esteves, 2002) (Çinar, 2005).

Bulanık mantık ve YSA tekniklerinin temel ve tamamlayıcı özellikleri, araştırmacıları, onları uyarlanabilir bir nöro-bulanık çıkarım sistemi veya Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) olarak adlandırılan entegre bir sistemde birleştirmeye yönlendirmiştir. ANFIS, YZ'ların öğrenme ve hesaplama güçlerini ve FLS'lerin yüksek düzeyde insan benzeri düşünme ve akıl yürütmesini bir araya getirerek hem YZ'ların hem de FLS'lerin faydalarını birleştirmektedir. Ek olarak, ANFIS'leri modelleme uygulamalarında onları çok yönlü bir araç yapan başka özelliklere de sahiptirler, yani belirli bir düzeyde hata toleransı anlamına gelen yüksek paralel yapı ve çok değişkenli sistemlerle uğraşmadaki doğal kolaylık (Qasem vd., 2017).

Bu konuyla ilgili çok sayıda ders kitapları ve makaleler mevcut olduğundan dolayı bu tez çalışmasında YZ teknikleri ile ilgili olarak konuya derinlemesine girilmemiştir. Bunun yerine, bu tekniklerin en yaygın olarak kullanılan, iyi bilinen ve kolayca anlaşılan, yapay sinir ağları,

bulanık mantık modeli ve ANFİS modeli uygulanabilir. Bu modeller birincil arıtma (Izgara, kum tutucu, gres-yağ tutucu ve ön çökeltme havuzu), ikincil arıtma (Anaerobik havuzlar, Aerobik havuzlar, son çökeltim havuzu) ve ileri arıtma da (fakültatif havuz) gibi karmaşık arıtma sistemlerini modellemek ve fizibilitelerini göstermek için uygulanmaktadır (Wan vd., 2011).

1.2. Amaç ve Kapsam

Bu çalışmada atıksu arıtma tesislerinde birincil ve biyolojik arıtma yapay zekâ modelleri kullanılarak arıtma verimliliği modellenmiştir.

Atıksu kalitesini etkileyen en önemli faktörlerden biri biyolojik oksijen ihtiyacı (BOİ), toplam azot (TN), toplam fosfor (TP) ve toplam askıda katı madde (TAKM) olup, laboratuvarda test edilmesi uzun zaman alır, günler sürer ve inceleme maliyeti yüksektir. Bu nedenle yapay zekâ modelleri deneylere, laboratuvar testlerine ve deneysel modellemeye alternatif olmuştur.

Atıksu kirlilik parametrelerinin belirlenmesinde kullanılan; sıcaklık (T), pH, hidrolik bekletme süresi (HRT) ve çözünmüş oksijen (ÇO) parametreleri modellemeye girdi verileri olarak BOİ, pH, TN, TP ve TAKM tahmin edilmesinde kullanılmıştır. Matematik modeller atıksu arıtma sistemlerinin boyutlandırılmasında ve optimum koşullarda işletilmesinde yaygın olarak kullanılmaktadır.

Kullanılan YZ modelleri; Bulanık Mantık, Yapay Sinir Ağları ve ANFİS modelleridir. Bu matematik modellerin kullanımı, atıksu arıtma tesislerinde kirlilik standartlarındaki parametrelerin deşarj standartlarına uygun hale getirilmesi ve atıksu arıtma verimini artırmayı amaçlamaktadır. Ayrıca modelleme, kirleticilerin atıksudan uzaklaştırılmasının etkinliğinin tahmin edilmesine de yardımcı olacak ve çevre ve halk sağlığı için alıcı ortama daha güvenli bir şekilde atıksuyun deşarj edilebilmesi sağlayacaktır. Sonuçta, tesis planlayıcıları ve işletmecileri atıksu arıtma tesislerini daha verimli ve daha kısa sürede boyutlandırabilir ve de işletebilirler. Bu durumda laboratuvarda prototip oluşturularak deneyler yapmaya gerek kalmayabilir. Bütün bu çalışmalarda ekonomiklik ve zaman baskısından da kurtulunabilir.

Regresyon analizi kullanılması ile atıksu kirlilik parametreleri ortaya çıkarılabilmektedir. Ancak, konu doğasında var olan doğrusal olmayan karmaşık etkileşimler nedeniyle, bu geleneksel regresyon yaklaşımı tatmin edici bulgular üretmemektedir. Doğrusal olmayan problemler, geleneksel tekniklerin kullanılması uygun modellemeye ters düşmektedir. Belirsizlik ve kesin olmayan durumlarda daha etkin uygulanabilecek çeşitli teknikler bulunmaktadır.

Yapay zekâ modelleri; atıksu arıtma tesislerinin tasarımı ve kontrolü için sistematik ve kapsamlı bir yaklaşım ortaya koyar. Atıksu arıtma süreçlerinin karmaşıklığı ile başa çıkmak için hibrit modeller üretme zorunluluğu ortaya çıkmıştır.

Bu çalışmada; birinci aşamada atıksu arıtma teknikleri hakkında bilgi verilerek atıksu arıtma tesislerinin birincil ve biyolojik arıtımı aşamaları için tasarım verileri ve arıtma verimi elde edilmektedir.

İkinci aşamada MATLAB APP DESIGNER, bulanık mantık ve yapay sinir ağları kullanılarak bir model oluşturulmuş ve çıkan sonuçlar birbiriyle karşılaştırılmıştır.

Üçüncü aşamada ANFIS hibrit modeli oluşturulmuş ve sonuçları bir önceki modellerle karşılaştırılmıştır.

Dördüncü ve son aşamada, modellerin geçerliliğini doğrulamak ve bu modellerden en iyi verimi elde etmek ve de bu modelleri kalibre ederek tahmin edilen verimlerini artırmak/iyileştirmek için çalışan bir atıksu arıtma tesisinden alınan gerçek veriler kullanılmıştır.

1.3. Literatür Taraması

FL tabanlı yöntemler, sinir ağları ve genetik algoritmalar gibi soft bilgi işlem araçlarının son yıllarda büyük ve genişleyen çalışma alanları bulmuştur. Ancak risk değerlendirmesi, maliyet-fayda analizi ve yaşam döngüsü etki değerlendirmesi gibi çevresel alanlarda bu metodolojiler yalnızca sınırlı bir şekilde kullanılmıştır. Bulanık mantık yaklaşımların, mevcut kullanımda olan diğer yöntemlere kıyasla hem yeni fırsatlar hem de beklenmedik sorunlar

sunduğundan, önümüzdeki yıllarda çevre politikaları üzerinde ne kadar etkili olacağını söylemek mümkün değildir(Chiroșcă vd., 2011).

Çevre politikalarında ortaya çıkan karmaşık ve kesin olmayan problem türleri için, karmaşık davranışları basit “EĞER-O HALDE” kuralları topluluğu olarak modelleme yeteneği, bulanık mantığı uygun bir modelleme aracı haline getirmiştir. Bulanık mantık aritmetik, programlama dilleri değişkenleri ve uygun olmayan karakterize edilmiş parametreleri ele almak için iyi çalıştığından, bulanık mantık yöntemleri, herkes tarafından programlama dillerine dayalı değerlendirmesi ve kullanım fırsatı sunmaktadır. Ayrıca, bulanık mantık aritmetiği gibi yaklaşık akıl yürütme yöntemleri, “girdi parametreleri” olarak iyi karakterize edilmiş istatistiksel dağılımları gerektirmemektedir. Bulanık mantığın risk değerlendirmesindeki bir diğer önemli avantajı, örneğin çevre ve halk sağlık hedeflerini daha uygun hedeflerle birleştirmek gibi farklı hedefleri bulunmaktadır. Aynı zamanda nitel ve nicel amaçların birleştirilmesi için kuralları da ortaya koymaktadır. Ancak çevre ve halk sağlığı riskini ve diğer çevresel etkileri ifade etmek için bulanık mantığın potansiyel sınırlamalarını iyi tanımak ve bunlar kullanılmalıdır (Vijayaraghavan ve Jayalakshmi, 2015).

Çok sayıda araştırmacılar, karmaşık çevre problemlerini modellerken “girdi parametreleri” ve “çıktı parametreleri” hakkında kesin ifadelerde bulunmada sıklıkla başarısız olurlar, ancak bulanık mantık, çevre parametrelerinin geliştirilmesine, gözlem uyumsuzluğu ve öngörülemeyen değer yargılarına duyulan ihtiyacı birçok yaygın problemi çözecek şekilde uygulanabilmektedir.

1970'li yıllardan itibaren atıksu arıtma tesislerinin biyolojik arıtma sistemlerine odaklanan çalışmalar yapılmaktadır. pH'nın endüstriyel atıksu için biyolojik arıtma havuzlarının verimliliği üzerindeki etkisi bulanık mantık kullanılarak incelenmiştir(Mohd Noor vd., 2004). Bulanık mantık modeli, ilgili ekonomik, teknik ve çevresel parametreleri değerlendirerek atıksu arıtma tesislerinin çıkışında düşük düşümlü hidroelektrik teknolojisi için en uygun seçeneği bulmak için kullanılmıştır(Ak vd., 2017).

Öte yandan, enerji tüketen bir süreç olan biyolojik arıtmadaki havalandırma sürecinin fiili kontrolüne çalışılmış ve bulanık mantık modeli kullanılarak dinamik değişkenlerin

havalandırma sürecinde ki enerji kullanımını daha da azalttığı bulunmuştur(Fan ve Boshnakov, 2010).

Bulanık model ayrıca biyolojik arıtma havuzlarında uygun arıtma teknolojilerinin seçilmesinde dört arıtma yöntemi değerlendirilerek kullanılmıştır. Bunlar; Anaerobik-Anoksik-Oksik, Üçlü Oksidasyon Hendeği, Anaerobik Tek Oksidasyon Hendeği, Sıralı Kesikli Reaktörlü Aktif Çamur Havuzu (Yao vd., 2020).

Bulanık model ayrıca arıtılmış atıksuyun (Tesis çıkış atıksu) tarımsal, endüstriyel vb. sahalarda yeniden kullanım gereksinimlerini karşılamak için yeniden kullanılmasının mümkün olup olmadığını da ortaya çıkarmada yardımcı olmaktadır(Nadiri vd., 2018).

YSA, en hızlı gelişen yapay zekâ teknolojilerinden biridir. Sadece doğrusal olmayan (linier) fonksiyonları oluşturarak karmaşık olayları tanımlayamaz, aynı zamanda geleneksel kontrol sistemlerinin eksikliklerini telafi etmelerine izin vererek kendi kendine öğrenme ve kendi kendine uyum sağlama avantajına da sahiptir (Shin vd., 2019). Son yıllarda, YSA, atıksu arıtımında başarılı bir şekilde modelleme de kullanılabilmektedir.

Bir biyolojik atıksu arıtma tesisinin girişindeki günlük BOİ'yi değerlendirmek için bir yapay sinir ağı modeli oluşturulmuştur. YSA modelinin ve çoklu doğrusal regresyon modelinin sonuçları birbirleri ile karşılaştırılmıştır. Girdi parametreleri KOİ, Q, AKM, N, ve P ile YSA yaklaşımı için ortalama karesel hatalar, ortalama mutlak bağıl hatalar ve belirleme katsayısı sırasıyla 708.01, %10,03 ve 0.919 bulunmuştur. Yapılan karşılaştırmalara dayanarak, YSA modelinin biyolojik atıksu arıtma tesislerinin girişindeki günlük BOİ'yi başarıyla tahmin etmek için kullanılabileceği araştırılmıştır(YILMAZ, 2009).

Yapılan modelleme çalışmalarında MATLAB® kullanılarak çevre mühendisliği problemlerinin hızlı ve doğru bir şekilde çözülebileceği, önemli ölçüde zaman ve enerji tasarrufu sağlanabileceği görülmüştür. Aynı zamanda prosesin nasıl işleyeceği, arıtma veriminin nasıl değişeceği, havuzların sayısı ve hacimlerinin kirlilik yüküne uygun olup olmadığı, hangi donanım ve boyutlarının uygun olduğu ve hangi şartlar altında uygulanacağı konusunda basit ve esnektir. Bu programlar yardımıyla mevcuttaki problemlerin parametreleri (havuz sayısı, sıcaklık, pH, ÇO vb.) değiştirilerek duruma göre elektrik enerji tüketimi minimuma indirilebilmektedir (AYLA, 2021).

Bursa Doğu AAT'sinde ki gerçek bir amonyak giderme tesisinden elde edilen veriler daha önce yapılan bir çalışmada kullanılmış ve çalışmada Simülatör programı, BioWin® 6.0 programı kullanılmıştır. Çeşitli sıcaklık ayarları altında, havalandırma modellerinde ayarlanan ÇO ve oksik-anoksik sürelerin TN atığı ve mikrobiyal popülasyon dağılımı üzerindeki etkisi araştırılmıştır (KALJUNEN, 2019).

2019 yılında araştırmacılar tarafından tipik bir atıksu arıtma tesisinin son çökeltme havuzundaki tüm ana parametreleri içeren bir matematiksel model oluşturulmuştur. Oluşturulan bu model, çökeltme havuzunda askıdaki partiküllerin çökmesi engellenmiş, sıkıştırma ve dağılma özellikleri ile esneklik sağlanmıştır. Aktif çamurun geri besleme kontrol uygulamaları için kullanışlı ve bilgisayar simülasyonları için yeterince basittir. Bilgisayar simülasyonları çalıştırılmış, sonuçlar incelenmiş ve oluşturulan model gerçekçi koşullar altında test edilmiştir(SYED, 2019).

AAT sürecini simüle etmek için “GPS-X simülasyonu” da kullanılmıştır. Kalibrasyon ve doğrulama prosedürleri tamamlanmış ve beklenen gerçek veriler arasında iyi düzeyde bir uyum bulunmuştur. İyileştirmeler, KOİ, BOİ, AKM, NO₃, TP ve toplam koliform sayısı için sırasıyla %48, %65, %93, %3, %48 ve %99 bulunmuştur(AL-JAWDHARI, 2022).

Öte yandan, daha önce Erzurum İli atıksu arıtma tesisi “GPS-X” bilgisayar yazılımı kullanılarak modellenmiştir. Modelleme çalışmaları için ölçülen giriş atıksu değerleri Toplam KOİ=633,5 mg/L, BOİ=321 mg/L, TKN=54 mg/L ve AKM=343 mg/L bulunmuştur. P.I.D. (İngilizce: Proportional Integral Derivative) kontrol algoritması, havalandırma tanklarındaki ÇO=1,5 mg/L'ye sabitlenmiş ve senaryonun C ve N maddelerinin uzaklaştırılması üzerindeki etkisi değerlendirilmiştir. Ayrıca Erzurum İli sıcaklık değişimleri için önemli bir arıtma operasyonu ölçüt olan “biyolojik aktivite” üzerindeki etkisi de incelenmiştir. Toplam KOİ = 75 mg/L, BOİ=21,83 mg/L ve AKM=38 mg/L'nin tahmini konsantrasyonları için 10°C'nin altındaki sıcaklıklarda deşarj gereksinimlerini karşılamamıştır(ALADAĞ, 2011).

Ayrıca, Hurma (Antalya İli) AAT, iki farklı bilgisayar modellemesi yaklaşımı kullanılarak incelenmiştir. Bunlar, geleneksel “ASM2” ve “YSA” adı verilen alternatif programlama modelleridir. Sonuç olarak, AAT'nin çıkış suyu TN, TP ve KOİ parametreleri gibi son model bulguları ile biyolojik büyüme hızı, havalandırma havuzundaki ÇO ve arıtma çamur yaşı gibi

ara program modelleri sonuçları elde edilmiştir. TN, TP ve KOI değerleri korelasyon katsayıları R^2 sırasıyla 0,56, 0,38 ve 0,41 olarak bulunmuştur. Bununla birlikte, AAT'den alınan aynı işletme verileri kullanarak, KOI değerini tahmin etmeyi amaçlayan YSA model denemeleri için model sonuçları, $R^2=0,70$ gibi bir korelasyon katsayısı ile daha yüksek bir model performansı oluşmuştur (Öztürk, 2007).

Anaerobik atıksu arıtma prosesinin sürekliliği, “Matlab/Simulink” ortamında programlama ve simülasyon kullanılarak modellenmiş ve incelenmiştir. Bu sürekliliği sağlamak için tüm süreçler matematiksel olarak modellenir ve anahtar süreç parametreleri belirlenmiştir. Tüm atıksu arıtma sürecinin uzun vadeli kontrol prosedürü, sistemin sürekliliğini sağlayandır. Sistem doğrusal olmayan özelliklere sahip olduğundan, atıksu arıtma sürecini temsil etmek için doğrusal olmayan durum uzayı denklemleri ve başlangıç koşulları kullanılmaktadır. Sonuç olarak, anaerobik atıksu arıtma sistemi artık yönetilebilmektedir (ÜLKÜ, 2006).

Konacık Belediyesi atıksu arıtma tesisi “GPS-X yazılım” kullanarak modellenmiştir. Arıtma tesisinin tüm proses tasarımı ve parametreleri simülasyon programına girildi ve bu simülasyon programında atıksu arıtma tesisinin mevcut verileri kullanılarak optimize edilmiştir. En son arıtma verileri kullanılarak N- giderimi ile ilgili verimlilik sorunu ele alınmış ve simülasyon aracı kullanılarak bu sorun için ideal bir çözüm bulunmuştur. Öte yandan, “GPS-X programı” yardımıyla atıksu arıtma tesisi ideal koşulları ve arıtma parametreleri için programlanmıştır. Bu değişken parametreler ve oluşturulan çözümler gerçek tesislere uygulanmış ve program çıktıları gerçek tesis sonuçları ile çapraz kontrol edilmiştir(KARADUMAN, 2011).

Modelleme ve maliyet analizi kullanılarak, arıtılmış atıksuyun yeniden kullanım uygulamaları için atıksu arıtma planları farklı şekilde değerlendirilmiştir. Bunun için, biyolojik arıtma uygulamalarında uzatılmış havalandırma (TS B), A2O (TS C), geleneksel aktif çamur (TS A) ve BioWin programlarında üç atıksu parametresi ve üç akış hızı kullanılmıştır. 30 yıllık bir dönem için, BioWin modellemesinin sonuçlarını içeren biyolojik arıtma seviyesi ve ileri arıtma seviyeleri için bir maliyet analizi yapılmıştır. Bu analiz hem yatırım hem de işletme giderlerini içermektedir(UYANIK, 2020).

MATLAB programının ANFIS araç kutusu kullanılarak geliştirilen matematiksel model, Mersin İli “Karaduvar Kentsel Atıksu Arıtma Tesisi” için işletme parametrelerinin girdi değerlerini dikkate alarak tahmini çıkış değerlerini belirlemek için değerlendirmiştir. KOİ, KOİ/BOİ, KOİ/TN ve KOİ/TP oranları için girdi ve çıktı parametreleri olarak “trimf, trapmf, gbellmf, gaussmf, gauss2mf, pimf, dsigmf, psigmf” üyelik fonksiyonları ve farklı üyelik fonksiyonları kullanılmıştır. Bireysel araştırmalar 10, 25, 50, 100, 150, 200, 250, 500 ve 1000 NMF'ler (üyelik fonksiyonları) üzerinde yürütülmüştür. Çıkan sonuçların değerlendirilmesi, “lineer optimizasyon yaklaşımı, trapmf üyelik fonksiyonu”, 500 NMF ve 1000 NMF'in tanımlanmasında kullanılmıştır. Optimum koşulların eğitimi için döngü ve eğitilen modeli değerlendirmek için 250 döngü kullanılmıştır(EROĞLU, 2021).

Arıtma prosesleri sonrasında alıcı ortamlara deşarj edilen çıkış atıksuyu hassas olmayan yerler için uygun arıtma prosesleri ile yeni bir kentsel atıksu arıtma tesisi tasarlanmış ve Kocaeli “Kullar Atıksu Arıtma Tesisi”ne giren atıksuyun kaynakları, debisi ve atıksu kirlilik miktarları değerlendirilmiştir. Yeni atıksu arıtma tesisini modellemek ve arıtma performansını değerlendirmek için yapay sinir ağı kullanılmıştır(ALKAY, 2016).

Kayseri İli Atıksu Arıtma Tesisi, atıksudan fosfor, nitrojen ve karbonu da gideren biyolojik bir atıksu arıtma tesisi şeklinde boyutlandırılmıştır. Hem evsel hem de endüstri atıksular Kayseri İli AAT'ne gönderilmiştir. Bu çalışmada Kayseri İli AAT'nin modellenmesi için tasarlanmış ve bunun programlanması için GPS-X adlı program kullanılmıştır. Arıtma tesisi simülasyonu için Uluslararası Su Kalitesi Birliği (IAWQ) tarafından önerilen “Aktif Çamur Modeli No.2d (ASM2d)” kullanılmıştır. Bu modelde aynı zamanda C'nun oksidasyonunu, nitrifikasyonu, denitrifikasyonu ve biyolojik fosfor giderimini simüle etmiştir(TOPKAYA, 2008).

Denizli İli Atıksu Arıtma Tesisi performansının YSA kullanılarak detaylı incelenmesi ve modellenmesi yapılmıştır. Denizli İli AAT'de arıtma prosesi olarak aktif çamur prosesi kullanılmıştır. Arıtma tesisinin giriş ve çıkış suyu sürekli olarak pH, Elektrik iletkenlik, BOİ, KOİ, TN ve TP için örneklenmiştir. YSA modellemesinde iyi uyum görülmüş ve KOİ, BOİ, TN, TP ve Çamur Hacim İndeksi (SVI) için model tahminleri ve gözlemler arasındaki

korelasyon katsayıları (R^2) sırasıyla 0.90, 0.83, 0.74, 0.75 ve 0.84 bulunmuştur(Yıldız Pulcu, 2009).

MATLAB Programı kullanarak atıksu arıtmanın performansını modellemek için yapay sinir ağları kullanılmıştır. Çalışmanın verileri, bitkilerle kaplı bir su altı yatakları sisteminden gelmiştir (Marahatta, 2004). Bu çalışmadaki arıtma performansı, çeşitli farklı kirlilik girdi parametreleri kullanılarak çeşitli atıksu çıktı parametrelerine dayalı olarak hesaplanmıştır. KOI_{Girdi} , $KOI_{Çıktı}$, TKM_{Girdi} , $TKM_{Çıktı}$, Uçucu Askıda Katı maddelerin girişi, Uçucu Askıda Katıların çıkışı ve Sıcaklık sırasıyla girdi ve çıktı parametreleri olmuştur. Bu model tabanlı yaklaşıma göre KOI , TKM , Uçucu Askıda Katılar ve sıcaklık, arıtma tesisi performansı üzerinde en büyük etkiyi göstermiştir. Arıtma tesisi veri modeli için doğruluk tahminleri %98 olmuştur (SUBAŞI, 2010).

Ankara İli “Merkezi Atıksu Arıtma Tesisi”, Aktif Çamur Model No. 1 (ASM1) mekanik modeli, Yapay Sinir Ağları (YSA) ve iki modeli birleştiren bir hibrit model ile donatılmış çalışma yapılmıştır. GPS-X bilgisayar programı kullanılarak bu Arıtma Tesisinin matematiksel modeli (ASM1)’de oluşturulmuştur. Ayrıca, tahmin doğruluğunu artırmak amacıyla her iki mevcut modelin en iyi özelliklerini birleştiren hibrit bir model geliştirilmiştir. Hibrit model yönteminin ASM1 ve YSA'dan daha iyi performans gösterdiği ve bu tesisin işletme koşullarını daha doğru bir şekilde yakaladığı görülmüştür(Dünyamin ve Şükrü, 2007).

Aralıklı döngülü uzun havalandırmalı sıralı kesikli reaktör için, fekal koliformunu ve toplam koliform eliminasyonunu (ICEAS-SBR) tahmin etmek için yapay sinir ağı (YSA) modelleri geliştirilmiştir. Ağ, atıksu giriş pH'sı, biyokimyasal oksijen ihtiyacı ($BOİ$), kimyasal oksijen ihtiyacı (KOI), toplam askıda katı madde (TAKM), yağ ve gres, toplam Kjeldahl azotu (TKN), amonyak azotu (AN), kullanılarak geliştirildi. toplam fosfor (TP), dışkı koliformu ve toplam koliform. YSA modelleri, arıtılmış atıksudaki fekal koliform ve toplam koliform seviyelerinin düzenlenmesine izin vererek, özellikle istiridye tüketicileri için halk sağlığı endişelerini azaltmaktadır (Khatri vd., 2019).

Modern (ileri AAT vb.) bir AAT’de atıksu arıtma ile biyogaz (CH_4) üretimi için anaerobik fermentasyon sürecini taklit etmek için yapay sinir ağları (YSA'lar) kullanılmıştır. Gerçek ölçekli endüstriyel verilere dayalı olarak hem sürecin teknolojik yönleri hem de arıtılmış

atıksuyun kalitesi göz önünde bulundurularak nöral modeller eğitildi, doğrulanıp ve test edilmiştir. Bir parametre duyarlılığı çalışması, işletme süreci faktörlerinin biyogaz verimi üzerinde atıksu kalitesinden (KOI , BOI , AKM , P_{gaz} , N_{gaz}) daha büyük bir etkiye sahip olduğunu ortaya koymuştur. Önerilen YSA modeli, diğer olası süreç yoğunlaştırma ve optimizasyon senaryolarının test edilmesinin yanı sıra bir tahmin aracı olarak da kullanılabilmektedir(Sakiewicz vd., 2020).

BOI eliminasyonunu tahmin etmek için, YSA tahminleri kullanılarak hiperbolik bir tasarım denklemi oluşturuldu. Bu denklem sıfır ve birinci dereceden kinetiği birleştirmektedir. YSA'ların sonuçları ve model tasarım denklemi, literatürdeki verilerle karşılaştırıldı ve makul derecede doğru olduğu bulundu. KOI 'nin ortadan kaldırılmasının, BOI 'nin ortadan kaldırılmasıyla yüksek oranda bağlantılı olduğu gösterilmiştir. KOI eliminasyonunu tahmin etmek için bir formül de geliştirilmiştir (Akratos vd., 2008).

YSA modelleri nehirlerde, göllerde, AAT'lerde, yeraltı suyunda, göletlerde ve akarsularda çeşitli modelleme problemlerini çözmek için kullanılabilmektedir(Chen vd., 2020).

Literatüre göre, bir hastane atıksu arıtma tesisinden çıkan çıkış suyundaki askıda katı madde ($AKM_{Çıkış}$) ve kimyasal oksijen ihtiyacı ($KOI_{Çıkış}$), üç farklı ANFIS ve YSA kullanılarak tahmin edilmiştir. Çıkış suyu tahmin sonuçları, ANFIS'in istatistiksel olarak YSA'yı geçtiğini göstermiştir (Cheng vd., 2018). ANFIS modeli, çıkış pH kalitesini tahmin etmek için kullanılır ve karşılaştırma olarak yapay sinir ağı kullanılmaktadır(Cakmakci, 2009). Başka bir çalışmada, giriş KOI , giriş hızı, giriş toplam kjeldahl nitrojeni, atıksuda uçucu yağ ve gress dahil olmak üzere mısır yağı işletmesi atıksuyunu işleyen tam ölçekli bir genişletilmiş granüler çamur yataklı reaktörden (EGSBR) KOI yükünü tahmin etmek için beş proses değişkeni kullanılmıştır. Önerilen ANFIS modeli, hibrit bir öğrenme yaklaşımı kullanılarak oluşturulmuş ve performansı, deneysel alandan rastgele seçilen bir dizi test verisi kullanılarak değerlendirilmiştir. ANFIS tabanlı tahminler, hata ortalamalarının karesi, uyum indeksi, iki faktör, kesirli varyans, sistematik hata oranı vb. dahil olmak üzere çeşitli tanımlayıcı istatistiksel metrikler kullanılarak doğrulanmıştır(Yetilmmezsoy vd., 2015). Günlük atıksu kirlilik verileri kullanılarak, atıksuyun $BOI_{Çıkış}$ ve $KOI_{Çıkış}$ tahmin etmek için ileri beslemeli sinir ağı (FFNN), destek vektör regresyonu (SVR) ve ANFIS kara kutu yapay zekâ modelleri (YZ) kullanılmıştır. Ek olarak, karmaşık süreç

tahmininde doğrusal ve doğrusal olmayan modellerin yeteneklerini karşılaştırmak için otoregresif entegre hareketli ortalama (ARIMA) doğrusal modeli kullanılarak $BOI_{Çıkış}$ ve $KOI_{Çıkış}$ parametreleri tahmin edilmiştir(Nourani vd., 2021). Bir başka araştırmada, endüstriyel bir AAT'de aktif çamur prosesinin lineer olmayan sistemi, ANFIS ve genelleştirilmiş lineer model (GLM) regresyonu kullanılarak tanımlanmıştır. Daha önce değerlendirilen girdi ve çıktı parametrelerine dayalı olarak BOI ve KOI tahmine dayalı modelleri geliştirilmiştir. Olasılıklar listesinden, sırasıyla GLM'ler ve ANFIS modelleri için en iyi regresör kombinasyonunu seçmek için en düşük mutlak büzülme ve seçim operatörü (LASSO) ve bulanık kaba kuvvet araması kullanılmıştır(Araromi vd., 2018). Ayrıca, ANFIS, aktif çamur sisteminde substratın doğrudan ters kontrolüne izin verir ve önerilen denetleyicinin performansı, substrat ayar noktaları izlenerek kanıtlanır ve bunun sonucu, önerilen denetleyicinin substrat konsantrasyon seviyesini verimli ve hassas bir şekilde yönetebildiğini ortaya çıkarmaktadır. Önerilen ters kontrolör, AAT (Gaya vd., 2014) için faydalı bir kontrol mekanizması olabilmektedir. Yapılmış bir çalışmada, tam ölçekli bir aerobik biyolojik AAT'de Kjeldahl azotunun uzaklaştırma verimliliğini ve modelleme sürecinde kullanılan girdi değişkenlerini değerlendirmek için destek vektör makinesi (SVM) ve ANFIS modelleri kullanılmıştır. pH, KOI , TK, serbest amonyak, amonyak azotu ve kjeldahl azotunu içeriyorsa, model geliştirmenin sonuçları, Kjeldahl azot giderme verimliliğini çoğaltmak için uyarlanabilir, işlevsel, gerçek zamanlı ve alternatif bir yaklaşım sağlamıştır (Matheri vd., 2021). Diğer bir başka bir çalışmada da anaerobik çürütücülerin çıktısını artırmak için başarılı ANFIS modellemesinin kullanımı kullanılmıştır (Erdirencelebi ve Yalpir, 2011). ANFIS modeli ayrıca da karbon ve nitrojeni uzaklaştırmak için kullanılmıştır. Karşılaştırma olarak, ileri beslemeli bir sinir ağı kullanılmaktadır. KOI , AKM ve amonyum nitrojen (NH_4-N) dahil olmak üzere incelenen tüm değişkenlerin, ANFIS modeli kullanılarak artan tahmin gücüne sahip olduğu bulunmuştur (Civelekoglu vd., 2007).

Önceki araştırmalara göre, çoğu biyolojik arıtma aşaması sırasında atıksudaki kirleticilerin nasıl elimine edileceğini bulmaya odaklanmıştır. Endüstriyel ve evsel AAT'lerini analiz etmek için yapay zekâ modelleri kullanılmıştır.

Bu kapsamda, Doğu Karadeniz Bölgesi İllerinden Samsun'da Doğu İleri Biyolojik AAT giriş ve çıkış verileri alınmıştır. En fazla sayıda giriş parametrelerinin kullanımına odaklanarak ve bu sayede atıksudan kirleticilerin uzaklaştırılmasının verimliliğini yüksek oranda doğrulukla

tahmin etmek için inceleyen yayınlamış bir çalışma henüz bulunmamaktadır. Literatürdeki açığı, yapay zekânın en fazla iki modelinin kullanılmıştır. Modellemelere en fazla dört girdi sayısı ile sınırlı olmuş ve çıktıları ise bir veya iki arasında kalmıştır.

Öte yandan bu çalışmada üç adet yapay zekâ modeli kullanılmıştır. Ayrıca MATLAB içerisinde AppDesigner komutu kullanılarak bir model daha oluşturulmuş ve bu modeller birbirleri ile karşılaştırılarak en yüksek tahmindeki verimliliğe sahip modeller elde edilmiştir. Bu anlamda, bu doktora tezinde oluşturulan modellerin, diğer bölgelerdeki AAT'lerinin tahmini, kontrolü ve boyutlandırmasında faydalı olacağı düşünülmektedir.

1.4. Araştırılan Atıksu Parametreleri Tanımlanması

Atıksular, günlük içme ve kullanma suyunun kullanımı sonucunda oluşmaktadır. Evsel atıksular; askıda, kolloidal ve çözünmüş halde organik maddeler içermektedir. İklim şartları, insanların yaşam standartları ve kültürel alışkanlıklar atıksu miktarı oluşumunu ve atıksu karakteristik özelliğini önemli ölçüde etkilemektedir. Şehir kanalizasyon şebekesine endüstriyel atıksuların deşarjı/verilmesi sonucu mevcut atıksu karakteristiğini çok büyük oranda değiştirmektedir. Evsel atıksuların; fiziksel, kimyasal, biyolojik ve bakteriyolojik karakteristik parametreleri Tablo 1’de verilmiştir.

Tablo 1. Evsel atıksuyun fiziksel, kimyasal, biyolojik ve bakteriyolojik parametreleri

Fiziksel parametreler	Kimyasal parametreler			Biyolojik ve Bakteriyolojik parametreler
	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 • E.Coli vb.

Atıksularda bulunan kirlilik belirleyici parametreler olarak Tablo 1'deki parametrelerin takibi pratik olmamaktadır. Bu sebeple BOİ, AKM, pH, TN ve TP parametreleri tesis performansı takibi için seçilen en kritik parametrelerdir (Sinan, 2010). Bu parametrelere ilişkin temel tanımlar aşağıda verilmiştir.

BOİ: Biyolojik oksijen ihtiyacı, aerobik biyolojik organizmaların belirli bir su örneğinde bulunan organik materyali belirli bir sıcaklıkta belirli bir süre boyunca parçalamak için ihtiyaç duyduğu (yani talep ettiği) çözünmüş oksijen miktarıdır. BOİ değeri en yaygın olarak 20 °C'de 5 günlük inkübasyon sırasında numunenin litresi başına tüketilen miligram oksijen olarak ifade edilir ve genellikle sudaki organik kirlilik derecesi için kullanılmaktadır (Sawyer ve McCarty, 2003). BOİ, atıksu arıtma tesislerinin etkinliğinin bir göstergesi olarak kullanılabilir. ABD'de Temiz Su Yasasında geleneksel bir kirletici olarak listelenmiştir. BOİ, her ikisinin de sudaki organik bileşiklerin miktarını ölçmesi bakımından KOİ'ye benzer bir işleve sahiptir.

Bununla birlikte, KOİ daha çok spesifiktir, çünkü sadece biyolojik olarak parçalanabilen organik madde seviyelerinden ziyade kimyasal olarak oksitlenebilen her şeyi ölçmektedir.

AKM: AKM, toplam askıda katı madde anlamına gelir ve boyutu 2 µm aşan suyla taşınan partikülleri ifade etmektedir. 2 µm küçük herhangi bir partikül ise ÇKM olarak kabul edilir. Toplam AKM'nin çoğunluğu inorganik malzemelerden oluşur; ancak algler ve bakteriler de AKM olarak kabul edilebilmektedir. AKM, kum, tortu ve plankton dahil suda yüzen veya “askıda kalan” herhangi bir şey olabilmektedir. Belirli su kaynakları çürüten bitki veya hayvanlarla kirlendiğinde, suya salınan organik parçacıklar genellikle askıda katı maddelerdir. Bazı tortular bir su kaynağının tabanına çöker iken, diğer AKM su yüzeyinde yüzer veya askıda asılı kalmaktadır. AKM, suyun berraklığını etkiler, bu nedenle bir su kaynağının TAKM içeriği ne kadar az ise, su o kadar berrak olacaktır.

TN: Toplam nitrojen, NO₃-N, NO₂-N, NH₄-N ve organik bağlı nitrojen yapılarının toplamıdır. Ancak toplam azot ve toplam Kjeldahl azotu aynı değildir. Çünkü toplam Kjeldahl nitrojen, organik bağlı nitrojen grupları ile amonyum-azotun toplamıdır (iyonik durumda NH₄-N olarak tanımlanır ve iyonik olmayan durumda NH₃-N olarak tanımlanır). Ayrıca toplam Kjeldahl azotu nitrat-azot ve/veya nitrat-azot içermez. Organik bağlı azot olarak belirtilen azot yapıları, üç değerlikli azot ile oluşturulan organik bağlı bileşikler olarak temsil edilir. Organik bağlı nitrojen bileşikleri farklı nitrojen durumları içerebilmektedir. Örneğin peptitler, proteinler, nükleik asitler, üre ve nitrojen içeren pestisitler (sentetik organik bileşikler olarak bilinir) üç değerlikli nitrojen içermektedir. Analitik hesaplamalar için, üç değerlikli azot ve amonyum-azot ile oluşturulan organik bağlı bileşiklerin toplamı, toplam Kjeldahl azotu olarak kabul edilebilmektedir. Yukarıdaki açıklamalara göre toplam Kjeldahl analiz yönteminin trivalent durumda nitrojen tayini için geçerli olduğunu söylenebilmektedir. Toplam Kjeldahl analiz yöntemi ise azid, azo, nitroso, azin, siyanür, nitrit ve nitrat yapıları için değerlendirilemez.

TP: Toplam fosfor (TP), bir numunede bulunan tüm fosforun, bu fosforun çözünmüş veya parçacık halinde olup olmadığının bir ölçüsüdür. Bu, atıksu arıtımında numune alırken yaygın olarak kullanılır ve özellikle su yollarının sağlığını belirlemek için kullanılır. Fosfor, su, toprak ve tortularda bulunan fosfat iyonu (PO₄³⁻) gibi çok sayıda bileşik formda bulunmaktadır. Fosfatlar ayrıca inorganik formda (ortofosfatlar ve polifosfatlar) veya organik formda (organik

olarak bağı fosfatlar) olabilmektedir. ABD Çevre Koruma Ajansı'na göre (EPA), toprak ve kayalar, AAT, gübrenilmiş çimenler ve ekili alanlardan gelen akışlar, başarısız septik sistemler, hayvan gübresi depolama alanlarından gelen akışlar, bozulmuş arazi alanları, drene edilmiş sulak alanlar, su arıtma gibi birçok fosfor kaynağı bulunmaktadır. ve ticari temizlik müstahzarları.

T ($^{\circ}\text{C}$): Atıksu sıcaklıkları normalde 10 ile 20°C arasında değişir. Genel olarak, atıksuyun sıcaklığı su kaynağının sıcaklığından daha yüksek olacaktır. Bunun nedeni, yapının sıhhi tesisat sistemi içinde evlerden ve ısıtmadan sıcak su eklenmesidir. Coğrafi konuma bağlı olarak, atıksuyun yıllık ortalama sıcaklığı değişmektedir. Suyun sıcaklığı, kimyasal reaksiyonlar ve reaksiyon hızları, sucul yaşam üzerindeki etkisi ve suyun faydalı kullanımlara uygunluğu nedeniyle çok önemli bir parametredir. Örneğin artan sıcaklık ile çözünmüş oksijen miktarında düşüş meydana gelmektedir. Dolayısıyla da alıcı su kütleinde canlı hayatını olumsuz etkilemektedir. Sıcaklık artışına eşlik eden biyokimyasal reaksiyonların hızındaki artış, yüzey sularında bulunan oksijen miktarındaki azalma ile birleştiğinde, genellikle yaz aylarında çözünmüş oksijen konsantrasyonlarında ciddi azalmaya neden olabilmektedir. Bakteri aktivitesi için optimum sıcaklıklar, yaklaşık 25°C ila 35°C aralığındadır. Sıcaklık 50°C 'ye yükseldiğinde aerobik sindirim ve nitrifikasyon durma noktasına ulaşmaktadır. Sıcaklık yaklaşık 15°C 'ye düştüğünde, metan üreten bakteriler oldukça inaktif hale gelir ve yaklaşık 5°C 'de ototrofik nitrifikasyon bakterileri pratik olarak çalışmayı durdurmaktadır.

ÇO: Çözünmüş oksijen, biyolojik arıtmada, canlı bakteriler de dahil olmak üzere yaşamı sürdürmek için mevcut atıksuda çözünmüş oksijenin nispi ölçüsü olarak tanımlanmaktadır. Biyolojik arıtma, çözünmüş oksijen ve canlı bakteri olan organizmalardan oluşan biyolojik bir flock sağlamak için hava kullanarak kanalizasyon ve endüstriyel atıksuların arıtılması için havalandırma sisteminde bir aerobik aktif çamur prosesi olarak tanımlanmaktadır. Oksijen, büyümek için enerji elde etmek için atıkları oksitledikleri için canlı organizmaların oksijene ihtiyaçları bulunmaktadır. Bu nedenle, atıksuyun ikincil veya biyolojik arıtımı için oksijenin kontrol edilmesi gerekmektedir. Havalandırma sistemindeki aktif çamur için çözünmüş oksijen kontrol süreçleri ve ayrıca atıksu deşarjı, ıslah ve yeniden kullanımında gerekmektedir.

Ortam koşulları ve atıksu koşulları, giren aktif çamur, havalandırma sistemindeki çözülmüş oksijen kontrol süreçlerini etkilemektedir. Uygun havalandırma, bir oksijen kaynağı, oksijenin aktif çamurda çözülmesi için bir araç ve mikroorganizmaların karıştırılan sıvıdan çökmesini önlemenin bir yolunu sağlamaktadır.

Karıştırma, O₂'nin yeterli şekilde dağıtılırsa, çoğu durumda sadece hava ekleme eylemiyle gerçekleştirilebilmektedir. Ancak yüksek saflıkta oksijen işlemlerinde oksijen akış hızının yeterli karıştırma için yetersiz olduğuna ve bir tür mekanik karıştırmanın da gerekli olduğuna dikkat edilmektedir. Düşük BOİ ihtiva eden atıksu arıtıldığında, minimum hava akış hızı genellikle çözülmüş oksijen ihtiyacından ziyade karıştırmaya dayanmaktadır. Bu hem mekanik olarak havalandırılan hem de dağınık hava sistemleri için geçerlidir. Tipik olarak, karışık sıvıda çözülmüş oksijen 2 mg/L veya daha fazla olduğunda oksijen gereksinimleri karşılanmaktadır. Bununla birlikte, optimum çözülmüş oksijen aralıkları tesisten tesise önemli ölçüde değişebilmektedir. Yüksek saflıkta oksijen proseslerinde, 10 ila 12 mg/L kadar yüksek çözülmüş oksijen seviyeleri ile düşük çözülmüş oksijen koşulları gözlemlenmiştir. Hangi çözülmüş oksijen konsantrasyonunun yeterli olduğunu belirlemek için arıtma sisteminde deneysel çalışma yapmak daha iyi olmaktadır.


HRT: HRT, atıksu arıtma işlemi sırasında belirli bir havzada bir galon atıksuyun kalacağı ortalama süredir. Daha teknik bir tanım için, HRT'yi, çözülebilir bir bileşiğin inşa edilmiş bir biyogaz reaktöründe veya havalandırma tankında kalan ortalama süresinin ölçüsü olarak düşünülmektedir. Bu süreç, hidrolik kalma süresi de dahil olmak üzere başka isimlerle anılır ve atıksu kalitesi üzerinde büyük bir etkisi bulunmaktadır.

pH: pH, sulu veya diğer sıvı çözeltilerin asitliğinin veya bazlığının nicel bir ölçüsüdür. Kimya, biyoloji ve tarım biliminde yaygın olarak kullanılan bu terim, hidrojen iyonunun konsantrasyon değerlerini – normalde litre başına yaklaşık 1 ila 10⁻¹⁴ gram eşdeğeri arasında değişir – 0 ila 14 arasındaki sayılara çevirir. nötr olan (ne asidik ne de alkali), hidrojen iyonunun konsantrasyonu litre başına 10⁻⁷ gram eşdeğeridir, bu da pH 7'ye tekabül eder. pH'ı 7'den düşük olan bir çözelti asidik olarak kabul edilir; pH değeri 7'den büyük olan bir çözelti bazik veya alkali olarak kabul edilmektedir.

1.5. Atıksu Arıtma Tesislerinin Üniteleri

Atıksuların arıtılması, doğanın, su kaynaklarının korunmasını ve canlı yaşamının sürdürülebilmesini sağlayan önemli faktörlerden birisidir. Atıksuların arıtılması atıksu arıtma tesislerinde gerçekleştirilmektedir. Modern anlamda AAT birçok adımdan oluşmaktadır. Atıksuların arıtımı, çeşitli kullanımlar sonucunda oluşan atıksuların deşarj edildikleri alıcı ortamın fiziksel, kimyasal, bakteriyolojik ve ekolojik özelliklerini değiştirmeyecek hale getirilmesi için uygulanan fiziksel, biyolojik ve kimyasal proseslerin birini veya birkaçını kapsamaktadır.

Birinci arıtma işlemi fiziksel (İnce ve kaba ızgaralar, elekler, kum tutucular, yüzey madde tutucular (yağ ve gress), dengeleme havuzları, çökeltim havuzları ve yüzdürme havuzları) çökeltme ve flotasyon işlemleriyle çökebilen veya yüzeabilen tanecikler ayrılmaktadır. İkincil arıtma işlemi biyolojik arıtma (Aerobik biyolojik arıtma ve anaerobik) atıksuda mevcut olan organik esaslı katı maddelerin mikroorganizmalar tarafından parçalanması ile atıksudan uzaklaştırılması işlemidir. Mikroorganizmaların arıtma işlemini gerçekleştirebilmek için pH, T(⁰C), ÇO, toksik maddeler gibi parametrelerin kontrol altında tutulması gerekmektedir. Üçüncül arıtma işlemi ileri arıtma (Azot giderme, fosfor giderme, filtrasyon, adsorbsiyon, dezenfeksiyon, iyon değiştirme, ters osmoz ve ultrafiltrasyon) proseslerinden oluşmaktadır ve atıksuyun içerisindeki uçucu organik karbon, ağır metal, iyon, nütrient, tat, koku gibi parametreler giderilmektedir. Kimyasal arıtma, kimyasal metotlar (kaogülant ekleyerek) kullanılarak fiziksel arıtım işlemleri sonrası uzaklaştırılmamış, suda çözünmüş halde bulunan kirleticilerin uzaklaştırılmasını sağlayan sistemdir. Bir atıksu arıtma tesisinin işleyiş şeması Şekil 1’de gösterilmektedir.



Şekil 1. Bir atıksu arıtımı ve arıtma kademeleri


2. YAPILAN ÇALIŞMALAR

2.1. Çalışma Alanı ve Veriler

2.1.1. Samsun Doğu ileri biyolojik atıksu arıtma tesisi ve tanımı

Karadeniz bölgesinin en büyük atıksu arıtma tesisi olma özelliğini elinde tutan Samsun İli “Doğu İleri Biyolojik Atıksu Arıtma Tesisi” ve derin deniz deşarjı projesi (DDD) Samsun'un Tekkeköy ilçesi sanayi bölgesi Karadeniz sahil kesiminde bulunmaktadır.

Samsun Su ve Kanalizasyon İdaresine (SASKİ) bağlı olan bu AAT'nin konumu Şekil 2’de verilmiştir. SASKİ Genel Müdürlüğü tarafından Samsun Doğu İleri Biyolojik AAT ve DDD’ı 01 Eylül 2014 tarihi itibarıyla işletmeye alınmış olup Çevre, Şehircilik ve İklim Değişimi Bakanlığı tarafından denetlenmektedir.



Şekil 2. Samsun İli “Doğu ileri biyolojik AAT’si”nin konumu

Tesisin birinci aşamada 2018 yılı proje $Q= 105.000 \text{ m}^3/\text{gün}$ ve ikinci aşamada proje debisi $Q=120.000 \text{ m}^3/\text{gün}$ olarak belirlenmiştir. Bu AAT Samsun il nüfusunun %44'ne hizmet vermektedir. Arıtma prosesi uzun havalandırmalı aktif çamur prosesi ilave olarak azot (N) ve fosfor(P) giderimi yapılmaktadır. İleri atıksu arıtma sonrasında tesis çıkış suları $D=1600 \text{ mm}$ dairesel çaplı boru ile yaklaşık $L= 2,45 \text{ km}$ mesafede deniz ortamına doğru ve $H= 23,5 \text{ m}$ deniz suyu yüzeyi altına Karadeniz'e deşarj edilmektedir. Bu tesis, kapasitesi itibari ile Karadeniz bölgesinde en büyük AAT olma özelliğine sahiptir.

Samsun Doğu İleri AAT'de yaklaşık $Q=1.000 \text{ m}^3/\text{gün}$ kapasiteli "biyodisk" ve Ultraviyole (UV) dezenfeksiyon üniteleri mevcut olup tesis içerisindeki yeşil alanların artırılmış atıksu ile sulanmaktadır (Şekil 3).



Şekil 3. Samsun İli Doğu ileri biyolojik AAT'ye ait bir hava fotoğrafı

Kentsel Atıksu Arıtımı Yönetmeliği'ne göre proje debisi $Q= 20.000 \text{ m}^3/\text{gün}$ ve üzerinde olan tesislerde $BOİ=25 \text{ mg/L}$ konsantrasyonu, $AKM=35 \text{ mg/L}$ konsantrasyonunu, $TN= 10\text{mg/L}$ konsantrasyonunu, $TP= 1 \text{ mg/L}$ ve SKKY'ne göre'nin altında değerler olması gerekmektedir.

2.1.2. Tesis Tanıtımı

Samsun “İli Doğu İleri Biyolojik AAT” aşağıdaki ünitelerden oluşmaktadır;

- i. Ön arıtma üniteleri:
 - a. Kaba ızgara (2Asıl+1Yedek Izgara), her bir ızgara kapasitesi $Q=4250\text{m}^3/\text{Sa}$, ızgara elek açıklığı $b=30\text{ mm}$ ve zincirli tip ızgaradır.
 - b. Giriş terfi pompa istasyonu (3Asıl+1Yedek Pompa), pompa kapasitesi $Q=2892\text{ m}^3/\text{Sa}$ olan dalgıç tip pompa.
 - c. İnce ızgaralar (2 Asıl+1Yedek), Her bir ızgara kapasitesi $Q=4250\text{m}^3/\text{Sa}$, elek açıklığı $b=6\text{ mm}$ ve perfore tip ızgara kullanılmıştır.
 - d. Havalandırılmalı kum ve yağ tutucu havuzları, nihai hidrolik kapasitesi $Q=10.000\text{ m}^3/\text{Sa}$ ile 2 adet donatılan üniteler ve nihai birim kapasitesi $Q=5.000\text{ m}^3/\text{Sa}$ kadardır.
- ii. İleri biyolojik arıtma üniteleri(A_2O):
 - a. “Bio-P” havuzları (4 adet), her bir tank hacmi $V=2625\text{ m}^3$ ve hidrolik bekletme süresi $HRT=0,7\text{ Sa}$ (anaerobik).
 - b. Havalandırma havuzları (4 adet), her bir tank hacmi $V=39.198\text{ m}^3$, hava debisi $Q_{\text{Hava}}=38.439\text{ Nm}^3/\text{Sa}$, üfleyici adedi (3+1) ve üfleyici basıncı $P=750\text{ mbar}$ (oksik ve anoksik).
 - c. Son çöktürme havuz adedi (5 adet), Havuz çapı $D=48,5\text{ m}$, her bir havuz hacmi $V=6.848\text{ m}^3$ ve çift taraflı “V” şeklinde savak tipi.
 - d. Geri devir ve fazla çamur pompa istasyonları
- iii. Atıksu Arıtma Çamuru üniteleri:
 - a. Çamur susuzlaştırma (%1), toplam havuz hacmi $V=2.250\text{ m}^3$, toplam hava hacmi $V_{\text{Hava}}=2.96\text{Nm}^3/\text{sa}$ ve 2 adet mikser .
 - b. Yoğunlaştırma (%5), yoğunlaştırıcı tambur gücü $N=1,1\text{ kW}$, yoğunlaştırıcı tambur kapasitesi $Q=70\text{m}^3/\text{Sa}$ ve (3+1) tambur
 - c. Santrifüj tipi dekantör (%25), dekantör gücü $N=30\text{kW}$, dekantör kapasitesi $Q=22\text{ m}^3/\text{sa}$ ve (2+1) dekantör

iv. Bio- filtre ünitesi, koku giderme verimliliği min. %95, 2 adet fan adedi, her bir fan maksimum kapasitesi $Q= 11.000\text{m}^3/\text{Sa}$.

v. Atıksu deşarj pompa istasyonu.

Samsun'un güney bölgesindeki yerleşim yerlerinden kaynaklanan evsel nitelikli atıksular, D=2000 mm çapında kolektör hattı ile Samsun Doğu İleri Biyolojik AAT'ne ulaşmaktadır. Tesise giren atıksular ilk aşamada ön arıtma ünitelerine verilmektedir.

2.2. Samsun Doğu AAT'nde Yapılan Analizler

Atıksu arıtma tesisinin verimli çalışmasını sağlamak, mevcut elementlerin yeterliliğini değerlendirmek ve ham kanalizasyonun özelliklerini anlamak için sık aralıklarla analizler yapılmalı ve kontrol edilmelidir. Gerekli veriler aşağıda gösterildiği gibi Samsun Büyükşehir Belediyesi'nden temin edilmiştir.

- BOİ
- TN
- TP
- AKM
- pH

Tesise ait başlıca işletme parametreleri Tablo 2'de verilmiştir.

Tablo 2. AAT İşletme parametreleri

Kirlilik Parametreleri	Giriş Atıksu Parametre Değerleri	Atıksu Deşarj Parametre Değerleri	Gerçekleşen Deşarj Parametre Değerleri
BOİ (mg/L)	250	25	10,1
TN (mg/L)	50	10	5,42
TP (mg/L)	10,5	1	0,52
AKM (mg/L)	300	35	16
pH (-)	6-10	6-9	7.13

2.3. Çalışmada Kullanılan Yöntemler

Yapay zekâ (YZ) modelleri, atıksu arıtma verimliliğini artırmak için uzun vadeli çözümler bulabileceklerini her geçen gün göstermiştir. YZ geliştirme ile YZ, insan düşünme süreçlerini modelleyerek karmaşık doğrusal olmayan atıksu arıtma süreçlerini modelleyebilen geleneksel arıtma süreç kontrol yöntemlerine göre daha fazla avantajlara sahiptir (Qiao vd., 2018).

Bu çalışmada aşağıda verildiği gibi MATLAB (MATLAB Release 2022b, 2022) kullanılarak YZ modelleri ve bir Normal model APP DESIGNER modeli oluşturulmuştur.


2.3.1. Normal Model (MATLAB APPDESİGNER)

APPDESİGNER, bir uygulama düzeni tasarlamak ve davranışını programlamak için etkileşimli bir geliştirme şeklidir. MATLAB Editörün tam entegre bir sürümünü ve çok sayıda etkileşimli UI bileşeni sağlamaktadır. Ayrıca, kullanıcı arayüzünüzü düzenlemek için bir ızgara/grit düzeni yöneticisi ve uygulamasının ekran boyutundaki değişiklikleri algılamasını ve bunlara yanıt vermesini sağlamak için otomatik yeniden akış seçenekleri sunmaktadır. Uygulamaları doğrudan “App Designer” araç şeridinden yükleyici dosyalarında paketleyerek veya bağımsız bir masaüstü veya web uygulaması oluşturarak (“MATLAB Compiler” gerektirir) dağıtımına olanak tanımaktadır. Tasarımcı, profesyonel bir yazılım geliştiricisi olmadan da profesyonel uygulamalar oluşturmaya olanak tanır. Grafik kullanıcı arabiriminin (GUI) tasarımını düzenlemek için görsel bileşenleri sürükleyip bırakır ve davranışını hızlı bir şekilde programlamak için entegre düzenleyiciyi kullanmaktadır.

MATLAB programı, APP DESIGNER komutunu kullanarak atıksu arıtma tesislerinin birincil arıtma ve ikincil arıtmada beklenen sonuçlarını kontrol etmeye ve tahmin etmeye yardımcı olan bir model oluşturmak için kullanılmıştır. Daha sonra bu sonuçlar, arıtılmış atıksuyun/çıkış suyunun alıcı ortam su kütleline deşarjı için “Su Kirliliği Kontrol Yönetmeliği (SKKY)” önerilen parametreler ile karşılaştırılmıştır. Bu model, Şekil 4’te gösterildiği gibi çıktıları üretmek için belirli bir kod içindeki bir dizi girdiye dayandırılmıştır.




a)



b)

Şekil 4. a) Birincil arıtma, b) ikincil arıtma ve c) model sonuçları özeti için “APP DESIGNER” modelinin arayüzü görünümü.

Şekil 4' ün devamı



c)

Model programlanırken, modelin mantıksal sonuçları olan BOİ, TN, TP, TAKM öngörebilmesi için birincil ve biyolojik/ikincil arıtma havuzlarının tasarım boyutları dikkate alınmıştır. Modelin gerçeğe yakın çıktılarının doğru tahmin edilebilmesi için, modeli çalıştırmadan önce girişte; T, ÇO, HRT, havuz yüzey alanı ($A_{Hav.}$), pH, Q vb. değerler girilmektedir.

Atıksu arıtımının her aşaması için arıtma verimliliğini hesaplamak için aşağıdaki denklem kullanılmıştır. İki arıtma aşamasının birleşik verimliliği, Denklem 2 kullanılarak hesaplanmıştır.

$$\eta(\%) = \frac{\text{Girdi Parametresi} - \text{Çıktı Parametresi}}{\text{Girdi Parametresi}} \times 100 \quad (1)$$

$$\eta \text{ Bileşik}(\%) = \left\{ 1 - \left[\left(1 - \frac{\eta^1}{100} \right) \times \left(1 - \frac{\eta^2}{100} \right) \right] \right\} \times 100 \quad (2)$$

2.3.2. Bulanık Mantık

Uzmanlar, sorunları çözerken genellikle sağduyuya güvenirler. Ayrıca “belirsiz ve belirsiz terimler” kullanırlar. Örneğin bir uzman “Güç trafosu biraz fazla yüklenmiş olsa da bu yükü bir süre daha tutabilirim” diyebilmektedir. Diğer uzmanlar bu ifadeyi anlamakta ve yorumlamakta zorluk çekmezler çünkü bu tür işitme sorunlarına ilişkin bir geçmişleri bulunmuştur.

Bununla birlikte, bir bilgisayar mühendisi, aynı düzeyde anlayışa sahip bir bilgisayar sağlamakta zorluk çekecektir. Bir bilgisayarda “belirsiz ve belirsiz” terimler kullanan uzman bilgisini nasıl temsil edilebilmektedir? Hiç yapılabilir mi? Sorusu sorulmaktadır.

Önemsiz ama yine de temel ve gerekli bir ifadeyle başlayalım: Bulanık mantık, bulanık mantık değil, bulanıklığı tanımlamak için kullanılan mantıktır. Bulanık mantık, belirsizliği kalibre eden kümeler olan bulanık kümeler teorisidir. Bulanık mantık, her şeyin derecelerini atıksu kabul ettiği fikrine dayanmaktadır. Parametreler, sıcaklık, yükseklik, hız, mesafe, güzellik gibi hepsi kayan bir ölçekte gelmektedir. Bulanık mantığın anlamı için çok sayıda sorular sorulabilir. Bunlar; motor gerçekten çok sıcak çalışmaktadır. Elektrikli arabalar çok hızlı değildir. Yüksek performanslı sürücüler çok hızlı dinamikler ve hassas düzenleme gerektirmektedir. Trabzon güzel bir şehir. Böyle bir kayan ölçek genellikle bir sınıfın üyelerini üye olmayanlardan ayırt etmeyi imkânsız hale getirir. Bir tepe ne zaman dağ olur?

Boolean teorisi veya geleneksel mantık, keskin ayrımlar kullanmıştır. Bu bir sınıfın üyeleri ile üye olmayanlar arasında kesin çizgiler çizmeye zorlamaktadır. Kesin çizgiler çizmeyi sağlamaktadır. Örneğin, 300 km veya daha kısa bir menzil için kısa ve 300 km'den daha uzun bir menzil için “Elektrikli bir aracın maksimum menzili kısadır” denilebilir. Bu duruma göre, 301km veya 300km ve 500m veya hatta 300km ve 1m mesafeyi kat edebilen herhangi bir elektrikli araç, uzun menzilli olarak tanımlanmıştır. Benzer şekilde, boyu 181 cm olduğu için Tom'un uzun olduğunu söylüyoruz. 180 cm'de bir çizgi çizersek, 179 cm olan David'in kısa olduğunu buluruz. David gerçekten küçük bir adam mı yoksa kuma rastgele bir çizgi mi çektik? Bulanık mantık, bu tür olumsuzluklardan kaçınmaya imkân vermektedir.

Bulanık mantık, insanların nasıl düşündüğünü yansıtmaktadır. Sözcük duygumuzu, karar vermemizi ve sağduyumuzu modellemeye çalışmaktadır. Sonuç olarak, yeni, daha insani, akıllı sistemlere öncülük etmektedir.

Bulanık veya çok değerli mantık 1930'larda Polonyalı bir mantıkçı ve filozof olan Jan Lukasiewicz tarafından ortaya konmuştur (Lukasiewicz, 1930). Uzun, yaşlı ve sıcak gibi terimlere dayalı olarak bulanıklığın matematiksel temsilini incelenmiştir. Klasik mantık sadece "1" (doğru) ve "0" (yanlış) değerleriyle çalışırken, Jan Lukasiewicz doğruluk değerleri aralığını "0" ile "1" arasındaki tüm gerçek sayılara genişleten mantığı tanıtmıştır. Verilen bir ifadenin "doğru" veya "yanlış" olma olasılığı bulunmaktadır. Örneğin, 181 cm boyundaki bir adamın gerçekten uzun olma olasılığı "0,86" değerine ayarlanabilir. Adamın uzun boylu olma ihtimali yüksektir. Bu çalışma, genellikle olasılık teorisi olarak adlandırılan kesin olmayan bir akıl yürütme tekniğine yol açmıştır.


Daha sonra, 1937'de bir filozof olan Max Black, "Belirsizlik: mantıksal analizde bir alıştırmaya" (Black, 1937) adlı bir makale yayımlanmıştır. Bu makalede, bir sürekliliğin dereceleri ima ettiğini savunmuştur. Ona göre, sayısız "sandalye"den oluşan bir çizgi düşünün. Bir uçta bir Chippendale var. Onun yanında Chippendale'e yakın, aslında ilkinden ayırt edilemeyen bir sandalye var. Sonraki 'sandalyeler' giderek daha az sandalyeye benziyor, ta ki sıra bir kütükle son bulana kadar. Bir sandalye ne zaman kütüğe dönüşür? Sandalye kavramı, sandalyeyi sandalye olmayandan ayıran net bir çizgi çizmemize izin vermez. Max Black ayrıca, eğer bir süreklilik ayrıkça, her bir ögeye bir sayı tahsis edilebileceğini belirtmiştir. Bu sayı bir dereceye işaret edecektir. Ancak asıl soru neyin derecesi olduğudur. Black bu sayıyı, 'sandalyeler' dizisindeki bir ögeye sandalye diyecek insanların yüzdesini göstermek için kullanmıştır; başka bir deyişle, belirsizliği bir olasılık meselesi olarak kabul etmiştir.

Ancak, Black'ın en önemli katkısı makalenin ekinde bulunmuştur. Bu ekte ilk basit bulanık kümeyi tanımlamış ve bulanık küme işlemlerinin temel fikirlerini özetlemiştir.

1965'te Berkeley'deki California Üniversitesi'nde Profesör ve Elektrik Mühendisliği Bölüm Başkanı olan Lotfi Zadeh, ünlü makalesi "Fuzzy setleri"ni yayımlamıştır. Aslında, Zadeh bulanıklığı yeniden keşfetti, tanımladı ve araştırdı ve daha da geliştirmek için çaba sarf etmiştir.

Zadeh, olasılık teorisi üzerine yaptığı çalışmayı kabul edilmiş bir matematiksel mantık sistemine genişletti ve daha da önemlisi, doğal dil terimlerini uygulamak için yeni bir kavram ortaya koymuştur. Bulanık terimleri temsil etmeye ve manipüle etmeye yönelik bu yeni mantığa “bulanık mantık” adı verilmiştir

Zadeh'in belirttiği gibi, terim somut, acil ve açıklayıcıdır; ne anlama geldiğini bilinmektedir. Bununla birlikte, Batı'daki birçok insan, genellikle olumsuz bir anlamda kullanıldığı için bulanık kelimesinden kaçınmaktadır. Bulanıklık, bulanık küme teorisine dayanır ve bulanık mantık, bu teorenin sadece küçük bir parçasıdır. Ancak Zadeh, bulanık mantık terimini daha geniş bir anlamda kullanmıştır (ZADEH, 1965). Bulanık mantık, klasik ikili mantığın kesin üyelik fonksiyonundan ziyade üyelik fonksiyon derecelerine dayalı bilgi temsili için bir dizi matematiksel ilke olarak belirlenmiştir. İki değerli Boole mantığının aksine, bulanık mantık çok değerli olduğu ortaya çıkmıştır. Üyelik fonksiyon dereceleri ve doğruluk dereceleri ile ilgilenmektedir. Bulanık mantık, “0” (tamamen yanlış) ile “1” (tamamen doğru) arasındaki mantıksal değerlerin sürekliliğini kullanmaktadır. Sadece siyah ve beyaz yerine, renklerin geçişini kullanır ve aynı anda şeylerin kısmen doğru, kısmen de yanlış olabileceğini kabul etmektedir. Şekil 5'te görülebileceği gibi, bulanık mantık, Boole mantığına bir dizi mantıksal değer eklemektedir. Klasik ikili mantık artık çok değerli bulanık mantığın özel bir durumu olarak düşünülebilmektedir.



Şekil 5. Boolean ve bulanık mantıkta mantıksal değerler aralığı: (a) Boole mantığı;(b) çok değerli mantık.

2.3.2.1.Bulanık Kümeler

Küme kavramı matematiğin temelidir. Ancak kendi dilimiz kümelerin en üst ifadesidir. Bulanık küme, basitçe bulanık sınırları olan bir küme olarak tanımlanabilir. X , söylemin evreni olsun ve öğeleri x olarak gösterilsin. Klasik küme teorisinde, X 'in kesin A kümesi, A 'nın karakteristik fonksiyonu olarak adlandırılan $f_A(x)$ fonksiyonu olarak tanımlanmaktadır.

$$f_A(x): X \rightarrow 0, 1, \quad (3)$$

Burada;

$$f_A(x) = \begin{cases} 1, & \text{if } x \in A \\ 0, & \text{if } x \notin A \end{cases}$$

Şeklinde ifade edilebilmektedir.

Bu küme, X evrenini iki öğeden oluşan bir kümeye eşlenir. X evreninin herhangi bir x öğesi için, $f_A(x)$ karakteristik işlevi, x, A kümesinin bir öğesiye “1”e ve x, A kümesinin bir öğesi değilse “0”a eşittir.

Bulanık teoride, X evreninin A bulanık kümesi, A kümesinin üyelik fonksiyonu olarak adlandırılan $\mu_A(x)$ fonksiyonu ile tanımlanmaktadır.

$$\mu_A(x): X \rightarrow [0, 1], \quad (4)$$

Burada;

$$\mu_A(x) = 1 \text{ if } x \text{ is totally in } A;$$

$$\mu_A(x) = 0 \text{ if } x \text{ is not in } A;$$

$$0 < \mu_A(x) < 1 \text{ if } x \text{ is partly in } A.$$

Şeklinde ifade edilmiştir. (Not: Program gövdesinde İngilizce olduğundan tercüme edilmemiştir)

Bu veri seti, olası seçeneklerin bir sürekliliğine izin vermektedir. X evreninin herhangi bir x ögesi için, $M_A(x)$ üyelik fonksiyonu, x 'in A kümesinin bir ögesi olma derecesine eşittir. Bu derece, “0” ile “1” arasında bir değer, ögenin üyelik değeri olarak da adlandırılan üyelik derecesini temsil eder ve A kümesindeki x 'dir.


2.3.2.2.Bilgisayarda Bir Bulanık Küme Temsili

Çalışmalarda öncelikle üyelik fonksiyonu belirlenmelidir. Bilgi ediniminden öğrenilen bir dizi yöntem burada uygulanabilir. Örneğin, bulanık kümeler oluşturmak için en pratik yaklaşımlardan biri, tek bir uzmanın bilgisine dayanır. Uzman, çeşitli elemanların belirli bir kümeye ait olup olmadığı konusunda görüşü sorulur. Bir başka yararlı yaklaşım, birden fazla uzmandan bilgi edinmektir. Bulanık kümeler oluşturmak için yeni bir teknik yakın zamanda tanıtılmıştır. Mevcut sistem için operasyon verilerini öğrenen ve daha sonra bulanık kümeleri otomatik olarak oluşturan yapay sinir ağlarına dayanmaktadır. Soru $M_A(x)$ 'in “0” veya “1” olmak üzere sadece iki değeri mi yoksa “0” ile “1” arasında herhangi bir değeri mi alabileceği sorusudur. Bu aynı zamanda 1965 yılında Lotfi Zadeh tarafından incelenen bulanık kümelerdeki temel soru olmuştur (ZADEH, 1965).

Eğer X referans süper küme ve A da X 'in 'in bir alt kümesi ise, A 'nın X 'in 'in bulanık bir alt kümesi olduğu ancak ve ancak şu şartla söylenir,

$$A = \{(x, M_A(x))\} \quad x \in X, M_A(x): X \rightarrow [0, 1] \quad (5)$$

Özel bir durumda, $X \rightarrow [0, 1]$ yerine $X \rightarrow \{0, 1\}$ kullanıldığında, bulanık alt küme A , kesin alt küme A olur. Bulanık ve kesin kümeler ayrıca Şekil 6'da gösterildiği gibi sunulabilmektedir.



Şekil 6. X 'in net ve bulanık alt kümesinin temsili

Sonlu referans süper kümesinin “A” bulanık alt kümesi " X " şu şekilde ifade edilebilmektedir:

$$A = \{(x_1, M_A(x_1))\}, \{(x_2, M_A(x_2))\}, \dots, \{(x_n, M_A(x_n))\} \quad (6)$$

Ancak, " A "'yı şu şekilde temsil etmek daha uygundur:

$$A = \{(M_A(x_1)/x_1)\}, \{(M_A(x_2)/x_2)\}, \dots, \{(M_A(x_n)/x_n)\} \quad (7)$$

Ayrırma sembolünün, üyelik değerini yatay eksenindeki koordinatıyla ilişkilendirmek için kullanıldığı yer.

Bilgisayarda sürekli bir bulanık kümeyi temsil etmek için, onu bir fonksiyon olarak ifade etmemiz ve sonra kümenin elemanlarını üyelik derecelerine göre grafik etmek gerekmektedir. Kullanılabilecek tipik fonksiyonlar Sigmoid, Gauss ve Pi'dir. Bu işlevler, bulanık kümelerdeki gerçek verileri temsil edebilir, ancak aynı zamanda hesaplama süresini de arttırmaktadır. Bu nedenle pratikte çoğu uygulama lineer uyum fonksiyonlarını kullanmaktadır.

2.3.2.3.Program Dili Bakımından Değişkenler ve Hedge (Sınır)

Bulanık set teorisinin kökünde program dili açısından değişkenler fikri yatmaktadır. Dilbilimsel bir değişken bulanık bir değişkendir. Örneğin, 'Yusuf uzun' ifadesi, Yusuf'un dilsel değişkenin dilsel değeri uzun boylu hale getirdiğini ima etmektedir. Bulanık uzman sistemlerinde, dilsel değişkenler bulanık kurallarda da kullanılmaktadır.

Dilsel bir değişken, beraberinde hedge adı verilen bulanık küme niteleyicileri kavramını taşımaktadır. Hedge, bulanık kümelerin şeklini değiştiren terimlerdenidir. “Çok”, “biraz”, “oldukça”, “az ya da çok” ve “hafif” gibi zarfları içermektedir. Hedge fiilleri, sıfatları, zarfları ve hatta tüm cümleleri değiştirebilmektedir.





Hedge operasyon görevi görmekte, bu çok konsantrasyon gerçekleştirir ve yeni bir alt küme oluşturmaktadır. Örneğin uzun boylu adamlardan çok uzun boylu erkeklerin alt kümesini üretir. Çok iyi derece de aynı amaca daha fazla hizmet etmektedir.

Yoğunlaştırmanın tersi bir işlem de genişlemedir. Kümeyi genişletir. Az ya da çok genişletme işlemi yapar; örneğin, az ya da çok uzun boylu erkekler kümesi, uzun boylu erkekler kümesinden daha geniştir.



Hedge operasyon olarak yararlıdır, ancak süreklilikleri bulanık aralıklara ayırabilirler. Örneğin, sıcaklığı tanımlamak için aşağıdaki hedge kullanılabilir: “Çok soğuk”, “orta derecede soğuk”, “hafif soğuk”, “nötr”, “hafif sıcak”, “orta derecede sıcak” ve “çok sıcak” şeklindedir. Açıkçası bu bulanık setler örtüşmektedir. Hedge, insan düşüncesini yansıtmaya yardımcı olur, çünkü insanlar genellikle “biraz sıcak” ve “orta derecede sıcak” arasında ayırım yapamamaktadır.

Hedge'in matematiksel ve grafiksel temsili Tablo 3 'te özetlenerek gösterilmiştir.

Tablo 3. Bulanık mantıkta çitlerin temsili

Çit	Matematiksel ifade	Grafiksel temsil
Bir miktar	$[\mu_A(x)]^{1.3}$	
Biraz	$[\mu_A(x)]^{1.7}$	
Çok	$[\mu_A(x)]^2$	
Çok fazla derece	$[\mu_A(x)]^3$	
Aşırı fazla	$[\mu_A(x)]^4$	
En az	$\sqrt{\mu_A(x)}$	

Tablo 3' ün devamı

Belli bir şekilde	$\sqrt{\mu_A(x)}$	
Gerçekte	$2[\mu_A(x)]^2 \quad \text{if } 0 \leq \mu_A(x) \leq 0.5$ $1 - 2[1 - \mu_A(x)]^2 \quad \text{if } 0.5 < \mu_A(x) \leq 1$	

2.3.2.4. Bulanık Setlerin İşlemleri

19. yüzyılın sonlarında Georg Cantor tarafından geliştirilen klasik küme teorisi, net kümelerin nasıl etkileşime girebileceğini açıklamıştır. Bu etkileşimlere operasyon denmektedir. Bunlar; tümleyen, kapsama, kesişme ve birleşme olarak görülmektedir.

Klasik ve bulanık kümeler işlemlerinin karşılaştırılması:


X söyleminin evreni üzerinde iki bulanık A ve B kümesinin kesişimini oluşturmak için bulanık işlem şu şekilde elde edilebilmektedir:

$$\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \cap \mu_B(x), \quad \text{Burada } x \in X$$

X evreninde iki bulanık A ve B kümesinin birleşimini oluşturmak için bulanık işlem şu şekilde verilebilmektedir:

$$\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \cup \mu_B(x), \quad \text{Burada } x \in X$$

Bulanık küme işlemleri için diyagramlar Şekil (7)'de gösterilmiştir.



Şekil 7. Bulanık küme işlemleri

2.3.2.5. Bulanık Kurallar

Bulanık bir kural, şu şekilde bir koşullu ifade olarak tanımlanabilmektedir:

IF x is A
THEN y is B

burada x ve y dilsel değişkenlerdir ve A ve B, sırasıyla X ve Y söylemleri evreninde bulanık kümeler tarafından belirlenen dilsel değerlerdir.

Klasik bir “IF-THEN” kuralı ikili mantığı kullanmaktadır.

Bulanık akıl yürütme iki farklı bölümden oluşur. Bunlar; önce kuralın değerlendirilmesi (kuralın “İF” kısmı) ve ima veya sonucun sonuca uygulanması (kuralın ”THEN kısmı).

Klasik kural tabanlı sistemlerde, kuralın öncülü doğruysa, sonuç da doğru çıkmaktadır. Öncülün bulanık bir ifade olduğu, bulanık sistemlerde tüm kurallar bir dereceye kadar işletilebilmektedir. Eğer öncül bir dereceye kadar üyelik için veriler doğruysa, çıktılar da aynı derecede doğrudur. Bir üretim kuralı olarak, bir bulanık kuralın birden çok önceliği olabilir. Bulanık bir kuralın sonucu birden çok parça içerebilmektedir.

Bu durumda, sonucun tüm parçaları öncülden eşit olarak etkilenmektedir. Genel olarak, bir bulanık uzman sistem, uzman bilgisini tanımlayan ve birbirini tamamlayan bir değil birkaç kuralı birlikte içermektedir. Her kuralın çıktısı bir bulanık kümedir, ancak genellikle uzman sistem çıktısını temsil eden tek bir sayı elde etmemiz gerekmektedir. Başka bir deyişle, bulanık değil de kesin bir çözüm elde etmek istenmektedir. Çıktı değişkeni için tek bir kesin çözüm elde etmek için, bir bulanık uzman sistem önce tüm çıktı bulanık kümelerini tek bir çıktı bulanık kümesinde toplar ve sonuçta ortaya çıkan bulanık kümeyi tek bir sayı halinde durulaştırmaktadır.

2.3.2.6. Bulanık Çıkarım

Bulanık çıkarım, bulanık kümeler teorisini kullanarak belirli bir girdiden çıktıya grafikleme işlemi olarak tanımlanabilmektedir.

2.3.2.6.1. Mamdani Çıkarım Yöntemi

En yaygın olarak kullanılan bulanık çıkarım tekniği Mamdani yöntemidir. 1975 yılında Londra Üniversitesi'nden Profesör Ebrahim Mamdani, bir buhar motoru ve kazan kombinasyonunu kontrol etmek için ilk bulanık sistemlerden birini ortaya koymuştur (Mamdani ve Assilian, 1975). Deneyimli insan operatörler tarafından sağlanan bir dizi bulanık kuralı uygulamıştır. Mamdani tarzı bulanık çıkarım süreci dört adımda gerçekleştirilir, bunlar: Girdi değişkenlerinin bulanıklaştırılması, kural değerlendirmesi, kural çıktılarının toplanması ve son olarak durulaştırma. Her şeyin birbirine nasıl uygunluğunu görmek için, iki girişli basit bir tek çıkışlı problemi incelenecek ve bu üç kuralı içeren problem çözülecektir.

Kural: 1

IF	x is A3
OR	y is B1
THEN	z is C ₁

Kural: 2

IF x is A2
AND y is B2
THEN z is C2

Kural: 3

IF x is A1
THEN z is C3

Burada x, y ve z dilsel değişkenlerdir; $A1, A2$ ve $A3, X$ söylemi evreninde bulanık kümeler tarafından belirlenen dilsel değerlerdir; $B1$ ve $B2, Y$ söylemi evreninde bulanık kümeler tarafından belirlenen dilsel değerlerdir; $C1, C2$ ve $C3$ (düşük, normal ve yüksek), Z söylemi evreninde bulanık kümeler tarafından belirlenen dilsel değerlerdir. Problem için Mamdani tarzı bulanık çıkarımın temel yapısı Şekil 8'de gösterilmiştir.

1. Adım: Bulanıklaştırma

İlk adım, x_1 ve y_1 kesin girdilerini almak ve bu girdilerin uygun bulanık kümelerin her birine ait olma derecesini belirlemektir.


2. Adım: Kural değerlendirme

İkinci adım, bulanıklaştırılmış girdileri, $\mu_{(x=A_1)} \mu_{(x=A_2)} \mu_{(y=B_1)} \mu_{(y=B_2)}$, almak ve bunları bulanık kuralların öncüllerine uygulamaktır. Belirli bir bulanık kuralın birden fazla öncülü varsa, önceki değerlendirmenin sonucunu temsil eden tek bir sayı elde etmek için bulanık operatör (AND veya OR) kullanılmaktadır. Bu sayı (doğruluk değeri) daha sonra sonuç üyelik fonksiyonuna uygulanmaktadır.

3. Adım: Kural çıktılarının toplanması

Toplama, tüm kuralların çıktılarının birleştirilmesi sürecidir. Başka bir deyişle, önceden kırılmış veya ölçeklenmiş tüm kural sonuçlarının üyelik fonksiyonlarını alır ve bunları tek bir bulanık kümede birleştirilmektedir. Böylece, toplama işleminin girdisi, kırılmış veya

ölçeklenmiş ardışık üyelik fonksiyonlarının listesidir ve çıktı, her çıktı değişkeni için bir bulanık kümedir. Şekil 8, her bir kuralın çıktısının, genel bulanık çıktı için tek bir bulanık kümede nasıl toplandığını göstermektedir.



Şekil 8. Mamdani bulanık çıkarımın temel yapısı

4. Adım: Durulaştırma

Bulanık çıkarım sürecindeki son adım durulaştırmadır. Bulanıklık, kuralları değerlendirilmesine yardımcı olur, ancak bulanık bir sistemin nihai çıktısının kesin bir sayı olması gerekmektedir. Durulaştırma işleminin girdisi, toplu çıktı bulanık kümesidir ve çıktı tek bir sayıdır.

Birkaç durulaştırma yöntemi vardır (Cox, 1999), ancak muhtemelen en popüler olanı en çok kullanılanı “centroid tekniği”dir. Dikey bir çizginin kümeyi iki eşit kütleye böleceği noktayı bulmaktadır. Matematiksel olarak bu ağırlık merkezi “COG” ile ifade edilebilmektedir:

$$\text{COG} = \frac{\int_a^b \mu_A(x) x dx}{\int_a^b \mu_A(x) dx} \quad \text{or} \quad \text{COG} = \frac{\sum_{x=a}^b \mu_A(x) x}{\sum_{x=a}^b \mu_A(x)} \quad (8)$$

2.3.2.6.2. Sugeno Çıkarım Yöntemi

Mamdani tarzı çıkarım, sürekli değişen bir fonksiyon boyunca integral olarak iki boyutlu bir şeklin ağırlık merkezinin bulunmasını gerektirmektedir. Genel olarak, bu matematiksel işlem hesaplama açısından çok verimli olmamaktadır.

Sonuç kuralının üyelik fonksiyonu olarak tek bir tek sivri uç metodu kullanılabilir. Bu yöntem ilk olarak 1985 yılında “Japonya'nın Zadeh'i” Michio Sugeno tarafından tanıtılmıştır (SUGENO, 1985). Bir metod veya daha doğrusu bir bulanık sivri uç, söylem evreninde tek bir belirli noktada birlik ve diğer her yerde sıfır olan bir üyelik fonksiyonuna sahip bir bulanık kümedir. Sugeno tarzı bulanık çıkarım, Mamdani yöntemine çok benzemektedir. Sugeno sadece bir kuralı değiştirmektedir. Bulanık küme yerine girdi değişkeninin matematiksel bir fonksiyonunu kullanmıştır. Sugeno tarzı bulanık kuralın formatı aşağıdaki şekildedir:

IF *x is A*
AND *y is B*
THEN *z is f(x,y)*

burada x, y ve z dilsel değişkenlerdir; A ve B , sırasıyla X ve Y söylemlerinin evreni üzerindeki bulanık kümelerdir ve $f(x, y)$ matematiksel bir fonksiyondur.

En yaygın olarak kullanılan “sıfır dereceli” Sugeno bulanık modeli, bulanık kuralları uygulaması aşağıdaki şekilde:

İF *x is A*
AND *y is B*
THEN *z is k*

burada k sabit bir katsayısıdır.

Bu durumda, her bulanık kuralın çıktısı sabittir. Diğer bir deyişle, tüm ardışık üyelik işlevleri, tekil sivri uçlarla temsil edilmektedir. Sugeno ve Mamdani yöntemlerinin benzerliği

oldukça dikkat çekicidir. Bunlar arasında tek ayırım, Sugeno'nun yönteminde kural sonuçlarının tekil olmasıdır.

Toplama işlemi tüm tekileri içerir. Şimdi bu tekil sivri ağırlıklı ortalamasını (W_A) bulmaktadır. Şöyle ki;

$$W_A = \frac{\mu(k1) \times k1 + \mu(k2) \times k2 + \mu(k3) \times k3}{\mu(k1) + \mu(k2) + \mu(k3)} \quad (9)$$

Şeklindedir.

Böylece mevcut problemin çözümündeki ihtiyaçlar için “sıfır dereceli” bir Sugeno sistemi yeterli olabilmektedir. Tekil çıktı işlevleri belirli bir sorunun ihtiyaçlarını oldukça sık karşılamaktadır.

Mamdani yöntemi uzman bilgisi elde etmek için çok yaygın olarak kabul edilmekte ve kullanılmaktadır. Uzmanlığı daha sezgisel ve daha insani bir şekilde tanımlamamızı sağlamaktadır. Mamdani tipi bulanık çıkarım önemli bir hesaplama yükü oluşturmaktadır. Öte yandan, Sugeno yöntemi hesaplama açısından daha etkilidir, optimizasyon ve uyarlamalı tekniklerle daha iyi çalışmaktadır. Bu da onun özellikle dinamik doğrusal olmayan sistemler için kontrol problemlerinin çözümünde çok daha cazip durum ortaya koymaktadır.

2.3.2.7. Bulanık “Uzman Sistem” Oluşturmak

Bulanık bir “uzman sistemin tasarımını” göstermek için, yedek parça servis merkezini çalıştırma problemi ele alınmıştır (Turksen vd., 1992). Bir servis merkezi, yedek parçaları tutar ve arızalı olanları onarır. Bir müşteri arızalı bir ürün getirir ve aynı türden bir yedek parça alır. Arızalı parçalar onarılır, rafa kaldırılır ve böylece yedek parça haline gelir. Rafta gerekli olan yedek parça varsa, müşteri onu alır ve servis merkezinden ayrılır. Ancak, rafta yedek parça yoksa müşteri, ihtiyaç duyduğu ürün hazır olana kadar beklemek zorundadır. Buradaki amaç, müşterileri memnun etmek için belirli karar politikaları konusunda hizmet merkezinin yöneticisine tavsiyede bulunmaktır.

“Bulanık uzman sistemi” geliřtirmede tipik bir sre ařađıdaki adımları iermektedir:

1. Adım: Problemi belirlenmesi ve dilsel deđiřkenleri tanımlanması.

Herhangi bir “uzman sistem” kurmanın ilk ve muhtemelen en önemli adımı, sorunun belirlenmesidir. Sorunun mhendislik aısından tanımlanması gereklidir. Bařka bir deyiřle, problem “girdiler” ve “ıktılar” deđiřkenlerini ve bunların aralıklarının belirlenmesi gerekmektedir.

2. Adım: Bulanık kmelerin belirlenmesi

Bulanık kmeler eřitli řekillerde olabilir. Bununla birlikte, bir gen veya bir yamuk genellikle uzman bilgisinin yeterli bir temsilini sađlayabilir ve aynı zamanda hesaplama srecini nemli lde de basitleřtirmektedir.

3. Adım: Bulanık kuralları ortaya ıkarma ve oluřturma.

Daha sonra bulanık kuralların elde edilmesi gerekmektedir. Bu grevi gerekleřtirmek iin, uzmandan daha nce tanımlanan bulanık dilsel deđiřkenler kullanılarak sorunun nasıl zlebileceđinin aıklaması istenebilmektedir.

Gerekli bilgiler ayrıca kitaplar, bilgisayar veri tabanları, akıř řemaları ve gzlemlenen insan davranıřları gibi diđer kaynaklardan da toplanabilir. Bu durumda, arařtırma makalesinde verilen kurallar uygulanabilmektedir(Turksen vd., 1992).

4. Adım: Uzman sistemde bulanık ıkarım yapmak iin bulanık kmeleri, bulanık kuralları ve prosedrleri kodlamak

Bulanık kmeleri ve bulanık kuralları tanımladıktan sonraki iř, bunları kodlamak ve bylece aslında bir “bulanık uzman sistem” kurulması sađlanmaktadır. Bu grevi gerekleřtirmek iin iki seenekten biri seilebilmektedir: C veya Pascal gibi bir programlama dili kullanarak sistemi kurmak veya “MathWorks'ten MATLAB Fuzzy Logic Toolbox1 veya Fuzzy'den Fuzzy Knowledge BuilderTM” gibi bir bulanık mantık geliřtirme aracı uygulanmaktadır.

Deneyimli bulanık sistem kurucularının ođu, daha fazla esneklik sunduđu iin genellikle “C/C++ programlama dilini” tercih etmektedir (Li ve Gupta, 1995; Cox, 1999). Ancak, bir

bulanık uzman sistemi hızlı bir şekilde geliştirmek ve prototip oluşturmak için en iyi seçim bir bulanık mantık geliştirmedir. Böyle bir araç genellikle bulanık sistemlerin oluşturulması ve test edilmesi için eksiksiz ortamlar sağlamaktadır. Örneğin, “MATLAB Fuzzy Logic Toolbox” beş bütünleşmiş grafik düzenleyiciye sahiptir: Bulanık çıkarım sistemi düzenleyicisi, kural düzenleyicisi, üyelik fonksiyon düzenleyicisi, bulanık çıkarım görüntüleyicisi ve çıktı yüzeyi görüntüleyicisidir. Tüm bu özellikler, bulanık sistemlerin tasarlanmasını çok daha kolay hale getirmektedir. Bu seçenek, bulanık uzman sistemler oluşturma konusunda yeterli deneyime sahip olmayanlar için de tercih edilmektedir. Bir bulanık mantık geliştirme aracı seçildiğinde, mühendisin yalnızca bulanık kuralları İngilizce benzeri sözdiziminde kodlaması ve üyelik fonksiyonlarını grafiksel olarak tanımlaması gerekmektedir. Bulanık uzman sistemini oluşturmak için en popüler araçlardan biri olan “MATLAB Fuzzy Logic Toolbox”ı kullanılmıştır. Bulanık kurallar ve grafiksel kullanıcı arayüzleri ile bilgi işlem için sistematik bir çerçeve sağlamaktadır. Yeni bulanık sistem kurucuları için bile uzmanlaşması kolay ve kullanımı da kolaydır.

5. Adım: Sistemi değerlendirmek ve ayarlamak.

Son ve en zahmetli iş, sistemi değerlendirmek ve ayarlamaktır. “The Fuzzy Logic Toolbox” sistemi performansının analiz edilmesine yardımcı olacak bir yüzey oluşturup oluşturamayacağının görülmesi istenmektedir.

Genel olarak, bir “bulanık uzman” sistemi ayarlamak, bulanık kümeleri belirlemekten ve bulanık kurallar oluşturmaktan çok daha fazla zaman ve çaba gerektirmektedir. Genellikle ilk bulanık kümeler ve bulanık kurallar serisinden probleme yeterli bir çözüm elde edilebilmektedir. Bu, bulanık mantığın kabul edilen bir avantajıdır; ancak, sistemi geliştirmek mühendislikten çok bir sanat haline gelmiştir.

Bulanık sistemlerin düzenlenmesi, aşağıdaki sırayla bir dizi eylemin yürütülmesini gerektirmektedir.

Bunlar;

1. Model “girdi” ve “çıkı” değişkenlerinin gözden geçirilmesi ve gerekirse aralıklarının yeniden tanımlanması. Değişken birimlere özellikle dikkat edilmel. Aynı etki alanında kullanılan değişkenler, söylem evreninde aynı birimlerde verilmelidir.
2. Bulanık kümelerin gözden geçirilmesi ve gerekirse söylem evreninde ek kümeler tanımlanmalıdır. Geniş bulanık kümelerin kullanılması, bulanık sistemin kabaca çalışmasına neden olabilmektedir.
3. Komşu kümeler arasında yeterli örtüşme sağlanmalı. Optimum örtüşme miktarını belirlemek için kesin bir yöntem olmamasına rağmen, üçgenden üçgene ve yamuktan üçgene bulanık kümelerin tabanlarının 25 % ila 50 %'si arasında çakışması gerektiği önerilmektedir (Cox, 1999).
4. Mevcut kuralların gözden geçirilmesi ve gerekirse kural tabanına yeni kurallar eklenmelidir.
5. Sistemin patolojik davranışını yakalamak için korunma kuralları yazma fırsatları için kural tabanını incelenmelidir.
6. Kural yürütme ağırlıkları ayarlanmalı. Çoğu bulanık mantık aracı, ağırlık çarpanını değiştirilerek kuralların öneminin kontrolüne izin vermektedir. “Bulanık Mantık Araç Kutusu”nda, tüm kuralların varsayılan ağırlığı (1.0) vardır, ancak kullanıcı, ağırlığı ayarlayarak herhangi bir kuralın gücünü azaltabilmektedir.
7. Bulanık kümelerin şekillerinin gözden geçirilmesi. Çoğu durumda, bulanık sistemler bir şekil yaklaşımına oldukça toleranslı olup ve bu nedenle bir sistem, bulanık kümelerin şekilleri tam olarak tanımlanmadığında bile iyi davranabilmektedir.

“Ağırlık merkezi tekniği” tutarlı sonuçlar veriyor gibi görünmektedir. Bu, toplam bulanık bölgenin yüksekliğine, genişliğine ve ayrıca seyrek tek tonlara duyarlı iyi dengelenmiş bir yöntemdir. Bu nedenle, bulanık sistemin diğer durulaştırma yöntemleri altında daha iyi davranacağına inanmak için güçlü bir neden yoksa, “ağırlık merkezi tekniği” önerilmektedir.

2.3.3. Yapay Sinir Ağı

Bir yapay sinir ağı, insan beynine dayalı bir akıl yürütme modeli olarak tanımlanmıştır. Beyin, birbirine yoğun şekilde bağlı bir dizi sinir hücresi veya nöron adı verilen temel bilgi işleme birimlerinden oluşmaktadır. İnsan beyni, aralarında yaklaşık 10 milyar adet nöron ve 60 trilyon adet bağlantı, sinaps barındırmaktadır (Shepherd, G.M. and Koch, 1990). Beyin, birden fazla nöronu aynı anda kullanarak, işlevlerini günümüzde var olan en hızlı bilgisayarlardan çok daha hızlı gerçekleştirebilmektedir. Her nöron çok basit bir yapıya sahip olmasına rağmen, bu tür unsurlardan oluşan bir muazzam düzenli bir işlem gücü oluşturmaktadır. Bir nöron, bir hücre gövdesi, soma, dendrit adı verilen bir dizi lif ve akson adı verilen tek bir uzun liften oluşmaktadır. Dendritler, soma çevresinde bir ağa dallanırken, akson diğer nöronların dendritlerine ve somalarına kadar uzanmaktadır. Sinyaller, karmaşık elektrokimyasal reaksiyonlarla bir nörondan diğerine yayılmaktadır. Ancak en ilginç bulgu, bir sinir ağının plastisite sergilemesidir. Uyarım modeline yanıt olarak, nöronlar bağlantılarının gücünde uzun vadeli değişiklikler gösterirler. Nöronlar ayrıca diğer nöronlarla yeni bağlantılar kurabilmektedir. Tüm nöron koleksiyonları bile bazen bir yerden başka bir yere göç edebilmektedir. Bu mekanizmalar beyindeki öğrenmenin temelini oluşturmaktadır.


Beynimiz oldukça karmaşık, doğrusal olmayan ve paralel bir bilgi işleme sistemi olarak düşünülebilmektedir. Bilgi, belirli konumlardan ziyade tüm ağ boyunca aynı anda bir sinir ağında depolanır ve işlenmektedir. Başka bir deyişle, sinir ağlarında hem veriler hem de işlenmesi yerel olmaktan çok küreseldir (Alnajjar ve Üçüncü, 2023).

Plastisite sayesinde, "doğru cevaba" götüren nöronlar arasındaki bağlantılar güçlenirken, "yanlış cevaba" götürenler zayıflamaktadır. Sonuç olarak, sinir ağları deneyim yoluyla öğrenme yeteneğine sahiptir. Öğrenme, biyolojik sinir ağlarının temel ve vazgeçilmez bir özelliğidir. Öğrenebilecekleri kolaylık ve doğallık, bir bilgisayarda biyolojik bir sinir ağını taklit etme girişimlerine yol açmıştır.

Günümüzdeki bir yapay sinir ağı (YSA), bir kâğıt uçağın süpersonik bir jete benzemesi gibi insan beynine benzemesine rağmen, ileriye doğru büyük bir adımdır. YSA'ları "öğrenme" yeteneğine sahiptir, yani performanslarını geliştirmek için deneyimleri kullanırlar. Yeterli sayıda örneğe maruz kaldığında, YSA'lar henüz karşılaşmadıkları diğerlerine genelleme

yapabilmektedir. El yazısı karakterleri tanıyabilir, insan konuşmasındaki kelimeleri belirleyebilir ve havaalanlarındaki patlayıcıları tespit edebilirler. Ayrıca, YSA'lar, insan uzmanların tanımakta başarısız olduğu kalıpları gözlemleyebilmektedir.

Bir yapay sinir ağı, beyindeki biyolojik nöronlara benzeyen, nöronlar olarak da adlandırılan çok sayıda basit ve yüksek düzeyde birbirine bağlı işlemcilerden oluşmaktadır. Nöronlar, sinyalleri bir nörondan diğerine geçiren ağırlıklı bağlantılarla bağlanmaktadır. Her nöron, bağlantıları aracılığıyla bir dizi girdi sinyali alır; ancak hiçbir zaman tek bir çıkış sinyalinden fazlasını üretmez. Çıkış sinyali, nöronun giden bağlantısı (biyolojik aksona karşılık gelen) aracılığıyla iletilmektedir. Giden bağlantı da aynı sinyali ileten birkaç kola bölünmektedir (sinyal bu dallar arasında hiçbir şekilde bölünmez). Giden dallar, ağıdaki diğer nöronların gelen bağlantılarında sonlanmaktadır. Şekil 9 tipik bir YSA'nın bağlantılarını göstermekte ve Tablo 4 biyolojik ve yapay sinir ağları arasındaki analogiyi göstermektedir (Medsker, 1995).



Şekil 9. Tipik bir yapay sinir ağının gösterimi

Nöronlar bağlantılarla birbirine bağlı ve her bağlantının kendisiyle ilişkili sayısal bir ağırlığı bulunmaktadır. Ağırlıklar, YSA'larda uzun süreli belleğin temel aracıdır. Her bir nöron

girişinin gücünü veya diğer bir deyişle önemini ifade etmektedir. Bir sinir ağı, bu ağırlıkların tekrar tekrar ayarlanması yoluyla “öğrenir”.


Tablo 4. Biyolojik ve yapay sinir ağlarındaki terimlerin karşılaştırılması

Biyolojik sinir ağı	Yapay sinir ağı
Soma	Nöron
Dendrit	Giriş
Akson	Çıkış
Sinaps	Ağırlık

Şekil 9’da gösterildiği gibi, tipik bir YSA, bir katman hiyerarşisinden oluşur ve ağlardaki nöronlar bu katmanlar boyunca düzenlenmektedir. Dış ortama bağlı nöronlar, giriş ve çıkış katmanlarını oluşturmaktadır. Ağırlıklar, ağ giriş/çıkış davranışını ortamdakiyle uyumlu hale getirmek için değiştirilmektedir. Her nöron, temel bir bilgi işleme birimidir. Girdiler ve sayısal ağırlıklar göz önüne alındığında aktivasyon seviyesini hesaplamak için bir araca sahiptir. Yapay sinir ağı kurmak için öncelikle kaç nöronun kullanılacağına ve nöronların bir ağ oluşturmak için nasıl bağlanacağına karar verilmelidir. Başka bir deyişle, önce ağ yapısı/formu seçilmeli. Sonrasında hangi öğrenme algoritmasının kullanılacağına karar verilir. Ve son olarak sinir ağı eğitilir, yani ağın ağırlıkları başlatılır ve bir dizi eğitim örneğinde ağırlıklar güncellenir.

2.3.3.1. Basit Bir Hesaplama Elemanı Olarak “Nöron”

Bir nöron, giriş bağlantılarından birkaç sinyal alır, yeni bir aktivasyon seviyesi hesaplar ve bunu çıkış bağlantıları aracılığıyla bir çıkış sinyali olarak gönderir. Giriş sinyali, ham veri veya diğer nöronların çıktıları olabilmektedir. Çıkış sinyali, problemin nihai çözümü veya diğer nöronlara girdi olabilmektedir. Şekil 10 tipik bir nöronu göstermektedir.



Şekil 10. Nöron diyagramı gösterilişi

1943'te Warren McCulloch ve Walter Pitts, çoğu yapay sinir ağının temeli olan çok basit bir fikir önermişlerdir. Nöron, giriş sinyallerinin ağırlıklı toplamını hesaplar ve sonucu bir eşik değeri olan θ ile karşılaştırmaktadır. Net girdi eşikten küçükse, nöron çıkışı +1'dir. Ancak net girdi eşikten büyük veya eşitse, nöron aktive olur ve çıkışı -1 değerine ulaşmaktadır (McCulloch ve Pitts, 1990). Başka bir deyişle, nöron aşağıdaki transfer veya aktivasyon fonksiyonunu kullanır:


$$X = \sum_{i=1}^n x_i w_i$$

$$Y = \begin{cases} +1 & \text{if } X \geq \theta \\ -1 & \text{if } X < \theta \end{cases} \quad (10)$$

Burada X , nöronun net ağırlıklı girdisidir, x_i , i giriş değeridir, w_i , i girişinin ağırlığıdır, n , nöron girişlerinin sayısıdır ve Y , nöronun çıkışıdır. Bu tür etkinleştirme işlevine işaret işlevi denir. Böylece, bir işaret aktivasyon fonksiyonuna sahip nöronun gerçek çıkışı aşağıdaki şekilde temsil edilebilir:

$$Y = \text{sign} \left[\sum_{i=1}^n x_i w_i - \theta \right] \quad (11)$$


Birçok etkinleştirme işlevi test edilmiştir, ancak yalnızca birkaçı pratik uygulamalar bulmuştur. Dört yaygın seçenek (adım, işaret, doğrusal ve sigmoid fonksiyonlar) Şekil (11)'de gösterilmektedir. Sert limit fonksiyonları olarak da adlandırılan adım ve işaret aktivasyon fonksiyonları, genellikle sınıflandırma ve örüntü tanıma görevleri için karar verme nöronlarında kullanılmaktadır.



Şekil 11. Bir nöronun aktivasyon fonksiyonları

Sigmoid fonksiyonu, “artı” ile “eksi” “sonsuz” arasında herhangi bir değer alabilen girişi “0” ile “1” arasında makul bir değere dönüştürmektedir. Bu fonksiyona sahip nöronlar geri yayılım ağlarında kullanılmaktadır. Doğrusal aktivasyon fonksiyonu, nöron ağırlıklı girdiye eşit bir çıktı sağlamaktadır. Doğrusal fonksiyona sahip nöronlar genellikle doğrusal yaklaşım için kullanılmaktadır.

1958'de Frank Rosenblatt, basit bir YSA eğitimi için ilk prosedürü sağlayan bir eğitim algoritması tanıtmıştır. Bu algılayıcı (Rosenblatt, 1958) bir sinir ağının en basit şeklidir. Ayarlanabilir sinaptik ağırlıklara sahip tek bir nöron ve sert bir sınırlayıcıdan oluşmaktadır. Tek katmanlı iki girişli bir algılayıcı Şekil 12'de gösterilmiştir.



Şekil 12. Tek katmanlı iki girişli algılayıcı

2.3.3.2. Algılayıcı


Rosenblatt algılayıcısının işleyişi McCulloch ve Pitts nöron modeline dayanmaktadır. Model, doğrusal bir birleştirici ve ardından bir sabit sınırlayıcıdan oluşmaktadır. Girdilerin ağırlıklı toplamı, girdisi pozitifse +1'e ve negatifse -1'e eşit bir çıktı üreten sert sınırlayıcıya uygulanmaktadır. Algılayıcının amacı girdileri, diğer bir deyişle dışarıdan uygulanan uyarımları $x_1; x_2; \dots; x_n$, iki sınıftan birine, örneğin A_1 ve A_2 şeklindedir. Böylece, bir temel algılayıcı durumunda, n-boyutlu uzay Hiper -düzlem tarafından iki karar bölgesine bölünürler. Hiper-düzlem, doğrusal olarak ayrılabilir bir fonksiyon ile tanımlanabilmektedir.

$$\sum_{i=1}^n x_i w_i - \theta = 0 \quad (12)$$

Burada;

x_1 ve x_2 olmak üzere iki girdi parametresi olması durumunda, karar sınırı Şekil 13a'da koyu renkle gösterilen düz bir çizgi şeklini almaktadır. Sınır çizgisinin üzerinde yer alan Nokta 1, A_1 sınıfına aittir ve çizginin altında kalan 2. nokta A_2 sınıfına aittir. Eşik θ , karar sınırını değiştirmek için kullanılmaktadır. Üç girişli Hiper-düzlem hala görselleştirilebilmektedir. Şekil 13b, üç girişli algılayıcı için üç boyutu göstermektedir. Buradaki ayırma düzlemi denklem ile tanımlanmaktadır.

$$x_1w_1 + x_2w_2 + x_3w_3 - \theta = 0 \quad (13)$$



Şekil 13. Algılayıcılarda doğrusal ayrılabilirlik: (a) iki girdili algılayıcı; (b) üç girdili algılayıcı

Bu, algılayıcının gerçek ve istenen çıktıları arasındaki farkı azaltmak için ağırlıklarda küçük ayarlamalar yapılarak uygulanmaktadır. Başlangıç ağırlıkları rastgele atanır, genellikle $[-0.5; 0.5]$ değerleri arasında ve ardından eğitim örnekleriyle tutarlı çıktı elde etmek için güncellenmektedir. Bir algılayıcı için ağırlık güncelleme işlemi özellikle basittir. p iterasyonunda, gerçek çıktı $Y(p)$ ve istenen çıktı $Y_d(p)$ ise, hata şu şekilde verilir:

$$e(p) = Y_d(p) - Y(p) , p = 1, 2, 3, \dots \quad (14)$$

Buradaki p yinelemesi, algılayıcıya sunulan " p th" (p 'inci) eğitim örneğini ifade eder. Hata, $e(p)$ pozitif ise, $Y(p)$ algılayıcı çıktısını artırmak gerekir, ancak negatifse $Y(p)$ 'yi azaltmak gerekmektedir. Her algılayıcı girdisinin toplam $X(p)$ girdisine $x_i(p) \times w_i(p)$ katkısı olduğunu dikkate alarak, girdi değeri $x_i(p)$ pozitifse, ağırlığındaki bir $w_i(p)$ artışının algılayıcı çıktısını $Y(p)$ arttırır, oysa $x_i(p)$ negatifse, $w_i(p)$ 'deki bir artış $Y(p)$ 'yi azaltma eğilimindedir. Böylece, aşağıdaki algılayıcı öğrenme kuralı oluşturulabilir:

$$w_i(p + 1) = w_i(p) + \alpha \times x_i(p) \times e(p) \quad (15)$$

α 'nın öğrenme oranı olduğu yerde, birlikten küçük pozitif bir sabittir. Algılayıcı öğrenme kuralı ilk olarak 1960 yılında Rosenblatt tarafından önerilmiştir (Rosenblatt, 1960). Bu kuralı kullanarak sınıflandırma görevleri için algılayıcı eğitim algoritması türetilmektedir.

1. Adım: Başlatma

Başlangıç ağırlıklarının düzenlenmesi $w_1; w_2; \dots; w_n$ ve θ 'yı $[-0.5; 0.5]$.

2. Adım: Aktivasyon

$x_1(p); x_2(p); \dots; x_n(p)$ girişlerini uygulayarak algılayıcıyı etkinleştirmek ve istenen çıktı $Y_d(p)$ elde edilmektedir. Yinelemede gerçek çıktıyı $p = 1$ hesaplanır.

$$Y(p) = \text{adım} \left[\sum_{i=1}^n x_i(p)w_i(p) - \theta \right] \quad (16)$$

Bu eşitlikte n , algılayıcı girdilerinin sayısı olup bu bir adım aktivasyon fonksiyonudur.

3. Adım: Ağırlık öğrenme çalışması

Algılayıcının ağırlıklarının güncelle

$$w_i(p + 1) = w_i(p) + \Delta w_i(p) \quad (17)$$

Bu eşitlikte $\Delta w_i(p)$ ve p iterasyonundaki ağırlık düzeltmesidir. Ağırlık düzeltmesi delta kuralı ile hesaplanır:


$$\Delta w_i(p) = \alpha \times x_i(p) \times e(p) \quad (18)$$

4. Adım: İterasyon

Yineleme p 'yi birer birer artırılır, 2. Adıma geri dönülür ve yakınsamaya kadar işlem tekrarlanmaktadır.

2.3.3.3.Çok Katmanlı Sinir Ağları

Çok katmanlı algılayıcı, bir veya daha fazla gizli katmana sahip ileri beslemeli bir sinir ağıdır. Tipik olarak ağ, kaynak nöronların bir giriş katmanından, en az bir orta veya gizli hesaplamalı nöron katmanından ve bir hesaplama nöronlarının çıktı katmanından oluşmaktadır. Giriş sinyalleri, katman temelinde ileri yönde yayılmaktadır. İki gizli katmana sahip çok katmanlı bir algılayıcı Şekil 14'te gösterilmiştir. Çok katmanlı bir sinir ağındaki her katmanın kendine özgü işlevi bulunmaktadır. Giriş katmanı, dış çevreden gelen giriş sinyallerini kabul eder ve bu sinyalleri gizli katmandaki tüm nöronlara yeniden dağıtmaktadır. Aslında, girdi katmanı nadiren bilgi işlem nöronlarını içerir ve bu nedenle girdi modellerine işlem yapılmamaktadır. Çıkış katmanı, gizli katmandan çıkış sinyallerini veya başka bir deyişle bir uyarıcı örüntüsünü kabul eder ve tüm ağın çıkış örüntüsünü meydana getirmektedir. Gizli katmandaki nöronların özellikleri algılar; nöronların ağırlıkları, girdi modellerinde gizli olan özelliklerini temsil etmektedir. Bu özellikler daha sonra çıktı katmanı tarafından çıktı modelinin belirlenmesinde kullanılmaktadır. Bir gizli katmanla, giriş sinyallerinin herhangi bir sürekli fonksiyonu temsil edilebilir ve iki gizli katmanla, süreksiz fonksiyonlar bile temsil edilebilmektedir.



Şekil 14. İki gizli katmana sahip çok katmanlı algılayıcı

Gizli bir katman, istenen çıktı “gizli” olarak saklamaktadır. Gizli katmandaki nöronlar, ağın giriş/çıkış davranışı aracılığıyla gözlemlenemezler. Gizli katmanın istenen çıktısının ne olması gerektiğini bilmenin açık bir yolu bulunmamaktadır. Başka bir deyişle, gizli katmanın istenen çıktısı, katmanın kendisi tarafından belirlenmektedir.

Ticari YSA'ları, bir veya iki gizli katman dahil olmak üzere üç ve bazen dört katman içermektedir. Her katman 10 ila 1000 nöron içerebilmektedir. Deneysel sinir ağları, üç veya dört gizli katman dahil olmak üzere beş veya altı katmana sahip olabilir ve milyonlarca nöron kullanılmaktadır. Ancak çoğu pratik uygulamada yalnızca üç katman kullanır, çünkü her bir ek katman, hesaplama yükünü katlayarak artırmaktadır.

Yüzden fazla farklı öğrenme algoritması mevcut olup, ancak en popüler yöntem geri yayımlı modeldir. Bu yöntem ilk olarak 1969'da önerilmiş (Bryson ve Ho, 1969), ancak zor hesaplamalar nedeniyle göz ardı edilmiştir. Geri yayımlı öğrenme algoritması ancak 1980'lerin ortalarında yeniden kullanıma sokulmuştur. Çok katmanlı bir ağda öğrenme, bir algılayıcı ile aynı şekilde ilerler. Ağa bir eğitim girdi desenleri seti sunulmaktadır. Ağ, çıktı modelini hesaplar ve bir hata varsa veya başka bir deyişle gerçek ve istenen çıktı modelleri arasında bir fark varsa, bu hatayı azaltmak için ağırlıklar ayarlanmaktadır. Bir algılayıcıda, her girdi için yalnızca bir

ağırlık ve bir çıktı bulunmaktadır. Ancak çok katmanlı ağda, her biri birden fazla çıktıya katkıda bulunan birçok ağırlık bulunmaktadır.

Geri yayımlı bir sinir ağında, öğrenme algoritmasının iki aşaması bulunmaktadır. İlk olarak, ağa girdi katmanına bir eğitim girdi modeli sunulmaktadır. Ağ daha sonra çıktı katmanı tarafından çıktı modeli oluşturulana kadar girdi modelini katmandan katmana yaymaktadır. Bu model istenen çıktıdan farklıysa, bir hata hesaplanır ve ardından ağ üzerinden çıktı katmanından girdi katmanına geriye doğru yayılmaktadır. Hata yayıldıkça ağırlıklar değiştirilebilmektedir. Diğer herhangi bir sinir ağında olduğu gibi, bir geri yayılım, nöronlar (ağın yapısı), nöronlar tarafından kullanılan aktivasyon fonksiyonu ve ağırlıkları ayarlama prosedürünü belirleyen öğrenme algoritması (veya öğrenme fonksiyonu) arasındaki bağlantılar tarafından belirlenmektedir. Tipik olarak, bir geri yayılım ağı, üç veya dört katmana sahip çok katmanlı bir ağıdır. Katmanlar tamamen bağlantılıdır, yani her katmandaki her nöron, bitişik ileri katmandaki diğer her nörona bağlıdır.

Bir nöron çıktısını Rosenblatt algılayıcısına benzer bir şekilde belirler. İlk olarak, daha önce olduğu gibi net ağırlıklı girdiyi hesaplar:

$$X = \sum_{i=1}^n x_i w_i - \theta \quad (19)$$

burada n , girdilerin sayısı ve θ , nörona uygulanan eşiktir. Daha sonra bu giriş değeri aktivasyon fonksiyonundan geçirilmektedir. Bununla birlikte, bir algılayıcıdan farklı olarak, geri yayılım ağındaki nöronlar bir Sigmoid aktivasyon fonksiyonunu kullanır:

$$y^{sigmoid} = \frac{1}{1 + e^{-X}} \quad (20)$$

Bu fonksiyonun türevinin hesaplanması kolaydır. Ayrıca nöron çıktısının “0” ile “1” arasında sınırlandırılmasını da garanti etmektedir.

Geri yayılım eğitim algoritması

1. Adım: Başlatma

Ağın tüm ağırlıklarını ve eşik seviyelerini, küçük bir aralık içinde eşit olarak dağıtılmış rastgele sayılara göre ayarlanır (Haykin, 1999):

$$\left(-\frac{2,4}{F_i}, +\frac{2,4}{F_i} \right)$$

burada F_i , ağdaki i nöronunun toplam giriş sayısıdır. Ağırlık başlatılması, nöron bazında yapılmaktadır.

2. Adım: Aktivasyon

Girdileri uygulayarak geri yayılım sinir ağı etkinleştirilir

$x_1(P); x_2(P); \dots; x_n(P)$ ve istenen çıktılar $y_{d,1}(P); y_{d,2}(P); \dots; y_{d,n}(P)$.

(a) Gizli katmandaki nöronların gerçek çıktıları hesaplanır:

$$y_j(P) = \text{sigmoid} \left[\sum_{i=1}^n x_i(P) \times w_{ij}(P) - \theta_j \right]$$

burada n , gizli katmandaki nöron j 'nin girdi sayısıdır ve sigmoid, sigmoid aktivasyon fonksiyonudur.

(b) Çıktı katmanındaki nöronların gerçek çıktılarının hesaplanması:

$$y_k(P) = \text{sigmoid} \left[\sum_{j=1}^m x_{jk}(P) \times w_{jk}(P) - \theta_k \right]$$

burada m , çıktı katmanındaki k nöronunun girdi sayısıdır.

3. Adım: Ağırlık eğitimi

Çıkış nöronlarıyla ilişkili olan hataları geriye doğru yayan geri yayılım ağındaki ağırlıkların güncellenmesi.

(a) Çıktı katmanındaki nöronlar için hata gradyanı hesaplanması:

$$\delta_k(P) = y_k(P) \times [1 - y_k(P)] \times e_k(P)$$

Burada

$$e_k(P) = y_{d,k}(P) - y_k(P)$$

Ağırlık düzeltmelerini hesaplanması:

$$\Delta w_{jk}(P) = \alpha \times y_j(P) \times \delta_k(P)$$

Çıkış nöronlarındaki ağırlıkları güncellenmesi:

$$w_{jk}(P + 1) = w_{jk}(P) + \Delta w_{jk}(P) \quad (21)$$

(b) Gizli katmandaki nöronlar için hata gradyanını hesaplanması:

$$\delta_j(P) = y_j(P) \times [1 - y_j(P)] \times \sum_{k=1}^l \delta_k(P) \times w_{jk}(P)$$

Ağırlık düzeltmelerini hesaplanması:

$$\Delta w_{ij}(P) = \alpha \times y_i(P) \times \delta_j(P)$$

Gizli nöronlardaki ağırlıkların güncellenmesi:

$$w_{ij}(P + 1) = w_{ij}(P) + \Delta w_{ij}(P)$$

4. Adım: İterasyon

Tekrarlama p 'yi birer birer artırmak, 2. Adıma geri dönüş ve seçilen hata kriteri karşılanana kadar işlemi tekrarlamak gerekmektedir.

2.3.3.4.Çok Katmanlı Sinir Ağlarında Hızlandırılmış Öğrenme

Genel olarak çok katmanlı bir ağ, sigmoidal aktivasyon fonksiyonu hiperbolik bir tanjant fonksiyonu ile temsil edildiğinde çok daha hızlı öğrenilmektedir.

$$y^{\tanh} = \frac{2a}{1 + e^{-bx}} - a \quad (22)$$

burada a ve b sabitlerdir.

a ve b için uygun değerler $a = 1.716$ ve $b = 0.667$ 'dir (Subramanian, 1991). Ayrıca Eşitlik 20'de delta kuralına göre bir momentum terimi ekleyerek eğitimi hızlandırılabilir (Rumelhart vd., 1986):

$$\Delta w_{jk}(P) = \beta \times \Delta w_{jk}(P - 1) + \alpha \times y_j(P) \times \delta_k(P) \quad (23)$$

burada β , momentum sabiti olarak adlandırılan pozitif bir sayı olup $0 \leq \beta < 1$ "0" ile "1" arasındadır. Tipik olarak, momentum sabiti $\beta = 0.95$ 'e ayarlanmaktadır.

Denklem 23 genelleştirilmiş delta kuralı olarak adlandırılır. Özel bir durumda, $\beta = 0$ olduğunda, 20 nolu denkleminin delta kuralını elde edilmektedir.

Watrous (1987) ve Jacobs'ta (1988) tarafından yapılan gözlemlere göre, momentumun geri yayılım algoritmasına dahil edilmesi eğitim üzerinde dengeleyici bir etkiye sahiptir. Başka bir deyişle, momentumun dahil edilmesi, sabit yokuş aşağı yönde inişi hızlandırma ve öğrenme yüzeyi inişler ve çıkışlar gösterdiğinde süreci yavaşlatma eğilimindedir. Saf bir geri yayılım algoritmasıyla yapılan bir karşılaştırma, dönem sayısını 224'ten 126'ya indirildiğini göstermektedir.

Geri yayımlı öğrenmenin yakınsamasını hızlandırmanın en etkili yollarından biri, eğitim sırasında öğrenme oranı parametresini ayarlamaktır. Küçük öğrenme oranı parametresi α , ağdaki ağırlıklarda bir yinelemeden diğerine küçük değişikliklere neden olur ve böylece düzgün bir öğrenme eğrisine geçiş oluşturur. Öte yandan, öğrenme hızı parametresi α , eğitim sürecini hızlandırmak için daha büyük yapılırsa, ağırlıklarda meydana gelen daha büyük değişiklikler

kararsızlığa neden olabilir ve bunun sonucunda ağ salınımlı hale gelebilmektedir. Yakınsamayı hızlandırmak ve kararsızlık tehlikesinden kaçınmak için iki sezgisel yöntem uygulanabilmektedir (Jacobs, 1988).


Bunlar;

Sezgisel 1. Karesi alınmış hataların toplamının değişimi, birbirini takip eden birkaç dönem için aynı cebirsel işarete sahipse, öğrenme oranı parametresi α arttırılmalıdır.

Sezgisel 2. Kare hataların toplamının değişiminin cebirsel işareti birbirini izleyen birkaç dönem için değişiyorsa, öğrenme hızı parametresi α azaltılmalıdır.

Öğrenme hızının uyarlanması, geri yayılım algoritmasında bazı değişiklikler gerektirir. İlk olarak, ağ çıktıları ve hataları, başlangıç öğrenme oranı parametresinden hesaplanmaktadır. Geçerli aşamadaki karesel hataların toplamı, önceki değeri önceden tanımlanmış bir orandan (tipik olarak 1,04) daha fazla olursa, öğrenme oranı parametresi azaltılır (tipik olarak 0,7 ile çarpılarak) ve yeni ağırlıklar ve eşikler hesaplanmaktadır. Ancak hata bir öncekinden daha az ise öğrenme oranı artmaktadır (tipik olarak 1,05 ile çarpılarak). Öğrenme oranını uyarlamanın gerçekten de yineleme sayısını azaltabileceğini göstermektedir.

Öğrenme hızı uyarlaması, momentumlu öğrenme ile kullanılabilmektedir. Şekil 15 her iki tekniği aynı anda uygulamanın faydalarını göstermektedir. Momentum ve uyarlanabilir öğrenme hızının kullanılması, çok katmanlı bir geri yayılım sinir ağının performansını önemli ölçüde artırmakta ve ağın salınımlı hale gelme şansını en aza indirmektedir. Sadece birkaç müzik parçası duyulduğunda, sesler ve sahneler de dahil olmak üzere tam bir duyuşal deneyimi hatırlanabilmektedir. Böyle durumlarda beyin rutin olarak bir şeyi başka bir şeyle ilişkilendirmektedir.



Şekil 15. Momentum ve uyarlanabilir öğrenme oranı ile öğrenme


Örüntü tanıma problemleri için geri yayılım algoritması ile eğitilmiş çok katmanlı sinir ağları kullanılmaktadır. Ancak belirtildiği gibi, bu tür ağlar özünde akıllı değildir. İnsan belleğinin çağrışımsal özelliklerini taklit etmek için farklı bir ağ türüne ihtiyaç vardır. Tekrarlayan bir sinir ağında olduğu gibi.

2.3.3.5.Hopfield Ağı

Tekrarlayan bir sinir ağı, çıkışlarından girişlerine geri besleme döngülerine sahip bir modeldir. Bu tür döngülerin varlığı, ağıın öğrenme kapasitesi üzerinde derin bir etkiye sahiptir.

Yeni bir giriş uygulandıktan sonra, ağ çıkışı hesaplanır ve girişi ayarlamak için geri beslenmektedir. Daha sonra çıktı tekrar hesaplanır ve çıktı sabit olana kadar işlem tekrarlanmaktadır.

Ardışık yinelemeler her zaman daha küçük ve daha küçük çıktı değişiklikleri üretmez, aksine kaotik davranışa yol açabilmektedir. Böyle bir durumda ağ çıkışı asla sabit olmaz ve ağın kararsız olduğu anlaşılmaktadır. Tekrarlayan ağların dengesi, 1960'larda ve 1970'lerde birçok araştırmacının ilgisini çekmiştir. Bununla birlikte, hiçbiri hangi ağı kararlı olacağını tahmin edememiş ve bazı araştırmacılar bir çözüm bulma konusunda karamsar kalmışlardır. Sorun ancak 1982'de John Hopfield'in dinamik olarak kararlı bir ağda bilgi depolamanın fiziksel ilkesini formüle etmesiyle çözülmüştür (Hopfield, 1982). Şekil 16'da "n" sayıda nörondan oluşan tek katmanlı bir Hopfield ağı gösterilmiştir.



Şekil 16. Tek katmanlı n-nöron Hopfield ağı

Her nöronun çıkışı, diğer tüm nöronların girdilerine geri beslenmektedir (Hopfield ağında kendi kendine geri bildirim yoktur). Hopfield ağı genellikle hesaplama elemanı olarak işaret aktivasyon fonksiyonu ile McCulloch ve Pitts nöronlarını kullanmaktadır.


Hopfield ağı şekil 11'de gösterilen işaret fonksiyonuna benzer şekilde çalışmaktadır. Nöronun ağırlıklı girdisi sıfırdan küçükse çıktı "-1" olur; giriş sıfırdan büyükse çıkış

“+1” olmaktadır. Ancak, nöronun ağırlıklı girdisi tam olarak sıfır “0” ise çıktısı değişmez. Başka bir deyişle, bir nöron “+1” veya “-1” olmasına bakılmaksızın önceki durumunda kalmaktadır.

$$Y^{sign} = \begin{cases} 1, & \text{if } X > 0 \\ -1, & \text{if } X < 0 \\ Y, & \text{if } X = 0 \end{cases} \quad (24)$$

İşaret etkinleştirme işlevi, doymuş bir doğrusal ile değiştirilebilir. $[-1; 1]$ ve bu bölgenin dışında bir işaret işlevi olarak kalır. Doymuş bir doğrusal fonksiyon Şekil 17'de gösterilmiştir. Ağıın mevcut durumu, tüm nöronların mevcut çıktıları tarafından belirlenir, $y_1; y_2; \dots; y_n$. Böylece, tek katmanlı bir “n-nöron” ağı için durum, durum vektörü tarafından aşağıdaki şekilde denklemleri ile tanımlanabilir:

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ \vdots \\ \vdots \\ y_n \end{bmatrix} \quad (25)$$



$$Y^{satlin} = \begin{cases} X, & \text{if } -1 < X < 1 \\ -1, & \text{if } X \geq 1 \\ Y, & \text{if } X \leq -1 \end{cases}$$

Şekil 17. Doymuş doğrusal aktivasyon fonksiyonu

Hopfield ağında, nöronlar arasındaki sinaptik ağırlıklar genellikle matris şeklinde aşağıdaki gibi temsil edilmektedir.

$$W = \sum_{m=1}^M Y_m Y_m^T - MI \quad (26)$$

Burada “M” ağ tarafından hafızaya alınacak durum sayısıdır, Y_m n-boyutlu ikili vektördür, $I, (n \times n)$ birim matrisi olup üst simge “T” matris transpozisyonunu belirtmektedir. Hopfield ağının bir işlemi geometrik olarak temsil edilebilmektedir.

Burada Hopfield ağ eğitim algoritmasını özetlenmesi;

1. Adım: Depolama

n-nöron Hopfield ağı, bir dizi "M" temel hafızayı depolamak için gereklidir, $Y_1; Y_2; \dots; Y_M$. Nöron i 'den nöron j 'ye sinaptik ağırlık şu şekilde hesaplanır:

$$w_{ij} = \begin{cases} \sum_{m=1}^M y_{m,i} y_{m,j}, & i \neq j \\ 0, & i = j \end{cases} \quad (27)$$

burada $y_{m,i}$ ve $y_{m,j}$, sırasıyla temel bellek Y_m 'nin i ve j 'inci öğeleridir. Matris formunda, nöronlar arasındaki sinaptik ağırlıklar aşağıdaki şekilde temsil edilmektedir.

$$W = \sum_{m=1}^M Y_m Y_m^T - MI$$

Ağırlık matrisi simetrikse ve ana köşegeninde sıfırlar varsa, Hopfield ağı bir dizi temel bellek depolayabilir (Cohen ve Grossberg, 1983).

Toplam ağırlık:

$$W = \begin{bmatrix} 0 & w_{12} & \cdots & w_{1i} & \cdots & w_{1n} \\ w_{21} & 0 & \cdots & w_{2i} & \cdots & w_{2n} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{i1} & w_{i2} & \cdots & 0 & \cdots & w_{in} \\ \vdots & \vdots & & \vdots & & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{ni} & \cdots & 0 \end{bmatrix} \quad (28)$$

Şeklinde gösterilmiştir.

Burada,

$$w_{ij} = w_{ji}.$$

Ağırlıklar hesaplandıktan sonra sabit kalmaktadır.

2. Adım: Test Edilmesi

Hopfield ağıının tüm temel anıları hatırlayabildiğini doğrulanması gerekmektedir. Başka bir deyişle, ağ, kendisiyle bir girdi olarak sunulduğunda herhangi bir temel bellek Y_m 'yi geri çağırmalıdır. Bu durum,

$$x_{m,i} = y_{m,i}, \quad i = 1, 2, 3, \dots, n \quad m = 1, 2, 3, \dots, M$$

$$y_{m,i} = \text{sign}(\sum_{j=1}^n w_{ij} x_{m,j} - \theta_i)$$

Şeklinde ifade edilebilir.

Burada $y_{m,i}$, gerçek çıktı vektörü Y_m 'nin i 'nci ögesi ve $x_{m,j}$, X_m girdi vektörünün j 'inci ögesi olmaktadır.

Bu durum matris şeklinde,

$$X_m = Y_m \quad m = 1, 2, 3, \dots, M$$

$$Y_m = \text{sign}(WX_m - \theta)$$

Tüm temel anılar mükemmel bir şekilde hatırlanırsa, bir sonraki adıma geçilebilmektedir.

3. Adım: Geri alım

Ağa bilinmeyen bir n-boyutlu vektör (sonda), X sunun ve kararlı bir durum alınsın. Tipik olarak, sonda, temel belleğin bozuk veya eksik bir versiyonunu temsil eder, yani,

$$X \neq Y_m, \quad m = 1, 2, 3, \dots, M$$

(a) Hopfield ağının alma algoritmasını ayarlayarak başlatılsın.

$$x_j(0) = x_j, \quad j = 1, 2, 3, \dots, n$$

ve her nöron için başlangıç durumunu hesaplınsın

$$y_i(0) = \text{sign}\left(\sum_{j=1}^n w_{ij}x_j(0) - \theta_i\right), \quad i = 1, 2, 3, \dots, n$$

burada $x_j(0), p = 0$ yinelemesinde X prob vektörünün j . öğesidir ve $y_i(0), p = 0$ yinelemesinde nöron i 'nin durumudur. Matris biçiminde, $p = 0$ yinelemesindeki durum vektörü olarak sunulmuştur. Bu

$$Y(0) = \text{sign}[WX(0) - \theta]$$

Şeklindedir.

$Y(p)$ durum vektörünün öğelerini aşağıdaki kurala göre güncellenir.

$$y_i(p+1) = \text{sign}\left(\sum_{j=1}^n w_{ij}x_j(p) - \theta_i\right)$$

Güncelleme için nöronlar ayrı ayrı, yani rastgele ve birer birer seçilmektedir. Durum vektörü değişmeden veya başka bir deyişle kararlı bir durum elde edilene kadar yinelemeyi tekrarlanmalıdır. Kararlılık koşulu aşağıdaki denklem ile tanımlanmıştır.

$$y_i(p+1) = \text{sign}\left(\sum_{j=1}^n w_{ij}y_j(p) - \theta_i\right), \quad i = 1, 2, 3, \dots, n \quad (29)$$

veya matris formunda,


$$Y(p+1) = \text{sign}[WY(p) - \theta] \quad (30)$$

Hopfield ağı her zaman kararlı bir duruma yakınsayacaktır, eğer geri alım eş zamansız olarak yapılmaktadır (Haykin, 1999). Ancak, bu kararlı durumun temel hafızalardan birini temsil etmesi gerekmez ve eğer bu bir temel hafıza ise en yakın olanı olması da gerekmemektedir.

2.3.3.6.Çift Yönlü İlişkisel Bellek

İlk olarak Bart Kosko tarafından önerilen çift yönlü çağrışımsal bellek (BAM), heteroassosiyatif bir ağıdır (Kosko, 1987). Bir küme A'dan gelen kalıpları başka bir kümeden, küme B'den kalıplarla ilişkilendirir ve bunun tersi de geçerli olmaktadır. Bir Hopfield ağı gibi, BAM da genelleştirebilir ve bozuk veya eksik girdilere rağmen doğru çıktılar üretebilmektedir. Temel BAM yapısı şekil 18'de gösterilmiştir. Bu tamamen bağlı iki katmandan oluşmakta olup bir girdi katmanı ve bir çıktı katmanı bulunmaktadır.

Giriş vektörü $X(p)$, Şekil 18a'da gösterildiği gibi bir çıktı vektörü $Y(p)$ üretmek için ağırlık matrisi W^T 'nin devrikine uygulanmaktadır. Daha sonra, $Y(p)$ çıktı vektörü, şekil (b)'deki gibi yeni bir $X(p + 1)$ girdi vektörü üretmek için ağırlık matrisi W 'ye uygulanır. Bu işlem, giriş ve çıkış vektörleri değişmeden veya başka bir deyişle BAM kararlı bir duruma gelene kadar tekrarlanmaktadır. BAM'ın arkasındaki temel fikir, desen çiftlerini depolamaktır. Böylece A kümesinden n -boyutlu X vektörü girdi olarak sunulduğunda, BAM, B kümesinden m -boyutlu Y vektörünü geri çağırır, ancak Y girdi olarak sunulduğunda, BAM geri çağırır X .



Şekil 18. BAM işlemi: (a) ileri yön; (b) geriye doğru yön

BAM'ı geliştirmek için, saklamak istenilen her desen çifti için bir korelasyon matrisi oluşturulması gerekmektedir. Korelasyon matrisi, X girdi vektörünün ve Y^T çıktı vektörünün devrik matris ürünüdür. BAM ağırlık matrisi, tüm korelasyon matrislerinin toplamıdır, aşağıdaki gibi ifade edilmektedir.

$$W = \sum_{m=1}^M X_m Y_m^T \quad (31)$$

Burada M , BAM'de saklanacak desen çiftlerinin sayısıdır. Bir Hopfield ağı gibi, BAM genellikle işaret aktivasyon fonksiyonu ile McCulloch ve Pitts nöronlarını kullanmaktadır. BAM eğitim algoritması aşağıdaki gibi sunulmaktadır.

1. Adım: Depolama

BAM, M çift deseni depolamak için gereklidir.

2. Adım: Test Edilmesi

BAM, A kümesinden herhangi bir vektörü alabilmeli ve ilgili vektörü B kümesinden alabilmeli ve ilişkili vektörü A kümesinden alabilmelidir. Bu nedenle, önce BAM'ın yapabildiğini doğrulanması gerekmektedir. X_m ile sunulduğunda Y_m 'yi hatırlanması gerekmektedir. Aşağıdaki ifadeli verilmektedir.

$$Y_m = \text{sign}(W^T X_m), \quad m = 1, 2, 3, \dots, M \quad (32)$$

Ardından, Y_m ile sunulduğunda BAM'ın X_m 'yi hatırladığını onaylanmaktadır. Bu durum aşağıdaki ifadeyle verilmiştir.

$$X_m = \text{sign}(W Y_m), \quad m = 1, 2, 3, \dots, M \quad (33)$$

3. Adım: Geri alım

BAM'a bilinmeyen bir vektör (sonda) X sunulmalı ve depolanmış bir ilişkilendirme almalı. Sonda, BAM'de depolanan A kümesinden (veya B kümesinden) bir modelin bozuk veya eksik bir versiyonunu sunabilmektedir. Bu anlama gelir,

$$X \neq X_m, \quad m = 1, 2, 3, \dots, M$$

(a) BAM alma algoritmasını ayarlayarak başlatılması.

$$X(0) = X, \quad p = 0$$

ve p iterasyonunda BAM çıktısını hesaplanması,

$$Y(p) = \text{sign}[W^T X(p)]$$

(b) $X(p)$ girdi vektörünü güncellenmesi:

$$X(p+1) = \text{sign}[W Y(p)]$$

ve girdi ve çıktı vektörleri daha fazla iterasyonla değişmeden kaldığı dengeye kadar iterasyon tekrarlanmaktadır. Giriş ve çıkış desenleri daha sonra ilişkili bir çift ile temsil edilecektir. BAM koşulsuz olarak kararlıdır (Kruse ve Nauck, 1998). Bu, herhangi bir ilişki kümesinin dengesizlik riski olmadan öğrenilebileceği anlamına gelmektedir. Bu önemli nitelik,

ileri ve geri yönlerde ağırlık matrisleri arasındaki devrik ilişkiyi kullanan BAM'den kaynaklanmaktadır.

BAM ve Hopfield ağı arasında da yakın bir ilişki bulunmaktadır. BAM ağırlık matrisi kare ve simetrik ise, $W = W^T$ şeklini almaktadır. Bu durumda, giriş ve çıkış katmanları aynı boyutta ve BAM, oto-ilişkili Hopfield ağına indirgenebilmektedir. Bu nedenle, Hopfield ağı bir BAM özel durumu olarak düşünülebilmektedir. Hopfield ağının depolama kapasitesine uygulanan kısıtlamalar BAM'a da genişletilebilmektedir. Genel olarak, BAM'de depolanacak maksimum ilişki sayısı, daha küçük katmandaki nöron sayısını aşmamalıdır. Daha da ciddi bir diğer sorun ise yanlış yakınsamadır. BAM her zaman en yakın ilişkilendirmeyi üretmeyebilir. Aslında, kararlı bir ilişki başlangıç girdi vektörü ile çok az ilgili olabilmektedir. Bu durumda BAM hala yoğun araştırma konusu olmaya devam etmektedir. Ancak, mevcut tüm sorunlarına ve sınırlamalarına rağmen BAM, en kullanışlı yapay sinir ağlarından biridir.

Bir sinir ağının temel özelliği, çevresinden öğrenme ve öğrenme yoluyla performansını artırma yeteneğine sahiptir. Şimdiye kadar denetimli veya aktif öğrenme düşünüldü, harici bir “öğrenme” veya ağı bir eğitim seti sunan bir gözetmen ile öğrenmedir. Ancak başka bir öğrenme türü daha bulunmakta ve bu denetimsiz öğrenmedir. Denetimli öğrenmenin aksine, denetimsiz veya kendi kendine organize öğrenme harici bir öğrenme gerektirmemektedir. Eğitim sırasında, sinir ağı bir dizi farklı girdi modeli alır, bu modellerdeki önemli özellikleri keşfeder ve girdi verilerini uygun kategorilere nasıl sınıflandıracağını öğrenmektedir. Denetimsiz öğrenme, beynin nöro-biyolojik organizasyonunu takip etme eğilimindedir. Denetimsiz öğrenme algoritmaları hızlı öğrenmeyi amaçlamaktadır. Aslında, kendi kendini organize eden sinir ağları, geri yayılım ağlarından çok daha hızlı öğrenir ve bu nedenle gerçek zamanlı olarak kullanılabilir.

2.3.3.7.Kendi Kendini Organize Eden Sinir Ağları

Kendi kendini organize eden sinir ağları, beklenmedik ve değişen koşullarla başa çıkmada çok etkilidir. Bu bölümde, kendi kendini organize eden ağlara dayanan Hebbian ve rekabetçi öğrenme ele alınmıştır.


(A)Hebbian Öğrenme

1949 yılında nöropsikolog Donald Hebb, biyolojik öğrenmede yaygın olarak Hebb-Yasası olarak bilinen temel fikirlerden birini önermiştir (Morris, 1999). Hebb Yasası, " i " nöronunun " j " nöronunu uyarmak kadar yakın olması ve aktivasyonuna tekrar katılması durumunda, bu iki nöron arasındaki sinaptik bağlantının güçlendiğini ve nöron j 'nin nöron i 'den gelen uyarılara daha duyarlı hale geldiğini belirtmektedir.

Hebb-Yasası aşağıdaki verildiği şekilde iki kural olarak gösterilmiştir (Stent, 1973):

1. Bir bağlantının her iki tarafındaki iki nöron eşzamanlı olarak etkinleştirilirse, o bağlantının ağırlığı artmaktadır.
2. Bir bağlantının her iki tarafındaki iki nöron eş zamansız olarak etkinleştirilirse, o bağlantının ağırlığı azalmaktadır.

Hebb-Yasası, öğrenme olmadan öğrenmenin temelini oluşturmaktadır. Burada öğrenme, çevreden geri bildirim alınmadan meydana gelen yerel bir olgudur. Şekil 19 bir sinir ağındaki Hebbian öğrenimini göstermektedir.



Şekil 19. Bir sinir ağında Hebbian öğrenme

Hebb-Yasasını kullanarak, p iterasyonunda w_{ij} ağırlığına uygulanan ayarlamayı aşağıdaki denklemde ifade edilebilmektedir:

$$\Delta w_{ij}(P) = F[y_j(P), x_i(P)] \quad (34)$$

Burada $F[y_j(P), x_i(P)]$ hem postsinaptik hem de presinaptik aktivitelerin bir fonksiyonudur. Özel bir durum olarak Hebb -Yasasını aşağıdaki şekilde gösterilmiştir (Haykin, 1999):

$$\Delta w_{ij}(P) = \alpha y_j(P) x_i(P) \quad (35)$$

α öğrenme oranı parametresidir.

Bu denklem, aktivite çarpım kuralı olarak da olarak adlandırılabilir. Bir çift nöron arasındaki sinaptik bağlantının ağırlığındaki bir değişikliğin, giren ve çıkan sinyallerin bir verisi ile nasıl ilişkili olduğunu göstermektedir. Hebbian öğrenimi, ağırlıkların yalnızca artabileceği anlamına gelmektedir. Başka bir ifade ile, Hebb-Yasası bir bağlantının gücünün artmasına izin verir, ancak gücü azaltmak için bir araç sağlamamaktadır. Dolayısıyla, giriş sinyalinin tekrarlanan uygulaması, ağırlığı w_{ij} doygunluğa dönüştürmektedir. Bu sorunu çözmek için sinaptik ağırlıkların büyümesine bir sınır getirmektedir. Bu durumda, eşitlik 35'teki Hebb-Yasası'na aşağıdaki gibi doğrusal olmayan bir unutma faktörü eklenerek oluşturulmuştur (Kohonen, 1989):

$$\Delta w_{ij}(P) = \alpha y_j(P) x_i(P) - \emptyset y_j(P) w_{ij}(P) \quad (36)$$

burada $\emptyset$ unutma faktörüdür.

Unutma faktörü $\emptyset$, tek bir öğrenme döngüsünde ağırlık azalmasını belirtmektedir. Genellikle “0” ile “1” aralığına düşmektedir. Unutma faktörü “0” ise, sinir ağı sadece sinaptik ağırlıklarını güçlendirebilir ve sonuç olarak bu ağırlıklar sonsuza doğru büyümektedir. Öte yandan, unutma faktörü “1”e yakınsa, ağ öğrendiklerinin çok azını hatırlamaktadır. Bu nedenle, ağırlık büyümesini sınırlarken sadece biraz “unutmaya” izin vermek için tipik olarak “0,01” ile “0,1” arasında oldukça küçük bir unutma faktörü seçilmiştir.

Eşitlik (36) genelleştirilmiş etkinlik çarpım kuralı olarak adlandırılan biçimde de aşağıdaki eşitlik 37’de yazılabilmektedir.

$$\Delta w_{ij}(P) = \phi y_j(P) [\lambda x_i(P) - w_{ij}(P)] \quad (37)$$

Burada

$$\lambda = \alpha / \phi$$

Şeklinde tanımlanmıştır.

Genelleştirilmiş etkinlik çarpımı kuralı, $p, x_i(p)$ yinelemesindeki presinaptik etkinlik (i nöronunun girişi) $w_{ij}(p)/\lambda$ 'den küçükse, yinelemedeki $(p + 1)$ değiştirilmiş sinaptik ağırlığın w_{ij} olduğunu ima etmektedir. $(p + 1), p, y_j(p)$ yinelemesinde postsinaptik aktiviteyle (j nöronunun çıktısı) orantılı bir miktarda azalacaktır. Öte yandan, eğer $x_i(p) w_{ij}(p)/\lambda$ 'den büyükse, o zaman yinelemedeki $(p + 1), w_{ij}(p + 1)$ değiştirilmiş sinaptik ağırlık da j nöronunun çıktısı olan $y_j(p)$ ile orantılı olarak artacaktır. Diğer bir deyişle, sinaptik ağırlığı değiştirmek için aktivite denge noktasını $w_{ij}(p)/\lambda$ 'ye eşit bir değişken olarak belirlenmektedir.

Bu yaklaşım, sinaptik ağırlıkların sonsuz artışının sorununu çözer. Bu durum genelleştirilmiş Hebbian öğrenme algoritmasını ortaya çıkarmaktadır.

Bu hesaplamanın adımları:

1. Adım: Başlatma

Başlangıç sinaptik ağırlıkları ve eşikleri küçük rastgele değerlere ayarlanması, örneğin bir aralık $[0; 1]$. Ayrıca, öğrenme oranı parametresi α ve unutma faktörü ϕ 'ye küçük pozitif değerler atanması.

2. Adım: Aktivasyon

p iterasyonunda nöron çıktısını hesaplanması,

$$y_j(P) = \sum_{i=1}^n x_i(P) w_{ij}(P) - \theta_j$$

burada n , nöron girdilerinin sayısıdır ve θ_j , nöron j 'nin eşik değeridir.

3. Adım: Öğrenme

Ağdaki ağırlıkların güncellenmesi:

$$w_{ij}(P + 1) = w_{ij}(P) + \Delta w_{ij}(P)$$

Bura da $\Delta w_{ij}(P)$, P iterasyonundaki ağırlık düzeltilmesidir.

Ağırlık düzeltilmesi, genelleştirilmiş etkinlik çarpım kuralı tarafından belirlenir:

$$\Delta w_{ij}(P) = \phi y_j(P) [\lambda x_i(P) - w_{ij}(P)]$$

4. Adım: İterasyon

İterasyon da p 'yi birer birer artırın, 2. Adıma geri dönün ve sinaptik ağırlıklar kararlı durum değerlerine ulaşana kadar işleme devam edilmelidir.


(B) Rekabetçi Öğrenme

Bir diğer popüler denetimsiz öğrenme türü, rekabetçi öğrenmedir. Rekabetçi öğrenmede, nöronlar aktive olmak için kendi aralarında rekabet etmektedir. Hebbian öğrenmede birkaç çıkış nöronu aynı anda etkinleştirilebilirken, rekabetçi öğrenmede herhangi bir zamanda yalnızca tek bir çıkış nöronu aktiftir. "Yarışmayı" kazanan çıktı nöronu, kazanan her şeyi alır nöron olarak adlandırılır. Rekabetçi öğrenmenin temel fikri 1970'lerin başında tanıtılmıştır (Fukushima, 1975). Bununla birlikte, rekabetçi öğrenme, Teuvo Kohonen'in kendi kendini organize eden özellik haritaları adı verilen özel bir yapay sinir ağı sınıfını tanıttığı 1980'lerin sonlarına kadar fazla ilgi çekmemiştir (Kohonen, 1989). Bu haritalar rekabetçi öğrenmeye dayanmaktadır.

Beyne, milyarlarca nöron ve yüz milyarlarca sinapstan oluşan çok karmaşık bir yapı olan serebral korteks tarafından yönetilmektedir. Korteks ne tekdüzey ne de homojendir. Farklı insan aktivitelerinden (motor, görsel, işitsel, somatosensoriyel, vb.) sorumlu olan ve bu nedenle farklı duyuşal girdilerle ilişkilendirilen, katmanlarının kalınlığı ve içlerindeki nöron türleri ile tanımlanan alanları içermektedir. Her duyuşal girdinin serebral korteksin karşılık gelen bir alanına eşlendiğini söylenebilmektedir. Başka bir deyişle, korteks insan beyinde kendi kendini organize eden bir hesaplama haritasıdır.

Kohonen, topografik harita oluşturma ilkesini formüle etmiştir (Kohonen, 1990). Bu ilke, bir çıktı nöronunun topografik haritadaki uzaysal konumunun, girdi modelinin belirli bir özelliğine karşılık geldiğini belirtmiştir. Kohonen ayrıca Şekil 20'de gösterilen özellikli haritalama modelini de önermiştir (Kohonen, 1982). Bu model, beyindeki kendi kendini

organize eden haritaların ana özelliklerini yakalar ve yine de bir bilgisayarda kolayca temsil edilebilmektedir.




Şekil 20. Kohonen modelinde a) (1, 0) ve b) (0,1) özellik eşleme

Kohonen modeli, girdi katmanından daha yüksek boyutlu bir çıktıya veya Kohonen katmanına sabit sayıda girdi deseni yerleştirerek topolojik bir eşleme sağlamaktadır. Şekil 20, Kohonen katmanı, her nöronun iki girdiye sahip olduğu 4'e 4 nöronlardan oluşan iki boyutlu bir kafesten oluşmaktadır. Kazanan nöron siyah ve komşuları gri renkte gösterilmiştir. Burada kazananın komşuları, kazanan fiziksel olarak yakın olan nöronlardır.

Fiziksel yakınlığın ne kadar yakın olduğu yapay sinir ağı tasarımcısı tarafından belirlenmektedir. Kazananın komşuluğu, her iki tarafta bir, iki ve hatta üç konumdaki nöronları içerebilmektedir. Örneğin, Şekil 20'de kazananın bir boyutundaki komşuluğunu göstermektedir. Genel olarak, Kohonen ağındaki eğitim, kazananın oldukça büyük bir boyuttaki komşuluğu ile başlamaktadır. Ardından, eğitim ilerledikçe komşuluk boyutu kademeli olarak azalmaktadır.

Kohonen ağı, tek bir hesaplama nöron katmanından oluşur, ancak iki farklı bağlantı türü bulunmaktadır. Giriş katmanındaki nöronlardan çıkış katmanındaki nöronlara ileri bağlantılar var ve ayrıca Şekil 21'de gösterildiği gibi çıkış katmanındaki nöronlar arasında yanıl bağlantılar bulunmaktadır. Yanıl bağlantılar, nöronlar arasında rekabet yaratmak için kullanılmaktadır. Çıktı katmanındaki tüm nöronlar arasında en büyük aktivasyon düzeyine sahip nöron kazanan olmaktadır (kazanan her nöronu alır). Bu nöron, çıkış sinyali üreten tek nörondur. Diğer tüm nöronların aktivitesi yarışmada bastırılmaktadır. Ağa bir girdi örüntüsü sunulduğunda, Kohonen katmanındaki her bir nöron, giriş katmanı ile Kohonen katmanı arasındaki sinaptik bağlantıların ağırlıklarının yol tarafı boyunca değiştirilen giriş modelinin tam bir kopyasını almaktadır. Yanıl geri besleme bağlantıları, kazanan nörondan uzaklığa bağlı olarak uyarıcı veya engelleyici etkiler üretmektedir.



Şekil 21. Kohonen ağıının yapısı

Standart rekabetçi öğrenme kuralı (Haykin, 1999), sinaptik ağırlığa uygulanan Δw_{ij} değişikliğini şu şekilde tanımlar:

$$\Delta w_{ij} = \begin{cases} \alpha(x_i - w_{ij}), & \text{if neuron } j \text{ wins the competition} \\ 0, & \text{if neuron } j \text{ loses the competition} \end{cases} \quad (38)$$

burada x_i giriş sinyali ve α öğrenme oranı parametresidir. Öğrenme hızı parametresi “0” ile “1” arasında yer almaktadır. Rekabetçi öğrenme kuralının genel etkisi, kazanan nöron j 'nin sinaptik ağırlık vektörü w_j 'nin X giriş modeline doğru hareket ettirilmesinde bulunmaktadır. Eşleştirme kriteri, vektörler arasındaki minimum Öklid mesafesinin eşdeğeridir.

Bir çift n'ye 1 vektörü X ve w_j arasındaki Öklid uzaklığı şu şekilde tanımlanır:


$$d = \|X - w_j\| = [\sum_{i=1}^n (x_i - w_{ij})^2]^{1/2} \quad (39)$$

burada x_i ve w_{ij} , sırasıyla X ve w_j vektörlerinin i 'inci elemanlarıdır.

X ve w_j vektörleri arasındaki benzerlik, Öklid mesafesi d 'nin tersi olarak belirlenir. Şekil (22)'de X ve w_j vektörleri arasındaki Öklid mesafesi, bu vektörlerin uçlarını birleştiren doğrunun uzunluğu olarak verilmektedir. Şekil 22'de açıkça görülmektedir ki Öklid mesafesi ne kadar küçükse, X ve w_j vektörleri arasındaki benzerlik o kadar büyük olacaktır. X girdi vektörüne en iyi uyan ve kazanan nöron jX 'i belirlemek için aşağıda denklem 40'ta ki koşul uygulanabilir (Haykin, 1999):

$$jX = \min_j \|X - w_j\|, \quad j = 1, 2, 3, \dots, m \quad (40)$$

burada m , Kohonen katmanındaki nöronların sayısıdır.



Şekil 22. X ve w_j Vektörleri arasındaki benzerlik ölçüsü Öklid mesafesi

Rekabetçi öğrenme algoritması aşağıdaki gibi özetlenmiştir (Kohonen, 1990):

1. Adım: Başlatma

Başlangıç sinaptik ağırlıklarını küçük rastgele değerlere ayarlanması, örneğin bir $[0; 1]$ ve öğrenme oranı parametresi α 'ya küçük bir pozitif değer atanması.

2. Adım: Aktivasyon ve benzerlik eşleştirme

X girdi vektörünü uygulayarak Kohonen ağı etkinleştirilir ve minimum mesafe Öklid kriteri kullanarak p iterasyonunda kazanan bütün değerleri alır (en iyi eşleşen) nöron jX 'i bulunur.

jX 'in hesaplanmasında;

$$jX(p) = \min_j \|X - W_j(p)\| = \left[\sum_{i=1}^n (x_i - w_{ij}(p))^2 \right]^{\frac{1}{2}}, \quad j = 1, 2, 3, \dots, m$$

Eşitliği kullanılır.

Burada n , giriş katmanındaki nöronların sayısı ve m çıktı veya Kohonen katmanındaki nöronların sayısıdır.

3. Adım: Öğrenme

Sinaptik ağırlıkların güncellenmesi

$$w_{ij}(p+1) = w_{ij}(p) + \Delta w_{ij}(p)$$


burada $\Delta w_{ij}(p)$, p yinelemesindeki ağırlık düzeltmesidir.

Ağırlık düzeltmesi, rekabetçi öğrenme kuralı tarafından belirlenir

$$\Delta w_{ij}(p) = \begin{cases} \alpha [(x_i - w_{ij}(p))], & j \in \Lambda_j(p) \\ 0, & j \notin \Lambda_j(p) \end{cases} \quad (41)$$

Burada α , öğrenme oranı parametresidir ve $\Lambda_j(p)$, p yinelemesinde kazanan hepsini alır nöron jX etrafında merkezlenen komşuluk fonksiyonudur.

Komşuluk fonksiyonu Λ_j genellikle sabit bir genliğe sahiptir. Bu, topolojik komşuluk içinde yer alan tüm nöronların aynı anda etkinleştirildiğini ve bu nöronlar arasındaki ilişkinin, kazanan hepsini alır, nöron jX 'e olan uzaklığından bağımsız olduğunu belirtmektedir. Komşuluk fonksiyonunun bu basit formu Şekil 23'te gösterilmiştir.



Şekil 23. Dikdörtgen komşuluk işlevi

Dikdörtgen komşuluk işlevi Λ_j ikili bir karakter şeklini alır. Böylece, nöron çıktılarını tanımlayarak ifade eder.

$$y_j = \begin{cases} 1, & j \in \Lambda_j(p) \\ 0, & j \notin \Lambda_j(p) \end{cases} \quad (42)$$

4. Adım: İterasyon

İterasyon p bir artırılı, 2. Adıma geri dönülür ve minimum mesafeli Öklid kriteri sağlanana veya özellik haritasında gözle görülür bir değişiklik meydana gelmeye kadar devam edilmelidir.

2.3.4. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS)

Sugeno bulanık modeli, belirli bir “girdi-çıkı” veri setinden bulanık kurallar üretmeye yönelik sistematik bir yaklaşım için önerilmiştir. Tipik bir Sugeno bulanık kuralı aşağıdaki gibi ifade edilebilir:


IF	x_1 is A_1
AND	x_2 is A_2
.....	
AND	x_m is A_m
THEN	$y = f(x_1, x_2, \dots, x_m)$

Burada $x_1, x_2, \dots, x_m$ girdi değişkenleridir; $A_1, A_2, \dots, A_m$ bulanık kümeler ve y , girdi değişkenlerinin sabit veya doğrusal bir fonksiyonudur. y bir sabit olduğunda, bir kuralın sonucunun bir tekil tarafından belirlendiği sıfır dereceli bir Sugeno bulanık modeli elde edilmektedir. y birinci dereceden bir polinom olduğunda, diğer bir şekliyle,

$$y = k_0 + k_1x_1 + k_2x_2 + \dots + k_mx_m$$

birinci dereceden bir Sugeno bulanık modeli elde edilmiştir.

Jang'ın ANFIS'i normalde altı katmanlı bir ileri beslemeli sinir ağı ile temsil edilebilir. Şekil 24'de birinci dereceden Sugeno bulanık modeline karşılık gelen ANFIS yapısını göstermektedir. Basit olma açısından, ANFIS'in iki girişi “ x_1 ve x_2 ” ve bir çıkışı “ y ” olduğu varsayılmıştır. Her girdi iki bulanık kümeyle ve çıktı birinci dereceden bir polinomla temsil edilmektedir.



Şekil 24. Uyarlamalı Sinirsel Bulanık Çıkarım Sistem Yapısı (ANFİS).

Burada Jang'ın ANFIS'indeki her katmanın amacını tartışılmıştır. Katman 1 giriş katmanıdır. Bu katmandaki nöronlar, harici net sinyalleri Katman 2'ye iletir. Bu durum denklem 42 ile aşağıda verilmiştir.

$$y_i^{(1)} = x_i^{(1)} \quad (43)$$

Bu denklemde $x_i^{(1)}$ girdi olup $y_i^{(1)}$ Katman 1'deki giriş nöronu i'nin çıktısıdır.

Katman 2 bulanıklaştırma katmanıdır. Bu katmandaki nöronlar bulanıklaştırmayı gerçekleştirir. Jang'ın modelinde, bulanıklaştırma nöronları bir çan eğrisi aktivasyon fonksiyonuna sahiptir. Normal bir çan şekline sahip bir çan aktivasyon fonksiyonu aşağıdaki şekilde belirtilmiştir:

$$y_i^{(2)} = \frac{1}{1 + \left(\frac{x_i^{(2)} - a_i}{c_i} \right)^{2b_i}} \quad (44)$$

Denklem 44'te $x_i^{(2)}$ girdiler ve $y_i^{(2)}$ Katman 2'deki i nöronunun çıktısıdır. a_i , b_i ve c_i sırasıyla nöron i 'nin çan eğrisi aktivasyon fonksiyonunun merkezini, genişliğini ve eğimini kontrol eden parametreleridir.

Katman 3, kural katmanıdır. Bu katmandaki her nöron, tek bir Sugeno tipi bulanık kurala karşılık gelmektedir. Bu kural nöronu, ilgili bulanıklaştırma nöronlarından girdiler alır ve temsil ettiği kuralın aktifleştirme gücünü hesaplamaktadır. ANFIS'te, kural öncüllerinin birleşimi, operatör çarpımı tarafından değerlendirilmektedir. Böylece, i nöronunun Katmanı 3'teki çıktısı aşağıdaki 45 denklemi ile elde edilir:

$$y_i^{(3)} = \prod_{j=1}^k x_{ji}^{(3)} \quad (45)$$

Bu denklemde $x_{ji}^{(3)}$ girdiler ve $y_i^{(3)}$ Katman 3'teki kural nöronu i 'nin çıktısıdır.

4. katman normalizasyon katmanıdır. Bu katmandaki her nöron, kural katmanındaki tüm nöronlardan girdi alır ve belirli bir kuralın normalleştirilmiş aktifleştirme gücünü hesaplar. Normalleştirilmiş ateşleme gücünü, belirli bir kuralın ateşleme kuvvetinin, tüm kuralların aktifleştirme gücünün toplamına oranıdır. Belirli bir kuralın nihai sonuca katkısını temsil etmektedir. Böylece, 4. katmandaki i nöronunun çıktısı 46 no'lu denklem ile belirlenir:

$$y_i^{(4)} = \frac{x_{ii}^{(4)}}{\sum_{j=1}^n x_{ji}^{(4)}} = \frac{\mu_i}{\sum_{j=1}^n \mu_j} = \bar{\mu}_i \quad (46)$$

Bu denklemde $x_{ji}^{(4)}$, Katman 3'te bulunan j nöronundan Katman 4'teki nöron i 'ye girdisi ve n kural nöronlarının toplam sayısıdır.

Katman 5 ise durulaştırma katmanıdır. Bu katmandaki her nöron, ilgili normalizasyon nöronuna bağlı ve ayrıca x_1 ve x_2 başlangıç girdilerini almaktadır. Durulaştırma nöronu, belirli bir kuralın ağırlıklı sonuç değerini 47 no'lu denklem ile hesaplanır:

$$y_i^{(5)} = x_i^{(5)} [k_{i0} + k_{i1}x_1 + k_{i2}x_2] = \bar{\mu}_i [k_{i0} + k_{i1}x_1 + k_{i2}x_2] \quad (47)$$

Denklemden $x_i^{(5)}$ girdidir ve $y_i^{(5)}$, Katman 5'teki durulaştırma nöronu i 'nin çıktısı ve k_{i0} , k_{i1} ve k_{i2} , kural i 'nin bir dizi sonuç parametresidir.

Katman 6'da tek bir toplam nöron ile temsil edilmektedir. Bu nöron, tüm durulaştırma nöronlarının çıktıların toplamını hesaplar ve genel ANFIS çıktısını üretir.

Modellemeden çıkış değeri y 48 no'lu denklem ile hesaplanır.

$$y = \sum_{i=1}^n x_i^{(6)} = \sum_{i=1}^n \bar{\mu}_i [k_{i0} + k_{i1}x_1 + k_{i2}x_2] \quad (48)$$

Şekil 24'te gösterilen ANFIS gerçekten de birinci dereceden Sugeno bulanık modeline fonksiyonel olarak eşdeğerdir.

Bununla birlikte, bir polinom formunda sonuç olarak bir kural belirlemek çoğu zaman zor veya hatta meydana gelmesi imkânsızdır. Uygun bir şekilde, bir ANFIS'in bir problemle başa çıkması için kural sonuç parametreleri hakkında önceden herhangi bir bilgiye sahip olması gerekli değildir. Bir ANFIS bu parametreleri öğrenir ve üyelik fonksiyonlarını ayarlamaktadır.

Bir ANFIS, en küçük kareler tahmincisi ile gradyan iniş yöntemini birleştiren bir hibrit öğrenme algoritması kullanmaktadır (Jang, 1993). İlk olarak, her bir üyelik nöronuna başlangıç aktivasyon fonksiyonları atanmaktadır. Giriş x_i 'ye bağlı nöronların fonksiyon merkezleri, x_i 'nin etki alanı eşit olarak bölünecek şekilde ayarlanır ve genişlikler ve eğimler, ilgili fonksiyonların yeterince örtüşmesine izin verecek şekilde düzenlenmelidir. ANFIS eğitim algoritmasında, her epok bir ileri geçiş ve bir geri geçişten oluşmaktadır. İleri geçişte, ANFIS'e bir eğitim seti giriş modeli (bir girdi vektörü) sunulur, nöron çıktıları katman bazında hesaplanır ve kural sonuç parametreleri en küçük kareler eğitici tarafından tanımlanmaktadır. Sugeno tarzı bulanık çıkarımda, bir çıktı, y , doğrusal bir fonksiyondur. Bu nedenle, üyelik parametrelerinin değerleri ve bir P girdi-çıkı modellerinin eğitim seti verildiğinde, sonuç parametreleri açısından P doğrusal denklemlerini aşağıdaki şekilde oluşturulabilir:

$$\left\{ \begin{array}{l} y_d(1) = \bar{\mu}_1(1)f_1(1) + \bar{\mu}_2(1)f_2(1) + \dots + \bar{\mu}_n(1)f_n(1) \\ y_d(2) = \bar{\mu}_1(2)f_1(2) + \bar{\mu}_2(2)f_2(2) + \dots + \bar{\mu}_n(2)f_n(2) \\ \vdots \\ y_d(p) = \bar{\mu}_1(p)f_1(p) + \bar{\mu}_2(p)f_2(p) + \dots + \bar{\mu}_n(p)f_n(p) \\ \vdots \\ y_d(P) = \bar{\mu}_1(P)f_1(P) + \bar{\mu}_2(P)f_2(P) + \dots + \bar{\mu}_n(P)f_n(P) \end{array} \right. \quad (49)$$

Bu fonksiyonda m girdi değişkenlerinin sayısı, n ise kural katmanındaki nöronların sayısıdır ve $y_d(P)$, $x_1(p), x_2(p) \dots x_m(p)$, girdileri sunulduğunda ANFIS'in istenen toplam model çıktısıdır.

Matris denkleminde,

$$y_d = AK \quad (50)$$

y_d bir $P \times 1$ istenen çıktı vektörüdür,

$$y_d = \begin{bmatrix} y_d(1) \\ y_d(2) \\ \vdots \\ y_d(p) \\ \vdots \\ y_d(P) \end{bmatrix}$$

A , bir $P \times n(1 + m)$ matrisidir,

$$A = \begin{bmatrix} \bar{\mu}_1(1) & \bar{\mu}_1(1)x_1(1) & \dots & \bar{\mu}_1(1)x_m(1) & \dots & \bar{\mu}_n(1) & \bar{\mu}_n(1)x_1(1) & \dots & \bar{\mu}_n(1)x_m(1) \\ \bar{\mu}_1(2) & \bar{\mu}_1(2)x_1(2) & \dots & \bar{\mu}_1(2)x_m(2) & \dots & \bar{\mu}_n(2) & \bar{\mu}_n(2)x_1(2) & \dots & \bar{\mu}_n(2)x_m(2) \\ \vdots & \vdots & & \vdots & & \vdots & \vdots & & \vdots \\ \bar{\mu}_1(p) & \bar{\mu}_1(p)x_1(p) & \dots & \bar{\mu}_1(p)x_m(p) & \dots & \bar{\mu}_n(p) & \bar{\mu}_n(p)x_1(p) & \dots & \bar{\mu}_n(p)x_m(p) \\ \vdots & \vdots & & \vdots & & \vdots & \vdots & & \vdots \\ \bar{\mu}_1(P) & \bar{\mu}_1(P)x_1(P) & \dots & \bar{\mu}_1(P)x_m(P) & \dots & \bar{\mu}_n(P) & \bar{\mu}_n(P)x_1(P) & \dots & \bar{\mu}_n(P)x_m(P) \end{bmatrix}$$

ve k , bilinmeyen sonuç parametrelerinin bir $n(1 + m) \times 1$ vektörüdür,

$$k = [k_{10}k_{11}k_{12} \dots k_{1m}k_{20}k_{21}k_{22} \dots k_{2m} \dots k_{n0}k_{n1}k_{n2} \dots k_{nm}]^T$$

Genellikle, fonksiyonun eğitimde kullanılan girdi-çıkı kalıplarının sayısı P , sonuç parametrelerinin sayısından $(1 + m)$ kadar daha fazladır. Bu çıkan değer burada üst belirlenmiş bir problemle uğraşıldığı anlamına gelir ve bu nedenle 50 denkleminin kesin çözümünü bile karşılayamamaktadır. Bunun yerine, k 'nin en küçük kareler tahmini bulunmalı; karesel hatayı en aza indiren k^* , $\|AK - y_d\|^2$ ifadesidir. Bu durum ters teknik kullanılarak yapılmaktadır.

k^* denklem 51 ile ifade edilmiştir.

$$k^* = (A^T A)^{-1} A^T y_d \quad (51)$$

Denklemden A^T , A 'nın devrik ve $(A^T A)^{-1} A^T$, $(A^T A)$ tekil değilse A 'nın sözde tersidir.

Kural ise; sonuç parametreleri belirlenir belirlenmez, gerçek bir ağ çıkış vektörü, y hesaplanabilir ve hata vektörü “ e ” belirlenebilmektedir.

Hata vektörü e denklem 52 ile ifa edilmiştir.

$$e = y_d - y \quad (52)$$

Geriye geçişte, geri yayılım algoritması uygulanır. Hata sinyalleri geri yayılır ve öncül parametreler zincir kuralına göre güncellenmektedir.

Örneğin, nöron A1'de kullanılan çan eğrisi fonksiyonun a parametresine uygulanan bir düzeltme ele alınarak incelenmiştir. Zincir kuralını aşağıdaki şekilde ifade edilebilir:

$$\Delta a = -\alpha \frac{\partial E}{\partial a} = -\alpha \frac{\partial E}{\partial e} \times \frac{\partial e}{\partial y} \times \frac{\partial y}{\partial (\bar{\mu}_i f_i)} \times \frac{\partial (\bar{\mu}_i f_i)}{\partial \bar{\mu}_i} \times \frac{\partial \bar{\mu}_i}{\partial \mu_i} \times \frac{\partial \mu_i}{\partial \mu_{iA1}} \times \frac{\partial \mu_{iA1}}{\partial a} \quad (53)$$

Burada denklem 53'te; v öğrenme oranı ve E ise ANFIS çıkış nöronu için karesi alınmış hatanın anlık değerini göstermektedir. Bu aşağıda şekildeki 54 denklemi ile ifade edilmiştir.

$$E = \frac{1}{2} e^2 = \frac{1}{2} (y_d - y)^2 \quad (54)$$

Bu durumda Δa 55 no'lu denklem şeklini almıştır.


$$\Delta a = -\alpha (y_d - y) (-1) f_i \frac{\bar{\mu}_i (1 - \bar{\mu}_i)}{\mu_i} \times \frac{\mu_i}{\mu_{iA1}} \times \frac{\partial \mu_{iA1}}{\partial a} \quad (55)$$

Bu 55 no'lu denklemde;

$$\frac{\partial \mu_{iA1}}{\partial a} = \mu_{A1}^2 \times \frac{2b}{c} \times \left(\frac{x1 - a}{c} \right)^{2b-1}$$

İfadesi ile b ve c parametrelerine uygulanan düzeltmeleri elde edilebilmektedir.

Jang tarafından önerilen ANFIS eğitim algoritmasında hem öncül parametreler hem de sonuç parametreleri optimize edilmiştir. İleri geçişte, önceki parametreler sabit kalırken sonuç parametreleri ayarlanmaktadır. Geriye geçişte, önceki parametreler ayarlanırken, sonuç parametreleri sabit tutulmaktadır. Bununla birlikte, bazı durumlarda, girdi-çıkı veri seti nispeten küçük olduğunda, üyelik fonksiyonları bir uzman tarafından tanımlanabilmektedir. Bu gibi durumlarda, bu üyelik fonksiyonları eğitim süreci boyunca sabit tutulur ve sadece sonuç parametreleri ayarlanmaktadır (Schuler ve Jang, 2007). ANFIS'in olağanüstü bir genelleme ve hızla yakınsama yeteneği bulunmaktadır. Bu özellikle çevrimiçi öğrenmede önemlidir. Sonuç olarak, Jang'ın modeli ve çeşitleri, özellikle uyarlamalı kontrolde çok sayıda uygulanmaktadır. Şekil 25, ANFIS tahmin modelini geliştirmek için genel ANFIS sürecini göstermektedir.




Şekil 25. ANFIS test adımının akış şeması (Alnajjar ve Üçüncü, 2022).

2.4. Veri Seti


Atıksu arıtma tesisinin giriş havuzundan alınan proses verileri, modelin oluşturulmasında kullanılan parametrelerdi. Samsun Doğu İleri Biyolojik AAT'nin 2014-2018 yıllarına ait bir yıllık verileri kullanılan veri setini oluşturmakta olup, günlük ölçüm verileri takvime göre düzenlenmiştir. Her parametrenin istatistiksel varyasyon aralığı araştırıldı ve ölçüm hataları ve mantıksal sınır dışı değerler arandı. Veri seti, eksik ölçüm değerlerine sahip parametreleri hariç tutmaktadır. Tablo 5, analizde kullanılan verilere ilişkin istatistiksel bilgileri vermektedir. Analizde kullanılan parametrelerin zaman değişimi grafikleri Şekil 26, 27, 28, 29, 30, 31 32, 33, 34, 35, 36, 37, 38, 39, 40,41 ve 42'de gösterilmektedir.

Tablo 5. Atıksu Arıtımında girdi ve çıktı değişkenlerin istatistiksel özellikleri.


İstatistiksel analiz			Minimum	Maksimum	Ortalama ($\bar{x}$)	Standart sapma (σ)	Varyans (S^2)
GİRDİLER	T (°C)		7.20	23.60	14.62	5.77	33.34
	ÇO (mg/L)		1.04	2.25	1.68	0.33	0.11
	HRT (Sa)	Biyo-fosfor havuzları (anaerobik)	1.43	2.82	1.95	0.32	0.10
		Havalandırma havuzları (anoksik-oksik)	28.90	56.95	39.33	6.37	40.52
		Son çökeltim havuzları	5.60	11.04	7.62	1.23	1.52
	İletkenlik (µs/cm)		1179.00	2336.40	1618.77	279.80	78285.47
	Q (m³/Gün)		89338.23	176068.90	132500.82	19800.25	392049824.27
	pH (-)		6.97	8.03	7.50	0.30	0.09
	BOİ (mg/L)		103.00	231.03	146.75	20.33	413.34
	TN (mg/L)		29.34	43.89	35.69	3.13	9.80
	TP (mg/L)		3.31	5.10	4.31	0.46	0.21
	AKM (mg/L)		109.10	223.23	174.77	23.59	556.56
ÇIKTILAR	BOİ (mg/L)		3.20	17.29	9.90	2.24	5.01
	TN (mg/L)		4.42	8.87	5.99	1.19	1.41
	TP (mg/L)		0.23	0.98	0.57	0.17	0.03
	AKM (mg/L)		7.29	17.57	10.21	2.56	6.55
	pH (-)		6.72	7.78	7.25	0.30	0.09




Şekil 26. Samsun Doğu İleri Biyolojik AAT Sahasında Hava Sıcaklık değişimi




Şekil 27. Samsun Doğu İleri Biyolojik AAT giriş havuzu ÇO (mg/L) ölçümlerizamana bağlı değişimi




Şekil 28. Samsun Doğu İleri Biyolojik AAT giriş havuzu Biyo-fosfor havuzları (anaerobik)- HRT ölçümlerinin zamana bağlı değişimi




Şekil 29. Samsun Doğu İleri Biyolojik AAT giriş havuzu Havalandırma havuzları (Anoksik-Oksik)-HRT (Sa) ölçümlerinin zamana bağlı değişimi




Şekil 30. Samsun Doğu İleri Biyolojik AAT giriş havuzu Son çökeltim havuzları HRT (Sa) ölçümlerinin zamana bağlı değişimi




Şekil 31. Samsun Doğu İleri Biyolojik AAT giriş havuzu iletkenlik ölçümlerinin zamana bağlı değişimi




Şekil 32. Samsun Doğu İleri Biyolojik AAT giriş havuzu debi ölçümlerin zamana bağlı değişimi




Şekil 33. Samsun Doğu İleri Biyolojik AAT giriş havuzu pH (-) ölçümlerin zamana bağlı değişimi




Şekil 34. Samsun Doğu İleri Biyolojik AAT giriş havuzu BOİ ölçümlerin zamana bağlı değişimi




Şekil 35. Samsun Doğu İleri Biyolojik AAT giriş havuzu TN ölçümlerin zamana bağlı değişimi




Şekil 36. Samsun Doğu İleri Biyolojik AAT giriş havuzu TP ölçümlerin zamana bağlı değişimi




Şekil 37. Samsun Doğu İleri Biyolojik AAT giriş havuzu AKM ölçümlerin zamana bağlı değişimi




Şekil 38. Samsun Doğu İleri Biyolojik AAT çıkışı BOİ ölçümlerin zamana bağlı Değişimi




Şekil 39. Samsun Doğu İleri Biyolojik AAT çıkış TN ölçümlerin zamana bağlı değişimi



Şekil 40. Samsun Doğu İleri Biyolojik AAT çıkış TP ölçümlerin zamana bağlı değişimi



Şekil 41. Samsun Doğu İleri Biyolojik AAT çıkış AKM ölçümlerin zamana bağlı değişimi



Şekil 42. Samsun Doğu İleri Biyolojik AAT çıkış pH (-) ölçümlerin zamana bağlı değişimi

2.4.1. Modellerin Giriş Parametrelerinin Belirlenmesi

Kullanılacak girdi parametrelerinin seçimi, model oluşturma sürecindeki en önemli adımlardan biridir. Bazı giriş parametreleri arasında karmaşık ilişkiler olabilmekte ve bu değişkenler arasında sıkı ilişkiler olabilmektedir. Mevcut modellerin alakasız verileri kullanması, model öğrenme güçlükleri yaratarak hata oranını yükseltmektedir. Hata oranı arttıkça modelin performansı düşmektedir. Araştırmanın bu bölümünde girdi verileri arasındaki korelasyon katsayıları hesaplanmıştır.

Bu bilgi, üç farklı model geliştirme kararına yol açmıştır. Her bir parametrenin BOİ, TN, TP, pH ve AKM'yi nasıl etkilediğini incelemek için modeller geliştirilmiştir. Bu geliştirilen modeller için girdi değerleri olarak Q, pH, T, HRT, BOİ, TN, TP, AKM ve ÇO seçilmiştir.

2.4.2. Veri Gruplarının Analizi

Bu çalışmada SASKİ tarafından işletilen Samsun Doğu İleri Biyolojik AAT'ne ait aylık analiz verileri kullanılmıştır. Tesiste parametre ölçümleri aylık olarak yapılmıştır.

FL, YSA ve ANFIS algoritmaları eğitimi yöntemlerinde kullanılan veriler eğitim, doğrulama ve test olmak üzere üç ayrı veri kümesine ayrılmıştır. Düzenlenmiş verilerin %70'i eğitim, %15'si doğrulama, %15' ise test kümesinde kullanılmıştır.

Kurulan modeller içinde birinci modellemede 7, ikinci modellemede 12, üçüncü modellemede ise 7 girdi parametresi ile 5 fonksiyon denklemi ele alınarak kullanılmıştır. Elde edilen OMH ve KHOK hata değerlerini içeren sonuçlar incelenerek ölçülen değere en yakın olan, en az hata değerini veren, fonksiyon için grafik ve tablolar oluşturulmuştur.

2.4.3. Çalışmada Kullanılan Değerlendirme Kriterleri

Model bulgularından elde edilen çıktı değerleri bir dizi faktör kullanılarak değerlendirilmiştir. Modelleri daha etkin bir şekilde karşılaştırmak ve sonuçları daha doğru değerlendirmek için çoklu değerlendirme kriterleri uygulanmıştır. Tahmin bulgularının doğruluğu, KHOK, OMH ve korelasyon katsayısı (R^2) kullanılarak değerlendirilmiştir. Bu kriterler arasındaki ilişkiler aşağıda olduğu gibi verilmiştir:

Karesel hatanın ortalama karekökü (KHOK)

$$KHOK = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{gözlenen} - x_{tahmin})^2} \quad (56)$$

Ortalama mutlak hata (OMH),

$$OMH = \frac{1}{N} \sum_{i=1}^N |x_{gözlenen} - x_{tahmin}| \quad (57)$$

Ortalama Mutlak Yüzde Hata(OMYH),

$$OMYH = \frac{1}{N} \sum_{i=1}^N \left| \frac{x_{gözlenen} - x_{tahmin}}{x_{gözlenen}} \right| \quad (58)$$

Medyan Mutlak Sapma(MMS),

$$MMS = \sum_{i=1}^N \frac{|x_{gözlenen} - Med(x)|}{N} \quad (59)$$

Ve korelasyon katsayısı (R^2)

$$R = \frac{\sum_{i=1}^N (x_{gözlenen} - \bar{x}_{gözlenen})(x_{tahmin} - \bar{x}_{tahmin})}{\left[\sum_{i=1}^N (x_{gözlenen} - \bar{x}_{gözlenen})^2 \right]^{1/2} \left[\sum_{i=1}^N (x_{tahmin} - \bar{x}_{tahmin})^2 \right]^{1/2}} \quad (60)$$

Şeklinde verilmiştir.

Bu denklemlerde;

$x_{gözlenen}$: Parametre değerinin gözlenmiş değerini;

x_{tahmin} : Parametre değerinin modellenmiş değerini;

N : veri sayısını;

$\bar{x}_{gözlenen}$: Parametre değerinin ortalamasını;

$\bar{x}_{tahmin}$: Parametre değerinin ortalamasını temsil etmektedir.


Şeklindedir.

3. BULGULAR

Bölüm 2'de özetlenen bulanık mantık, ANFIS ve yapay sinir ağları için modeller bu bölümde oluşturulur ve sonuçlar tablolar ve grafikler halinde gösterilir. SASKİ Doğu İleri Biyolojik AAT, geliştirilen modellerde kullanılan verileri elde edilmiştir.


3.1. Bulanık Mantık ile Parametreler Tahmini

Samsun Doğu İleri Biyolojik AAT'de en yüksek eliminasyona (BOI , TN, TP, AKM ve pH) neden olan operasyonel parametrelerin belirlenmesine yönelik denemelerin planlanması ve modellenmesi için MATLAB 2022b tarafından sunulan FL Toolbox(fuzzyLogicDesigner) sunulmaktadır. Tüm arıtma havuzları için (T , °C), ($ÇO$, mg/L), (HRT , Saat), (pH , -), (BOI_{in} , mg/L), (TN_{in} , mg/L), (TP_{in} , mg/L) ve (AKM_{in} , mg/L)'nin tümü, bulanık denetleyici için giriş değişkenleri olarak kabul edilmiştir. Bu nedenle, kontrol döngülerindeki değiştirilen değişkenler, çıktı değişkenleri olarak kabul edilen değişkenler olmuştur. Sonuç olarak (BOI_{out} , mg/L), (TN_{out} , mg/L), (TP_{out} , mg/L) ve (AKM_{out} , mg/L) çıkış değişkenlerdir. Giriş ve çıkışları bağlamak için MF'yi seçmek gereklidir. Bu çalışmada, Gauss MF'yi seçmek için bir Mamdani bulanık arayüz tekniği kullanılmıştır. “IF-THEN” koşulu, toplam 2187 kuralı çerçevelemek için kullanılır. Doğu İleri Biyolojik AAT'nin bulanık kontrolünün yapısı şekil 43'te gösterilmiştir. Durulaştırma tekniği olarak merkez yaklaşımı seçilmiş ve FI işlemi için Mamdani yöntemi kullanılmıştır.




Şekil 43. Doğu İleri Biyolojik AAT için bulanık kontrol yapısı.

Atıksuyun arıtılmasının iyileştirilmesi için, sonucun varyansına ilişkin verileri uzmanların uzman görüşüyle birleştirerek, öngörülen modele girdiler için bulanık MF'ler oluşturmak için dilsel değişkenler kullanılmaktadır. Tablo 6 ve Tablo 7'de gösterildiği gibi Türkiye'nin SKKY uyarınca dört kategoriye ayrılan tüm girdi parametreleri Şekil 44'te ve çıktı parametreleri için Düşük (L), Orta (M) ve Yüksek (H) Şekil 45'te dil değişkenlerinin olduğunu göstermektedir.



Şekil 44. Sürecin girdi değişkenleri için MF'ler



Şekil 45. BOİ, TN, TP ve AKM çıkış değişkenleri proses parametreleri için MF'ler

Tablo 6. Giriş değişkenlerine karşılık gelen Gauss-MF'lerinin parametreleri.

Girdiler	MF	b (Genişlik)	C (Merkez)
T _a (°C)	Low	8.4945	-5.00
	Mid	8.4945	15.00
	High	8.4945	35.00
ÇO (mg/L)	Low	1.0406	0.10
	Mid	1.0406	2.55
	High	1.0406	5.00
HRT (Saat)	Low	7.4072	35.93
	Mid	7.4072	53.37
	High	7.4072	70.81
pH(-)	Low	0.8495	5.00
	Mid	0.4247	6.50 and 8.00
	High	0.8495	9.00
BOİ (mg/L)	Low	42.4727	100.00
	Mid	42.4727	200.00
	High	42.4727	300.00
TN(mg/L)	Low	5.3091	25.00
	Mid	5.3091	37.50
	High	5.3091	50.00
TP(mg/L)	Low	0.6371	3.00
	Mid	0.6371	4.50
	High	0.6371	6.00
AKM(mg/L)	Low	42.4727	100.00
	Mid	42.4727	200.00
	High	42.4727	300.00
Q(m ³ /gün)	Low	12741.8182	100000.00
	Mid	12741.8182	130000.00
	High	12741.8182	160000.00
İletkenlik (µS/cm)	Low	297.3091	1100.00
	Mid	297.3091	1800.00
	High	297.3091	2500.00

Tablo 7. SKKY ve çıkış değişkenlerine bağlı Gauss-MF parametreleri (Resmî Gazete Tarihi: 31.12.2004 Resmi Gazete Numarası: 25687).

Çıktı	Birim	SKKY'ne göre Değerler	Üyelik Fonk.	b (Genişlik)	C (Merkez)
BOİ	(mg/L)	4	I	2	1
		8	II	2	6
		20	III	2	14
		>20	IV	2	20
TN	(mg/L)	0.5	I	0.7	0.5
		1.5	II	0.7	1.85
		5	III	0.7	3.25
		>5	IV	0.7	5
TP	(mg/L)	0.02	I	0.1	0.02
		0.16	II	0.1	0.2
		0.65	III	0.1	0.405
		>0.65	IV	0.1	0.65
AKM	(mg/L)	5	I	2	5
		15	II	2	11.6667
		30	III	2	23.3333
		>30	IV	2	30


Önerilen bulanık modelin Şekil 46'da gösterilen tahmin senaryosunda 2187 “İF THEN” kuralı kullanılmıştır. “AND” ve “OR”nın mantıksal eşleşmesi, Min ve Maks operatörleri kullanılarak değerlendirilmiştir. Fikirler ve kapsamlı prosedürler oluşturmak için uygun şekilde Min ve Maks operatörlerini kullanılmıştır. Durulaştırma için ağırlık merkezi yaklaşımı kullanılmıştır.

Rule	Weight	Name
1 If T(a)(C) is Low and DO(mg/L) is Low and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is IV	1	rule1
2 If T(a)(C) is Mid and DO(mg/L) is Low and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is IV	1	rule2
3 If T(a)(C) is High and DO(mg/L) is Low and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is IV	1	rule3
4 If T(a)(C) is Low and DO(mg/L) is Mid and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is IV	1	rule4
5 If T(a)(C) is Mid and DO(mg/L) is Mid and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule5
6 If T(a)(C) is High and DO(mg/L) is Mid and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule6
7 If T(a)(C) is Low and DO(mg/L) is High and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule7
8 If T(a)(C) is Mid and DO(mg/L) is High and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule8
9 If T(a)(C) is High and DO(mg/L) is High and HRT(hr) is Low and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule9
10 If T(a)(C) is Low and DO(mg/L) is Low and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is IV	1	rule10
11 If T(a)(C) is Mid and DO(mg/L) is Low and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule11
12 If T(a)(C) is High and DO(mg/L) is Low and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule12
13 If T(a)(C) is Low and DO(mg/L) is Mid and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule13
14 If T(a)(C) is Mid and DO(mg/L) is Mid and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule14
15 If T(a)(C) is High and DO(mg/L) is Mid and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is II	1	rule15
16 If T(a)(C) is Low and DO(mg/L) is High and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is II	1	rule16
17 If T(a)(C) is Mid and DO(mg/L) is High and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is I	1	rule17
18 If T(a)(C) is High and DO(mg/L) is High and HRT(hr) is Mid and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is I	1	rule18
19 If T(a)(C) is Low and DO(mg/L) is Low and HRT(hr) is high and pH is Low and TN(mg/L) is Low and Q(m3/day) is Low and CONDUCTIVITY(us/cm) is Low then TN out(mg/L) is III	1	rule19

Şekil 46. FIS kurallarına bir örnek



Modelin çıktısı, oluşturulan değerdir. BOİ, TN, TP ve AKM, verim sınırını belirlemek için kullanılabilecek birkaç olgusal sınırdır. FIS Kod Editor Matlab bulanık kümeleri oluşturduktan, üyeliklerini ve bulanık kurallarını değiştirdikten sonra Şekil 47'de gösterilen net sayıyı elde edilebilmektedir.


Şekil 48'de görüldüğü gibi, FLC tekniği, girdilerin çıktı parametrelerini nasıl etkilediğini izlemek için çeşitli yüzey görünümleri sağlamaktadır. Tahmin edilen modelin etkilene bilirliliği, üretilen verilerdeki test verileri kullanılarak, verimler ve beklenen özellikleri dikkate alınarak değerlendirilmiştir. FL ortamında Doğu İleri Biyolojik AAT tarafından çevreye deşarj edilen atıksuyun kalitesini belirlemek için geliştirilen model her bir girdi ve çıktı verisi için oluşturulmuştur. Kullanılan verileri dikkate alındığında, modelin sonucu anlamlı çıkmıştır. Mantıksal modele uygun olarak artırılmış atıksuyun alıcı ortama verilmesinin kontrol etmek için kolayca ölçülebilir bazı limitler belirlenmiştir. Düzenlenen modelin beklenen kapasitesi, hazırlanan bilgilerdeki test verileri kullanılarak ve verimler ile tahmin edilen değerler karşılaştırılarak değerlendirilmiştir. Yapılandırılmış bulanık modelin uygulanabilirliğini göstermek için birkaç veri analizi ve ilgili değerlendirmeler yapılmıştır. Yüzey figürü BOİ, TN, TP, AKM, sıcaklık, pH, Q, HRT, iletkenliği ve çözünmüş oksijen arasındaki ilişkiyi göstermektedir. Sonuçlar deneysel ve gözlemlenen veriler arasında önemli derecede uygunluk olduğunu göstermiştir.



Şekil 47. Doğu İleri Biyolojik AAT süreci için FL kontrol sonuçları

Şekil 47''nini devamı





Şekil 48. Girdi değişkenlerinin BOİ, TN, TP ve AKM üzerindeki etkisinin yüzeysel veri analizi.

Üç boyutlu kontrol yüzeyi, verili söylem evreninin çeşitli kuralları tarafından yönetilen girdi ve çıktı tutarlılığını içermektedir. MATLAB-b'de kuralları uygulamak için FL tasarımcı araçları ve Mamdani tipi FI yaklaşımı kullanıldı. 3 boyutlu bir yüzey grafiği, AAT'deki BOİ, TN, TP ve AKM arasındaki etkileşimleri ve girdileri göstermektedir. Test deneyinden ve bulanık modelden elde edilen sonuçlar karşılaştırılmış; Doğu İleri Biyolojik AAT sonuçlarının 3 boyutlu yüzey izi ve gerçek verilerle karşılık gelmiştir.

3.1.1. Değerlendirme

Bu çalışmada, Türkiye'nin Samsun İli Samsun Doğu İleri Biyolojik AAT'sinden elde edilen tesis verilerini analiz etmek için FL modeli kullanılmıştır. FL modelinin doğruluğunu göstermek için gözlemlenen ve tahmin edilen değerler birbiri ile karşılaştırılmıştır. FL modeli kullanılarak yüzey haritaları da üretilmiş ve Doğu İleri Biyolojik AAT için ideal değer bulunmuştur. Öte yandan, Doğu İleri Biyolojik AAT'nin modellenmesi, sistemin daha iyi bilinmesine, tanınmasına ve AAT'lerin performansında bir iyileşmeye yol açabilmektedir. Ancak, sürecin karmaşıklığı ve belirsizliği göz önüne alındığında, geleneksel deterministik modelleri kullanmak oldukça zordur. Yapay zekâ (YZ) veya veriye dayalı metodolojiler olarak bilinen farklı bir modelleme araçları kategorisi, sistemin yapısı veya mevcut durumu hakkında bilgi gerektirmemektedir. Öte yandan, bu yöntemlerin kalitesi, verilerin doğruluğundan önemli ölçüde etkilenmektedir. Özellikle FL modellerinin faydası, sistem hakkında önceden bilgi sahibi olmadan atıksu giriş-çıkış konsantrasyonlarını tahmin etme kapasiteleri bulunmaktadır. Bu inceleme, Mamdani modelinin AAT, BOİ, TN, TP ve AKM sınırlarını ne kadar doğru tahmin ettiğini göstermiştir. Ek olarak, girdiler ve çıktılar arasındaki matematiksel ilişkiler hakkında yapılan varsayımlar bulunmamaktadır. Bu modeller, sürecin fiziksel durumunu açıkça hesaba katmadan, girdiler ve sonuçlar arasındaki ilişkileri de belirleyebilmektedir. Bu çalışmamın ana amacı, YZ tekniklerinin atıksu arıtma sistemlerini simüle etmek için kullanılabileceğini göstermiştir. Çalışma aynı zamanda ileri atıksu arıtmadaki kirletici maddelerin giderme oranları ortaya koymuştur. Atıksu arıtma tesislerinin daha güvenilir, verimli ve sürdürülebilir olacak şekilde çağdaştırma, iyileştirme konusunda karar vericilere ve atıksu ile ilgilenen tüm mühendislere yardımcı olacaktır. FL modeli (Mamdani) tatmin edici olmuş ve arıtılmış atıksuyun (çıkış) alıcı ortama verilmesinde SKKY'deki değerlerinin altında kalınmıştır.

3.2. Yapay Sinir Ağı ile Parametrelere Tahmini

Bu çalışmada kullanılan veriler Doğu İleri Biyolojik AAT laboratuvarında yapılan araştırmalardan alınmıştır. Giriş ham atıksu ve arıtılmış atıksu (çıkış) için BOİ, TN, TP, AKM, T, ÇO, pH, HRT, Q ve iletkenlik tesis atıksu laboratuvarında Eylül 2014- Aralık 2018 tarihleri arasında toplanmıştır. Toplanan veriler bu tez çalışması kapsamında çok ayrıntılı olarak incelenmiştir. Arıtma tesisi performansı için çeşitli modelleme alternatifleri karşılaştırıldıktan sonra, ham giriş atıksu kalitesi ile nihai arıtılmış atıksu (çıkış) kalitesi arasında bağlantı kurulmuştur. Tablo 8’de, işletmeye giren veriler ve arıtılan atıksu için tanımlayıcı istatistiksel analizi göstermektedir. Sinir ağları, bilimsel ve mühendislik hesaplamaları için yüksek performanslı etkileşimli bir yazılım paketi olan MATLAB® (R2022b) (MATLAB-b, 2022) yazılım sinir ağı araç kutusu kullanılarak tasarlanmış, oluşturulmuş, eğitilmiş ve test edilmiştir. Veri ön işleme ve organizasyon işlemleri de Microsoft® Excel® for Microsoft 365 MSO kullanılarak gerçekleştirilmiştir. Doğu İleri Biyolojik AAT'nin çıkış atıksu kalitesi YSA modellerinin çıktısı, girdileri ise ham atıksu kalitesi parametreleridir. Çıktılar, mevcut verilerin kapsamlı bir incelemesine dayalı olarak BOİ, TN, TP ve AKM atıksu parametreleri olarak tanımlanmıştır. Giriş değişkenlerini oluşturan on iki ham atıksu (giriş) parametresi. BOİ, TN, TP, AKM, T, ÇO, pH, HRT, Q ve iletkenlik, Şekil 49'da gösterildiği gibi ham atıksuyun parametreleridir. Veriler, bir eğitim seti, bir doğrulama seti ve bir test seti olarak üçe sınıfa ayrılmıştır. Yapay Sinir Ağının genelleştirme kapasitesini artırmak için erken durdurma stratejisi kullanılmıştır.

Tablo 8. AAT'den elde edilen sonuçların bir özeti

Girdiler										
TP (mg/L)	TN (mg/L)	BOİ (mg/L)	pH	Q (m³/Gün)	conductivity µS/cm	HRT (Sa)			ÇO (mg/L)	Ta (°C)
						Son çökeltim havuzları	Havalandırma havuzları	Biyofosfor havuzları		
3.51	36.89	116.98	7.38	109296.57	2336.40	9.02	46.55	2.31	1.23	20.30
3.90	39.98	180.33	7.33	131236.61	2208.87	7.51	38.77	1.92	1.54	16.50
3.93	39.24	231.03	7.80	129814.43	2017.57	7.60	39.19	1.94	1.82	12.70
3.48	34.01	132.00	7.25	90461.68	2152.52	10.90	56.24	2.79	1.93	9.40
3.70	36.32	135.12	7.96	146457.68	1248.81	6.73	34.74	1.72	2.06	7.20
3.60	36.66	125.26	7.35	146532.11	1339.93	6.73	34.72	1.72	2.13	7.20
3.54	37.62	124.73	7.70	155486.65	1557.06	6.34	32.72	1.62	1.94	8.10
3.31	35.15	116.44	7.15	176068.90	1355.20	5.60	28.90	1.43	1.86	11.30
4.63	43.61	159.53	7.16	120352.52	1724.65	8.19	42.28	2.09	1.75	15.60
4.73	43.89	189.79	7.76	151272.80	1987.17	6.52	33.63	1.67	1.19	20.20
4.25	39.25	138.14	6.98	155321.29	2128.71	6.35	32.76	1.62	1.06	23.20
4.82	38.13	152.84	7.03	145172.84	1991.77	6.79	35.05	1.74	1.04	23.60
4.42	36.21	139.93	7.90	140601.97	1884.57	7.01	36.19	1.79	1.07	20.30
4.14	33.70	125.57	7.54	143115.71	1367.03	6.89	35.55	1.76	1.35	16.50
3.98	31.78	120.10	7.53	138194.60	1702.10	7.14	36.82	1.82	1.49	12.70

Tablo 8'in devamı

6.52	33.63	1.67	1.96	9.40
7.36	37.96	1.88	2.07	7.20
7.33	37.84	1.87	2.25	7.20
6.34	32.70	1.62	1.98	8.10
5.85	30.19	1.50	1.86	11.30
6.12	31.60	1.56	1.78	15.60
5.95	30.70	1.52	1.36	20.20
6.06	31.27	1.55	1.21	23.20
7.40	38.20	1.89	1.11	23.60
7.61	39.24	1.94	1.35	20.30
8.06	41.58	2.06	1.68	16.50
7.90	40.78	2.02	1.97	12.70
9.77	50.43	2.50	1.99	9.40
9.03	46.59	2.31	2.12	7.20
9.10	46.97	2.33	2.16	7.20
8.00	41.26	2.04	2.05	8.10
7.28	37.57	1.86	1.94	11.30
9.80	50.58	2.51	1.73	15.60
8.08	41.67	2.06	1.38	20.20
7.41	38.25	1.89	1.26	23.20

Sıra No	Çıktılar					AKM (mg/L)
	pH	AKM (mg/L)	TP (mg/L)	TN (mg/L)	BOİ (mg/L)	
1	7.13	13.90	0.71	5.96	3.20	174.70
2	7.08	15.23	0.71	7.52	3.49	177.71
3	7.55	17.57	0.98	8.48	4.24	223.23
4	7.00	16.40	0.90	8.07	6.16	157.26
5	7.71	16.32	0.62	8.09	5.22	170.03
6	7.10	12.96	0.71	8.87	8.15	153.57
7	7.45	11.23	0.32	8.68	9.61	152.81
8	6.90	9.80	0.47	8.22	10.07	167.10
9	6.91	11.94	0.53	6.76	10.94	212.45
10	7.51	12.70	0.40	6.94	11.86	195.27
11	6.73	10.90	0.45	6.76	11.63	139.97
12	6.78	10.39	0.85	6.94	11.47	204.65
13	7.65	10.40	0.85	6.76	11.55	160.10
14	7.29	9.23	0.84	6.47	11.99	134.39
15	7.28	10.90	0.85	6.39	12.17	141.80

Tablo 8'in devamı


16	7.23	17.29	0.64	8.51	17.29	140.68	3.56	31.60	117.06	7.48	151272.45	1462.97
17	7.11	12.58	0.44	5.50	10.67	144.81	3.81	30.72	131.70	7.36	134028.61	1314.90
18	6.93	9.59	0.42	4.78	9.27	130.59	4.22	31.13	127.30	7.18	134453.69	1339.34
19	7.42	10.00	0.50	4.71	9.17	109.10	3.62	29.97	103.00	7.67	155603.77	1440.26
20	7.33	8.87	0.68	4.42	10.13	156.73	4.21	30.19	143.80	7.58	168521.70	1581.17
21	7.00	10.50	0.52	5.22	10.24	162.00	3.68	29.51	134.00	7.25	161022.48	2097.29
22	7.14	9.20	0.56	4.99	10.43	162.00	3.88	29.34	134.00	7.39	165721.77	1987.63
23	7.18	9.23	0.60	5.35	10.05	152.55	3.91	30.54	147.35	7.43	162706.39	1845.00
24	7.23	8.06	0.69	6.31	8.82	180.55	4.55	33.19	153.77	7.48	133192.03	1696.32
25	7.07	9.13	0.71	5.51	9.90	176.53	4.78	35.96	147.45	7.32	129658.27	1602.70
26	7.00	8.26	0.68	5.24	9.62	194.94	4.43	38.05	151.82	7.25	122358.52	1704.03
27	6.91	11.93	0.65	5.64	10.84	200.90	4.95	39.34	177.62	7.16	124775.83	1655.70
28	6.77	11.80	0.66	4.74	9.67	156.71	4.43	35.96	144.03	7.02	100897.29	1438.03
29	7.25	8.52	0.67	4.48	9.04	177.16	4.08	36.03	142.12	7.50	109210.81	1197.10
30	6.72	7.29	0.64	4.94	8.66	160.96	4.14	34.00	139.36	6.97	108329.43	1394.18
31	6.78	7.35	0.35	5.39	9.04	174.26	4.60	36.37	137.85	7.03	123323.58	1274.03
32	7.00	8.27	0.23	4.90	8.79	170.90	4.52	35.67	138.04	7.25	135422.27	1424.17
33	7.71	7.32	0.60	5.35	9.36	182.84	4.53	35.87	147.48	7.96	100593.97	1220.58
34	7.40	7.80	0.59	6.22	10.53	158.33	4.48	35.72	152.61	7.65	122106.93	1502.27
35	7.62	8.16	0.34	4.83	10.05	173.94	4.77	37.01	155.44	7.87	133032.58	1485.42

Tablo 8'in devamı

189.29	5.09	37.21	161.77	7.83	137377.81	1513.97	7.18	37.04	1.83	1.21	23.60
186.13	4.88	37.17	159.84	7.57	121632.87	1514.63	8.11	41.83	2.07	1.46	20.30
186.10	4.63	37.23	152.64	8.03	134038.52	1392.16	7.36	37.96	1.88	1.58	16.50
201.63	5.10	36.02	153.94	7.89	111369.90	1431.67	8.85	45.69	2.26	1.67	12.70
193.00	4.56	35.76	147.67	7.77	102792.42	1433.55	9.59	49.50	2.45	1.84	9.40
180.00	3.99	32.84	133.33	7.36	130794.77	1179.00	7.54	38.90	1.93	1.98	7.20
210.00	4.43	34.81	151.02	7.65	128470.46	1493.89	7.68	39.60	1.96	2.03	7.20
214.52	4.45	33.94	153.40	7.89	148172.32	1655.10	6.65	34.34	1.70	2.01	8.10
192.80	4.77	35.42	152.58	7.45	132974.83	1877.10	7.42	38.26	1.90	1.87	11.30
197.03	4.81	37.87	165.33	7.49	134435.90	1653.74	7.33	37.85	1.87	1.77	15.60
198.83	4.83	37.54	159.33	7.66	132773.77	1783.17	7.43	38.32	1.90	1.54	20.20
196.42	4.65	37.29	158.33	7.09	126288.39	1629.71	7.81	40.29	2.00	1.43	23.20
172.39	4.74	38.46	157.31	7.80	135347.90	1754.65	7.29	37.59	1.86	1.38	23.60
182.33	4.60	37.04	159.04	7.68	118811.93	1710.93	8.30	42.82	2.12	1.43	20.30
175.16	4.57	36.22	153.17	7.99	89338.23	1522.00	11.04	56.95	2.82	1.69	16.50
182.60	4.22	36.29	149.40	7.89	98709.30	1503.77	9.99	51.55	2.55	1.83	12.70
198.32	4.48	36.17	149.11	7.36	151094.77	1461.74	6.53	33.67	1.67	1.94	9.40
109.10	3.31	29.34	103.00	6.97	89338.23	1179.00	5.60	28.90	1.43	1.04	7.20
223.23	5.10	43.89	231.03	8.03	176068.90	2336.40	11.04	56.95	2.82	2.25	23.60
174.77	4.31	35.69	146.75	7.50	132500.82	1618.77	7.62	39.33	1.95	1.68	14.62
23.59	0.46	3.13	20.33	0.30	19800.25	279.80	1.23	6.37	0.32	0.33	5.77
556.56	0.21	9.80	413.34	0.09	392049824.27	78285.47	1.52	40.52	0.10	0.11	33.34


Tablo 8'in devamı

36	7.58	9.00	0.39	4.68	10.06
37	7.32	8.80	0.62	5.93	10.61
38	7.78	8.42	0.41	5.65	10.60
39	7.64	8.50	0.60	5.43	11.23
40	7.52	9.58	0.75	6.49	12.63
41	7.11	9.74	0.58	5.72	11.14
42	7.40	8.36	0.47	5.69	10.54
43	7.64	8.29	0.30	5.43	10.35
44	7.20	8.70	0.47	5.34	10.25
45	7.24	8.68	0.38	5.36	10.86
46	7.41	9.03	0.42	4.58	11.42
47	6.84	8.52	0.36	5.35	10.40
48	7.55	8.71	0.33	4.91	10.31
49	7.43	8.70	0.65	5.52	10.20
50	7.74	9.06	0.67	5.30	10.14
51	7.64	8.90	0.39	5.82	9.85
52	7.11	8.90	0.66	6.15	10.68
Mini	6.72	7.29	0.23	4.42	3.20
Maks	7.78	17.57	0.98	8.87	17.29
Ortal	7.25	10.21	0.57	5.99	9.90
Stan	0.30	2.56	0.17	1.19	2.24
varya	0.09	6.55	0.03	1.41	5.01



Şekil 49. Samsun Doğu İleri Biyolojik AAT için Kullanılan YSA Yapısı

Verilerin modele beslendiği ve girdilerin ağırlıklı toplamının hesaplanmasının yapıldığı giriş katmanı, verilerin işlendiği gizli katman ve katmanlar YSA sonuçlarının oluşturulduğu çıkış katmanı temel yapısını oluşturmaktadır. Bir YSA modelinin Karmaşık bir sinir ağı tahmin modeli, ağı verimliliğini azaltabilecek zayıf eğitime karşı savunmasızdır. Tek bir gizli katmana sahip bir İleri Beslemeli Geri Yayılma (BP) sinir ağı modelinin, eğer gizli katman yeterli sayıda nöron içeriyorsa, az sayıda süreksizliğe sahip doğrusal olmayan fonksiyonları doğru bir şekilde tahmin edebildiğini gösterilmiştir (Hong ve Bhamidimarri, 2003). Bu nedenle; bu araştırmada gizli katmanlı BP modeli kullanılmıştır. Gizli katmandaki nöronların sayısı, literatüre göre çeşitli şekillerde sayılabilir, ancak bu yaklaşımların tümü tamamen ampiriktir ve genel olarak kullanılamamaktadır. Sonuç olarak, gizli katmandaki 40 nöron, çok geniş bir literatürden seçilmiştir (Pai, 2008) ve gizli katmandaki nöron transfer fonksiyonunun hiperbolik “tansig” veya “logsig sigmoid” fonksiyonlar olduğuna karar verilmiştir. Optimum model yapısı, deneme yanılma yöntemi kullanılarak bulunmuştur. Tüm sinir ağının çıkış karakteristiği, son katmandaki transfer fonksiyonundan önemli ölçüde etkilenebilmektedir. Tahmini çıktı, çıktı katmanı için aynı Sigmoid işlevi kullanılarak gerçek olarak geri kazanılmaktadır. Bununla birlikte, doğrusal bir fonksiyon, çıktıyı negatif değerden pozitif değere ve sonsuza kadar tahmin ederek çıktıları yeniden eşleştirmekten kaçınmaktadır (Hanbay vd., 2008). Sonuç olarak, çıkış katmanı nöronları için transfer fonksiyonu olarak doğrusal bir fonksiyon seçilmiştir. Yapay sinir ağı, eğitim seti kullanılarak eğitilmiştir. Doğrulama seti kullanılarak eğitim setinin hatası izlenmiştir. Doğrulama setinin doğrulama hatası, genellikle eğitim başlangıcında eğitim hatasındaki artışla birlikte azalmıştır. Bununla birlikte, ağ çok fazla miktarda eğitilmişse, eğitim hatası azalırken bile, doğrulama hatası istikrarlı bir şekilde artmıştır. Doğrulama hatası en düşük olan ağ bu noktada en iyi model olmuş ve ağ eğitimi sonlandırılmıştır. Model son olarak test seti kullanılarak doğrulanmıştır. Bu çalışmada, iterasyonların hedef değeri 1000 olmuş ancak YSA modeli Şekil 50'de gösterildiği gibi 7 iterasyonda (minimum hata) sonlandırılmıştır.




Şekil 50. Programdaki sinir ağı eğitim arayüzü

Arıtılmış atıksu (çıkış) için BOİ, TN, TP, AKM ve pH tahmini için en iyi ağ yapısını belirlemek üzere 12 giriş ve 5 çıkışlı bir ağ oluşturulmuştur. Tablo 9, YSA ve OKH'nın tahmin sonuçlarını tesiste toplanan verilerle karşılaştırmaktadır. Modelin istatistiksel performans sonuçları Tablo 9'da gösterilmektedir. Bu tablodaki değerleri elde etmek için tüm yapılandırmalar hesaplanmaktadır (eğitim, test ve doğrulama). Hata seviyeleri makul ve çıktı tahmini için istatistiksel performansa dayalı olarak tahmin edilen aralık içinde kalmıştır. Sonuç olarak, YSA modelinin verileri etkili bir şekilde genelleştirdiği ve yeni veriler (eğitim veya test setinden gelmeyen veriler) sunulduğunda muhtemelen kesin tahminler yapma yeteneğine sahip olduğu sonucuna varılmıştır.


Tablo 9. YSA Modeli çıktı tahmin performansı

Hata	Gözlem ve YSA arasındaki hata				
	BOİ (mg/L)	TN (mg/L)	TP (mg/L)	AKM (mg/L)	pH (-)
MMS	0.6223	0.4099	0.0653	0.6786	0.0534
OKH	0.6159	0.2893	0.0057	0.7576	0.0060
KOKH	0.7848	0.5379	0.0758	0.8704	0.0772
OMYH	0.0710	0.0708	0.1276	0.0690	0.0074
R ²	0.8838	0.8080	0.8099	0.8876	0.9396

Şekil 51 her konfigürasyondan en iyi performans gösteren model için doğrusal regresyon grafiğini göstermektedir. MSE değerlerine dayalı olarak, Şekil 51’de öngörülen ve gerçek veriler arasındaki karşılaştırma grafiğini gösterir ve YSA modeli uygun bir uyum göstermiştir. Sonuç olarak 12 nöronlu girdi katmanı, 40 nöronlu gizli katman ve 5 çıktı katmanı nöronlu çıktı tahmini tasarımının ideal tasarım olacağına karar verilmiştir. Bu çalışmada Samsun Doğu İleri Biyolojik AAT'nin dinamik davranışını araştırma ve süreç değişkenleri arasında var olan karmaşık etkileşimleri yakalamak için bir YSA modelinin nasıl uygulanacağı konusu ele alınmıştır. Bazı önemli çıkış suyu kalitesi parametrelerinin özelliklerine ilişkin önceki gözlemlere dayalı olarak arıtma tesis performansını tahmin etmek için bir YSA modeli oluşturarak, tesis güvenli bir şekilde çalıştırılabilir ve kontrol edilebilmektedir. Ağın eğitim arayüzü MATLAB’deki regresyon butonu, ağın çıktıları ve ilgili hedefleri arasında doğrusal bir tekraralama gerçekleştirmektedir. En iyi model regresyon sonuçları Şekil 50’de verilmiştir. Yapılan çalışmada; Test (R-değeri= 0,88712), doğrulama (R-değeri= 0,90496) ve eğitim (R-değeri= 0,98645) için çıktının hedefleri yakından takip ettiğini gösterilmiştir. Bu sayılar, 0,95294 R-değeri ile beş çıkışlı bir toplam cevaba dönüştürülmektedir. YSA modelinin doğrulama ve test veri seti için tahmin sonuçlarının iyi olduğu belirlenmiştir (Şekil 52).




Şekil 51. YSA modeli için gerçek verilerin ve tahmin edilen değerlerin dağılımı (Eniyi performans için regresyon grafiği)




Şekil 52. BOİ, TN, TP, AKM ve pH için gerçek ve tahmin edilen yüzde azalma değerlerinin dağılımını gösteren grafiği.

Şekil 52'inin devamı




BOİ, TN, TP, AKM ve pH'ı tahmin etmek için LM yöntemiyle bütünleşmiş geri yayımlı geleneksel bir YSA modeli oluşturulmuştur. Gizli katmanda 40 nöron bulunan MLP tek gizli katman tabanlı çıktı tahmin modeli, yukarıda belirtilen aday modeller arasında AAT'nin performansını tahmin etmek için en iyi modeldir, çünkü aksine eğitim, doğrulama ve test setleri için R değerleri birbirine daha yakındır ve minimumdur. Ölçülen çıkış değerlerinin MLP ağının beklenen değerlerine göre görselleştirilmesi, performans istatistiklerinin incelenmesine destek sağlar. MLP ve RBF sinir ağlarının performansı Şekil 53 ve Şekil 54'de verilmiştir. Eğitim, doğrulama ve test veri kümeleri için iterasyon sayısına karşı OKH grafiği Şekil 53'te verilmiştir. YSA simülasyonu, minimum OKH'ye ulaşıldığında veya maksimum eğitim iterasyon sayısı kullanıldığında sona ermektedir. Eğitim süreci 2. iterasyona ulaştığında, OKH artan yineleme

sayılarıyla kademeli olarak düşmüştür. Ek olarak, OKH önemli ölçüde azalmış ve değerinin en düşük olduğu 7. iterasyonda zirve yapmıştır.




Şekil 53. MLP ağ eğitim performansı.



Şekil 54. Program çıktı olarak RBF ağ eğitim performansı.

Şekil 55'te verildiği gibi, bir çubuk grafiğindeki çubuğun yüksekliği, kaç tane veri noktasının 1000 değerine yakın olduğunu göstermektedir. Çıktı yine de istenen değere çok yakındır ve hatalar neredeyse “0” (sıfır) olduğundan YSA modelleri iyi sonuç vermiştir. Hata değerleri, histogram işlevinde belirtilen 1000 numarası tarafından belirlenmiştir. 50 veya 100.000 numaraları denenebilir. Yanlış değerler, 0'a en yakın histogram bölme numarasıdır. Sıfıra yakın bölme çubukları, daha yüksek hata değerlerinden daha uzunsa, model performansı iyidir, çünkü sıfır hatası, çıkışların hedefe yakın olduğunu göstermektedir.



Şekil 55. YSA modelinin sıfır hata alması için hata histogramı

3.2.1. YSA'ı Değerlendirmesi

Arıtma tesisinde ham atıksu BOİ, TN, TP, AKM konsantrasyonları ve pH'a göre, oluşturulan YSA modelleri AAT performansını doğru ve güvenilir bir şekilde tahmin etmiştir. YSA'yı geliştirmek için kullanılan verilerdeki karmaşık, modelin düşük performansının ana nedeni olmuştur. Sonuçlar, önceden veri hazırlığı ve analizinin YSA eğitimi için çok önemli olduğunu ortaya koymuştur. Ağ yapılandırmasının karmaşıklığının (veri giriş sayısı, gizli katmanlar ve nöronlar) daha fazla ilerleme gözlemlenmeyene kadar kademeli olarak artırılması önerilmektedir. Bu araştırmada, on iki girdi ve beş çıktıdan oluşan bir tasarım yeterli olmuştur.

Sonuçlar, daha fazla girdi eklemenin her zaman avantajlı olmadığını da ortaya koymuştur. Atıksu arıtma sürecinde girdi parametrelerinin önemi, oluşturulan modellerden bir başka araştırmasıdır. Üç katmanlı MLP-BP, 40 nöronlu gizli katmanda tansig aktivasyon fonksiyonu, çıkış katmanında purelin aktivasyon fonksiyonu ve yedi yineleme numaralı LM eğitim yöntemi en iyi modelleri üreten sinir ağının parametreleri olmuştur. Deneysel ve simüle edilmiş çıktılar, YSA tahminine göre neredeyse tam olarak eşleştiği ortaya çıkmıştır. Sonuçlar, MLP YSA'nın girdi verilerinin düşük deneysel değerleri ile YSA eğitimi sırasında daha yüksek R ve daha düşük MSE değerlerine sahip olarak doğru sonuçlar verdiğini göstermiştir. Sonuç, bu modelin AAT'ler için çevrimiçi kontrol ve yönetim sistemleri için yumuşak bir sensör olarak başarılı bir şekilde kullanılabileceğini göstermektedir. Modeli gerçek zamanlı çalışma koşullarına ilişkin çok gerçekçi bilgilerle daha da iyileştirmek için düzenli veri ölçümleri gerektiren daha güvenilir bir kontrol sisteminin uygulanması başka bir öneri olabilir.


3.3. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Parametrelere Tahmini

Samsun Doğu İleri Biyolojik Atıksu Arıtma Tesisi deneysel verileri, bu çalışma için MATLAB R2022b versiyonunda ANFIS modellerini oluşturmak için kullanılmıştır. Her yanıt için (BOİ, TN, TP, AKM ve pH) yedi girdili ve bir çıktılı bir model oluşturulmuştur. Kullanıcının, eğitim verilerini kullanarak her deneme için bir Sugeno bulanık sistem prototipi oluşturmasına izin veren model, MATLAB programı ve bulanık mantık araç kutusu kullanılarak türetilmiştir. Sağlanan veri setini çıkararak, kümeleyerek, birinci dereceden bir Sugeno FIS üretmek için "genfis2" işlevi kullanılmıştır. ANFIS algoritması, bulanık sistemin bir prototipi sağlandığında eğitim verilerinden öğrenerek bulanık sistemi ayarlar ve optimize eder ve ardından prototiple aynı yapıya sahip bir Sugeno bulanık sistemi oluşturmaktadır. "AND" yöntemi bir üründür "OR" yöntemi olasılıksal olup ve Sugeno bulanık sistemi bu operatörler kullanılarak otomatik olarak ayarlanmaktadır. "OR" toplama tekniği maksimumdur, çıkarım yöntemi minimumdur ve durulaştırma yöntemi ağırlıklı bir ortalamadır. Girdi üyelik fonksiyonları (MF'ler), Gauss MF'leri olarak tanımlanırken, çıkış MF'leri doğrusal olarak tanımlanmıştır. Normalleştirilmiş veri tabanının doğrulama veri tabanı, oluşturulan modeli

doğrulamak için kullanılmaktadır. Oluşturulan bulanık sistem doğrulama verilerini doğru bir şekilde tahmin ederse hesaplama tamamlanacaktır.


Seçilen parametrelerin ölçümü, birkaç giriş ve çıkış parametresi setini içerir ve birkaç yıl içerisindeki tüm mevsimsel dalgalanmaları hesaba katmaktadır. AAT'den alınan verilere karşılık gelen çıktılar olarak pH, İletkenlik, ÇO, AKM, BOİ, Sıcaklık, TN, TP, HRT ve Q vb. içermektedir. Bu çalışmada kullanılan girdi ve çıktı parametreleri ve bu parametrelerin istatistiksel ölçümleri Tablo 5'te verilmiştir.

Şekil 56'da verildiği gibi, girdi/çıkış üyelik fonksiyonlarını kullanan veri güdümlü modeli oluşturmak için Sugeno tipi bulanık kural tabanlı sistem kullanılmıştır. Bu çerçevede, üyelik fonksiyonlarını güncellemek için hibrit yaklaşım (geriye yayılım + en küçük kareler tahmini) kullanılmıştır.



Şekil 56. ANFIS çıktı tahmini için şematik gösterim

Şekil 56'ının devamı




Tahakkuk eden toplam atanan veri kümesinin boyutu 52 ve bu değerler iki bölüme ayrılmıştır. Bunların %70'i (36 adeti) modeli eğitmek için ve geri kalan %30'u (16adet) modelin performansını test etmek için kullanılmıştır. Bu veriler için; bu kurallara bir örnek olarak şekil 57'de gösterildiği gibi her çıktı için bünyesi kuralları kural sayısı 2187'dir. Modelin girdi üye fonksiyonları olarak üç Gauss üye fonksiyonu kullanıldı ve verileri değerlendirmek için 100 kere iterasyon kullanılmıştır. Modeli oluşturmak için toplam 2178 bulanık kural kullanılmıştır.

	Rule	Weight	Name
1	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule1
2	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule2
3	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule3
4	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule4
5	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule5
6	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule6
7	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule7
8	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule8
9	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule9
10	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule10
11	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule11
12	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule12
13	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule13
14	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule14
15	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule15
16	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule16
17	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule17
18	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule18
19	If Ta _(OC) is in1mf1 and DO _(mg/L) is in2mf1 and HRT(H)Biyofosfor_havuzlari_(anaerobik) is in3mf1 and HRT(H)Havalandirma_havuzlari_(anoksik-oksik) is in4mf1 and HRT(H)Son_cukurturme_havuzlari ...	1	rule19

Şekil 57. Durulaştırılmış sonuçlar elde etmek için kural görüntü ekranı.


Tesis gerçek verileri T, HRT, ÇO, konsantrasyon ve debi (Q) gibi proses değişkenlerinin atıksu kirleticileri üzerinde önemli bir etkiye sahip olduğunu ortaya koymuştur. Arıtma verimliliğini daha iyi tahmin etmek ve kabul edilebilir ve SKKY'nın verilerin yakalamak için veriye dayalı ANFIS kullanılmaktadır. Girdi/çıktı üyelik fonksiyonları, Sugeno tipi bulanık kural tabanlı bir sistem yoluyla veri güdümlü modeli oluşturmak için kullanılmaktadır. Bu çerçevede, üyelik fonksiyonlarını güncellemek için hibrit yöntem (geriye yayılım + en küçük kareler tahmini) kullanılmaktadır. Ayarlanmış ANFIS yapısının “AND” VE “OR” mantıksal bağlayıcıları ve üyelik kuralları ile organizasyon kurallarıdır. Modelin daha iyi çalışmasını sağlamak için yapı, çeşitli giriş üyelik fonksiyonları, kurallar ve çıkış üyelik fonksiyonları aracılığıyla bağlanmaktadır. Bu, daha öngörülebilir özelliklerle sonuçlanmaktadır. Üyelik fonksiyonunun türü ve seçilen üyelik fonksiyonu, ANFIS'in ne kadar iyi performans gösterdiğini etkilemektedir. Bulanık tabanlı üyelik fonksiyonları, ANFIS yapısındaki üçgen, yamuk, Çan Eğrisi, Gauss, Pi-şekilli, Sigmoidal ve asimetrik fonksiyonlar dahil olmak üzere çeşitli şekillerde oluşmaktadır. Optimum bulanık tabanlı üyelik fonksiyonunun yanı sıra toplam üyelik fonksiyonlarının sayısını belirlemek için çok sayıda sayısal simülasyon çalışması gerçekleştirilmiştir. Her program çalıştırmanın etkinliği, güvenilir bir istatistiksel göstergesi olan kök ortalama kare hatası (KOKH) kullanılarak değerlendirilmiştir. Bu sayısal çalışmalar, üç Gauss üyelik fonksiyonu kullanıldığında doğrusal bir çıktı fonksiyonunun daha düşük bir KOKH'ye sahip olduğunu ortaya çıkarmıştır. Sonuç olarak, bu yapı en iyi veya ideal ağ olarak

kabul edilmektedir. Bu nedenle, aşağıdaki çalışma bu ideal ANFIS topolojisinden yararlanmaktadır. En iyi sonuçlar, her bir girdi değişkeni için genelleştirilmiş çan eğrisi şeklindeki MF'lere sahip tüm ANFIS modelleri için çeşitli girdi değişkenleriyle elde edilmiştir. Bu modeller BOİ, TN, TP ve AKM'yi tahmin etmek için kullanılmıştır. Sonuç olarak eğitim aşamasında deneme yanılma yoluyla iyileştirilen atıksu arıtma tesisi prosesi için BOİ, TN, TP, AKM, pH dinamik kirlilik parametrelerinin izlenmesi yeterli olmuştur. Öncül parametrenin başlangıç değerine ve tahmine dayalı modelin düzenine karar verildikten sonra, hibrit ağ bir teknik kullanılarak eğitilmiştir. Ardından hibrit ağın arıtma tesislerinin kirlilik parametreleri kesilmiştir. Değişkenlerin üyeliğini belirlemek için öncül parametrenin elde edilmesi gerekmektedir. Model eğitildikten sonra çıkarım için bulanık dil kuralları kullanılmıştır (bkz. Şekil 57). Bu kurallar, ağ eğitildikten sonra alınmıştır. Çıkmış olan değerlerini girdi değerleriyle karşılaştırmak için çok sayıda yeni buluşsal kriter de dahil edilmiştir. Grafik çıktıları ve durulaştırılmış bulgular üretmek de mümkündür. “Fuzzy Logic Toolbox” tarafından üretilen bir “Surface Viewer” ekran arayüzü çizimi Şekil 59'da gösterilmiştir. Değişken sonuçların iki veya üç boyutlu olarak çizilmesi ve karşılaştırılması mümkündür. Şekil 58'de değişkenlerin kütle merkezine göre uygulanan kuralların sonuçlarını ve ilişkili çıktıları göstermektedir. Arayüz, giriş değerlerini değiştirerek çıkış değişkenleri için bulanıklaştırılmış değerlerin manuel olarak belirlenmesine izin vermektedir. Sağlanmış olan verilere bağlı olarak “Rule Viewer”, bir dizi çıktı değeri üretmiştir. Tüm gerçek girdi değerleri için durulaştırılmış çıktı değerleri elde etmek üzere arayüzü kullanılmaktadır. Durulaştırılmış çıktı sonuçlarını gerçek girdi değerleri doğrultusunda yönlendirmek için, MATLAB kodlarını kullanan bir yazılım oluşturulmuştur. Şekil 58'de çıktı değerini tahmin etmek için ANFIS sisteminin nasıl kullanıldığını göstermektedir.




Şekil 58. Giriş ve çıkış yanıtı ANFIS kuralı gösterimi.

Şekil 58'in devamı



ANFIS, kişinin öğrenme süreci boyunca gözden kaçan kavramları öngörmesini sağlayan YZ çok önemli bir bileşenidir (bkz. şekil 59). Toplanan bulgular, modelin tahmin sürecine uygunluğunu belirlemek için çeşitli teknikler kullanılarak incelenmiştir.



Şekil 59. Farklı girdi çıktıların çıktıları üzerindeki etkileri için 3B yüzey sunumu.


ANFIS ve YSA modellerinin Samsun Doğu İleri Biyolojik AAT'nin doğrusal olmayan doğasını ne kadar iyi yakaladığını değerlendirmek için grafiksel ve istatistiksel teknikler kullanılmıştır. Genel olarak, ANFIS modelleri Samsun Doğu İleri Biyolojik AAT'den çıkan kirleticilerin değerlerini tahmin etmede iyi sonuç vermiş ve doğru değere çok yakın sonuç vermiştir.

Bu çalışma sonucunda, deneysel elde edilmiş olan değer ile YSA ve ANFIS modellerinden elde edilen tahminler arasında iyi bir yaklaşım olduğu ortaya çıkmıştır. ANFIS modelleri, YSA'nın aksine atıksu parametrelerini tahmin etmek için daha uygun olduğu görülmüştür. Şekil 60'ta deneysel olarak elde edilmiş olan değer ile ANFIS ve YSA tarafından yapılan model tahminleri arasındaki görsel ilişkiyi gösteren karşılaştırma tabloları verilmiştir. Grafikler, önerilen tüm modeller ve deneysel sonuçlar arasında kabul edilebilir bir korelasyon olduğu görülmüştür. Modların faktöriyel ve eksenel noktalarının çoğu için anlamlı bir sapma bulunmamıştır. Ek olarak, Şekil 60, test aşaması sırasında ANFIS modellerinin gözlenen ve beklenen atıksu kirlilik parametrelerinin dar aralıklı dağılımlarını göstermektedir. “0” ile “1” arasında değişen ve bağımlı değişkenin öngörülebilir kapsamını gösteren korelasyon katsayısı (R^2), bir değişkenin kabul edilebilir bağımlılığını doğrulamak için kullanılmıştır. ANFIS modelinin üst ve alt ekstrem değerlerinin dağılım grafiğindeki veri noktalarının en iyi uyum çizgisinden fazla sapmaması modelin iyi uyum gösterdiğini ortaya koymuştur.

$$y = 0.9788x + 0.1729$$

$$R^2 = 0.9607$$


BOİ



$$y = 0.9275x + 0.8687$$

$$R^2 = 0.8838$$


BOİ



$$y = 1.0229x - 0.1292$$

$$R^2 = 0.8203$$


TN



$$y = 0.8072x + 1.2918$$

$$R^2 = 0.808$$


TN



$$y = 1.0059x - 0.0124$$

$$R^2 = 0.9176$$


TP



$$y = 0.8132x + 0.0938$$


$$R^2 = 0.8099$$

TP




Şekil 60. En iyi seçilmiş modeller olan ANFIS ve YSA kullanılarak ölçülen ve tahmin edilen atıksu çıktılarının dağılım grafikleri.

Şekil 60'ın devamı




Önerilen modelin BOİ, TN, TP, AKM ve pH parametreleri için test sonuçları Şekil 61'de gösterilmiştir. Her bir parametre için gözlemlenen değer mavi renkte çizgi ile temsil edilmektedir. Önerilen modellerin sağladığı beklenen değer turuncu renkte çizgi ile gösterilmiştir. İki çizgi, Şekil üzerinde neredeyse örtüşüyor gibi görünerek önerilen modellerin geçerliliğini kanıtlamıştır. Ek olarak, ANFES, görüntülenen bu şekilde YSA'dan daha doğru olduğu anlaşılmıştır.



Şekil 61. ANFIS ve YSA kullanılarak tahmin edilen ve gözlemlenen atıksu çıkışları.

Şekil 61'in devamı



Modelin kesin olan yeteneklerini daha fazla araştırmak için Tablo 10'da verilmiş olan değerler kullanılarak model tahminlerine beş istatistiksel hata fonksiyonu uygulanmaktadır. Her model için MMS, OKH, KOKH, OMYH ve R^2 hata fonksiyonları değerlendirilmiştir. Bu hata fonksiyonlarının düşük değerleri modelin güçlü tahmin etme yeteneğini göstermiştir.

Sonuç, tüm modellerin önemsiz hata seviyelerine sahip olduğunu göstermiştir. Bunlara ek olarak modeller için de R^2 değerlendirmesi yapılmıştır. Joglekar ve May'e (1987) göre, tahmin edilen ve deneysel değerler arasında güvenilir bir korelasyon, en az $R^2 = 0.8$ 'lik bir değeri gerektirmektedir (Joglekar ve May, 1987). Modelin tahminlerinin doğruluğu, daha büyük R^2 seviyeleri ile artmaktadır. İstatistiksel bulgular genel olarak YSA'nın AAT için en düşük tahmin doğruluğuna sahip model olduğunu göstermiştir. Ancak ANFIS modeli YSA modelinden biraz daha iyi performans göstermiştir.

Tablo 10. Çeşitli ANFIS ve YSA modellerinin eğitim ve test aşamaları için performans değerleri

Hata	Gözlem ve YSA verileri arasındaki hata					Gözlem ve ANFIS verileri arasındaki hata				
	BOİ (mg/L)	TN (mg/L)	TP (mg/L)	AKM (mg/L)	pH (-)	BOİ (mg/L)	TN (mg/L)	TP (mg/L)	AKM (mg/L)	pH (-)
MMS	0.6223	0.4099	0.0653	0.6786	0.0534	0.2105	0.2943	0.0673	0.3321	0.0232
OKH	0.6159	0.2893	0.0057	0.7576	0.0060	0.1997	0.3236	0.0027	0.4099	0.0060
KOKH	0.7848	0.5379	0.0758	0.8704	0.0772	0.4469	0.5689	0.0524	0.6402	0.0772
OMYH	0.0710	0.0708	0.1276	0.0690	0.0074	0.0197	0.0544	0.0549	0.0378	0.0031
R²	0.8838	0.8080	0.8099	0.8876	0.9396	0.9607	0.8203	0.9176	0.9424	0.9650

ANFIS'in mimarisi, geleneksel sinir ağlarının sınırlamalarını aşmak için YSA ve bulanık mantığın yanı sıra MF'lerin dilsel ifadelerini ve "IF-THEN" kurallarını içerir; tahmin performansını iyileştirmek için. ANFIS, sonuç olarak atıksu arıtımının etkinliğini simüle etmek için mükemmel bir araç olduğu anlaşılmıştır. ANFIS şeffaftır ve aynı zamanda girdiler ve çıktılar arasında karmaşık etkileşimlere sahip bir kara kutu olan YSA'nın aksine anlaşılması ve kullanılması kolay "IF-THEN" kurallarına sahiptir.

3.3.1. Değerlendirme

Mevcut bu çalışmanın ana amacı, yapay sinir ağlarının (YSA) ve uyarlanabilir ağ tabanlı bulanık çıkarım sistemlerinin (ANFIS) atıksu arıtma tesislerinden kaynaklanan atıksudaki kirleticileri ne kadar iyi tahmin ettiğini incelemiş ve ortaya koymuştur.

Sonuçlar, YSA ve ANFIS'in atıksu arıtma tesislerinde oluşan BOİ, TN, TP, AKM ve pH kirlilik parametrelerinin tahmini için başarılı ve yeterli doğrulukla uygulanabilecek umut verici tahmin teknikleri olduğunu göstermiştir. Her iki modelin tahmin ve simülasyondaki performansı, pratik olarak tüm eğitim ve test verilerinde (MMS), (OMH), (KHOK) ve korelasyon katsayıları R^2 değerleri kullanılarak değerlendirilmiştir. İstatistiksel parametre daha küçük bir değere sahip olduğunda her iki model de daha iyi performans görülmüştür. Her iki modelde de atıksu kirleticileri için, $0,808 \leq R^2 \leq 0,965$ aralığında iyi bir regresyon analizi elde edilmiş olduğu görülmüştür.


3.4. MATLAB APP DESIGNER

“App Designer” komutu kullanılarak AAT'lerin (birincil arıtma ve ikincil arıtma) beklenen arıtma parametreleri sonuçlarını kontrol etmeye ve tahmin etmeye yardımcı olan bir model oluşturmak için MATLAB programı kullanılmıştır. Daha sonra bu sonuçlar, arıtılmış atıksuların alıcı ortam su kaynaklarına deşarj edilmesi için Türkiye’de Çevre Kanunu’nun Yönetmeliklerindeki SKKY (Yönetmelikteki kirlilik ile ilgili renkler: Sınıf 1: Yeşil, sınıf 2: Sarı, sınıf 3: Turuncu ve sınıf 4: Kırmızı) ile karşılaştırılmıştır. Model, çıktıları üretmek için belirli bir kod içindeki bir dizi girdi parametresine dayanmaktadır. Model, Şekil 62’de gösterildiği gibi birincil arıtma arayüzü, biyolojik arıtma arayüzü ve özet arayüzü olmak üzere üç arayüzünden oluşmaktadır.



Şekil 62. Birincil arıtma için “APP DESIGNER” modelinin arayüzü, ikinci arıtma için “APP DESIGNER” modelinin arayüzü ve sonuç özeti arayüzü.

Şekil 62'ini devamı



En önemli girdiler arasında hidrolik bekletme süresi (HRT), sıcaklık (T) ve çözünmüş oksijen (ÇO) bulunmaktadır. Çıktı, BOİ, TN, TP, pH ve AKM'nin giderim verimliliğidir. “APP DESIGNER” modellerinin sonuçları Tablo 11'de gösterilmiştir.

Tablo 11. “APP DESIGNER” Model'den elde edilen sonuçların özeti


	“APP DESIGNER” Model Çıktı Değerleri					“APP DESIGNER” Verimlilik Değerleri			
Sıra No	BOİ (mg/L)	TN (mg/L)	TP (mg/L)	AKM (mg/L)	pH (-)	BOİ (%)	TN (%)	TP (%)	AKM (%)
1	8.50	6.25	0.41	11.72	7.14	92.73	83.07	88.24	93.29
2	13.28	6.68	0.45	11.34	7.05	92.64	83.29	88.39	93.62
3	16.80	6.61	0.46	13.74	7.46	92.73	83.17	88.38	93.84
4	14.13	7.95	0.54	10.27	7.32	89.30	76.63	84.40	93.47
5	15.43	9.09	0.61	14.21	8.02	88.58	74.97	83.48	91.65
6	14.32	8.85	0.60	11.51	7.28	88.57	75.86	83.46	92.51
7	14.72	9.24	0.59	11.44	7.52	88.20	75.43	83.37	92.51
8	9.48	6.46	0.42	12.51	6.89	91.86	81.63	87.31	92.51
9	11.88	7.27	0.55	12.34	6.95	92.55	83.32	88.19	94.19
10	13.78	7.53	0.56	12.43	7.56	92.74	82.84	88.08	93.64
11	11.22	7.21	0.54	11.60	6.67	91.88	81.62	87.34	91.72
12	12.36	7.16	0.62	17.24	6.60	91.91	81.21	87.19	91.58
13	11.32	6.72	0.56	13.46	7.51	91.91	81.45	87.30	91.60
14	10.22	6.10	0.53	9.59	7.39	91.86	81.89	87.17	92.86
15	9.64	5.90	0.50	10.23	7.18	91.98	81.45	87.46	92.79
16	9.38	5.91	0.45	10.08	7.15	91.99	81.29	87.29	92.83
17	10.37	5.59	0.47	10.62	7.04	92.12	81.79	87.65	92.67
18	10.01	5.59	0.52	9.95	6.76	92.14	82.05	87.63	92.38
19	8.29	5.50	0.45	8.40	7.40	91.96	81.65	87.50	92.30
20	11.66	5.58	0.53	10.98	7.21	91.89	81.51	87.30	93.00
21	10.82	5.43	0.47	12.48	6.98	91.92	81.61	87.14	92.30
22	10.90	5.52	0.49	11.28	7.22	91.87	81.18	87.33	93.04
23	11.80	5.63	0.50	10.93	7.11	91.99	81.55	87.33	92.84
24	12.38	6.11	0.58	15.05	7.15	91.95	81.60	87.31	91.67
25	9.37	5.23	0.47	7.34	6.85	93.65	85.46	90.07	95.84
26	9.61	5.66	0.43	7.23	7.07	93.67	85.12	90.33	96.29

Tablo 11'in devamı

27	11.21	5.71	0.49	9.66	6.81	93.69	85.49	90.15	95.19
28	9.02	5.50	0.44	7.24	6.77	93.74	84.70	90.07	95.38
29	8.72	5.18	0.40	8.59	7.33	93.86	85.61	90.27	95.15
30	8.49	5.05	0.41	6.81	6.65	93.91	85.15	89.99	95.77
31	8.53	5.22	0.44	6.07	6.81	93.81	85.63	90.42	96.52
32	9.81	5.75	0.48	9.21	6.85	92.89	83.89	89.31	94.61
33	9.62	5.35	0.45	7.21	7.44	93.48	85.08	90.11	96.06
34	9.66	5.42	0.45	7.19	7.41	93.67	84.83	89.94	95.46
35	10.91	6.12	0.51	9.52	7.60	92.98	83.47	89.34	94.53
36	11.57	6.10	0.55	11.13	7.41	92.85	83.60	89.11	94.12
37	9.89	5.57	0.49	6.67	7.36	93.81	85.02	89.95	96.42
38	10.94	5.89	0.50	10.14	7.85	92.83	84.19	89.31	94.55
39	9.91	5.49	0.51	9.35	7.58	93.56	84.77	89.96	95.37
40	9.63	5.28	0.45	7.45	7.30	93.48	85.23	90.14	96.14
41	8.68	4.85	0.40	6.51	7.17	93.49	85.23	89.89	96.38
42	9.48	5.10	0.44	10.21	7.45	93.72	85.35	90.17	95.14
43	10.63	5.52	0.48	11.74	7.75	93.07	83.74	89.29	94.53
44	10.95	5.82	0.51	9.77	7.33	92.82	83.57	89.26	94.94
45	12.23	6.27	0.53	10.64	7.13	92.60	83.45	88.95	94.60
46	11.60	6.23	0.53	11.69	7.37	92.72	83.40	89.09	94.12
47	9.97	5.75	0.46	6.80	6.82	93.70	84.58	90.15	96.54
48	11.29	6.32	0.51	9.69	7.42	92.82	83.56	89.26	94.38
49	10.11	5.43	0.46	6.50	7.40	93.64	85.35	89.96	96.44
50	9.97	5.54	0.46	7.45	7.87	93.49	84.71	89.94	95.75
51	9.48	5.39	0.43	8.25	7.71	93.65	85.14	89.85	95.48
52	10.57	5.99	0.49	7.96	7.69	92.91	83.44	89.10	95.99
Min.	8.29	4.85	0.40	6.07	6.60	88.20	74.97	83.37	91.58
Maks.	16.80	9.24	0.62	17.24	8.02	93.91	85.63	90.42	96.54
Ortalama	10.86	6.09	0.49	10.02	7.24	92.53	82.90	88.45	94.16
Standart sapma	1.86	0.98	0.05	2.42	0.33	1.32	2.53	1.78	1.55
Varyans	3.44	0.96	0.00	5.86	0.11	1.74	6.41	3.16	2.39


“APP DESIGNER” Modelden elde edilen sonuç verileri, Şekil 63'te gösterildiği gibi AAT'nin gerçek verileri ile karşılaştırılmıştır.

Ayrıca Tablo 12’de model sonuçları ile gerçek sonuçlar arasında farklı şekillerde hesaplanan hata değerleri gösterilmiştir.



Şekil 63. Parametreler için deneysel ve tahmin edilen yüzde azalma değerlerinin dağılım

Şekil 63'ün devamı



Tablo 12. Çıktı parametrelerinin tahmin modeli için performans istatistik değerleri

Hata	Gözlem ve “APP DESIGNER” model verileri arasındaki hata				
	BOİ (mg/L)	TN (mg/L)	TP (mg/L)	AKM (mg/L)	pH (-)
MMS	2.0149	0.6130	0.1671	2.0500	0.1050
OKH	12.3153	0.6766	0.0384	7.1070	0.0208
KOKH	3.5093	0.8226	0.1959	2.6659	0.1443
OMYH	0.3116	0.1049	0.2993	0.1971	0.0145
R^2	0.1254	0.5360	0.0008	0.1856	0.8124

4. TARTIŞMA

Bu çalışma sonucunda, Tablo 13'te tüm modeller arasında en iyi tahmin sonuçlarını sağlayan modeller ve bunların bulgularını üreten tahmin tekniği gösterilmiştir. Bulguların ışığında ANFIS modelinin en iyi sonucu verdiği görülmüştür. Seçilen modellerin en iyi belirleme katsayısına ve en düşük hata değerlerine sahip olduğu anlaşılmıştır.

Tablo 13. Tüm modellerden en iyi değerleri.

Hata	En iyi arıtma parametre değerleri				
	BOİ (mg/L)	TN (mg/L)	TP (mg/L)	AKM (mg/L)	pH (-)
MMS	0.2105	0.2943	0.0653	0.3321	0.0232
OKH	0.1997	0.2893	0.0027	0.4099	0.0060
KOKH	0.4469	0.5379	0.0524	0.6402	0.0772
OMYH	0.0197	0.0544	0.0549	0.0378	0.0031
R ²	0.9607	0.8203	0.9176	0.9424	0.9650

FL Model'de: Samsun Doğu İleri Biyolojik Atıksu Arıtma Tesisinin modellenmesi, atıksu arıtma tesislerinin performansını artırabilir ve sistemin daha iyi arıtma çalışabilirliğinin anlaşılmasını sağlayabilmektedir. Bununla birlikte, süreçteki karmaşıklık ve belirsizlik, geleneksel deterministik modelleri kullanarak görevi biraz karmaşık hale getirmektedir. Arıtma sistemin yapısı veya durumu hakkında önceden bilgi gerektirmeyen, yapay zekâ veya veriye dayalı teknikler olarak bilinen başka bir modelleme araçları seti mevcuttur. Öte yandan, bu prosedürlerin kalitesi büyük ölçüde tesis veri sayısına ve veri kalitesine bağlıdır.

YZ modelleri, özellikle bulanık mantık modelleri, sistem hakkında önceden bilgi sahibi olmadan atıksu parametrelerini tahmin edebilme avantajına sahiptir. Ayrıca, girdi ve çıktı parametreleri arasındaki matematiksel ilişkiler hakkında hiçbir varsayım bulunmamaktadır. Ayrıca, bu sürecin tesis yapısı açıkça dikkate alınmadan, bu modeller girdiler ve çıktılar arasındaki bağlantıları tanıyabilmektedir. Bu araştırma çalışmasının temel amacı, yapay zekâ tekniklerinin AAT'nin modellenmesinde kullanılabileceği hipotezini test etmiştir.

Sonuç olarak, bu araştırma çalışmanın amacı, FL modelinin bu çalışmada geliştirilen veriye dayalı teknikleri iyileştirmedeki etkinliğini araştırmak olmuştur. Karmaşık ve kayıp

değerlerin etkisini ortadan kaldırmak için verilerin hazırlanması ve BOİ, TN, AKM, pH ve TP'yi tahmin etmek için bir yazılım sensörü geliştirilmesi gibi başka amaçlar da bu projenin doğasında vardır.

Araştırma çalışmasının sonuçlardan elde edilen, FL ile karmaşık problemlerin modellenmesi için uygun ve geleneksel yöntemlere kıyasla çok fazla hesaplama çabasından önemli ölçüde tasarruf sağlamakta olduğu tespit edilmiştir.

Bulanık mantık modeli (Mamdani) tatmin edici olmuş ve arıtılmış atıksuyun alıcı ortam şartları için SKKY'deki sınıflandırmalara göre arıtılmış atıksu için gerekli spesifikasyon değerleri sınırlarında kalmıştır.

YSA Model'de: Arıtma tesisindeki atıksuyun BOİ, TN, TP, AKM ve pH kirlilik değerlerine göre oluşturulan YSA modelleri AAT'nin performansını doğru ve güvenilir bir şekilde tahmin etmiştir. YSA'nı geliştirmek için kullanılan kirlilik verilerinin karmaşık, modelin düşük performansının ana nedeni olmuştur.

Sonuçlar, önceden veri hazırlığı ve analizinin YSA eğitimi için çok önemli olduğunu göstermiştir. Ağ yapılandırmasının karmaşıklığının (giriş sayısı, gizli katmanlar ve nöronlar) daha fazla ilerleme gözlemlenmeyene kadar kademeli olarak artırılması önerilmektedir. Bu araştırma çalışmasında, on iki girdi ve beş çıktıdan oluşan bir tasarım yeterli olmuş ve sistem daha fazla girdi parametresi ile donatılmıştır.


Sonuçlar, daha fazla girdi eklemenin de her zaman avantajlı olmadığını da göstermiştir. Atıksu arıtma sürecinde girdi parametrelerinin sayısının modellerin çalıştırılmasında önem göstermektedir. Üç katmanlı MLP-BP, 40 nöronlu gizli katmanda “tansig” aktivasyon fonksiyonu, çıkış katmanında “purelin” aktivasyon fonksiyonu ve yedi iterasyon numaralı LM eğitim yöntemi en iyi modelleri üreten sinir ağının parametreleri olmuştur. Deneysel ve simüle edilmiş çıktılar, YSA tahminine göre tama yakın olarak eşleşmiştir. Sonuçlar, MLP YSA'nın girdi parametrelerinin düşük deneysel değerleri ile YSA eğitimi sırasında daha yüksek R^2 ve daha düşük MSE değerlerine sahip olarak doğru sonuçlar verdiğini göstermiştir. Sonuç, bu modelin AAT'ler için çevrimiçi kontrol ve yönetim sistemleri için yumuşak bir sensör olarak başarılı bir şekilde kullanılabileceğini göstermiştir. Modelin gerçek zamanlı çalışma koşullarına

ilişkin çok gerçekçi parametreleri, daha da iyileştirmek için düzenli ölçümler gerektiren ve daha güvenilir bir kontrol sisteminin uygulanması diğer bir öneri olabilir.

ANFIS Model’de: Mevcut çalışmanın temel amacı, ANFIS’lerin AAT’lere giren atıksudaki kirletici parametrelerinin nasıl başarılı bir şekilde tanımladığını incelemek olmuştur. Bulgular, ANFIS’in AAT’lerinden çıktıları BOİ, TN, TP, AKM ve pH atıksu kirletici parametrelerinin yeterli doğrulukla tahmin etmek için kullanılabilecek yüksek değerlerde bir tahmin tekniği olduğunu göstermiştir. MMS, OKH, KOKH ve korelasyon katsayıları R^2 değeri, eğitim ve test verilerinin neredeyse tamamı kullanılarak modellerin simülasyon ve tahmindeki performansını değerlendirmek için kullanılmıştır. İstatistiksel hata parametreleri daha küçük bir değere sahip olduğunda, model daha iyi performans göstermektedir. ANFIS modelinde atıksu kirletici parametreleri için $0,8203 < R^2 < 0,965$ aralığında başarılı bir regresyon analizi ortaya çıkmıştır. Bu modelde eğitim aşamasındaki sonuçlar test aşamasından daha doğru ancak modelin nihai sonuçlarındaki hata değerlerinden de anlaşılacağı gibi tatmin edici olmuştur.


APP DESIGNER Model’de: Bu modelde elde edilen sonuçlar AAT’nin gerçek çıkış kirlilik parametre değerlerine çok yakın olduğu görülmüştür. Hata değerleri yüksek, R^2 değerleri düşük çıkmıştır. Bunun nedeni, modelin kirlilik parametresindeki düşme ve giderme giderme verimi ve girdi kirlilik parametrelerin çıktı parametreleri üzerindeki etkisi ile ilgili daha önceki kaynak çalışmalara dayanılarak oluşturulmuştur. Modeldeki gerçek verilerde tesadüfen meydana gelen değişiklikleri hesaba katmak oldukça zordur. Örneğin AAT’inin işletmeye alındığında model verileri gerçek verilerden uzakmış gibidir. Sonuç olarak, bu model geleceği küçük bir hata oranıyla tahmin etmede çok güveni sonuçlar vermektedir.

Şekil 64’te modellerden üretilen en iyi tahmin giderim veriminin değerleri ile gözlemlenen (gerçek veriler) değerler arasındaki değişimi göstermektedir.




Şekil 64. Tahmin edilen giderim veriminin değerleri ile gözlemlenen (ölçülen) değerler arasındaki değişimi.

Şekil 64'ün devamı



Şekil 64'ün devamı



Modellerin karşılaştırılmasında bulanık mantık kendi başına bir öğrenme yöntemi değildir. Regresyon, karar ağacı kural tabanları, en yakın komşu vb. gibi harici öğrenme yöntemlerinden kaynaklanan sürekli olasılıklara dayanan sınıf üyeliği için bir bilgi temsil modelidir. Bulanık küme öğrenme süreci “bulanıklaştırma” olarak bilinir ve çıktı sınıfı çözünürlüğü, “bulanıklaştırma” dır. Her iki adım da genellikle karmaşıklığı azaltmak ve ilgisiz olan bilgileri reddetmek için optimizasyonları içermektedir.

Buna karşılık, YSA, eğitildiği örneklerde en bilgilendirici olan niteliklere yanıtını en üst düzeye çıkarmak için ağın yollarını şekillendiren bir öğrenme yöntemini (genellikle geri yayılım) içermektedir. YSA'lar genellikle sınıflandırma dışındaki amaçlar için kullanılmaktadır.

Yukarıdaki bilginin profesyonel olarak bulanık kümelerden daha yararlı olması muhtemel olduğundan YSA'larının kullanılması önerilmiştir. Bununla birlikte, kademeli olarak yanıt vermek ve uygun bir şekilde azaltmak için, uyarlanabilir kontrol sistemlerinde bulanık kümeler hala kullanılmaktadır. Ayrıca, Bulanık mantık, kesin olmayan veya belirsiz verilere dayalı olarak kesin kararlar alınmasına izin verirken, YSA, sorunları matematiksel olarak modellemekten çözmek için insan düşünme sürecini dâhil etmeye çalışmaktadır.

YSA karmařık stokastik problemlerin özümü için standart bir tekniktir. Bu araştırma alışmasında, AAT'nin modellenmesi ve optimizasyonu için YSA ve ANFIS uygulanmıştır. ANFIS modelinden elde edilen sonuçlarda YSA'dan marjinal olarak daha iyi olduğu ortaya ıkmıştır. Ayrıca, ANFIS modeli, daha sağlam bir sonuç elde etmek için girdi ve ıktı kirlilik parametrelerinin deęerlerini düzenlemektedir.



5. SONUÇLAR

Bu tez çalışmasında Samsun ilinde faaliyet gösteren Samsun Doğu İleri Biyolojik AAT giriş ve çıkışında BOİ, TN, TP, AKM ve pH tahminine yönelik çalışma yapılmıştır. Çalışmada tasarlanan modellerin çıktılarını etkileyen girdiler olarak incelenen parametreler T, ÇO, HRT, Q, elektriksel iletkenlik, BOİ, TN, TP, AKM ve pH olmuştur. Bu parametrelerin zamanla değişimlerine bağlı olarak atıksuyun AAT’de arıtılması için AAT’lerinin ayrıntılı olarak bilgisayar destekli modelleri uygulanmış ve bu modellerde atıksu parametre değişimlerinin AAT’nin çıktı parametreleri üzerine olan etkileri ayrıntılı olarak irdelenmiştir.

Bu Dr.-tez çalışma kapsamında “APP DESIGNER MATLAB”, bulanık mantığı, yapay sinir ağları ve ANFIS ile kirlilik parametrelerinin tahmin modeli oluşturulmuştur.

Mekanik ve biyolojik atıksu arıtma proseslerindeki atıksu parametrelerinin bulanık mantıkla kontrol edilmiştir. Arıtılmış atıksudaki kirletici parametreleri ve AAT’nin bakım ve işletme giderlerini daha azaltmak için 4 adet çıktı parametrelerinin her biri için 7 girdi parametresi olacak şekilde tasarlanmış ve uygulanmıştır. Programdaki bulanık mantık model denetleyicinin tesis giriş ve çıkışlarının her birinin etkileri ve bunların bağlantıları açıklanmış ve gösterilmiştir. Çalışılmış modellemenin sonuçları, bulanık mantık model denetleyicisinin aynı anda bakım ve işletme maliyetlerini aşağıya çekme ve AAT’nin çıkış atıksu kalitesinin çevre alıcı ortamları için daha iyi hale getirmektedir.

Çalışılan Model çıktıları, arıtılmış atıksuyun, tesis çıkışı atıksu alıcı ortamı için Türkiye’de kabul edilmiş olan SKKY’ye göre kabul edilebilir atıksu kalite standartları tutturulmuştur.

Oluşturulmuş YSA modeller, AAT’i giriş kirlilik parametrelerinden BOİ, TN, TP, AKM ve pH değerine dayalı AAT’nin arıtma performansını başarıyla tahmin etmiştir.

Elde edilmiş olan sonuçlar, YSA’nın eğitimi için önceden veri hazırlama ve analiz etme ihtiyacını göstermiştir. YSA’nın kurulumundaki karmaşıklığı (giriş sayısı, gizli katmanlar ve nöronlar), daha fazla uygun gelişme görülünceye kadar sürekli olarak artırılmıştır. Bu YSA’ı modelinde on iki girdi ve beş çıktıdan oluşan bir arıtma model tasarımı yeterli olmuş; daha fazla girdi sistemin aşırı donanımlı hale gelmesine neden olmuştur.

Çıkan sonuçlar ayrıca artan girdilerin her zaman faydalı olmadığını da ortaya koymuştur. Oluşturulan modellerden elde edilen bir diğer bulgu da atıksu arıtma sürecinde girdi parametrelerinin önemli olduğunu göstermiştir. YSA'nın en iyi modelleri, üç katmanlı "MLP-BP", 40 nöronlu gizli bir katmanda "tansig", çıkış katmanında "purelin" aktivasyon fonksiyonu ve yedi iterasyonu "LM eğitim yöntemi" kullanılarak oluşturulmuştur. YSA tahminine göre, AAT'den elde edilmiş olan parametreler ve tez çalışmasındaki simülasyondan elde edilen çıktılar birbirine çok yakın değerler olmuştur.

YSA'nın eğitimi sırasında daha yüksek " R^2 " ve daha düşük "OKH" değerlerine sahip olmak, "MLP ANN"nin doğru bulgular ürettiğini ortaya koymuştur.

YSA modelinin AAT'ler için çevrimiçi kontrol ve yönetim sistemlerine başarıyla uygulanabileceğini ortaya konulmuştur.

Bu çalışmada YSA'da AAT'nin dinamik arıtma davranışını taklit etmek için kullanılabileceğini göstermiştir. YSA yalnızca süreç (giderim verimliliği) davranışını doğru bir şekilde tahmin etmekle kalmaz, aynı zamanda YZ modellerinin bilgi oluşturulmasına izin vererek kısmen bilinen bir AAT'nin dinamik davranışı hakkında bir fikir vermektedir.

Yedi girdi parametresi kullanılarak önerilen model eğitilmiş, doğrulanmış ve test edilmiştir.

YSA modelinde gözlemlenen verilerin (ölçülen) dağılımıyla tamamen tutarlı bir şekilde dağıtılır ve YSA modelinin AAT'nin birincil ve ikincil arıtmasında kirletici parametrelerin giderim veriminin tahmin edebildiği etkinliği göstermiştir.

YSA sınırlı bir deneyim ve bilgi birikimine sahip olursa bile, doğru modelleri daha kısa süre içerisinde oluşturulmasına yardımcı olmaktadır.

YSA ve ANFIS modeller AAT'lerden çıkan atıksudaki kirletici parametreleri nasıl başarılı bir şekilde tanımladığını incelemek, bu çalışmanın ana hedeflerinden biri olmuştur. YSA ve ANFIS'in AAT'lerin BOİ, TN, TP, AKM ve pH çıkış parametreleri başarılı bir şekilde ve yüksek yeterli doğrulukla tahmin etmek için kullanılabilecek tahmin teknikleri olduğunu göstermiştir.

MMS, OKH, KOKH ve korelasyon katsayısı R^2 değerleri, her iki modelin simülasyon ve tahmindeki performanslarının değerlendirilmesi için yaklaşık tüm eğitim ve test verilerini kullanılmıştır.

İstatistiksel parametreler daha küçük bir değere sahip olduğunda, her iki model de daha iyi performans oluştuğunu göstermiştir. Düşük KOKH ve çok yüksek R^2 değerlerinde BOİ, TN, TP ve AKM'nin simüle edilmiş giderim gözlenen konsantrasyonlarla yakından eşleştiğini göstermiştir.

ANFIS performans ve genelleme yeteneği YSA'dan daha iyi olduğu görülmüştür. ANFIS kullanımı ile BOİ, TN, TN ve AKM'nin giderim verimini tahmin etmek için KOKH ve R^2 değerleri önemli ölçüde iyileştirilmiştir. Genel olarak ANFIS'nin atıksu arıtma sistemlerinde kirlenici parametrelerinin giderim mekanizmalarını tahmin etmek için kullanılabileceğini açık olarak göstermiştir.

Çalışmada kullanılan modeller yardımıyla BOİ, TN, TP, AKM ve pH testi analizlerinin sonuçlarını bekletmeden elde edilmektedir.

Modeller yardımı ile üretilen bu tahmini kirlilik parametre değerleri ile gerçek değerlerin analizi için gereken süreyi beklemeden veya analizde tüketilen sarf malzemelerini kullanmadan çıktı parametrelerinin yaklaşık değerleri tahmin edilmektedir.

Çalışma kapsamında AAT'de ham atıksu parametreleri kullanılan programlara girilerek çıkış atıksuyunda kirlilik parametreleri doğru hesaplanmış

Bu programla teorik olarak kirlilik parametreleri verilerek çıkış atıksu da kirlilik parametreleri teorik çıkış verileri üretilebilir.

Giriş ve Çıkış atıksu parametre fiziksel ve biyolojik arıtma ünitelerinin fiziksel boyutlandırmalarından bağımsızdır.

6. ÖNERİLER

Bu tez çalışmasında BOİ, TN, TP, AKM ve pH gibi çeşitli çıktı kirlilik parametrelerinin değerleri 4 farklı Bilgisayar Modelleri kullanılarak tahmin edilmiştir. Bu Bilgisayar Modelleri her ne kadar kullanılabilir sonuçlar üretse de elde edilen gözlem ve ölçüm verilerinin daha fazla olması halinde çıktı verileri üzerinde etkisinin araştırılmasında faydalı olacaktır.

İleri de yapılacak olan bilimsel çalışmalarında NO₂ ve NO₃ parametreleri de dikkate alınmalıdır. Buradan çıkan nihai sonuçlarla tesislerin arıtma verimleri dikkate alınabilir. NO₂ ve NO₃ giderim verimlerinin BOİ, TN ve TP üzerindeki etkisinin izlenmesi çalışılabilir.

Bu tez çalışması kapsamında çalışılan modellerin daha farklı AAT'lerin de denemesi de yapılabilir.

Yapılan bu çalışmada kullanılan modeller yakın bölgelerde AAT'lerinde kullanılarak test edilebilir.

Modelin geliştirilmesinde çalışan AAT'lerinden verilerin alınarak önerilen programlarda kullanılması sonucu daha iyi sonuçlar ortaya çıkacaktır.

AAT için gelecekteki otomatik gerçek zamanlı kontrol sistemleri, dinamik süreçlerin durumundaki değişiklikleri tahmin etme ve bunlara hızlı bir şekilde yanıt verme kapasiteleri nedeniyle YSA'ları kullanabilmektedir.

7. KAYNAKLAR

- Ak, M., Kentel, E., Kucukali, S., 2017. A fuzzy logic tool to evaluate low-head hydropower technologies at the outlet of wastewater treatment plants. *Renew. Sustain. Energy Rev.* 68, 727–737. <https://doi.org/10.1016/j.rser.2016.10.010>
- Akratos, C.S., Papaspyros, J.N.E., Tsihrintzis, V.A., 2008. An artificial neural network model and design equations for BOD and COD removal prediction in horizontal subsurface flow constructed wetlands. *Chem. Eng. J.* 143, 96–110. <https://doi.org/10.1016/j.cej.2007.12.029>
- Al-Jawdhari, M.M.J., 2022. Evaluation Of The Performance Of The Wastewater Treatment Plant In Karbala By Gps-X Modeling. Master's Thesis, Ondokuz Mayıs University, Institute Of Graduate Studies, Samsun.
- Aladağ, E., 2011. Erzurum Kenti İçin Aktif Çamur Tesisi Tasarımı Ve Modellenmesi. Yüksek Lisans Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum.
- Alkay, T., 2016. Kocaeli Kentsel Atıksu Arıtma Tesislerinin Yapay Sinir Ağları İle Modellenmesi Ve Entegre Tesis Tasarımı. Yüksek Lisans Tezi, Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Yalova.
- Alnajjar, H.Y.H., Üçüncü, O., 2023a. Removal efficiency prediction model based on the artificial neural network for pollution prevention in wastewater treatment plants. *Arab Gulf J. Sci. Res.* <https://doi.org/10.1108/AGJSR-07-2022-0129>
- Alnajjar, H.Y.H., Üçüncü, O., 2023b. Performance Prediction and Control for Wastewater Treatment Plants Using Artificial Neural Network Modeling of Mechanical and Biological Treatment. *Arch. Environ. Prot.* 49, 16–29. <https://doi.org/10.24425/aep.2023.145893>
- Alnajjar, H.Y.H., Üçüncü, O., 2022. Enhance modelling predicting for pollution removal in wastewater treatment plants by using an adaptive neuro-fuzzy inference system. *Environ. Res. Technol.* 5, 213–226. <https://doi.org/10.35208/ert.1106463>
- Alnajjar, H.Y.H., Üçüncü, O., 2021. Using of a Fuzzy Logic as One of The Artificial Intelligence Models to Increase the Efficiency of The Biological Treatment Ponds in Wastewater Treatment Plants. *Int. J. Environ. Pollut. Environ. Model.* 4, 85–94.
- Araromi, D.O., Majekodunmi, O.T., Adeniran, J.A., Salawudeen, T.O., 2018. Modeling of an activated sludge process for effluent prediction—a comparative study using ANFIS and GLM regression. *Environ. Monit. Assess.* 190. <https://doi.org/10.1007/s10661-018-6878-x>
- Ayla, N.C., 2021. Su Ve Atıksu Arıtma Proseslerinin Bilgisayar Esaslı Modellenmesi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Black, M., 1937. Vagueness: an exercise in logical analysis. *Philos. Sci.* 4, 69–81. <https://doi.org/10.7551/mitpress/7064.003.0006>
- Bryson, A.E., Ho, Y.C., 1969. *Applied Optimal Control*. Blaisdell.

<https://doi.org/10.2307/1267777>

- Cakmakci, M., 2009. Multi-Scale Fuzzy Inference System for Influent Characteristic Prediction of Wastewater Treatment. *Bioprocess Biosyst. Eng.* 35, 3674–3684. <https://doi.org/10.1016/j.compchemeng.2009.02.004>
- Chen, Y., Song, L., Liu, Y., Yang, L., Li, D., 2020. A review of the artificial neural network models for water quality prediction. *Appl. Sci.* <https://doi.org/10.3390/app10175776>
- Cheng, Z., Li, X., Bai, Y., Li, C., 2018. Multi-Scale Fuzzy Inference System for Influent Characteristic Prediction of Wastewater Treatment. *Clean - Soil, Air, Water* 46. <https://doi.org/10.1002/clen.201700343>
- Chiroșcă, A., Dumitrașcu, G., Barbu, M., Caraman, S., 2011. Fuzzy control of a wastewater treatment process. *Smart Innov. Syst. Technol.* 10 SIST, 155–163. https://doi.org/10.1007/978-3-642-22194-1_16
- Çinar, Ö., 2005. New tool for evaluation of performance of wastewater treatment plant: Artificial neural network. *Process Biochem.* 40, 2980–2984. <https://doi.org/10.1016/j.procbio.2005.01.012>
- Civelekoglu, G., Perendeci, A., Yigit, N.O., Kitis, M., 2007. Modeling carbon and nitrogen removal in an industrial wastewater treatment plant using an adaptive network-based fuzzy inference system. *Clean - Soil, Air, Water* 35, 617–625. <https://doi.org/10.1002/clen.200700076>
- Cohen, M.A., Grossberg, S., 1983. Absolute stability of global pattern formation and parallel memory storage by competitive neural networks. *IEEE Trans. Syst. Man. Cybern.* SMC-13, 815–826. <https://doi.org/10.1109/TSMC.1983.6313075>
- Cox, E., 1999. *The Fuzzy Systems Handbook*, 2. ed. ACADEMIC PRESS LIMITED, San Diego.
- Dünyamin, G., Şükrü, D., 2007. Aktif Çamur Prosesi Havalandırma Havuzu Askıda Katı Madde (Akm) Konsantrasyonunun Mekanistik, Yapay Sinir Ağı Ve Hibrit Yöntemlerle Modellenmesi. *Selçuk Üniversitesi Mühendislik, Bilim Ve Teknol. Derg.* 22, 1–10.
- Erdirencelebi, D., Yalpir, S., 2011. Adaptive network fuzzy inference system modeling for the input selection and prediction of anaerobic digestion effluent quality. *Appl. Math. Model.* 35, 3821–3832. <https://doi.org/10.1016/j.apm.2011.02.015>
- Eroğlu, T., 2021. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (Anfis) İle Mersin İli Karaduvar Kentsel Atıksu Arıtma Tesisi Performansının Modellenmesi. Yüksek Lisans Tezi, Mersin Üniversitesi, Mersin Üniversitesi Fen Bilimleri Enstitüsü, Mersin.
- Esteves, S.R.R., 2002. Monitoring and Control of Biological Textile Wastewater Treatment Using Artificial Neural Networks. University of Glamorgan in.
- Fan, L., Boshnakov, K., 2010. Fuzzy logic based dissolved oxygen control for SBR wastewater treatment process. *Proc. World Congr. Intell. Control Autom.* 4142–4146. <https://doi.org/10.1109/WCICA.2010.5553972>

- Fukushima, K., 1975. Cognitron: A self-organizing multilayered neural network. *Biol. Cybern.* 20, 121–136.
- Gaya, M.S., Abdul Wahab, N., Sam, Y.M., Samsudin, S.I., Jamaludin, I.W., 2014. ANFIS direct inverse control of substrate in an activated sludge wastewater treatment system. *Appl. Mech. Mater.* 554, 246–250. <https://doi.org/10.4028/www.scientific.net/AMM.554.246>
- Hanbay, D., Turkoglu, I., Demir, Y., 2008. Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks. *Expert Syst. Appl.* 34, 1038–1043. <https://doi.org/https://doi.org/10.1016/j.eswa.2006.10.030>
- Haykin, S., 1999. *Neural Networks - A Comprehensive Foundation*.
- Hong, Y.S., Bhamidimarri, R., 2003. Evolutionary self-organising modelling of a municipal wastewater treatment plant. *Water Res.* 37, 1199–1212. [https://doi.org/10.1016/S0043-1354\(02\)00493-1](https://doi.org/10.1016/S0043-1354(02)00493-1)
- Hopfield, J.J., 1982. Neural networks and physical systems with emergent collective computational abilities. *Proc. Natl. Acad. Sci. U. S. A.* 79, 2554–2558. <https://doi.org/10.1073/pnas.79.8.2554>
- Jacobs, R.A., 1988. Increased rates of convergence through learning rate adaptation. *Neural Networks* 1, 295–307. [https://doi.org/https://doi.org/10.1016/0893-6080\(88\)90003-2](https://doi.org/https://doi.org/10.1016/0893-6080(88)90003-2)
- Jang, J.-S.R., 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man. Cybern.* 23, 665–685. <https://doi.org/10.1109/21.256541>
- Joglekar, A.M., May, A.T., 1987. Product excellence through design of experiments. *Cereal Foods World* 32, 857–858. [85860862864866800](https://doi.org/10.1016/0022-0248(87)90000-0).
- Kaljunen, N.U., 2019. *Modelling Of Start-Up Phase Of The Deammonification Systems*. Master Thesis, Marmara University Institute For Graduate Studies In Pure And Applied Sciences, Istanbul.
- Karaduman, Ö., 2011. *Konacık Belediyesi Atıksu Arıtma Tesisinin Modellenmesi Ve Mevcut Problemlerinin Bilgisayar Simülasyonu İle Çözülmesi*. Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü, Mühendislik Ve Fen Bilimleri Enstitüsü, Gebze.
- Khatri, N., Khatri, K.K., Sharma, A., 2019. Prediction of effluent quality in ICEAS-sequential batch reactor using feedforward artificial neural network. *Water Sci. Technol.* 80, 213–222. <https://doi.org/10.2166/wst.2019.257>
- Kohonen, T., 1990. The self-organizing map. *Proc. IEEE* 78, 1464–1480. <https://doi.org/10.1109/5.58325>
- Kohonen, T., 1989. *Self-Organization and Associative Memory: 3rd Edition*. Springer-Verlag, Berlin, Heidelberg.
- Kohonen, T., 1982. Self-organized formation of topologically correct feature maps. *Biol. Cybern.* 43, 59–69. <https://doi.org/10.1007/BF00337288>
- Kosko, B., 1987. Adaptive bidirectional associative memories. *Appl. Opt.* 26, 4947–4960.

<https://doi.org/10.1364/AO.26.004947>

- Kruse, R., Nauck, D., 1998. *Neuro-Fuzzy Systems BT - Computational Intelligence: Soft Computing and Fuzzy-Neuro Integration with Applications*, içinde: Kaynak, O., Zadeh, L.A., Türkşen, B., Rudas, I.J. (Ed.), . Springer Berlin Heidelberg, Berlin, Heidelberg, ss. 230–259.
- Li, H., Gupta, M., 1995. *Fuzzy Logic And Intelligent Systems*. Kluwer Academic Publishers, Boston.
- Lukasiewicz, J., 1930. Philosophical remarks on many-valued systems of propositional logic. Reprinted in *Selected Works*, L. Borkowski, ed., *Studies in Logic and the Foundations of Mathematics*,. *Stud. Log. An Int. J. Symb. Logic*, 70, 157–182.
- Mamdani, E.H., Assilian, S., 1975. An experiment in linguistic synthesis with a fuzzy logic controller. *Int. J. Man. Mach. Stud.* 7, 1–13. [https://doi.org/10.1016/S0020-7373\(75\)80002-2](https://doi.org/10.1016/S0020-7373(75)80002-2)
- Matheri, A.N., Ntuli, F., Ngila, J.C., Seodigeng, T., Zvinowanda, C., 2021. Performance prediction of trace metals and cod in wastewater treatment using artificial neural network. *Comput. Chem. Eng.* 149, 107308. <https://doi.org/10.1016/j.compchemeng.2021.107308>
- MATLAB Release 2022b, 2022. The MathWorks Inc. MathWorks Inc. <https://www.mathworks.com>.
- Mcculloch, W.S., Pitts, W., 1990. A logical calculus nervous activity. *Bull. Math. Biol.* 52, 99–115.
- Medsker, L.R., 1995. *Expert Systems and Neural Networks*, içinde: *Hybrid Intelligent Systems*. Springer US, Boston, MA, ss. 39–56. https://doi.org/10.1007/978-1-4615-2353-6_3
- Mohd Noor, S.B., Khor, W.C., Ya 'acob, M.E., 2004. Fuzzy logic control of a nonlinear ph-neutralisation in waste water treatment plant. *Int. J. Eng. Technol.* 1, 197–205.
- Morris, R.G.M., 1999. D.O. Hebb: *The Organization of Behavior*, Wiley: New York; 1949. *Brain Res. Bull.* 50, 437. [https://doi.org/https://doi.org/10.1016/S0361-9230\(99\)00182-3](https://doi.org/https://doi.org/10.1016/S0361-9230(99)00182-3)
- Nadiri, A.A., Shokri, S., Tsai, F.T.C., Asghari Moghaddam, A., 2018. Prediction of effluent quality parameters of a wastewater treatment plant using a supervised committee fuzzy logic model. *J. Clean. Prod.* 180, 539–549. <https://doi.org/10.1016/j.jclepro.2018.01.139>
- Niu, G., Yi, X., Chen, C., Li, X., Han, D., Yan, B., Huang, M., Ying, G., 2020. A novel effluent quality predicting model based on genetic-deep belief network algorithm for cleaner production in a full-scale paper-making wastewater treatment. *J. Clean. Prod.* 265, 121787. <https://doi.org/10.1016/j.jclepro.2020.121787>
- Nourani, V., Asghari, P., Sharghi, E., 2021. Artificial intelligence based ensemble modeling of wastewater treatment plant using jittered data. *J. Clean. Prod.* 291, 125772. <https://doi.org/10.1016/j.jclepro.2020.125772>
- Öztürk, C., 2007. Yapay Sinir Ağları ve Asm2 Kullanılarak Aktif Çamur Prosesinin Kontrolü

- ve Modellenmesi Control. DOKTORA TEZİ ,Hacettepe Üniversitesi, Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin, ANKARA.
- Pai, T.-Y., 2008. Gray and Neural Network Prediction of Effluent from the Wastewater Treatment Plant of Industrial Park Using Influent Quality. *Environ. Eng. Sci.* 25, 757–766. <https://doi.org/10.1089/ees.2007.0136>
- Qasem, N., Ebtehaj, I., Madavar, H.R., 2017. Optimizing ANFIS for sediment transport in open channels using different evolutionary algorithms. *J. Appl. Res. Water Wastewater* 7, 290–298.
- Qiao, J., Wang, G., Li, W., Li, X., 2018. A deep belief network with PLSR for nonlinear system modeling. *Neural Networks* 104, 68–79. <https://doi.org/10.1016/j.neunet.2017.10.006>
- Rosenblatt, F., 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychol. Rev.* 65, 386–408. <https://doi.org/10.1037/h0042519>
- Rosenblatt, F., 1960. Perceptron Simulation Experiments. *Routledge Libr. Ed. Econom.* 415–451. <https://doi.org/10.4324/9781315717791-15>
- Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning representations by back-propagating errors. *Nature* 323, 533–536. <https://doi.org/10.1038/323533a0>
- Sakiewicz, P., Piotrowski, K., Ober, J., Karwot, J., 2020. Innovative artificial neural network approach for integrated biogas – wastewater treatment system modelling: Effect of plant operating parameters on process intensification. *Renew. Sustain. Energy Rev.* 124. <https://doi.org/10.1016/j.rser.2020.109784>
- Sawyer, C.N., McCarty, P., 2003. *Chemistry for environmental engineering and Science* 5th Ed., 5. ed, McGraw Hill Inc. McGraw Hill Inc., New York.
- Schuler, A.J., Jang, H., 2007. Density effects on activated sludge zone settling velocities. *Water Res.* 41, 1814–1822. <https://doi.org/10.1016/j.watres.2007.01.011>
- Shepherd, G.M. and Koch, C., 1990. Introduction to synaptic circuits, *The Synaptic Organization of the Brain*. Oxford University Press, New York.
- Shin, Y., Kim, Z., Yu, J., Kim, G., Hwang, S., 2019. Development of NOx reduction system utilizing artificial neural network (ANN) and genetic algorithm (GA). *J. Clean. Prod.* 232, 1418–1429. <https://doi.org/10.1016/j.jclepro.2019.05.276>
- Stent, G.S., 1973. A Physiological Mechanism for Hebb's Postulate of Learning. *Proc. Natl. Acad. Sci.* 70, 997–1001. <https://doi.org/10.1073/pnas.70.4.997>
- Subaşı, H., 2010. Yapay Sinir Ağı İle Atıksu Arıtma Performansının Modellenmesi. Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Subramanian, I.R., 1991. Applications of Neural Networks to Character Recognition. *Int. J. Pattern Recognit. Artif. Intell.* 5, 353–382.
- SUGENO, M., 1985. *Industrial Applications of Fuzzy Control*, North-Holland, Amsterdam. Amsterdam. <https://doi.org/10.1177/1757913910379198>

- SYED, F.I., 2019. Development of a Mathematical Model of a Secondary Settling Tank in Wastewater Treatment Plants with Control Purposes. M. Sc. Thesis, Gaziantep University, Graduate School Of Natural & Applied Sciences Development, Gaziantep.
- Topkaya, P., 2008. Computer Simulation Of A Complete Biological Treatment Plant. Master Thesis, Middle East Technical University, The Graduate School Of Natural And Applied Sciences, Ankara.
- Turksen, I.B., Tian, Y., Berg, M., 1992. A fuzzy expert system for a service centre of spare parts. *Expert Syst. Appl.* 5, 447–464. [https://doi.org/10.1016/0957-4174\(92\)90029-R](https://doi.org/10.1016/0957-4174(92)90029-R)
- Ülkü, A.B., 2006. Anaerobik Arıtma Sisteminin Modellenmesi Ve Kontrolü. Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü, Mühendislik Ve Fen Bilimleri Enstitüsü, Gebze.
- Uyanık, P., 2020. Evaluation Of Wastewater Treatment Alternatives For Different Water Reuse Applications With Modeling And Cost Analysis. Master Thesis, Middle East Technical University, Middle East Technical University, Ankara.
- Vijayaraghavan, G., Jayalakshmi, M., 2015. A Quick Review on Applications of Fuzzy Logic in Wastewater Treatment. *Int. J. Res. Appl. Sci. Eng. Technol.* 3, 421–425.
- Wan, J., Huang, M., Ma, Y., Guo, W., Wang, Y., Zhang, H., Li, W., Sun, X., 2011. Prediction of effluent quality of a paper mill wastewater treatment using an adaptive network-based fuzzy inference system. *Appl. Soft Comput. J.* 11, 3238–3246. <https://doi.org/10.1016/j.asoc.2010.12.026>
- Yao, L., Xu, Z., Lv, C., Hashim, M., 2020. Incomplete interval type-2 fuzzy preference relations based on a multi-criteria group decision-making model for the evaluation of wastewater treatment technologies. *Meas. J. Int. Meas. Confed.* 151, 107137. <https://doi.org/10.1016/j.measurement.2019.107137>
- Yetilmezsoy, K., Ozgun, H., Dereli, R.K., Ersahin, M.E., Ozturk, I., 2015. Adaptive neuro-fuzzy inference-based modeling of a full-scale expanded granular sludge bed reactor treating corn processing wastewater. *J. Intell. Fuzzy Syst.* 28, 1601–1616. <https://doi.org/10.3233/IFS-141445>
- Yılmaz, E.C., 2009. Bir Atıksu Arıtma Tesisinin Girişindeki Biyolojik Oksijen İhtiyacının Yapay Sinir Ağları Kullanılarak Modellenmesi Yüksek Lisans Tezi Enstitü Anabilim Dalı : Çevre Müh. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Yıldız Pulcu, S., 2009. Denizli (Merkez) Atıksu Arıtma Tesisi Performansının Yapay Sinir Ağları Kullanılarak Modellenmesi. Yüksek Lisans Tezi, Harran Üniversitesi, Fen Bilimleri Enstitüsü, Şanlıurfa.
- ZADEH, L.A., 1965. Fuzzy sets. *Information and Control. Fuzzy sets. Inf. Control* 8 353, 338–353. <https://doi.org/10.1061/9780784413616.194>

8. EKLER

EK 1: Bu tezde kullanılan şekil 25'in telif hakkı müsaade yazısı.

2:33 2023/1/26

RightsLink Printable License

ELSEVIER LICENSE
TERMS AND CONDITIONS

Jan 26, 2023

Licensed Content Pages 12

Start Page 1957

End Page 1968

Type of Use reuse in a thesis/dissertation

This Agreement between Dr. Hussein Alnajjar ("You") and Elsevier ("Elsevier") consists of your license details and the terms and conditions provided by Elsevier and Copyright Clearance Center.

<https://s100.copyright.com/AppDispatchServlet>

License Number 5476440278760

License date Jan 26, 2023

Licensed Content Publisher Elsevier

Licensed Content Publication Journal of Environmental Chemical Engineering

Licensed Content Title ANFIS based Modelling of dewatering performance and polymer dose optimization in a wastewater treatment plant

Licensed Content Author Eugene Hong,Anteneh Mesfin Yeneneh,Tushar Kanti Sen,Ha Ming Ang,Ahmet Kayaalp

Licensed Content Date Apr 1, 2018

Licensed Content Volume 6

Licensed Content Issue 2

Publisher Tax ID GB 494 6272 12

2:33 2023/1/26

RightsLink Printable License

Portion figures/tables/illustrations

Number of figures/tables/illustrations 1

Format both print and electronic

Are you the author of this Elsevier article? No

Will you be translating? Yes, without English rights

Number of languages 1

Title HİDROLİK MODELLEME: ATIKSU ARITMA TESİSİ (AAT) ÖRNEKLERİ

Institution name KARADENİZ TEKNİK ÜNİVERSİTESİ

Portions 2

Specific Languages Turkish

Requestor Location Dr. Hussein Alnajjar
Turkey
ORTAHIŞAR / TRABZON

Trabzon, 0 61080
Turkey
Attn: Karadeniz Technical University

Ek 2 : Samsun Doğu İleri Biyolojik Atıksu Arıtma Tesisi'ne teknik gezi kabul Yazısı



T.C.
SAMSUN BÜYÜKŞEHİR BELEDİYE BAŞKANLIĞI
Samsun Su ve Kanalizasyon İdaresi Genel Müdürlüğü
Atık Su Arıtma Dairesi Başkanlığı



Sayı : E-64237394-804.01-45615
Konu : Teknik Gezi ve Veri Talebi

25.10.2022

KARADENİZ TEKNİK ÜNİVERSİTESİ REKTÖRLÜĞÜNE

İlgi : 18.10.2022 tarihli ve E-44710342-622.03-8845 sayılı yazımız

İlgide kayıtlı yazınızda Üniversiteniz Mühendislik Fakültesi öğretim üyelerinden Dr. Öğr. Üyesi Osman ÜÇÜNCÜ'nün teknik çalışmaları kapsamında, atık su arıtma tesisimiz ile ilgili veri ve teknik gezi için izin talep edilmektedir.

Talebiniz İdaremizce uygun görülmüş olup, teknik gezinin tarihinin önceden tarafımıza bildirilmesi hususunda;

Gereğini bilgilerinize arz ederim.

Cihan GÜLLER
Genel Müdür a.
Genel Müdür Yardımcısı

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Doğrulama Kodu: sz+Yff-xQ6L7c-9HiOVh-RVcMbO-yLKWTSGm Doğrulama Linki: <https://www.turkiye.gov.tr/icisleri-belediye-ebys>

Denizveleri Mah. 228. Sok. No:4/b Atakum/ Samsun
Telefon No: (362)311 20 00 Faks No: (362)432 44 45
e-Posta: saski@saski.gov.tr İnternet Adresi: <https://www.saski.gov.tr>
Kep Adresi: samsunsaski@hs01.kep.tr

Bilgi için: Haluk YAZICI

Telefon No:



ÖZGEÇMİŞ

Hussein ANAJJAR, Lise eğitimini Filistin'in Gazze şehrinde 2007 yılında tamamlamış olması, erken dönemdeki akademik kararlılığının bir ifadesidir. Hussein'in akademik serüveni, 2007 yılında Gazze'de İslamic Üniversitesi'nden İnşaat Mühendisliği lisans derecesi ile başlamıştır. Sağlam temelini daha da güçlendirmek amacıyla Hussein, aynı kurumda İnşaat Mühendisliği alanında yüksek lisans derecesini 2014 yılında başarıyla tamamlamıştır. 2018 yılında Karadeniz Teknik Üniversitesinde İnşaat Mühendisliği Anabilim Dalında doktora programına başladı. Hussein, Arapça, İngilizce ve Türkçe dâhil olmak üzere çeşitli dillerde yeterlilik göstermektedir. Yurtdışı Türkler ve Akraba Topluluklar Başkanlığı (YTB) bursunu ve Orta Doğu Su Arıtma Araştırma Merkezi (MEDRC) kazanması, sadece öğrenimine olan bağlılığını değil, aynı zamanda uluslararası bir akademisyen olarak potansiyelini de yansıtmaktadır.

Yayınlar

- Alnajjar, H.Y.H., 2023. The sustainability of wastewater treatment efficiency and its estimated impact for onsite wastewater treatment plant systems in semi-urban areas: a Khan Yunis case study. *Desalin. Water Treat.* 287, 29–38. <https://doi.org/10.5004/dwt.2023.29384>
- Alnajjar, Hussein Y.H., Üçüncü, O., 2023a. Performance prediction and control for wastewater treatment plants using artificial neural network modeling of mechanical and biological treatment. *Arch. Environ. Prot.* 49, 16–29. <https://doi.org/10.24425/aep.2023.145893>
- Alnajjar, Hussein Y.H., Üçüncü, O., 2023b. Enhance and improve modelling prediction by using an adaptive neuro-fuzzy inference system-based model to predict pollution removal efficacy in wastewater treatment plants. *Desalin. Water Treat.* 286, 52–63. <https://doi.org/10.5004/dwt.2023.29320>
- Alnajjar, Hussein Y H, Üçüncü, O., 2023. Removal efficiency prediction model based on the artificial neural network for pollution prevention in wastewater treatment plants. *Arab Gulf J. Sci. Res. ahead-of-p.* <https://doi.org/10.1108/AGJSR-07-2022-0129>
- Alnajjar, H.Y.H., Üçüncü, O., 2022. Enhance modelling predicting for pollution removal in wastewater treatment plants by using an adaptive neuro-fuzzy inference system. *Environ. Res. Technol.* 5, 213–226. <https://doi.org/10.35208/ert.1106463>
- Alnajjar, Hussein Y.H., Üçüncü, O., 2021. Increasing The Efficiency of Biological Treatment Ponds in Wastewater Treatment Plants Using Artificial Intelligence Models, içinde: 7th INTERNATIONAL STUDENT SYMPOSIUM. FEDERATION OF INTERNATIONAL STUDENT ASSOCIATIONS, Samsun, ss. 147–161.
- Alnajjar, Hussein Y H, Üçüncü, O., 2021. Using of a Fuzzy Logic as One of The Artificial Intelligence Models to Increase the Efficiency of The Biological Treatment Ponds in Wastewater Treatment Plants. *Int. J. Environ. Pollut. Environ. Model.* 4, 85–94.