

T.C.
KİLİS 7 ARALIK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI
YÜKSEK LİSANS TEZİ

İLERİ BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE
ÇIKIŞ PARAMETRELERİNİN DERİN ÖĞRENME
YÖNTEMLERİYLE DEĞERLENDİRİLMESİ

ERCAN UYGUN

DANIŞMAN: Dr. Öğr. Üyesi Mustafa Mikail ÖZÇİLOĞLU

KİLİS

2024

ÖZET

İLERİ BİYOLOJİK ATIKSU ARITMA TESİSLERİNDE ÇIKIŞ PARAMETRELERİNİN DERİN ÖĞRENME YÖNTEMLERİYLE DEĞERLENDİRİLMESİ

Ercan UYGUN

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Kilis 7 Aralık Üniversitesi, Lisansüstü Eğitim Enstitüsü

Danışman: Dr. Öğr. Üyesi Mustafa Mikail ÖZÇİLOĞLU

Sayfa: 85

Yıl: 2024

Atıksu arıtma tesislerinde çıkış suyu parametrelerinin tebliğde belirtilen kriterleri sağlama derecesi, tesisin verimliliğinin ölçüsüdür. Bu nedenle sisteme giren kirli su ve tesisten çıkan arıtılmış suda bazı parametreler için ölçümler yapılarak tebliğde belirtilen kriterleri sağlayıp sağlamadığı takip edilir.

Bu tez çalışmasında, atıksu arıtma tesisleri, arıtma yöntemleri ve atıksu arıtma tesisi çıkış parametreleri ile ilgili genel bilgi verilmiş, daha sonra derin öğrenme ve derin öğrenme yöntemleri açıklanmıştır. Sonrasında ise RNN, LSTM, GRU ve LSTM/GRU derin öğrenme modelleri tasarlanarak, atıksu arıtma tesisi çıkış parametrelerine ait veriler üzerinde uygulanmıştır. Sonrasında ise RNN, LSTM, GRU ve LSTM/GRU derin öğrenme modelleri tasarlanarak, atıksu arıtma tesisi çıkış parametrelerine ait veriler üzerinde uygulanmıştır. Uygulanan modellerin, düzenli alınmış atıksu arıtma tesisi parametrelerinde başarılı sonuçlar verdiği gözlenmiş, derin öğrenme yöntemlerinin başarılı sonuç verebilmesi için düzenli ve yeterli sayıda veri olması gerektiği sonucuna varılmıştır. Çalışmada, en iyi sonuç veri yapısı en düzenli olan pH parametresi ile elde edilmiştir. Modeller farklı performans ölçütlerine göre değerlendirilerek sonuçları analiz edilmiştir. Uygulanan derin öğrenme modellerine göre en başarılı sonuçlar genel olarak GRU ve LSTM modelleri ile elde edilmiştir.

Anahtar Sözcükler: Atıksu, Derin öğrenme, RNN, LSTM, GRU.

ABSTRACT

EVALUATION OF OUTPUT PARAMETERS IN ADVANCED BIOLOGICAL WASTE WATER TREATMENT PLANTS USING DEEP LEARNING METHODS

Ercan UYGUN

Department of Electrical and Electronics Engineering
Kilis 7 Aralik University, Graduate Education Institute
Supervisor: Asst. Prof. Dr. Mustafa Mikail ÖZÇİLOĞLU

Page: 85

Year: 2024

The degree to which the output water parameters in wastewater treatment plants meet the criteria specified in the circular is a measure of the efficiency of the plant. For this reason, measurements are made for some parameters in the dirty water entering the system and the treated water leaving the plant, and whether they meet the criteria specified in the circular is monitored.

In this thesis, general information about wastewater treatment plants, treatment methods and wastewater treatment plant output parameters are given, then deep learning and deep learning methods are explained. Afterwards, RNN, LSTM, GRU and LSTM/GRU deep learning models were designed and applied on the data of wastewater treatment plant outlet parameters. It was observed that the applied models gave successful results on the regularly collected wastewater treatment plant parameters, it was concluded that there should be regular and sufficient number of data for deep learning methods to give successful results. In the study, the best result was obtained with the pH parameter with the most organized data structure. The models were evaluated according to different performance criteria and their results were analyzed. According to the deep learning models applied, the most successful results were generally obtained with GRU and LSTM models.

Keywords: Waste water, Deep learning, RNN, LSTM, GRU.

TEŞEKKÜR

Tez çalışmam süresince, konunun belirlenmesinden itibaren tamamlanıncaya kadar beni yönlendiren ve destekleyen danışmanım sayın Dr. Öğr. Üyesi Mustafa Mikail ÖZÇİLOĞLU'na, tezimin kaynağını oluşturan ileri biyolojik atıksu tesisleri ile ilgili ihtiyacım olan her türlü bilgiye ve gerekli dokümanlara erişmemde yardımcı olan Gaziantep İleri Biyolojik Atıksu Arıtma Tesisi ikinci kısım Elektrik Elektronik Mühendisi sayın Bayram DURMUŞ'a ve tez çalışmamın en önemli unsuru olan verileri sağlayan Gaziantep Su ve Kanalizasyon İdaresi yetkililerine teşekkürlerimi sunarım.



..../08/2024

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda bilimsel etik ilke ve kurallara uygun davrandığımı; bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, kullanmış olduğum tüm bilgiler ve yorumlar için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi, hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili bu beyanıma aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

İmza

Ercan UYGUN

İÇİNDEKİLER

	sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	iv
İÇİNDEKİLER	v
ŞEKİLLER DİZİNİ	x
GÖRSELLER DİZİNİ	xii
SİMGELER ve KISALTMALAR DİZİNİ	xiii
1. GİRİŞ	1
1.1. Amaç	2
2. KAVRAMSAL ÇERÇEVE	4
2.1. Atıksu Arıtma Yöntemleri	4
2.1.1. Fiziksel arıtma	5
2.1.1.1. Izgaralar ve elekler	5
2.1.1.2. Öğütücüler	6
2.1.1.3. Dengeleme havuzları	7
2.1.1.4. Yüzdürme havuzları	7
2.1.1.5. Kum tutucular	7
2.1.1.6. Çöktürme (çökeltim) havuzları	8
2.1.2. Kimyasal arıtma	9
2.1.2.1. Nötralizasyon	9
2.1.2.2. Koagülasyon	9
2.1.2.3. Flokülasyon	9
2.1.3. Biyolojik arıtma	9
2.1.4. İleri biyolojik arıtma	10
2.1.4.1. Azot giderme	10
2.1.4.2. Fosfor giderme	11
2.1.4.3. Dezenfeksiyon	11
2.2. İleri Biyolojik Atıksu Arıtma Tesislerinde Giriş Çıkış Parametreleri	11

2.2.1. Debi	11
2.2.2. BOİ (Biyokimyasal/Biyolojik Oksijen İhtiyacı)	12
2.2.3. KOİ (Kimyasal Oksijen İhtiyacı)	12
2.2.4. Askıda Katı Madde (AKM)	12
2.2.5. pH	13
2.2.6. Azot (N) ve Fosfor (P) değerleri	13
2.2.7. Sıcaklık	13
2.3. Literatür Özeti	14
3. MATERYAL VE YÖNTEM	17
3.1. Derin Öğrenme	17
3.2. Derin Öğrenme Modelleri	18
3.2.1. Konvolüsyonel sinir ağları	18
3.2.1.1. Giriş katmanı	19
3.2.1.2. Konvolüsyon (Evrişim) katmanı	20
3.2.1.3. Düzleştirilmiş doğrusal birim katmanı (ReLU)	20
3.2.1.4. Havuzlama (Pooling) katmanı	21
3.2.1.5. Tam bağlantılı katman	22
3.2.1.6. Dropout (Seyreltme) katmanı	22
3.2.1.7. Sınıflandırma katmanı	23
3.2.2. Tekrarlayan sinir ağları	23
3.2.3. Uzun kısa süreli bellek ağları	28
3.2.4. Geçitli tekrarlayan birim	29
3.2.5. Sınırlı Boltzmann makineleri	30
3.2.6. Derin inanç ağları	30
3.2.7. Derin oto-kodlayıcılar	31
3.3. Derin Öğrenme Uygulamaları	32
3.3.1. Görüntü/video/ses işleme	32
3.3.2. Doğal dil işleme	33
3.3.3. El yazısı karakter tanıma	34
3.3.4. İmza doğrulama	34
3.3.5. Tıbbi görüntü işleme	34
3.4. Derin Öğrenme Kütüphaneleri	35

3.4.1. Theano	35
3.4.2. TensorFlow	35
3.4.3. Keras	35
3.4.4. Caffe	36
3.4.5. PyTorch	36
3.4.6. Pandas	36
3.4.7. Numpy	36
3.4.8. Matplotlib	36
3.4.9. Scikit-Learn	36
3.4.10. Seaborn	37
3.5. Derin Öğrenmede Hiper parametreler	37
3.6. Performans Değerlendirme Ölçütleri	40
3.6.1. Regresyon modelleri için performans değerlendirme ölçütleri	40
3.6.2. Sınıflandırma modelleri için performans değerlendirme ölçütleri	43
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	46
4.1. İleri Biyolojik Atıksu Arıtma Tesis Verileri	46
4.2. Çıkış Parametrelerine Derin Öğrenme Modellerinin Uygulanması	50
4.2.1. RNN modelinin uygulanması	50
4.2.2. LSTM modelinin Uygulanması	56
4.2.3. GRU modelinin uygulanması	61
4.2.4. LSTM/GRU modelinin uygulanması	67
4.2.5. Performans değerlendirme ölçütlerine göre sonuçlar	73
4.3. Araştırma Bulguları	77
5. SONUÇ VE ÖNERİLER	79
6. KAYNAKLAR	81

ÖZGEÇMİŞ

TABLÖLAR DİZİNİ

Tablo 3.1. Tekrarlayan sinir ağlarının türleri	27
Tablo 3.2. Doğal dil işleme problemleri ve kullanılan derin öğrenme yöntemleri	33
Tablo 4.1. Çıkış parametreleri üzerinde RNN sonuçları	52
Tablo 4.2. Çıkış parametreleri üzerinde LSTM sonuçları	57
Tablo 4.3. Çıkış parametreleri üzerinde GRU sonuçları	63
Tablo 4.4. Çıkış parametreleri üzerinde LSTM/GRU sonuçları	68
Tablo 4.5. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MSE'ye göre)	73
Tablo 4.6. Çıkış parametrelerinin uygulanan modellere göre sonuçları (RMSE'ye göre)	73
Tablo 4.7. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MAE'ye göre)	73
Tablo 4.8. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MAPE'ye göre)	74
Tablo 4.9. Performans değerlendirme ölçütlerine göre sonuçlar (MGD'ye göre)	74
Tablo 4.10. Performans değerlendirme ölçütlerine göre sonuçlar (MPD'ye göre)	74
Tablo 4.11. Çıkış parametrelerinin uygulanan modellere göre sonuçları (EVS'ye göre)	75
Tablo 4.12. Çıkış parametrelerinin uygulanan modellere göre sonuçları (R ² 'ye göre) ..	75
Tablo 4.13. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (MSE'ye göre)	75
Tablo 4.14. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (RMSE'ye göre)	76
Tablo 4.15. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (MAE'ye göre)	76
Tablo 4.16. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (MAPE'ye göre)	76
Tablo 4.17. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (MGD'ye göre)	76
Tablo 4.18. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (MPD'ye göre)	77

Tablo 4.19. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (EVS'ye göre)	77
Tablo 4.20. Uygulanan modellerin çıkış parametrelerine göre sonuçlar (R ² 'ye göre)	77



ŞEKİLLER DİZİNİ

Şekil 3.1. Yapay zeka, makine öğrenmesi ve derin öğrenme	17
Şekil 3.2. Klasik yapay sinir ağı ve derin öğrenme	17
Şekil 3.3. Makine öğrenmesi ve derin öğrenme	18
Şekil 3.4. Konvolüsyonel sinir ağı yapısı	19
Şekil 3.5. Konvolüsyon katmanında özellik haritasının çıkarılması	20
Şekil 3.6. ReLu fonksiyonu ile matrisin doğrusal olmayan yapıya dönüştürülmesi	21
Şekil 3.7. 2x2 havuzlama	22
Şekil 3.8. Dropout işleminin uygulanması	23
Şekil 3.9. Tekrarlayan sinir ağının genel yapısı	24
Şekil 3.10. RNN gizli katmanının t zaman adımıdaki çıktısı	24
Şekil 3.11. Bir LSTM hücre bloğunun yapısı	29
Şekil 3.12. GRU bloğunun yapısı	29
Şekil 3.13. RBM ağının yapısı	30
Şekil 3.14. Derin inanç ağının yapısı	31
Şekil 3.15. Derin oto kodlayıcı ağının yapısı	32
Şekil 3.16. Aktivasyon fonksiyonları	39
Şekil 3.17. Karışıklık matrisi	43
Şekil 3.18. ROC-AUC eğrisi	45
Şekil 4.1. Atıksu arıtma tesis verileri	46
Şekil 4.2. Veri setinin parametrelere göre eğitim ve test olarak ayrılması	48
Şekil 4.3. RNN modelinde eğitim ve test kayıp fonksiyonu	52
Şekil 4.4. RNN modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması	53
Şekil 4.5. RNN modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı	55
Şekil 4.6. LSTM modelinde eğitim ve test kayıp fonksiyonu	58
Şekil 4.7. LSTM modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması	59
Şekil 4.8. LSTM modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı	61
Şekil 4.9. GRU modelinde eğitim ve test kayıp fonksiyonu	63

Şekil 4.10. GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması	64
Şekil 4.11. GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı	66
Şekil 4.12. LSTM/GRU modelinde eğitim ve test kayıp fonksiyonu	69
Şekil 4.13. LSTM/GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması	70
Şekil 4.14. LSTM/GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı	72



GÖRSELLER DİZİNİ

Görsel 1.1. İleri biyolojik atıksu arıtma tesisi	1
Görsel 2.1. Atıksu arıtma tesisinde ızgaralar	5
Görsel 2.2. Döner tamburlu elek	6
Görsel 2.3. Öğütücü	6
Görsel 2.4. Dengeleme havuzu	7
Görsel 2.5. Kum tutucu	8
Görsel 2.6. Çökeltim havuzu	8
Görsel 4.1. RNN mimarisinin parametreleri ve katmanları	51
Görsel 4.2. LSTM mimarisinin parametreleri ve katmanları	56
Görsel 4.3. GRU mimarisinin parametreleri ve katmanları.....	62
Görsel 4.4. LSTM/GRU mimarisinin parametreleri ve katmanları	67

SİMGELER ve KISALTMALAR DİZİNİ

1. Simgeler

CH ₄	: Metan
CO	: Karbonmonoksit
CO ₂	: Karbondioksit
EC	: Elektriksel iletkenli
N	: Azot
N ₂	: Azot gazı
NH ₃	: Amonyak
P	: Fosfor
pH	: Hidrojen iyon konsantrasyonu
R ²	: Belirlilik katsayısı
tanh	: Hiperbolik tanjant

2. Kısaltmalar

AAT	: Atıksu Arıtma Tesisi
AE	: Oto-Kodlayıcı
AKM	: Askıda Katı Madde
AnMBR	: Anaerobik Membran Biyoreaktör
ARIMA	: Otoregresif Entegre Hareketli Ortalama
AUC	: Eğri Altında Kalan Alan
BOİ	: Biyokimyasal Oksijen İhtiyacı
BOİ ₅	: Analizi 5 Gün ile Sınırlandırılmış Biyokimyasal Oksijen İhtiyacı
CNN	: Konvolüsyonel Sinir Ağı
DAE	: Derin Oto-Kodlayıcı
DBN	: Derin İnanc Ağı
DenseNet	: Yoğun Bağlantılı Evrişim Ağı
DNN	: Derin Sinir Ağı
EEG	: Elektroensefalogram
EVS	: Açıklanan Varyans Puanı
FN	: Yanlış Negatif

FP	: Yanlıř Pozitif
FPR	: Yanlıř Pozitif Oranı
GBDT	: Gradyan Arttırıcı Karar Ağacı
GRU	: Geçitli Tekrarlayan Birim
KNN	: K-En Yakın Komşuluk Sinir Ağı
KOİ	: Kimyasal Oksijen İhtiyacı
LSTM	: Uzun Kısa Süreli Bellek Ağı
MAE	: Ortalama Mutlak Hata
MGD	: Ortalama Gama Dağılımı
ML	: Makine Öğrenmesi
MPD	: Ortalama Poison Dağılımı
MSE	: Ortalama Kare Hata
NLP	: Doğal Dil İşleme
ODSC	: Open Data Science Community (Açık Veri Bilimi Topluluğı)
PDP	: Kısmi Bağımlılık Planı
RBM	: Sınırlı Boltzmann Makineleri
ReLu	: Düzeltilmiş Doğrusal Birim
RF	: Rasgele Orman
RMSE	: Ortalama Kare Hata Karekökü
RNN	: Tekrarlayan Sinir Ağı
ROC	: Alıcı Çalışma Karakteristik Eğrisi
SGD	: Stokastik Gradyan Azaltma
TN	: Doğru Negatif
TP	: Doğru Pozitif
VIM	: Değişken Önem Ölçümü
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Nüfus artışı, hızlı kentleşme, sanayileşme gibi faaliyetler, mevcut temiz su kaynaklarını kirleterek atıksuya dönüştürmekle birlikte su talebinde de artışı da beraberinde getirmektedir. Su talebindeki artışı karşılamak için düşünülebilecek en basit çözüm su kaynaklarının miktarının artırılması gibi düşünülebilir. Ancak bu durum hem teknik açıdan hem de teknolojik olarak sınırlandırıcı bazı faktörler içermektedir (Alpaslan, 2021). Bu sebeple mevcut su kaynaklarının hem korunması hem de kullanımının verimli hale getirilmesi son derece önemlidir (Kurtkulak, 2014). Bu bağlamda atıksuların arıtılarak geri kazandırılması (özellikle tarımsal sulama amaçlı olarak) ile mevcut su kaynaklarında tüketim azaltılırken, bir yandan da geri kazanılan arıtılmış atıksuların çevreye olan etkileri azaltılmış olmaktadır.

Kullanımları neticesinde kirlenerek atıksuya dönüşmesi sonucunda kısmen kaybettikleri fiziksel, kimyasal ve biyolojik özelliklerinin sulara yeniden kazandırılması ve çevreye zarar vermelerinin önlenmesi için yapılan işlemler atıksuların arıtılması olarak ifade edilmektedir.

Atıksuların arıtılması, atıksu arıtma tesislerinde (Görsel 1.1) birtakım fiziksel, kimyasal ve biyolojik işlemlerden geçirilmesiyle gerçekleştirilmektedir. Arıtılmış atıksuların hangi amaçla kullanılacağı, kullanılacak teknolojiyi de belirlemektedir.



Görsel 1.1. İleri biyolojik atıksu arıtma tesisi

Tarımsal sulama amaçlı kullanılan suyun miktarı, toplam su tüketiminde önemli bir orana sahiptir. Bu da tarımsal sulamada atıksuların kullanılmasını ön plana çıkarmaktadır. Bununla birlikte, hem çevre ve insan sağlığını korumak, hem de arıtıldıktan sonra kullanılan atıksulardan kaynaklanacak başka olumsuz etkileri azaltmak için bazı önemli kriterlere dikkat etmek gerekmektedir. Bu kriterler ülkemizde Atıksu Arıtma Tesisleri Teknik Usuller Tebliğinde açıklanmıştır.

Atıksu arıtma tesislerinde çıkış suyu parametrelerinin tebliğde belirtilen kriterleri sağlama derecesi, tesisin verimliliğinin ölçüsüdür. Bu nedenle sisteme giren kirli su ve tesisten çıkan arıtılmış su için ölçümler yapılarak tebliğde belirtilen kriterleri sağlayıp sağlamadığı takip edilir.

Atıksuyun kullanılacağı alan, karakteristiği, geri kazanıldıktan sonra beklenen su kalitesi, içinde bulunan eser elementlerin miktarı, enerji ihtiyacı gibi parametreler, atıksuların geri kazanımı için belirlenecek teknoloji tipini etkileyen faktörlerdir.

Mevcut atıksu arıtma sistemlerinin çoğu, büyük ölçekli uygulamalar için yaygın olarak kullanılan aerobik aktif çamur prosesine dayalı olarak tasarlanmıştır (Ang & Mohammad, 2020; Newhart vd., 2019). Atık su arıtma tesisleri genellikle karmaşık bir yapıya sahiptir ve giriş yüklerindeki ve doğal koşullardaki dalgalanmalar, mikrobiyal topluluğun aktivitesini engelleyebilir ve atık su kalitesini bozabilir. Kimyasal oksijen ihtiyacı (KOİ), biyokimyasal oksijen ihtiyacı (BOİ), askıda katı maddeler (AKM) gibi spesifik parametrelerin izlenmesi ve düzenli ölçümleri ile su kalitesi değerlendirilmektedir. Ancak bu parametrelerin düzenli ölçümlerinde maliyet etkinliği, karmaşıklık ve uzun süreli gözlemler gibi hususlar ön plana çıkmaktadır (Lotfi vd., 2019).

1.1. Amaç

Arıtılmış atık sular tarımsal sulamada kullanılmaya başlandıktan sonra, arıtma tesisinin çıkış suyunda günlük olarak BOİ, KOİ, AKM ve elektriksel iletkenlik (EC) parametrelerinin, haftalık olarak Azot (N) ve Fosfor (P) parametrelerinin ölçülmesi ve takip edilmesi gerekmektedir. Ayrıca periyodik olarak veya gerektiğinde ağır metaller de takip edilmelidir. Atıksu arıtma tesislerinin performansını değerlendirmek ve gerektiğinde iyileştirmeler yapabilmek için belirtilen parametrelerin ölçülmesi ve

tahmin edilmesi gereklidir. Bu uygulama, geri kazanılmış atıksu kalitesinde meydana gelebilecek olumsuz deęişimlerin tespit edilmesiyle birlikte, atıksu arıtma tesisinin denetlenmesini de sağlamaktadır. Arıtılmış suyun kalitesinin belirlenmesinde kullanılan parametrelerin doğrudan ölçümü pahalı ve yüksek bakım gerektiren hat içi problemler veya analizörler gerektirdiğinden, bu çalışmada atıksu arıtma tesisi çıkış parametrelerinin derin öğrenme yöntemleri kullanılarak tahmin edilmesi amaçlanmaktadır.



2. KAVRAMSAL ÇERÇEVE

Atıksuların kullanım amaçları, kurulacak tesisin teknoloji gereksinimini de belirlemektedir. Arıtılarak geri kazanılmış sular, tarımsal sulama veya yeşil alanların sulanması için kullanılmak istendiğinde, dezenfeksiyonu iyi yapılmış biyolojik arıtmaya ihtiyaç vardır. Doğrudan veya dolaylı olarak yeniden kullanım amaçlanmaktaysa, o zaman membran teknolojileri gibi ileri arıtma seçeneklerinin düşünülmesi gerekir.

Atıksu içerisinde, tane boyutlarına göre çökebilir, askıda, kolloidal ve çözünmüş halde bulunan maddeler, kirlenmeye neden olmaktadır. Kirletici olarak ifade edilen bu maddelerin atıksudan uzaklaştırılması için farklı yöntemler kullanılmaktadır. Buradaki temel amaç, geri kazanılmış atıksular, ortama gönderildiğinde insan sağlığı ve çevre açısından ortaya çıkması muhtemel zararların etkilerini ortadan kaldırmak veya mümkün olan en alt seviyeye indirebilmektir (Kavak, 2016). Kriterlere uygun kaliteli bir arıtmadan söz edilebilmesi için, atıksu arıtma tesislerinin de teknolojik gelişmelere uyum sağlaması gerekmektedir.

Bu bölümde atıksu arıtma yöntemleri ve ileri biyolojik atıksu arıtma tesislerinde giriş-çıkış parametreleri detaya girilmeden açıklanacaktır.

2.1. Atıksu Arıtma Yöntemleri

Atıksuların arıtılmasında kullanılan yöntemler, salınacağı ortama ve karakteristik özelliklerine göre fiziksel arıtma, kimyasal arıtma ve biyolojik arıtma olarak sınıflandırılmaktadır. Atıksu bünyesinde bulunan çökelebilen maddelerin uzaklaştırılmasında fiziksel arıtma kullanılır. Çözünmüş halde atıksu bünyesinde bulunan kirletici maddelerin, kimyasal reaksiyonlar gerçekleştirilerek çözünürlüğü düşük bileşiklere dönüştürülmesi için, kolloidal ve askıda maddelerin ise yumaklar oluşturarak çökeltilmesi için kimyasal arıtma uygulanır. Atıksu bünyesinde çözünmüş veya kolloidal halde bulunan, biyolojik olarak parçalanabilir maddelerin mikroorganizmalar tarafından besin ve enerji kaynağı olarak kullanılarak uzaklaştırılması için biyolojik arıtma kullanılır (Sağlam, 2019). Fiziksel ve kimyasal olarak beraber yapılan arıtmalar organik maddelerin giderilmesinde yetersiz kalabildiğinden dolayı verim genel olarak biyolojik arıtmalara göre daha düşüktür. Atıksu bünyesinde ayrıışmayan organik maddelerin varlığı söz konusu ise biyolojik

arıtmalar yetersiz kalabilmektedir. Biyolojik ve kimyasal arıtmada giderilemeyen kirleticilerin uzaklaştırılmasında ileri arıtma sistemleri tercih edilir.

2.1.1. Fiziksel arıtma

Birincil arıtma olarak da tanımlanabilecek olan fiziksel arıtma; atıksu bünyesindeki kirletici maddenin fiziksel özelliklerine bağlı olarak uygulanan arıtma yöntemidir. Esas arıtma prosesleri için bir hazırlık aşaması olarak düşünülebilir. Atıksu arıtılmasının sonraki ilerleyen aşamalarında, arıtma işleminde kullanılan ekipmanlara zarar vermesi muhtemel, suda çözünmemiş haldeki gözle görülür katı maddelerin henüz arıtma işlemi başlatılmadan ham atıksudan uzaklaştırılması bu aşamada gerçekleştirilmektedir. Fiziksel arıtma işlemleri iki ana nedene dayanmaktadır. Bunlar, tesislerdeki boru ve kanalların tıkanmasını önlemek için kaba malzemelerin uzaklaştırılması ve arıtma tesisinin diğer ünitelerine gelecek yüklerin en alt düzeyde tutulmasıdır (Durak, 2020). Fiziksel arıtma, ızgaralar, elekler, öğütücüler, parçalayıcılar, dengeleme ve yüzdürme havuzları, filtreler, kum tutucular ve çökeltme havuzları gibi ünitelerden oluşmaktadır.

2.1.1.1. Izgaralar ve elekler

Kaba ve hacimli maddelerin atıksudan uzaklaştırılarak pompa, boru ve teçhizata zarar vermemesi; tesisin diğer ünitelerine gelen yükün azaltılmasında ızgaralar kullanılır (Kavak, 2016; Demirkol, 2021). Izgaralar, kaba ve ince ızgaralar olarak sınıflandırılırlar (Görsel 2.1).



a) Kaba ızgara



b) İnce ızgara

Görsel 2.1. Atıksu arıtma tesisinde ızgaralar

Askıdaki tanecikleri ve elyaflı maddeleri tutmak için arıtma tesislerinde elekler kullanılır (Görsel 2.2). Elekler de tuttukları maddelerin boyutlarına göre kaba ve ince elekler olarak sınıflandırılırlar.



Görsel 2.2. Döner tamburlu elek

2.1.1.2. Öğütücüler

Arıtma işlem ve süreçlerinde kaba danelerin sorun oluşturmalarını önlemek için kullanılırlar. Görsel 2.3’de öğütücü resmi görülmektedir.



Görsel 2.3. Öğütücü

2.1.1.3. Dengeleme havuzları

Atıksulardaki kirlilik yükünün zaman içindeki değişimlerini dengelemek ve tesise giren atıksu debisinin düzenli olmasını sağlarlar. Dengeleme havuzlarında, konsantrasyonun dengelenmesi ve çökelmenin önlenmesi amacıyla karıştırma işlemi uygulanır (Görsel 2.4).



Görsel 2.4. Dengeleme havuzu

2.1.1.4. Yüzdürme havuzları

Atıksu içerisinde bulunan yoğunluğu sudan küçük olan katı maddelerin ve yağ, gres, solvent gibi sıvı maddelerin yüzdürülmek suretiyle suyun yüzeyinde toplanması ve uzaklaştırılması için kullanılırlar.

2.1.1.5. Kum tutucular

Biyolojik olarak ayrıştırılamayan kum, çakıl gibi küçük parçacıklar, mekanik ekipmanlara zarar verebilmekte, kum, çöktürme havuzları, çamur çürütme ve susuzlaştırma ünitelerinde tıkanmalara sebep olmakta, bu şekilde ciddi işletme problemleri oluşturmaktadır. Kum tutucularda büyük partiküller, akım hızı düşürülerek çöktürülmekte ve sonrasında havuzun tabanından alınmaktadır. Yüzen diğer maddeler ve yağ ise, yağ ayırma bölümünün yüzeyinde toplanır, sıyırıcı köprüsünün ayrı bir kolu ile yağ haznesine süpürülerek sistemden uzaklaştırılır. Görsel 2.5'te kum ve yağ tutucu ünitesinin resmi görülmektedir.



Görsel 2.5. Kum tutucu

2.1.1.6. Çöktürme (çökeltim) havuzları

Yoğunluğu sudan daha fazla olan askıda katı maddeler ile kimyasal ve biyolojik işlemlerle çökebilir hale getirilen katı maddeler, çökeltim havuzlarında yerçekimi etkisiyle çökeltilerek sudan ayrıştırılırlar. Böylece kirleticilerin diğer arıtma ünitelerine geçmeleri engellenmiş olur. Biyolojik ve kimyasal arıtma işleminin öncesinde ön çöktürme, sonrasında ise son çöktürme amacı ile kullanılırlar (Görsel 2.6). Kendiliğinden çökebilen maddelerin ayrıştırılması ön çökeltim havuzlarında, biyolojik atıkların giderimi ise son çökeltim havuzlarında gerçekleştirilmektedir.



Görsel 2.6. Çökeltim havuzu

2.1.2. Kimyasal arıtma

Kimyasal atıksu arıtma işlemleri, suda çözünmüş olan veya askıda bulunan kirleticilerin fiziksel durumlarını değiştirmek suretiyle çökelmelerini sağlamak üzere uygulanan arıtma işlemleridir. Kimyasal arıtmadaki temel amaç, fiziksel arıtma ile giderilemeyen çözünmüş, askıda ve kolloidal maddelerin, dışarıdan kimyasal madde eklenmesi suretiyle kimyasal tepkimeler oluşturularak sudan uzaklaştırılmasını sağlamaktır (Demirkol, 2021).

Kimyasal arıtma yöntemleri fiziksel arıtma ile birlikte kullanıldığı gibi, biyolojik arıtmalar ile birlikte de kullanılabilir. Kimyasal arıtmada, atık suya kimyasal maddeler ilave edilmesi sonucu, çöktürülmek istenen maddeler çökelti olarak çamur hâlinde sudan ayrılır. Kimyasal arıtma uygulamaları nötralizasyon, koagülasyon ve flokülasyon olarak sıralanabilir.

2.1.2.1. Nötralizasyon

Atıksuların uygun pH değerine ayarlanması amacı ile suya asit veya baz ilavesi yapılması işlemidir.

2.1.2.2. Koagülasyon

Atıksu bünyesinde bulunan kolloidal ve askıda katı maddelerle birleşerek flok oluşturmaya hazır hale gelmesi için, koagülant maddelerin uygun pH'da atıksuya ilave edilmesi işlemidir. Çok uzun bekletme süresi olmadan atık sudan ayrılamayan askıda maddeler ve kolloidlere hızlı karıştırma ünitelerinde koagülant ilavesi ile, bekletme süresi oldukça kısaltılmış olur. Askıda maddeler çözünbilir organikler ise biyolojik arıtmayla giderilebilir.

2.1.2.3. Flokülasyon

Flokülasyon (yumaklaştırma), atıksuyun yavaşça belirli bir süre karıştırılarak, koagülasyon işlemi ile oluşturulan küçük taneciklerin birbiriyle birleşmesi ve kolay çökebilir flokların oluşturulması işlemidir.

2.1.3. Biyolojik arıtma

Atıksuların karakterizasyonuna bağlı olarak arıtma yöntemleri değişiklik göstermektedir. Ön arıtma yöntemleri ile uzaklaştırılamayan çözünmüş ve kolloidal

organik maddelerin atıksudan uzaklaştırıldığı ikincil arıtım aşaması biyolojik arıtmadır. Günümüzde, kimyasal arıtma yöntemlerine daha kaliteli çıkış suyu elde edildiğinden dolayı biyolojik arıtma tercih edilmektedir. Biyolojik arıtmanın temelinde tek hücreli canlılar olan mikroorganizmalar yer almaktadır. (Sağlam, 2019). Biyolojik arıtma, atıksu bünyesinde bulunan askıda maddeler ile çözünmüş olan organik maddelerin, mikroorganizmalar yardımıyla bakteriyolojik faaliyetler gerçekleştirmesi sonucunda karbondioksit, su ve yeni mikroorganizma hücrelerine ayrıştırılarak giderilmesi işlemidir.

Biyolojik arıtma sistemleri ortamda oksijen varlığına göre havalı (aerobik) ve havasız (anaerobik) olarak sınıflandırılırlar. Havanın bulunduğu ortamda gerçekleştirilen arıtma işlemi aerobik arıtma, havasız ortamda gerçekleştirilen arıtma işlemi ise anaerobik arıtmadır.

2.1.4. İleri biyolojik arıtma

Atıksuların salınacakları ortamlara verilmeden önce içeriğinde bulunan kirleticilerin ayrıştırılması, daha sonra alıcı ortama verilmesi, söz konusu ortamların korunması için önemlidir. Atıksuların bünyesinde biyolojik olarak parçalanabilen maddeler ve mikroorganizmaların yanında azot (N) ve fosfor (P) gibi nütrient maddeler de bulunmaktadır. Arıtma tesisleri sıkışında ortama salınan arıtılmış sudaki N ve P konsantrasyonlarının belirlenen değerlerin altında olması gerekmektedir.

Azot, fosfor, ağır metaller gibi, fiziksel veya biyolojik arıtma yöntemleriyle yeterli düzeyde arılamayan ya da arıtılması mümkün olmayan kirleticileri sudan uzaklaştırmak belirlenen sınırların altına indirmek için uygulanan biyolojik arıtma yöntemleri, ileri biyolojik arıtma olarak isimlendirilmektedir. İleri veya son arıtma, biyolojik arıtma işleminden çıkan atıksuyun kalitesinde iyileştirme yapmak için uygulanan arıtmadır. İleri arıtmadaki temel amaç, nitrifikasyon ve denitrifikasyon işlemleriyle atıksu içerisinde amonyak (NH_3), azot ve fosfor giderilmesidir.

2.1.4.1. Azot giderme

Nitrifikasyon işlemi ile atıksu içinde bulunan amonyum iyonları, azot bakterileriyle önce nitrite sonrada nitrata dönüştürülür. Sonraki aşamada ise denitrifikasyon işlemi ile nitratlar azot gazı (N_2) olarak sudan uzaklaştırılır.

2.1.4.2. Fosfor giderme

Biyolojik ve kimyasal yöntemler birlikte veya ayrı ayrı kullanılarak, atıksu içerisindeki fosfor bileşiklerini giderilmeye çalışılır. Kimyasal arıtma ile yüksek pH değerinde fosfor, fosfat tuzları halinde çöktürülür. Biyolojik arıtma ile de fosfat, mikroorganizmalar tarafından besin maddesi olarak hücrelerine alınır

2.1.4.3. Dezenfeksiyon

Arıtma tesisi çıkışında arıtılmış sular ortama verilmeden önce, suda bulunan hastalık yapıcı virüs ve bakterilerin çeşitli yöntemlerle giderilmesi için dezenfeksiyon işleminden geçirilirler. Klor bileşikleri, iyot, ozon, fenol bileşikler, ağır metaller, çeşitli asitler ve alkaliler, dezenfeksiyon için kullanılan çeşitli kimyasallardır.

2.2. İleri Biyolojik Atıksu Arıtma Tesislerinde Giriş Çıkış Parametreleri

Atıksular, arıtma işleminden geçirildikten sonra, tarımsal sulama, yeşil alan sulaması, dinlenme amaçlı olarak kullanılan sulak alanların beslenmesi gibi çeşitli amaçlarla kullanılmaktadırlar. Kentsel atıksuların arıtılması için kurulacak arıtma tesislerinin tasarımında, salınacağı ortama bağlı olarak çıkış suyu kalitesine de dikkat edilmektedir. Atıksuların arıtılmasında, hangi parametresinin ne derecede arıtılacağı yasal mevzuatlarla belirlenmektedir. Ülkemizde bu konuda “Su Kirliliği ve Kontrolü Yönetmeliği” standartları geçerlidir.

Atıksu arıtma tesisleri tasarlanırken ilk aşama, tesise giren atıksuyun debisi, debinin günlük, saatlik gibi periyotlardaki değişim miktarı, atık özelliğine göre kirlilik değerleri, (BOİ, KOİ, AKM, pH, N, P vb.) ve çıkış suyu kalitesi gibi verilerin belirlenmesidir. Bu verilerin her biri arıtılacak atıksuya veya arıtma tesisine göre belirli bir önceliğe sahiptir (Azman, 2005).

2.2.1. Debi

Tesis tasarımında en başta gelen ve yeterince doğrulukla belirlenmesi gereken başlangıç verilerinden biri “debi” değeridir. Debi değeri belirlenirken en güvenilir yöntem ölçüm yapmak olmakla beraber ölçüm yapmanın zor olduğu veya uzun zaman gerektirdiği, ya da ölçüm yapmanın mümkün olmadığı durumlarda evsel atıksu arıtma tesisleri için eğer varsa kanalizasyon projesinde öngörülen değerler esas alınır. Bu durumda su miktarının

kiři bařına dūřen oranından yararlanılır. Kiři bařına dūřen su miktarı iin evre mūhendislerince belirlenmiř olan $0,2 \text{ m}^3/\text{kiři/gūn}$ deęeri kullanılabilir.

Atıksu arıtma tesislerinin tasarımında debinin deęiřim miktarı da nemlidir. Arıtma tesisine gelen saatlik debi deęiřiminin nemli olduęu durumlarda mutlaka dengeleme havuzu yapılmalıdır.

2.2.2. BOİ (Biyokimyasal/Biyolojik Oksijen İhtiyacı)

Biyokimyasal/Biyolojik Oksijen İhtiyacı (BOİ); hava ieren bir su ortamında karbon, hidrojen, oksijen, azot, fosfor ve kūkūrt ieren organik maddelerin, bakteriler tarafından paralanıp sindirilebilmeleri iin gerekli olan oksijen miktarı olarak tanımlanabilir (elikkol, 2019). lūmū uzun zaman almaktadır ve deneysel hata oranı yūksektir. evreye etkilerin deęerlendirilmesinde ve arıtma sistemi tasarımında kullanılmaktadır. BOİ lūmū iin reaksiyonun 20 gūnde tamamlandıęı (%95-%99) kabul edilmektedir. Ancak, 20 gūnlūk sūre lūmler iin ok uzun olduęundan, bu sūre reaksiyonların %60-%70 oranında tamamlandıęı kabul edilen 5 gūn ile sınırlandırılmıř ve BOİ₅ olarak adlandırılmıřtır. BOİ₅, 5 gūnlūk BOİ ‘ye karřı gelen deęerler olarak lūlūr. Atıksu iinde biyolojik olarak paralanabilen organik kirlilięin bir gstergesidir.

2.2.3. KOİ (Kimyasal Oksijen İhtiyacı)

KOİ, birkaç saat iinde lūlebilen bir parametredir. Atıksu būnyesindeki hem biyolojik hem de kimyasal olarak okside edilebilen organik kirlilięi gsterir.

KOİ analizi toplam 3 saat ierisinde sonulanabilmektedir. KOİ analizi kısa sūrdūęū iin oęu zaman BOİ yerine tercih edilmektedir. KOİ parametresi, bazı istisnai durumlar dıřında, BOİ parametresinden daha yūksektir. Atıksularda, BOİ ve KOİ deęerleri arasında $KOİ/BOİ = 1,5 - 3$ řeklinde bir oran bulunmaktadır. Atıksu arıtma tesisinde uygulanacak biyolojik arıtma yntemleri iin belirleyici faktr KOİ/BOİ oranıdır.

2.2.4. Askıda Katı Madde (AKM)

Atıksu ierisinde bulunan katı maddeler, zūnmūř ve zūnmemiř katı maddeler olarak iki řekilde sınıflandırılırlar. zūnmemiř katı maddeler de, kebilen ve kemeyen (askıda kalan) katı maddeler olarak iki alt gruba ayrılır. Suda kemeyerek

askıda asılı kalan yaklaşık bir mikron büyüklüğünde veya daha büyük olan katı maddeler askıda katı madde (AKM) olarak ifade edilir. Askıda katı maddeler suların estetik, içme, endüstriyel kullanım gibi çeşitli amaçlar için kullanılmasını doğrudan etkilemektedir.

2.2.5. pH

Atıksudaki hidrojen iyonu konsantrasyonunun değeri olarak ifade edilebilecek olan pH, suyun asitlik veya bazlık durumunu gösteren logaritmik bir ölçüdür. Biyolojik ve kimyasal arıtma işlemlerinin belirlenmesinde pH değeri önemlidir. Ülkemizde hem ham atıksu hem de arıtılmış atıksu için pH değeri 6-9 aralığında kabul edilebilir değer olarak alınmaktadır.

2.2.6. Azot (N) ve Fosfor (P) değerleri

Evsel atıksulara karışan organik maddeler su içerisinde biyolojik olarak parçalanarak oksijen tüketimine sebep olmaktadır. Eğer ortama azot ve fosfor gibi organik madde besinleri de eklenirse su oksijensiz hale geçecektir. Dolayısıyla arıtma tesisi planlamasında azot ve fosforun da kirlilik göstergeleri arasına eklenmesi önemlidir. Nutrientler olarak tanımlanan azot ve fosfor elementleri, mikroorganizmalar için besi elementleridir ve büyümeleri için çok gereklidir.

Yüzeysel sulara verilen atıksu deşarjları nedeniyle oluşan alg ve yosunlarının kontrolü istendiğinde, atıksular salınacağı ortamlara verilmeden önce, bünyesindeki azotun uzaklaştırılması veya oranının azaltılması gerekmektedir.

Alg ve diğer mikroorganizmaların çoğalması bakımından fosfor da önemlidir. Fosfor sulara fosfat olarak bulunur. Evsel atıksular genellikle fosfor bileşiklerince zengindir.

2.2.7. Sıcaklık

Mikroorganizmaların metabolizma ile ilgili faaliyetlerinin tümü kimyasal reaksiyonlara dayanmaktadır. Mikroorganizmaların meydana getirdiği tepkimeler de kimyasal tepkimelerde olduğu gibi sıcaklığa bağlıdır. Sıcaklık metabolik aktiviteleri etkilemekle birlikte, biyolojik çamurun çökme özelliği, gaz transfer hızı gibi faktörleri de etkiler.

2.3. Literatür Özeti

Teknolojinin gelişmesiyle beraber yapay zekâ, makine öğrenmesi ve özellikle de derin öğrenme yöntemlerinin uygulanmasının birçok alanda başarılı sonuçlar vermesi, atıksu arıtma tesislerinde tesis çıkış parametrelerinin tahmin edilmesi noktasında araştırmacıları bu konuya yöneltmektedir.

Lotfi, K. ve diğerleri. (2019), “Predicting wastewater treatment plant quality parameters using a novel hybrid linear-nonlinear methodology” isimli çalışmalarında, atık su kalite parametrelerini modellemek için doğrusal stokastik model (ARIMA) ve doğrusal olmayan aykırı değer sağlam aşırı öğrenme makine tekniğini çeşitli ön işlemlerle birleştiren yeni bir metodoloji sunmuşlardır. İncelenen parametrelerin her biri için 144 farklı (144×8 model) doğrusal model sunmuşlar ve her parametrenin üstün modelin, istatistiksel indekslere dayalı olarak seçmişlerdir. Ayrıca 48 doğrusal olmayan modeli ve 48 hibrit modeli ele almışlardır. Hibrit modelde her bir zaman serisinin lineer ve lineer olmayan terimlerini (sırasıyla) modellemek için lineer ve lineer olmayan yaklaşımların kullanılmasının, tüm zaman serileri için tahminlerin verimliliğini ve doğruluğunu arttırdığını ifade etmişlerdir. Giren atıksu lineer olmayan toplam askıda katı modeli ve atık KOİ ve BOİ modellerinin 0.95'lik yüksek bir korelasyon katsayısı ile en iyi performansı elde ettiğini hesaplamışlar, hibrit modellerin kullanımının, atık BOİ modeli için elde edilen en iyi performans ile tüm kalite parametrelerinin tahmin kabiliyetini geliştirdiğini ortaya koymuşlardır.

Simsek & Alkay (2020), “Artificial neural network approach for the prediction of effluents streams from a wastewater treatment plant: A case study in Kocaeli (Turkey)” isimli çalışmalarında, Kocaeli (Türkiye) ilinde bulunan iki farklı atıksu arıtma tesis çıkış suyu parametreleri üç katmanlı Yapay Sinir Ağları (YSA) ile değerlendirilerek modelleme yapılmıştır. Çıktı parametreleri olarak belirlenen kimyasal oksijen ihtiyacı (KOİ), askıda katı madde (AKM), pH ve sıcaklık değerleri beş girdi parametresi (akış hızı, KOİ, AKM, pH ve sıcaklık) ile tahmin edilmiştir. YSA modeli 400 veri seti ile geliştirilerek çıkış suyu pH, sıcaklık, KOİ ve AKM değerlerinin modellemesi yapılmıştır. YSA modeli; gizli katmanda tanjant sigmoid transfer fonksiyonu (tansig) ve çıkış katmanında lineer transfer fonksiyonu (purelin) optimum olarak belirlenmiştir. Bu fonksiyonları kullanarak eğitim, validasyon ve test setleri için regresyon değerleri

sırasıyla 0.94, 0.96 ve 0.95 olarak bulunmuştur. Gizli katmanda optimum nöron sayısı minimum ortalama kare hata değeri temel alınarak saptanmıştır. Elde edilen sonuçlara göre YSA modelinin çıkış suyu pH, sıcaklık, KOİ ve AKM değerlerinin tahmininde etkin ve doğru performans gösterdiği belirlenmiştir.

Elmaadawy K. ve diğerleri. (2021), “Utilization of random vector functional link integrated with manta ray foraging optimization for effluent prediction of wastewater treatment plant” isimli çalışmalarında, aktif çamur arıtma prosesi ile işletilen tam ölçekli bir atıksu arıtma tesisinin (AAT) temel performans göstergelerini tahmin etmek için yenilikçi bir tahmine dayalı model kullanmışlardır. Önerilen model, Manta Ray Toplayıcı Optimize Edici ile birleştirilmiş Rastgele Vektör Fonksiyonel Bağlantı ağlarından oluşur. Rastgele Vektör Fonksiyonel Bağlantı ağlarını, aşırı öğrenme gibi yaygın geleneksel YSA problemlerini önleyen gelişmiş bir Yapay Sinir Ağı (YSA) olarak kullanmışlardır. Modellerin performansı, R^2 , RMSE ve diğerleri gibi farklı değerlendirme ölçütleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlara dayanarak, seçtikleri modelin, tahmin etmek için daha yüksek bir performans ve geç toplam askıda katı ve optimal BOİ₅'i tahmin etmek için daha yüksek bir performans ve geçerlilik sergilediğini ifade etmişlerdir.

Wang, D. ve diğerleri (2021), “A machine learning framework to improve effluent quality control in wastewater treatment plants” isimli çalışmalarında geleneksel mekanik modellerin çeşitli eksikliklerinden kaçınmak için atıksu arıtma tesisi süreçlerini modellemek için Makine Öğrenimi (ML) yöntemleri kullanmışlardır. Araştırma çerçeveleri Rasgele Orman (RF) modelleri, Derin Sinir Ağı (DNN) modelleri, Değişken Önem Ölçümü (VIM) analizleri ve Kısmi Bağımlılık Planı (PDP) analizlerinden oluşmuş ve süreçler arasındaki zaman gecikmelerinin etkisini hesaba katan yeni bir yaklaşım kullanmışlardır.

Wang, G ve diğerleri. (2021), “Soft-sensing of Wastewater Treatment Process via Deep Belief Network with Event-triggered Learning” isimli çalışmalarında atıksu arıtma tesisinde yumuşak algılama modelinin verimliliğini ve doğruluğunu geliştirmek için Olay Tetiklemeli Öğrenme ile bir Derin İnanç Ağı önermişlerdir. Deneysel sonuçlara göre, Olay Tetiklemeli Öğrenme ile Derin İnanç Ağı verimliliğinin dokuz rakip

modelden %27,6-%64,9 daha yüksek olduğunu göstermişler, buna göre de önerilen modelin endüstriyel dağıtım için hazır olduğunu ifade etmişlerdir.


Wang, R. ve diğerleri. (2022), “Model construction and application for effluent prediction in wastewater treatment plant: Data processing method optimization and process parameters integration” isimli çalışmalarında, atık Kimyasal Oksijen İhtiyacının (KOİ) tahmini için modeller oluşturmak üzere dokuz makine öğrenme algoritmasını benimsemiştir. Sonuçlar, hem K-En Yakın Komşunun (KNN) hem de Gradient Boosting Decision Tree'nin (GBDT) mükemmel tahmin etkileri gösterdiğini, optimize edilmiş modellerin ayrıca atık toplam fosfor, toplam nitrojen ve pH tahminine de uygulandığını belirtmiştir.

Li, G. ve diğerleri. (2022) “Application of deep learning for predicting the treatment performance of real municipal wastewater based on one-year operation of two anaerobic membrane bioreactors” isimli çalışmalarında gerçek belediye atık sularının anaerobik membran biyoreaktörler (AnMBR'ler) kullanılarak arıtılmasını modellemek ve tahmin etmek için veriye dayalı derin öğrenme yöntemleri uygulanmıştır. İki AnMBR'nin bir yıllık işletim verilerine dayanarak, deneysel koşullarla ilgili altı parametre (reaktör sıcaklığı, ortam sıcaklığı, giriş sıcaklığı, giriş pH, giriş KOİ ve akış) ve atık su arıtma değerlendirmesi için sekiz parametre (pH, atık KOİ, KOİ giderme verimliliği, biyogaz bileşimi (CH₄, N₂ ve CO₂), biyogaz üretim hızı ve oksidasyon-indirgenme potansiyeli) seçmişlerdir. Girdi parametreleri ile çıktı değerlendirme parametreleri arasındaki ilişkiyi analiz etmek ve yeniden oluşturmak için üç derin öğrenme ağ yapısı önermişler. İstatistiksel analiz, derin öğrenmenin AnMBR deneysel sonuçlarıyla yakından uyumlu olduğunu gösterdi. Önerilen yoğun bağlantılı evrişim ağının (DenseNet) tahmin doğruluk oranı %97,44'e kadar ulaşabildiğini ve tek hesaplama süresinin 1 saniyeye düşürülebildiğini, bunun da derin öğrenme yöntemleriyle AnMBR arıtma tahmininin yüksek performans gösterdiğini belirtmişlerdir.

3. MATERYAL VE YÖNTEM


3.1. Derin Öğrenme

Derin öğrenme, insan beyninin öğrenme ve karar verme yöntemlerinden esinlenerek geliştirilen, makine öğrenmesi için kullanılan farklı yöntemlerden biridir (Şekil 3.1). Yapay sinir ağları sayesinde insan beynindeki nöronların hareketinin taklit edilmesi temeline dayanmaktadır.



Şekil 3.1. Yapay zeka, makine öğrenmesi ve derin öğrenme


Derin öğrenme, 2010'lu yıllarda kullanılmaya başlanmış olup, makine öğreniminde kullanılan hesapları büyük ve tek bir katmanda değil, tek bir seferde birçok katmanda yapma kabiliyetine sahiptir. Çok katmanlı perseptron yapısında, en fazla iki gizli katman kullanılabilirken, derin öğrenme sinir ağı yapısında çokça gizli katman kullanılır (Şekil 3.2).



Şekil 3.2. Klasik yapay sinir ağı ve derin öğrenme

Derin öğrenmeyi klasik yapay sinir ağlarından ayıran temel farklar; daha çok veri ve daha çok işlem gücüne sahip olması, yeni doğrusal olmayan (non-linear) aktivasyon fonksiyonlarının bulunması, yeni başlatma (initialization) yöntemleri, yeni

düzenleme (regularization) yöntemlerinin olması şeklinde sıralanabilir. Kendi içerisinde yer alan katmanların özellik haritası çıkarabilmesi, derin öğrenme algoritmalarını standart yapay sinir ağından veya makine öğrenmesi sistemlerinden ayıran en büyük ve önemli farktır. Şekil 3.3'te görüldüğü gibi geleneksel makine öğrenme modellerinde sınıflandırma yapmadan önce her sınıfın özelliğinin belirtilmesi gerekmektedir. Derin öğrenmede ise bu özellikler otomatik olarak çıkartılır ve öğrenilir. Bu durum, derin öğrenmede denetimsiz öğrenme yapma kabiliyeti olduğunu ifade etmektedir. Her iki ağ yapısında da hata tabanlı öğrenme gerçekleşse de, çok katmanlı perseptron yapısında denetimli öğrenme yapılmaktayken, derin öğrenmede denetimsiz öğrenme yapılabilir.



Şekil 3.3. Makine öğrenmesi ve derin öğrenme

3.2. Derin Öğrenme Modelleri

Derin öğrenme, sinir ağlarını, hiyerarşik olasılık modellerini ve çeşitli denetimsiz ve denetimli özellik öğrenme algoritmalarını kapsayan zengin bir yöntem ailesidir. Çeşitli görevlerde önceki son teknolojik tekniklerden daha iyi performans göstermeleri ve Görsel, işitsel, tıbbi vb. farklı kaynaklardan gelen karmaşık verilerin çok olması, derin öğrenme yöntemlerine olan ilginin neden olmuştur. Derin öğrenmede kullanılan mimariler; konvolüsyonel (evrimsel) sinir ağları, tekrarlayan (yinelemeli) sinir ağları, uzun kısa süreli bellek ağları, kısıtlı (sınırlı) boltzmann makineleri, derin inanç ağları ve derin oto kodlayıcılardır (Tan ve diğerleri, 2021).


3.2.1. Konvolüsyonel sinir ağları

Derin Öğrenmenin temel mimarisi olarak kabul edilen “Konvolüsyonel Sinir Ağları (Convolution Neural Network-CNN)”, matematiksel bir işlem olan evrişimden adını

almıştır ve çok katmanlı ileri beslemeli bir yapay sinir ağı türüdür. Konvolüsyonel (evrimsel) sinir ağları, görsel bilginin analiz edilmesi, görüntü sınıflandırma, nesne tespiti ve takibi gibi problemleri çözmek için geliştirilmiştir.

Bilgisayarlara bir nesne görüntüsü verildiğinde bilgisayarlar bu görüntüyü bir matris olarak değerlendirirler. Görüntüdeki her piksel için matriste o piksele göre değişen bir değer karşılık gelmektedir. Konvolüsyonel yapay sinir ağları çok sayıda gizli katmanda bu matrisleri işleyerek farklı özelliklerini algılar ve böylece nesneleri kolay bir şekilde ayırt edebilir. Konvolüsyonel sinir ağları görüntü sınıflandırma ve nesne tanımlama gibi görüntü tabanlı çalışmalar başta olmak üzere, ses işleme, doğal dil işleme (NLP), biyomedikal gibi birçok farklı alanda uygulanmaktadır. Özellikle görüntü işleme alanında, görülen en iyi sonuçlar elde edilmiştir.

CNN, uygulama sırasına göre, konvolüsyon katmanı, havuzlama katmanı ve en son olarak tam bağlantı katmanı olmak üzere temelde artarda gelen 3 ana katmandan oluşmaktadır (Şekil 3.4). Konvolüsyon katmanları, doğrusal aktivasyon fonksiyonları (doğrultucu, sigmoid, tanh, vb.) tarafından takip edilen doğrusal evrimsel filtrelerle özellik haritaları oluşturur



Şekil 3.4. Konvolüsyonel sinir ağı yapısı


3.2.1.1. Giriş katmanı

CNN'in ilk katmanı giriş katmanıdır. Bu katmanda modele ham şekilde verilen giriş verisinin boyutu ve çözünürlüğü, tasarlanacak CNN modelinin başarımı için önemlidir. Görüntü boyutu yüksek olursa, eğitim ve test süreleri uzayabilir, aynı zamanda bellek ihtiyacı da ortaya çıkabilir. Ancak sonuçta modelin başarısı artabilir. Giriş verisinde görüntü boyutu küçük seçilirse, bellek ihtiyacı azalır, eğitim süresi düşebilir ancak

bununla birlikte modelin performansı da düşebilir. Hem performans, hem de eğitim süresi açısından ideal giriş verisi boyutunu bulmak önemlidir.

3.2.1.2. Konvolüsyon (Evrişim) katmanı

Dönüşüm katmanı olarak da ifade edilebilecek bu katman CNN'in temelini oluşturur. Dönüşümdeki temel düşünce, 2x2, 3x3, 5x5 gibi farklı boyutlarda belirlenen bir filtrenin Şekil 3.5'ten de anlaşılacağı gibi tüm görüntü üzerinde dolaştırılıp yeni bir matris oluşturulmasıdır (İnik ve Ülker, 2017). Buradan anlaşılacağı üzere, konvolüsyon katmanında önemli rol oynayan faktör filtrelerdir. Filtreler ile kendinden önce gelen görüntüye konvolüsyon işlemi uygulanarak bir çıkış verisi elde edilir. Bu işlemler gerçekleştirilirken aynı zamanda özellik haritası çıkarılmış olur. Kullanılan filtrelerin katsayıları eğitim sırasında her adımda yinelenerek ağ üzerinde önemli bölgelerin yeri tespit edilir. Filtreleme sonucunda giriş verisinden daha küçük bir matris elde edilir.



Şekil 3.5. Konvolüsyon katmanında özellik haritasının çıkarılması


Filtreleme için kullanılan matrise bağlı olarak görüntü üzerinde farklı özellikler çıkartılabilir. Uygulanacak filtrenin sayısı, boyutu ve ağı yapısı gibi parametreler, sistemi tasarlayan kişi tarafından belirlenirken, bu filtre değerlerini CNN eğitim aşamasında kendi öğrenir.

3.2.1.3. Düzleştirilmiş doğrusal birim katmanı (ReLU)

Konvolüsyon katmanının sonunda veriye düzleştirme (doğrultma) işlemi uygulanır. Aktifleştirme katmanı olarak ta bilinen katman, aslında konvolüsyon katmanının tamamlayıcı adımı olarak düşünülebilir. Çok katmanlı yapay sinir ağlarında doğrusal olmayan dönüşümler kullanılmaktadır Aktivasyon fonksiyonunun katmana yaptığı etki

negatif deęerleri sıfıra çekmesidir (Şekil 3.6). Bu katmanda aktivasyon fonksiyonu olarak sigmoid, hiperbolik tanjant, ReLu, sinüs, step, eşik deęer fonksiyonları kullanılmaktadır.

Aktivasyon fonksiyonu olarak çok fazla fonksiyon bulunmasına rağmen, derin öğrenme modellerinde en yaygın kullanılan fonksiyon ReLu (Rectified Linear Unit)'dur ($f(x)=\max(0,x)$). ReLu, bir önceki katmandaki doğrusal olan yapıyı doğrusal olmayan yapıya dönüştürmek için kullanılır. Dolayısıyla ağı öğrenimi daha hızlanmış olur. ReLU, özellik haritasındaki tüm negatif piksel deęerlerini sıfır olarak deęiştirmek üzere her piksel için ayrı ayrı uygulanır.




Şekil 3.6. ReLu fonksiyonu ile matrisin doğrusal olmayan yapıya dönüştürülmesi

3.2.1.4. Havuzlama (Pooling) katmanı

ReLu katmanından sonra genellikle havuzlama yerleştirilir. Havuzlamanın temel amacı, veride derinlik boyutunu etkilemeden bir sonraki konvolüsyon katmanına uygulamak üzere giriş boyutunu (Genişlik x Yükseklik) azaltmaktır (İnik ve Ülker, 2017). Havuzlama katmanı sonucunda boyuttaki azalma bilgi kaybına yol açmaktadır. Sonraki ağ katmanları için daha az hesaplama yükü oluşturması ve sistemin ezberlemesini önlemesi açısından böyle bir kayıp faydalıdır.

Konvolüsyon katmanında olduğu gibi, havuzlama katmanında da belli filtreler tanımlanmaktadır. Bu filtreler görüntü üzerinde belli bir adım atma deęerine göre gezdirilir. Bu esnada görüntüdeki piksellerin maksimum deęerleri (maksimum havuzlama) veya deęerlerin ortalaması (ortalama havuzlama) alınarak işlem yapılır

(Şekil 3.7). Genellikle, daha iyi performans gösterdiği için maksimum havuzlama tercih edilir. Havuzlama işlemi, konvolüsyon katmanı sonucunda elde edilen filtre sayısı kadar, görüntülerin hepsi için gerçekleştirilir. Havuzlama katmanı CNN’lerde isteğe bağlıdır, bazı mimarilerde bu işlem gerçekleştirilmez.




Şekil 3.7. 2x2 havuzlama

3.2.1.5. Tam bağlantılı katman

Sırasıyla gelen konvolüsyon, ReLu ve havuzlama katmanlarından sonra, CNN mimarisinde tam bağlantılı katman gelmektedir. Kendinden önceki katmanın tüm alanlarına bağlı olan tam bağlantılı katmanın sayısı farklı mimarilerde değişebilir. Tam bağlantılı katmanlar sınıf skorları gibi hedefleri optimize etmek için kullanılabilir ve genellikle CNN mimarisinin sonuna doğru bulunur.

3.2.1.6. Dropout (Seyreltme) katmanı

Çok katmanlı yapay sinir ağlarında, sinir ağı eğitilirken aşırı öğrenme adı verilen ağı ezberlenmesi olayını önlemek için dropout katmanı kullanılır (Srivastava ve diğerleri, 2014). Dropout katmanında uygulanan temel işlem Şekil 3.8’de görüldüğü gibi ağın bazı düğümlerinin kaldırılmasıdır.




Şekil 3.8. Dropout işleminin uygulanması

3.2.1.7. Sınıflandırma katmanı

Tam bağlantılı katmandan sonra gelen sınıflandırma katmanında sınıflandırma işlemi yapılmaktadır. Katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısı kadar olmalıdır. Bu katmanda farklı sınıflandırıcılar kullanılmakla birlikte, başarılı sonuçlar vermesinden dolayı çoğunlukla softmax sınıflandırıcı tercih edilir. Softmax katmanı, kendisinden önce gelen tam bağlı katmandan aldığı girdi verisini sınıflandırmak için kullanır.

3.2.2. Tekrarlayan sinir ağları

Tekrarlayan sinir ağları (Recurrent neural network – RNN), işlenmesi ve tahmin edilmesi en zor veri türlerinden biri olan sıralı verileri işlemek için tasarlanmıştır. Yapısı itibariyle diğer yapay sinir ağlarından farklıdır. Diğer ağlar, ileri besleme işlemi veya geri yayılım işlemi sırasında doğrusal bir yönde seyahat ederken, tekrarlayan ağ, ileri besleme geçişi yerine bir yinleme ilişkisini takip eder ve öğrenmek için zaman içinde geri yayılımı kullanır. Tekrarlayan sinir ağları, önceki gizli katman çıkışlarını hem bir sonraki katmanda hem de tekrar aynı katmanda giriş olarak kullanarak (Şekil 3.9) bir döngü oluşturan, bu döngü esnasında bilgilerin sıralı olarak kullanılmasına dikkat eden, öğrenme ve tahmin temelli bir yapay sinir ağı modelidir. Bu ağ yapısı ile bilgilerin kalıcı olarak döngülerde kalmasına ve gerektiği zaman kullanılmasına izin verilmektedir.




Şekil 3.9. Tekrarlayan sinir ağının genel yapısı

RNN'lerin temel özelliği, gizli birimler arasında bilginin bir zaman adımından diğerine aktarılmasına izin veren tekrarlayan bağlantıların varlığıdır. Bu, her zaman adımındaki gizli durumun yalnızca o zaman adımındaki girdinin bir fonksiyonu değil aynı zamanda önceki gizli durumun da bir fonksiyonu olduğu anlamına gelir. Başka bir ifadeyle RNN'lerde geçmiş bilgiler bir geri bildirim döngüsüyle mevcut duruma iletilerek gelecek tahminlerine dahil edilmektedir.

Bir RNN'in gizli katmanının t zaman adımındaki çıktısı,

$$h_t = f(h_{t-1}, x_t)$$

olarak ifade edilebilir. Bu durum Şekil 3.10'da görülmektedir.



Şekil 3.10. RNN gizli katmanının t zaman adımındaki çıktısı

Konuşmayı tanıma, dil modelleme, çeviri, metin oluşturma, duygu analizi, video analizleri, güvenlik algılama, hisse senedi tahmini, zaman serilerine bağlı tüm

uygulamaları modelleme gibi alanlar RNN'lerin uygulamaları arasında yer alır (Gavcar ve Metin, 2021). Genel olarak, RNN'ler sıralı verileri işlemek ve zamansal bağımlılıkları modellemek için güçlü bir araçtır ve bu da onları birçok makine öğrenimi uygulamasının önemli bir bileşeni haline getirmektedir. Diğer tüm makine öğrenmesi ve derin öğrenme yöntemlerinde olduğu gibi RNN'lerin uygulanmasının da kendine göre avantaj ve dezavantajları bulunmaktadır.

RNN'lerin avantajları:

- ✓ Sıralı Verileri İşleyebilme Yeteneği: RNN'ler değişen uzunluklardaki sıralı verileri işleyebilir, bu da onları doğal dil işleme, konuşma tanıma ve zaman serisi analizi gibi uygulamalarda faydalı kılar.
- ✓ Bellek: RNN'ler, gizli durumların kullanımı yoluyla sıradaki önceki girişler hakkındaki bilgileri tutma yeteneğine sahiptir. Bu, RNN'lerin bir cümledeki sonraki kelimeyi tahmin etme veya hisse senedi fiyatlarını tahmin etme gibi görevleri gerçekleştirmesine olanak tanır.
- ✓ Çok yönlülük: RNN'ler sınıflandırma, regresyon ve diziden diziye haritalama dahil olmak üzere çok çeşitli görevler için kullanılabilir.
- ✓ Esneklik: RNN'ler, belirli görevler için hibrit modeller oluşturmak amacıyla Konvolüsyonel Sinir Ağları (CNN'ler) veya ileri beslemeli sinir ağları gibi diğer sinir ağı mimarileriyle birleştirilebilir.

RNN'lerin dezavantajları:

- ✓ Kaybolan Gradyan Problemi: Kaybolan gradyan problemi, RNN'lerde, özellikle de çok katmanlı veya uzun dizili olanlarda ortaya çıkabilir ve uzun vadeli bağımlılıkların öğrenilmesini zorlaştırır. Bu da uzun zaman önceki bilgiye erişmeyi zorlaştırır.
- ✓ Hesaplama Açısından Pahalı: RNN'ler, özellikle uzun dizileri işlerken veya karmaşık mimariler kullanırken hesaplama açısından pahalı olabilir.
- ✓ Yorumlanabilirlik Eksikliği: RNN'lerin yorumlanması, özellikle ağın nasıl tahmin veya karar verdiğini anlamak açısından zor olabilir.

- ✓ Overfitting (Aşırı uyum): RNN modelleri, özellikle küçük veri setlerinde, aşırı uyum eğilimi gösterebilir. Bu, modelin eğitim verilerine aşırı uyum sağlayıp yeni verilere iyi genelleme yapamaması anlamına gelir.

Genel olarak, RNN'lerin bazı dezavantajları olsa da sıralı verileri işleme ve önceki girişlerin hafızasını koruma yetenekleri, onları birçok makine öğrenimi uygulaması için güçlü bir araç haline getirmektedir.

RNN'ler genellikle bire bir mimari ile karakterize edilirler. Bir giriş dizisi, bir çıktı ile ilişkilendirilir. Bununla birlikte, bunlar belirli amaçlar için çeşitli konfigürasyonlara esnek bir şekilde ayarlanabilir. Aşağıda birkaç yaygın RNN türü görülmektedir.

Birden çoğa RNN: Birden çoğa RNN'ler genellikle dizi üreticileri olarak kullanılır. Sadece bir girdi (bir vektör) alır ve bir çıktı dizisi üretir. Örneğin, bir başlangıç notası veya/veya bir "tür" verildiğinde bir müzik parçası üretilebilir. Benzer şekilde, belirtilen bir başlangıç kelimesiyle birden çoğa RNN'ler kullanılarak bir film senaryosu yazılabilir. Diğer ilginç uygulama resim yazısıdır: RNN bir resim alır ve resmin açıklamasını (kelimelerden oluşan bir cümle) çıktı olarak verir (ODSC, 2020).

Çoktan Bire RNN: Ardışık verileri sınıflandırmak için yaygın olarak kullanılır. Birden fazla zaman adımlı girdi dizisini alır, ancak tüm diziyi geçtikten sonra yalnızca bir çıktı üretir. Duygu analizi bunun iyi bir örneğidir. Benzer şekilde, haber makalelerinin konu sınıflandırmasında, bir şarkının türünü belirlenmesinde, bir hastanın EEG izine dayanarak nöbet geçirip geçirmediğini belirlemek için çoktan bire RNN'ler kullanılabilir (ODSC, 2020).






Çoktan çoğa RNN: Model, birden fazla çıkışı tahmin etmek için birden fazla girdi kullanır. Senkronize ve senkronize olmayan olmak üzere iki farklı şekilde kullanılır.

Çoktan çoğa senkronize RNN, giriş dizisindeki her bir ögenin bir çıktıya sahip olmasına izin verir. Bir mağazanın günlük ürün satışları, bir hisse senedinin günlük kapanış fiyatı, bir fabrikanın saatlik elektrik tüketimi gibi konular senkronize çoktan çoğa RNN'lerden yararlanılabilecek zaman serisi tahmininin bazı örnekleridir (ODSC, 2020).

Çoktan çoğa senkronize olmayan RNN, tüm girdi dizisi işlendikten sonra çıktı dizisinin oluşturması istenildiğinde kullanılabilir çoktan çoğa RNN türüdür. Bu RNN türü,

makine çevirisi için başvurulacak bir modeldir. Örneğin Fransızca-İngilizce çeviride, model önce Fransızca tam bir cümle okur ve ardından İngilizce çevrilmiş bir cümle üretir. Geçmiş aydan veri verildiğinde, gelecekteki birden fazla güne ait satışları tahmin etmek gibi çok adımlı ileriye dönük tahmin, çoktan çoğa senkronize olmayan RNN türü için verilebilecek başka bir örnektir. Tablo 3.1’de, RNN’lerin türeri, model yapıları ve uygulama alanlarına örnekler verilmiştir.

Tablo 3.1. Tekrarlayan sinir ağlarının türleri (Stanford Üniversitesi).


RNN Türü	Model Yapısı	Örnek
Bire bir $T_x = T_y = 1$		Geleneksel RNN sinir ağı
Birden çoğa $T_x = 1, T_y > 1$		Müzik üretimi, resim altyazısı oluşturma
Çoktan bire $T_x > 1, T_y = 1$		Duygu sınıflandırma
Çoktan çoğa (senkronize) $T_x = T_y$		İsim, varlık tanıma
Çoktan çoğa (senkronize olmayan) $T_x \neq T_y$		Makine çevirisi

3.2.3. Uzun kısa süreli bellek ağları

Uzun kısa süreli bellek (Long Short-Term Memory-LSTM), Hochreiter ve Schmidhuber (1997) tarafından, tekrarlayan sinir ağlarındaki kaybolan gradyan sorununu çözmek için özel olarak tasarlanmıştır. Değerleri rastgele aralıklarla hatırlayan, ileri beslemeli sinir ağlarının aksine geri besleme bağlantıları olan bir tekrarlayan sinir ağı mimarisidir (Gavcar, E. ve Metin, H.M., 2021; Akın ve Şahin, 2024).

Gradyan iniş, bir fonksiyonun minimumunu bulmak için birinci dereceden yinelemeli bir optimizasyon algoritmasıdır. RNN, Gradyan iniş algoritmasını kullanır. Standart RNN mimarileri için gradyan inişi ile ilgili problem, önemli olaylar arasındaki zaman gecikmesinin boyutuna bağlı olarak hata gradyanlarının katlanarak hızla kaybolmasıdır. LSTM, uzun süreli bağımlılıkları öğrenebilme yeteneği ile öne çıkar. Gizli katmanlarda özel “kapı” yapıları kullanarak, hangi bilginin saklanıp hangi bilginin atılacağına karar verir. Bu, uzun dizi verilerindeki önemli bilgileri koruyarak, uzun dönem hafıza problemine bir çözüm sunar. LSTM’lerle uzun süreli bellek de dahil olmak üzere farklı aralıktaki anılar, gradyan kaybolma ve patlama sorunu olmadan öğrenilebilir. LSTM, RNN mimarisi içinde kullanılan bir tür hücredir. Sıralı verilerin analizi için kullanılır ve özellikle zaman serileri gibi uzun süreli bağımlılıklar içeren verilerin işlenmesinde etkilidir (Haskol, 2023).


LSTM hücresi, giriş, unutma ve çıkış kapılarından oluşan bir mekanizma ile donatılmıştır (Şekil 3.11). Giriş kapısı, yeni verilerin LSTM hücresine giriş yapmasını sağlar. Unutma kapısı, önceki bloktan gelen verinin ne kadarının bellekte kalıp ne kadarının unutulacağını belirler. Aday bellek, yeni bilgi oluşumunun uyarılmasını ve son olarak çıkış kapısı, LSTM hücresindeki çıkış verisinin hesaplanmasını ve sonraki zaman adımlarına taşımak üzere diğer hücrelere aktarılmasını sağlar (Haskol, 2023; Akın ve Şahin, 2024). LSTM hücresindeki kapılardan $[0,1]$ aralığında çıktı elde etmek için sigmoid, $[-1,1]$ aralığında çıktı elde etmek için de hiperbolik tanjant (tanh) fonksiyonları kullanılır (Akın ve Şahin, 2024).



Şekil 3.11. Bir LSTM hücre bloğunun yapısı

3.2.4. Geçitli tekrarlayan birim

Geçitli tekrarlayan birim (Gated Recurrent Unit - GRU), LSTM'in daha basitleştirilmiş bir versiyonu olarak görülebilir. LSTM'den farklı olarak GRU, kaybolan gradyan sorununu çözmek için bir güncelleme kapısı ve sıfırlama kapısı kullanır (Şekil 3.12). Bu kapılar hangi bilginin önemli olduğuna karar verir ve onu çıktıya iletir. Kapılar, zamanla kaybolmadan veya alakasız bilgileri kaldırmadan, uzun zaman öncesine ait bilgileri depolamak üzere eğitilebilir.




Şekil 3.12. GRU bloğunun yapısı

Güncelleme kapısı, bir LSTM'in unutma ve girdi kapısına benzer şekilde hareket eder. Hangi bilgilerin atılacağına ve hangi yeni bilgilerin ekleneceğine karar verir. Sıfırlama kapısı, ne kadar geçmiş bilginin unutulacağına karar vermek için kullanılır. LSTM'den farklı olarak GRU'da C_t hücre durumu yoktur. Yalnızca gizli bir durumu vardır ve basit

mimarisi nedeniyle GRU'nun eğitim süresi, LSTM modellerine göre daha düşüktür. GRU mimarisinin anlaşılması kolaydır çünkü önceki zaman damgası h_{t-1} 'den x_t girişini ve gizli durumu alır ve yeni gizli durum h_t 'yi çıkarır.

3.2.5. Sınırlı Boltzmann makineleri

Sınıflandırma, regresyon ve özellik öğrenimi işlemlerini yapan Sınırlı Boltzman makineleri (Restricted Boltzmann Machines – RBM), giriş veri seti üzerinde olasılıksal dağılımları öğrenebilen bir sinir ağıdır (Doğan ve Türkoğlu, 2019). RBM temelde, görünür veya giriş katmanı ve gizli katman olarak adlandırılan iki katmandan oluşur (Şekil 3.13). RBM'ler sınıflandırma problemlerinde kullanılabilir.




Şekil 3.13. RBM ağının yapısı

Şekil 3.13'te görülen her daire, düğüm adı verilen nöron benzeri bir birimi temsil eder. Basitçe hesaplamaların gerçekleştiği yerler olan düğümler birbirine katmanlar halinde bağlanır, ancak aynı katmandaki iki düğüm birbirine bağlanmaz. Dolayısıyla katman içi iletişim yoktur. Her düğüm, girdiyi işleyen ve bu girişi iletip iletmeyeceği konusunda rastgele kararlar alan bir hesaplama merkezidir.

3.2.6. Derin inanç ağları

Derin inanç ağları (Deep Belief Network – DBN), sınırlı Boltzmann makinelerinin (RBM) yığınlarıyla oluşturulur. Art arda eklenen sınırlı Boltzman makineleri katmanlarından oluşan bir sinir ağıdır (Şekil 3.14). Sınırlı Boltzman makinelerinin sırasıyla eğitilerek öğrenilmesiyle gerçekleşir (Doğan ve Türkoğlu, 2019). Derin inanç ağlarında ağın her katmanı bağımsız olarak eğitilebilir. Derin inanç ağları, karar verme


sürecine odaklanan yüksek kapasiteli öğrenme becerisine sahip oldukları için çok farklı uygulamalarda kullanılabilen önemli bir yapay zekâ türüdür.



Şekil 3.14. Derin inanç ağının yapısı

3.2.7. Derin oto-kodlayıcılar

Derin oto-kodlayıcılar (Autoencoders – AE), girdi verisine en fazla benzerliğe sahip çıkışı üretecek, veri ile ilişkili önemli bilgilere sahip fonksiyonu bulurlar. Derin Oto kodlayıcı modeli, daha az öznitelik kullanarak daha fazla başarı oranı elde etmeyi amaçlayan bir derin öğrenme yöntemidir. Veri setindeki öznitelik sayısını düşürerek hem doğruluk oranını hem de hızı artırmayı hedeflemektedir. Derin oto-kodlayıcılar kodlayıcı, kod çözücü ve gizli katman olmak üzere üç kısımdan meydana gelen tam bağlı bir yapay sinir ağıdır.



Şekil 3.15. Derin oto kodlayıcı ağının yapısı

Bir oto kodlayıcıda, kodlayıcı ve kod çözücü olmak üzere iki aşama bulunmaktadır (Şekil 3.15). Bu aşamalar tek bir modelmiş gibi beraber eğitilirler. Kodlayıcı katmanı veriyi sıkıştırırken çözücü katman sıkıştırılmış veriyi açmak için kullanılırlar (Karcı, 2021). Model, kodlayıcı aşamasında verilen girişi alır ve gizli katmanlarını kullanarak girişi, giriş birimlerinden daha küçük birimlerle ifade etmeye çalışır. Kod çözücü aşamasında ise, gizli katmanlarını kullanarak şifrelenmiş bilgiden verilen girişi yeniden oluşturmaya çalışır. Derin oto kodlayıcılar özellik çıkarma ve veri sıkıştırma işlemlerinde sıklıkla kullanılmaktadır (M. Uçar ve E. Uçar, 2019).

3.3. Derin Öğrenme Uygulamaları

Verinin olduğu her alanda derin öğrenme yöntemleri başarılı bir şekilde uygulanabilir. Doğal dil işleme, sinyal ve görüntü işleme, video işleme, bilgisayar oyunları, robotlar ve otonom arabalar, ses, konuşma, yüz, metin tanıma, duygu analizi, dijital pazarlama, nesne algılama, derin öğrenmenin uygulandığı popüler alanlara örnek olarak gösterilebilir.

3.3.1. Görüntü/video/ses işleme

Derin öğrenme, birçok görüntü işleme alanının yanı sıra video ve ses işleme alanlarında da sıklıkla kullanılmaktadır. Bu nedenle derin öğrenme, görsel-işitsel ses etkinliği tespiti, fonolojik özelliklerin tespiti ve sınıflandırılması, konuşmacı duygu tanıma, konuşma geliştirme ve tanıma, gürültü ayırma, insan eylemi tanıma, duygu, ifade ve nesne tanıma gibi ses ve video uygulamalarında kullanılmıştır.

Ses işleme alanında yapılan derin öğrenme çalışmaları daha çok konuşma tanıma uygulamalarında yapılmaktadır. Bu işlemi gerçekleştirmek için en çok kullanılan derin öğrenme mimarilerinin RNN, gürültü giderici oto kodlayıcılar ve derin inanç ağları olduğu görülmüştür.

Video işleme, uzun süredir bilgisayarlı görü topluluğunun merkezinde yer almaktadır. Bu alanda videoda nesne tanıma, yüz tanıma, duygu tanıma ve eylem tanıma gibi birçok önemli sorun bulunmaktadır. Derin CNN'ler tarafından öğrenme, çeşitli görüntü tabanlı sınıflandırma görevlerinde olağanüstü etkinlik göstermiştir. Derin CNN'ler, CNN'lerin hesaplama verimliliğinin gerçek zamanlı uygulamalarda kullanılabileceği anlayışıyla

birlikte video sorunlarının üstesinden gelmek için de kullanılmaya başlanmıştır. Nesne tanıma, literatürde en çok çalışılan alanlardan biridir.

3.3.2. Doğal dil işleme

Günümüzde üzerinde çok yoğun araştırmalar yürütülen doğal dil işleme, yapay zekanın en zorlu alanlarından biridir. Doğal dil işleme problemlerinin çözümleri için derin öğrenme, makine öğrenmesi, istatistiksel analiz ve kural tabanlı yaklaşımlar hibrit biçimde kullanılmaktadır. Yazım yanlışlarının düzeltilmesi, otomatik çeviri sistemleri, dil öğrenimi uygulamaları, kişisel asistan uygulamaları gibi doğal dile değen her alanda doğal dil işleme devreye girmektedir (Yapıcı ve diğerleri, 2019). Derin öğrenme algoritmalarından özellikle DAE, LSTM, CNN mimarileri doğal dil işleme alanında oldukça başarılı ve etkileyici sonuçlar vermiştir. Doğal dil işleme problemlerinin çözümünde kullanılan derin öğrenme yöntemleri Tablo 3.2’de verilmiştir (Küçük ve Arıcı, 2018).

Tablo 3.2. Doğal dil işleme problemleri ve kullanılan derin öğrenme yöntemleri

Doğal dil işleme problemi	Kullanılan derin öğrenme yöntemleri
Metin sınıflandırma	Evrişimsel sinir ağları, Yinelemeli evrişimsel sinir ağları, LSTM ve evrişimsel sinir ağları
Metin ayrıştırma	Evrişimsel sinir ağları
Duygu analizi	Derin oto-kodlayıcılar, Evrişimsel sinir ağları
Bilgi çıkarımı	Derin sinir ağları
Varlık ismi tanıma	LSTM ve evrişimsel sinir ağları
Zamansal ilişki çıkarımı	Evrişimsel sinir ağları
Olay çıkarımı	Evrişimsel sinir ağları
Sözcük türü etiketleme	Derin sinir ağları, LSTM
Metin sıralama	Evrişimsel sinir ağları
Otomatik harf çevirisi	Derin inanç ağları
Otomatik soru cevaplama	Evrişimsel sinir ağları, LSTM

3.3.3. El yazısı karakter tanıma

Karakter tanıma, araştırmacılar için hala en zorlu alanlardan biridir. Özellikle el yazısı karakter tanıma, karakterin genellikle farklı bir yazara, yazı stiline ve gürültüye göre çeşitli görünümlere sahip olması nedeniyle zorlu bir iştir. El yazısı tanıma, çevrimiçi (kontur yörüngesi tabanlı) ve çevrimdışı (görüntü tabanlı) olmak üzere iki türden oluşur. Yetersiz sayıda özelliğin karakterize edilmesi nedeniyle, çevrimdışı el yazısı karakter tanıma sorunu, çevrimiçi olduğundan daha zordur. Derin öğrenmedeki büyük gelişmelerle birlikte, birçok araştırmacı derin öğrenme tabanlı yöntemler kullanarak bu sorunu çözmeye çalışmaktadır.

3.3.4. İmza doğrulama

İmzalar, yüzlerce yıldır en yaygın kullanılan biyometrik kimlik doğrulama tekniğidir. İmzalar kağıt üzerinde yüzlerce yıldır kalemle imzalanmıştır. Günümüzde teknolojinin gelişmesiyle birlikte tablet, bilgisayar gibi elektronik cihazlar aracılığıyla da online imza kullanılabilir. Bu nedenle günümüzde çevrimdışı (statik) ve çevrimiçi (dinamik) olmak üzere iki tür imza vardır.

Çevrimdışı imza doğrulamasında, bir belge üzerinde işlem için giriş verisi olarak kullanılan bir imza bulunur ve dijital görüntü temsilini elde etmek için taranır. Çevrimdışı imzanın sınıflandırma için çok az özelliği vardır. Çevrimiçi imza, yazma sırasında kalem hareketlerini kaydetmek için sayısallaştırma tableti veya basınca duyarlı kalem gibi özel donanımlar tarafından imzalanır.

Hukuken mali ve manevi yükümlülükler getiren imzalar, günümüzde özellikle hukuki belgelerde, bankacılıkta ve ticari işlemlerde yaygın olarak kullanılan bir doğrulama tekniğidir. Bu nedenle imza doğrulama/tanıma, araştırmacılar için en önemli alanlardan biridir.

3.3.5. Tıbbi görüntü işleme

Derin öğrenme, tıbbi görüntü analizi problemlerinin çözümünde de oldukça etkilidir. Son yıllarda derin öğrenme algoritmalarındaki gelişmeler tıbbi görüntü analizi çalışmalarını büyük ölçüde etkilemiştir. Tıbbi görüntüler üzerinde derin öğrenme algoritmaları kullanılarak sınıflandırma, nesne tespiti, bölütleme, kayıt, geri getirme gibi

alanlarda oldukça başarılı sonuçlar elde edilmiştir. Derin öğrenme modelleri, özellikle büyük miktarda MR verileri ile nesnel yorumlar yapılmasına imkan sağlamıştır.

3.4. Derin Öğrenme Kütüphaneleri

Derin öğrenme uygulamalarının kolaylaştırılabilmesi için çeşitli kuruluşlar veya üniversiteler tarafından geliştirilmiş farklı özelliklere sahip kütüphaneler bulunmaktadır. Bu kütüphanelerden Python programlama dilinde en yaygın kullanılan açık kaynak kodlu kütüphanelerden bazıları açıklanmıştır.

3.4.1. Theano

Matematiksel ifadeleri etkili bir şekilde tanımlamayı, en iyilemeyi ve değerlendirmeyi sağlayan bir Python kütüphanesidir. İşlemek ve değerlendirmek için özellikle matris değerli yapıları optimize eder.

3.4.2. TensorFlow

TensorFlow, üst düzey sayısal hesaplamalar gerçekleştirmek için açık kaynaklı Python makine öğrenimi kütüphanesidir (Kara, 2020). Aslında TensorFlow bir kütüphaneden ziyade, uçtan uca makine öğrenmesi projeleri yapmak için kullanılabilecek bir platform olarak değerlendirilebilir. Makine öğrenimi modelleri oluşturmak ve eğitmek için esnek ve yüksek performanslı bir platform sağlar. Görüntü sınıflandırma, konuşma tanıma ve doğal dil işleme gibi görevler için yaygın olarak kullanılır. Veri akışı grafikleriyle verimli sayısal hesaplamalara olanak tanımaktadır.

3.4.3. Keras

Keras, daha kolay model geliştirmeyi sağlayan, Tensorflow ve Theano için üst katman olarak yazılmış bir Python kütüphanesidir. Makine öğrenimi alanında yapay sinir ağlarının kurulumunu ve eğitimini kolaylaştırmak için tasarlanmıştır. Kullanımı kolay ve anlaşılır bir API yapısına olduğundan dolayı, derin öğrenmede uzman olmayanlar için bile kolaylık sağlar. Sınıflandırma, regresyon, görüntü işleme, doğal dil işleme, zaman serisi veriler üzerinde analiz ve sınıflandırma gibi birçok problemin çözümünde kullanılabilir.

3.4.4. Caffe

Model ve optimizasyonların, kodlamaya gerek olmadan ayar dosyası üzerinden yapılabilirdiği, derin öğrenme yapısı hızlı ve modüler olacak şekilde tasarlanmış bir kütüphanedir.

3.4.5. PyTorch

Açık kaynaklı bir makine öğrenim kütüphanesidir. Bilgisayarla görme ve doğal dil işleme gibi uygulamalar için kullanılır. PyTorch ile hem yapısal hem de yapısal olmayan veriler kolaylıkla analiz edilebilir. Sınıflandırma, nesne tespiti, görüntü bölme, doğal dil işleme problemlerinin çözümünde yaygın kullanılmaktadır.

3.4.6. Pandas

Veri analizi ve modelleme gibi işlemleri gerçekleştirmeye yarar. Farklı formatlardaki verilerin kolay analizi için kullanılır. Python'da tablo verileriyle çalışmayı kolaylaştıran Pandas, özellikle zaman serisi verileri ve sayısal tabloları işlemek için bir veri yapısı oluşturur.

3.4.7. Numpy

Veri Bilimi çalışmaları için olmazsa olmaz olan, çok büyük ölçekteki matematiksel hesaplamaları kolay, hızlı ve esnek bir şekilde gerçekleştirmeyi sağlayan çözümleri içeren bir kütüphanedir. Veri madenciliği, makine öğrenimi, veri analizi, tek ya da çok boyutlu dizi içeren hesaplama yapılarında kullanılır (Öztürk, 2020).

3.4.8. Matplotlib

Python'da veri görselleştirme için yaygın olarak kullanılan bir kütüphanedir. Çizgi grafikleri, dağılım grafikleri, histogramlar, çubuk grafikler ve daha fazlasını içeren çok çeşitli grafikler oluşturmak için tercih edilen Matplotlib, verileri görselleştirmek için güçlü bir araçtır (Öztürk, 2020).

3.4.9. Scikit-Learn

Sınıflandırma, regresyon, kümeleme, veri işleme, model seçimi, ön işleme gibi çeşitli uygulamalar için etkili bir şekilde kullanılabilen bir kütüphane olan Scikit-learn, NumPy, SciPy gibi kütüphanelerle birlikte çalışabilen hem denetimli hem de denetimsiz makine öğrenmesini destekleyen bir kütüphanedir (Kara, 2020).

3.4.10. Seaborn

Matplotlib üzerine kurulu ve onu tamamlayan bir veri görselleştirme kütüphanesidir. Özellikle istatistiksel grafikler için çok kullanışlı bir kod yapısı sağlar.

3.5. Derin Öğrenmede Hiper parametreler

Ne olması gerektiği, modeli tasarlayan kişiye bırakılmış, probleme, veri setine göre değişiklik gösteren parametreler hiper-parametre olarak adlandırılmaktadır. Derin öğrenmede kullanılan bazı yaygın hiper parametreler şunlardır:

- Veri setinin boyutu
- Öğrenme hızı (Learning rate)
- Toplu boyutu (Batch size)
- Gizli katman sayısı
- Gizli katmandaki nöron sayısı
- Seyreltme (dropout) değeri ve seyreltme uygulanacak katmanlar
- Aktivasyon fonksiyonu
- Optimizasyon algoritması
- Eğitim tur (epoch) sayısı
- Düzenleme teknikleri (Emeç ve Özcanhan, 2023).

Derin öğrenme uygulamalarında en önemli faktör veri setinin büyüklüğü ve çeşitliliğidir. Öğrenmedeki başarının iyi olması veri setinin büyüklüğü ile doğru orantılıdır. Bir derin öğrenme uygulamasında, veri setinin büyüklüğü ne kadar fazla olursa öğrenme de o oranda iyi olacaktır. Veri setindeki çeşitliliğin fazla olması da modelin başarısına olumlu katkı sağlar. Bununla beraber veri setinin büyük olması, öğrenme zamanını ve öğrenme sonucunda elde edilecek modelin büyüklüğünü de o oranda arttıracaktır.


Bir ağın parametrelerini ne kadar hızlı güncellediğini tanımlayan kavram öğrenme oranıdır. Öğrenme oranı düşük olursa öğrenme süreci yavaşlar ancak öğrenme başarısını artırır.

Toplu boyutu (mini batch size), modelin aynı anda kaç veriyi işleyeceğini belirleyen parametredir.


Derin öğrenme yöntemlerini diğer yapay sinir ağlarından ayıran en önemli fark, modele uygulanan gizli katman sayısıdır. Gizli katmanlar giriş ve çıkış katmanları arasında bulunurlar. Yapılan birçok çalışmada gizli katman sayısının artırılmasının (modelin derinliğinin artması anlamına gelir) modelin öğrenme başarısını artırdığını kanıtlamıştır. Gizli katmanlardaki nöron sayıları ise hafızada tutulan bilgileri ifade etmektedir. Nöron sayısı artarsa bellek ihtiyacı ve hesaplama zamanının da artması gerekecektir. Nöron sayısının az olması ise yetersiz uyum (underfitting) probleminin oluşmasına neden olur.

Derin öğrenme modelinde aşırı uydurma (overfitting) probleminin oluşmasını önlemek için seyreltme(dropout) kullanılır. Bu işlem aynı zamanda zayıf bilgilerin unutulması anlamına da gelmektedir. Seyreltme değeri olarak genellikle %20 ile %50 arasında bir değer kullanılmaktadır. Tüm katmanlara seyreltme uygulanması ya da tüm katmanlarda aynı seyreltme değerinin kullanılması zorunlu değildir.


Çok katmanlı yapay sinir ağlarında doğrusal olmayan dönüşüm işlemleri için aktivasyon fonksiyonları kullanılır. Bunu nedeni; derin öğrenme yöntemlerinin doğrusal olmayan yapıya sahip problemlerin çözümünde diğer sinir ağı yapılarına göre daha etkili sonuçlar vermesidir. Derin öğrenme modellerinde en sık kullanılan aktivasyon fonksiyonları ReLu, sigmoid, softmax ve hiperbolik tanjant fonksiyonlarıdır. Bu fonksiyonlar içinde en fazla kullanılan ReLu fonksiyonudur. ReLu fonksiyonu biyolojik nörona benzetilebilir. Gelen değerlerin pozitif olup olmadığına bakar, değer pozitifse olduğu gibi alır, değer negatifse sıfır olarak geçirir. İkili sınıflandırmalar yapılırken çıkış katmanında genellikle sigmoid fonksiyonu kullanılır. Sigmoid fonksiyonu, aldığı değerleri sıfır ile 1 arasında tutar. Yüksek gelen değer 1'e yakın olurken, düşük gelen değer sıfıra yakın olur. Çoklu sınıflandırma problemlerinde çıkış katmanında softmax fonksiyonu kullanılır. Softmax fonksiyonu yapısal olarak sigmoid fonksiyonuna benzer. Gelen girdi değerinin belirli bir sınıfa ait olma olasılığını 0 ile 1 arasında bir değer üreterek belirler. Hiperbolik tanjant (tanh) fonksiyonunun da yine sigmoid fonksiyonuna benzer bir yapısı bulunmaktadır. Ancak burada aralık -1 ile +1 arasında tanımlanmaktadır. Açıklanan aktivasyon fonksiyonlarının grafikleri Şekil 3.16'da görülmektedir.




a) ReLu fonksiyonu



b) Sigmoid fonksiyonu



c) Softmax fonksiyonu



d) Hiperbolik tanjant fonksiyonu

Şekil 3.16. Aktivasyon fonksiyonları

Derin öğrenme uygulamalarında öğrenme işlemi temelde bir optimizasyon problemidir. Doğrusal olmayan problemlerin çözümünde optimum değeri yakalayabilmek için optimizasyon algoritmaları kullanılır. Derin öğrenme modellerinde genellikle varsayılan optimizasyon algoritması Stochastic gradient descent algoritması kullanılmaktadır. Bununla birlikte adagrad, adadelata, adam, adamax, rmsprop gibi çeşitli optimizasyon algoritmaları da, derin öğrenme modellerinde yaygın olarak kullanılmaktadır. Diğer optimizasyon algoritmaları ile karşılaştırıldığında stochastic gradient descent (SGD) algoritmasının daha yavaş çalışmakta, resim tanıma gibi bazı problemlerde kötü sonuçlar verebilmektedir. Adaptif algoritmalar dinamikler ve modelin öğrenme hızlarını kendileri öğrenirler.

Eğitim sırasında veri setindeki tüm verilerin ağı kaç defa gösterileceği epoch (tur) sayısı ile ifade edilir. Model verilere az gösterilirse öğrenme gerçekleşmez, fazla

gösterilirse bu defa da aşırı öğrenme gerçekleşir. Bu duruun dengede tutulması gerekmektedir.

Tasarlanmış olan derin öğrenme modelinde aşırı uyumu (overfitting) önleyerek model başarımını artırmak için düzenleme (regularization) teknikleri kullanılmaktadır. Düzenleme, modeli basitleştirerek kısıtlama işlemidir. Derin öğrenme modellerinde vri artırma, sentetik veri üretme, gürültü ekleme, seyreltme, erken durdurma, transfer öğrenme gibi çeşitli düzenleme teknikleri kullanılmaktadır.

3.6. Performans Değerlendirme Ölçütleri

Derin öğrenme süreçlerinde, geliştirilen modellerin gerçek veriler üzerinde ne kadar etkili olduğunu değerlendirmek için performansının ölçülmesi gerekir. Performans ölçümü, bir modelin doğruluğunu ve veri uyumunu belirler, karar verme süreçlerinde güvenilirliği artırır. Bu nedenle, yapay zekâ projelerinde performans ölçümünün titizlikle yapılması ve doğru metriklerin seçilmesi büyük önem taşır (Karakaş, 2024).

Makine öğrenmesin modellerinin başarısının nasıl ölçüleceği ya da iyi bir model olduğuna nasıl karar verilebileceği performans ölçütleri (metrikler) ile belirlenir. Farklı türdeki modeller için farklı değerlendirme ölçütleri kullanılır.

Makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan metrikler, regresyon modelleri ve sınıflandırma modelleri için farklılık göstermektedir. Regresyon modelleri sürekli değerleri, sınıflandırma modeli ise kategorik değerleri öngörür.

3.6.1. Regresyon modelleri için performans değerlendirme ölçütleri

Regresyon modelleri, “sürekli” değerleri tahmin etmek için kullanılan denetimli öğrenme modelleridir. Bu tür modellerin performansını değerlendirmek için kullanılan başlıca ölçütler, modelin tahmin ettiği değerlerle gerçek değerler arasındaki farkları değerlendirerek, modelin başarısını ve tahmin yeteneğini ölçer. Bu amaç için kullanılan bazı metrikler şunlardır aşağıda açıklanmıştır.

Ortalama Mutlak Hata (Mean Absolute Error (MAE)): Veri setindeki gerçek değerlerle modelin tahmin ettiği değerlerin arasındaki farkın mutlak değerinin ortalamasını alır. Bu sayede modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçerler. Değer ne kadar düşük olursa model performansının o kadar iyi olduğu kabul edilir.

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

Burada y gerçek değer, $\hat{y}$ tahmin edilen değer, n örnek sayısıdır.

Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error (MAPE)): Veri setindeki gerçek değerlerle modelin tahmin ettiği değerlerin arasındaki farkın gerçek değere kıyasla ne kadar büyük olduğunu ifade eder. Diğer bir ifadeyle, modelin tahmininin yüzde olarak gerçek değerden ortalama ne kadar uzakta olduğunu gösterir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}$$

Ortalama Kare Hata (Mean Squared Error (MSE)): Gerçek değerlerle tahmin edilen değerlerin arasındaki farkların karelerinin ortalamasıdır. Veri setinde bulunan fazla aykırı değerler MSE'yi olumsuz yönde etkiler. Düşük bir değer modelin doğruluğunun daha iyi olduğunu gösterir.

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

Ortalama Kare Hata Karekökü (Root Mean Squared Error (RMSE)): MSE'nin karekökü alınarak elde edilir. Özellikle, tahmin hatalarının önemli olduğu durumlarda değerlendirme için RMSE tercih edilir.

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

Belirlilik Katsayısı (R-squared- R^2): Bu metrik, bir derin öğrenme modelinin bağımsız değişkenlerle bağımlı değişken arasındaki ilişkiyi açıklama yeteneğini değerlendirmek için kullanılır. Modelin veri setindeki değişkenliği ne kadar iyi açıkladığını ölçen bir metriktir. 0 ile 1 arasında değerler alır. Eğer R^2 değeri 1'e yakınsa, modelin bağımlı değişkeni açıklamada başarılı olduğu ve verilere iyi uyum sağladığı, sıfıra yakınsa, modelin bağımlı değişkeni açıklamada başarısız olduğu ve verilere uyum sağlamada zayıf olduğu söylenebilir.

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

Burada $\bar{y}$, gerçek değerlerin ortalamasıdır.

Açıklanan Varyans Puanı (Explained Variance Score - EVS): Makine öğreniminde tahminlerin kalitesini değerlendirmek için kullanılan bir ölçüttür. Modelin tahmininin gerçek verilerin varyansını ne kadar iyi açıkladığını test eder. R^2 değerinde olduğu gibi, 1 mümkün olan en iyi sonuçtur.

$$EVS(y, \hat{y}) = 1 - \frac{Var(y - \hat{y})}{Var(y)}$$

EVS değeri, sürekli değerleri tahmin eden regresyon modellerinde öncelikli olarak kullanılır, çünkü bir modelin sürekli verilerde bulunan varyansı açıklama yeteneğini niceliksel olarak belirler.

Açıklanan varyans değeri ile belirleme katsayısı olan R^2 değeri arasındaki fark, açıklanan varyans değerinin tahmindeki sistematik sapmaları hesaba katmamasıdır. Bu nedenle, belirleme katsayısı olan R^2 değeri genellikle tercih edilmektedir.

Ortalama Poisson Dağılımı (Mean Poisson Deviance – MPD): Veri setlerinde tahmin edilen ortalama değerlerin yanlışlığını verir. İyi bir model için değerinin sıfıra yakın olması istenir.

$$MPD = \frac{1}{n} \sum_{i=0}^{n-1} (2(y_i \log(y_i/\hat{y}_i) + \hat{y}_i - y_i))$$


Ortalama Gama Dağılımı (Mean Gamma Deviance – MGD): Ortalama gama dağılımı, her zaman pozitif değerde olan ve yatık dağılımlara sahip sürekli değişkenleri modellemek için kullanılır. Değerin sıfıra yakın olması, modelin iyi olduğu anlamına gelir.

$$MGD = \frac{1}{n} \sum_{i=0}^{n-1} (2(\log(\hat{y}_i/y_i) + \hat{y}_i/y_i - 1))$$

3.6.2. Sınıflandırma modelleri için performans değerlendirme ölçütleri

Sınıflandırma modelleri, genellikle sınıflar arasındaki doğru ve yanlış tahminleri ölçen metrikler kullanılarak değerlendirilirler. Sınıflandırma problemlerinde modelin performansını değerlendirmek için kullanılan yaygın performans metrikleri şunlardır:

Karışıklık Matrisi: Sınıflandırma modelleri için performans değerlendirme metriklerinin anlaşılabilmesi için karışıklık matrisinin bilinmesi gerekir. Karışıklık matrisi, sınıflandırma problemlerinde bir modelin performansını değerlendirmek için kullanılan temel araçtır (Şekil 3.17). Sınıflandırma modellerinde kullanılan diğer tüm performans ölçütleri karışıklık matrisinden elde edildiği için bu matrisi iyi anlamak önemlidir.



The diagram illustrates a confusion matrix for a binary classification problem. It features a 2x2 grid of colored cells. The horizontal axis is labeled 'GERÇEK' (Actual) with 'Pozitif' (Positive) and 'Negatif' (Negative) categories. The vertical axis is labeled 'TAHMİN' (Predicted) with 'Pozitif' (Positive) and 'Negatif' (Negative) categories. The cells are: Top-Left (Green) labeled 'TP' (True Positive), Top-Right (Red) labeled 'FP' (False Positive), Bottom-Left (Red) labeled 'FN' (False Negative), and Bottom-Right (Green) labeled 'TN' (True Negative).

	Pozitif	Negatif
Pozitif	TP	FP
Negatif	FN	TN

Şekil 3.17. Karışıklık matrisi

Karışıklık matrisi dört farklı değer içermektedir. Bunlar:

Doğru Pozitif (True Positive – TP): Gerçekte pozitif olan ve modelin de bunu pozitif olarak doğru tahmin ettiği değerlerin sayısıdır.

Yanlış Pozitif (False Positive – FP): Gerçekte negatif olan, ancak modelin bunu pozitif olarak yanlış tahmin ettiği değerlerin sayısıdır.

Yanlış Negatif (False Negative – FN): Gerçekte pozitif olan, ancak modelin bunu negatif olarak yanlış tahmin ettiği değerlerin sayısıdır.

Doğru Negatif (True Negative – TN): Gerçekte negatif olan ve modelin de bunu negatif olarak doğru tahmin ettiği değerlerin sayısıdır.

Karışıklık matrisi scikit-learn gibi birçok makine öğrenme kütüphanesinde bulunur ve sınıflandırma modellerinin performans değerlendirmesinde yaygın olarak kullanılır.

Karışıklık matrisindeki bu dört değer kullanılarak sınıflandırma problemlerinde modellerin performans değerlendirmesini yapmak için aşağıdaki metrikler hesaplanabilir.

Doğruluk (Accuracy): Modelin doğru yaptığı tahmin sayısının toplam tahmin sayısına oranıdır. Diğer bir ifadeyle toplam tahminler içerisinde doğru tahminlerin oranını verir. Ancak dengesiz veri setlerinde doğruluk oranı yeterli olmayıp diğer değerlendirme metriklerine de bakmak gereklidir.

$$\text{Doğruluk} = \frac{TP}{TP + TN + FP + FN}$$

Kesinlik (Precision): Modelin pozitif olarak tahmin ettiği değerlerin gerçekte kaç tanesinin pozitif olduğunu gösterir.

$$\text{Kesinlik} = \frac{TP}{TP + FP}$$

Duyarlılık (Hassasiyet) (Recall/Sensitivity): Modelin pozitif olarak tahmin etmesi gereken değerlerin ne kadarını pozitif olarak tahmin ettiğini gösterir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN}$$


F1 Skoru: Kesinlik ve duyarlılığın harmonik ortalamasını alarak bu iki metriği dengeleyen bir performans ölçüsüdür. Dengesiz veri setlerinde kullanışlıdır. En yüksek 1, en düşük sıfır değerini alır.

$$F1 \text{ Skoru} = \frac{2 \times (\text{Kesinlik} \times \text{Duyarlılık})}{(\text{Kesinlik} + \text{Duyarlılık})}$$

ROC Eğrisi ve AUC Skoru: ROC eğrisi (Receiver Operating Characteristic Curve), sınıflandırma modelinin farklı kesme noktalarında yanlış pozitif oranı (FPR) ile duyarlılık arasındaki ilişkiyi grafiksel olarak verir (Şekil 3.18). Modelin ne kadar iyi performans gösterdiğinin ölçüsü eğrinin sol üst köşeye yakınlığı ile belirlenir.

$$\text{Duyarlılık (TPR)} = \frac{TP}{TP + FN}$$

$$\text{Özgüllük (Yanlış Pozitif Oran - FPR)} = \frac{FP}{FP + TN}$$



Şekil 3.18. ROC-AUC eğrisi

AUC Skoru (Area Under the Curve) ROC eğrisinin altında kalan alanı ölçerek tek bir sayısal değerle ifade eder. 0 ile 1 arasında değer alır.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA


Bu bölümde Gaziantep İleri Biyolojik Atıksu Arıtma Tesisi Temel çıkış parametrelerini içeren veriler üzerinde derin öğrenme mimarileri uygulanmış ve belirlenen parametrelerin değerlendirilmesinde derin öğrenme mimarilerinin uygulanabilirliği sorgulanmıştır.

Uygulama çalışmaları Intel(R) Core(TM) i7 işlemcili 16 GB Ram belleği ve 512 GB SSD harddiskli bulunan bilgisayar kullanılarak, Anaconda Navigator üzerinde çalışan Jupyter Notebook IDE'si (sürüm 6.4.12) ve Python 3 (sürüm 3.9.12) programıyla gerçekleştirilmiştir.

Atıksu arıtma tesisi temel çıkış parametrelerinden olan Debi, Sıcaklık, BOİ₅, KOİ, AKM, pH, gibi veriler üzerinde farklı derin öğrenme modelleri uygulanmış ve sonuçlar değerlendirilmiştir.


4.1. İleri Biyolojik Atıksu Arıtma Tesis Verileri

Çalışmada kullanılan tesise ait çıkış parametresi verileri Şekil 4.1'de grafikler haline verilmiştir.




a) Debi


Şekil 4.1. Atıksu arıtma tesis verileri



b) Sıcaklık




c) pH




d) AKM

Şekil 4.1. Atıksu arıtma tesis verileri (devamı)




e) BOI₅



f) KOI


Şekil 4.1. Atıksu arıtma tesis verileri (devamı)

Veri seti içerisinde 2020-2022 yılları arasını kapsayan 974 günlük veri bulunmaktadır. Verilerin %70'i eğitim, %30'u test verisi olarak ayarlanmıştır. Bu şekilde her bir çıkış parametresinde 681 veri eğitim için, 293 veri test için ayrılmıştır (Şekil 4.2).




a) Debi


Şekil 4.2. Veri setinin parametrelere göre eğitim ve test olarak ayrılması



b) Sıcaklık




c) pH




d) AKM

Şekil 4.2. Veri setinin parametrelere göre eğitim ve test olarak ayrılması (devamı)



e) BOİ₅



f) KOİ

Şekil 4.2. Veri setinin parametrelere göre eğitim ve test olarak ayrılması (devamı)

Veri seti günlük verilerden oluşmaktadır. Modeller, geçmiş 15 günlük verilere bakarak sonraki 10 günü tahmin edecek şekilde oluşturulmuştur. Mevcut atıksu arıtma tesis verilerinin ölçekleri birbirinden farklı olsa da uygulanan yöntemlerin sonuçlarıyla ilgili çıkarımlarda bulunabilmek adına hiper parametreler tüm modeller için aynı tutulmuştur. Böylece uygulanan yöntemin hangi tür veride ne kadar başarılı olduğu görülebilecektir.

4.2. Çıkış Parametrelerine Derin Öğrenme Modellerinin Uygulanması

4.2.1. RNN modelinin uygulanması

RNN modeli, dört adet RNN katmanı, her bir katmanda 64 birim, bir adet yoğun (dense) katmanı ve aşırı öğrenmeyi engelleyebilmek adına her RNN katmanından hemen sonra

%50’lik Dropout katmanı olacak şekilde tasarlanmıştır. Hata metriği olarak ‘ortalama karekök hata (mean squared error – mse)’, optimizasyon olarak “Adam” (Adaptif Momentum) tercih edilmiştir. Uygulanan RNN modelinin yapısı Görsel 4.1’de görülmektedir. Model, 100 epochs ve 16 parti boyutu (batch_size) ile eğitilmiştir.

```

1 tf.keras.backend.clear_session()
2 model=Sequential()
3
4 model.add(SimpleRNN(64,return_sequences=True, input_shape=(time_step,1)))
5 model.add(Dropout(0.5))
6
7 model.add(SimpleRNN(64, return_sequences=True))
8 model.add(Dropout(0.5))
9
10 model.add(SimpleRNN(64, return_sequences=True))
11 model.add(Dropout(0.5))
12
13 model.add(SimpleRNN(64))
14 model.add(Dropout(0.5))
15
16 model.add(Dense(1))
17
18 model.compile(loss='mse',optimizer='adam')
19 model.summary()

```

a) RNN modelinin katman yapısı

Layer (type)	Output Shape	Param #
simple_rnn (SimpleRNN)	(None, 15, 64)	4224
dropout (Dropout)	(None, 15, 64)	0
simple_rnn_1 (SimpleRNN)	(None, 15, 64)	8256
dropout_1 (Dropout)	(None, 15, 64)	0
simple_rnn_2 (SimpleRNN)	(None, 15, 64)	8256
dropout_2 (Dropout)	(None, 15, 64)	0
simple_rnn_3 (SimpleRNN)	(None, 64)	8256
dropout_3 (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65
Total params: 29,057		
Trainable params: 29,057		
Non-trainable params: 0		

b) RNN modelinin katmanlarının özeti


Görsel 4.1. RNN mimarisinin parametreleri ve katmanları

Atıksu arıtma tesisinin belirlenen çıkış parametreleri üzerine RNN uygulandığında alınan sonuçlar Tablo 4.1’de verilmiştir. Tabloda kalın değerler en iyi sonuçları, altı çizili değerler ise en kötü sonuçları göstermektedir.


Tablo 4.1. Çıkış Parametreleri üzerinde RNN sonuçları

Parametre	MSE	RMSE	MAE	MAPE	MGD	MPD	EVS	R ²
Debi	<u>1.7051E+05</u>	<u>412.9248</u>	<u>317.8423</u>	0.0106	0.0001	5.7159	0.3243	0.3215
Sıcaklık	13.6041	3.6883	3.2221	0.1630	0.0545	0.8318	0.6062	0.5501
pH	0.0274	0.1656	0.1220	0.0154	0.0004	0.0034	<u>0.0732</u>	0.0104
AKM	359.5929	18.9629	12.4655	0.3864	0.1253	5.7323	0.4530	0.3266
BOI ₅	1412.4466	37.5825	30.5799	<u>0.9598</u>	--	--	0.2484	<u>-0.1001</u>
KOI	3499.3238	59.1550	27.1420	0.2589	0.1144	17.2948	0.5182	0.5125


RNN modelinin eğitim ve test verileri üzerindeki kayıp fonksiyonu grafiği Şekil 4.3'te verilmiştir.




a) Debi



b) Sıcaklık




c) pH




d) AKM

Şekil 4.3. RNN modelinde eğitim ve test kayıp fonksiyonu




e) BOİ₅




f) KOİ

Şekil 4.3. RNN modelinde eğitim ve test kayıp fonksiyonu (devamı)

RNN modelinin eğitim ve test verileri üzerindeki tahmin başarısı ile gerçek verilerin karşılaştırmalı grafiği Şekil 4.4'te verilmiştir.




a) Debi




b) Sıcaklık


Şekil 4.4. RNN modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması



c) pH




d) AKM



e) BOİ5


Şekil 4.4. RNN modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması
(devamı)




f) KOİ

Şekil 4.4. RNN modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması
(devamı)


RNN modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı Şekil 4.5'te verilmiştir.




a) Debi



b) Sıcaklık




c) pH




d) AKM

Şekil 4.5. RNN modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı



e) BOİ₅



f) KOİ

Şekil 4.5. RNN modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı

4.2.2. LSTM modelinin Uygulanması

LSTM modeli, dört adet LSTM katmanı, her bir katmanda 64 birim, bir adet yoğun (dense) katmanı ve aşırı öğrenmeyi engelleyebilmek adına her LSTM katmanından hemen sonra %50’lik Dropout katmanı olacak şekilde tasarlanmıştır. Hata metriği olarak ‘ortalama karekök hata (mean squared error – mse)’, optimizasyon olarak “Adam” (Adaptif Momentum) tercih edilmiştir. Uygulanan LSTM modelinin yapısı Görsel 4.2’de görülmektedir. Model, 100 epochs ve 16 parti boyutu (batch_size) ile eğitilmiştir.

```
1 tf.keras.backend.clear_session()
2 model=Sequential()
3
4 model.add(LSTM(64,return_sequences=True,input_shape=(time_step,1)))
5 model.add(Dropout(0.5))
6
7 model.add(LSTM(64,return_sequences=True))
8 model.add(Dropout(0.5))
9
10 model.add(LSTM(64,return_sequences=True))
11 model.add(Dropout(0.5))
12
13 model.add(LSTM(64))
14 model.add(Dropout(0.5))
15
16 model.add(Dense(1))
17
18 model.compile(loss='mean_squared_error',optimizer='adam')
19
20 model.summary()
```

a) LSTM modelinin katman yapısı

Görsel 4.2. LSTM mimarisinin parametreleri ve katmanları

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 15, 64)	16896
dropout (Dropout)	(None, 15, 64)	0
lstm_1 (LSTM)	(None, 15, 64)	33024
dropout_1 (Dropout)	(None, 15, 64)	0
lstm_2 (LSTM)	(None, 15, 64)	33024
dropout_2 (Dropout)	(None, 15, 64)	0
lstm_3 (LSTM)	(None, 64)	33024
dropout_3 (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65
Total params: 116,033		
Trainable params: 116,033		
Non-trainable params: 0		

b) LSTM katmanlarının özeti


Görsel 4.2. LSTM mimarisinin parametreleri ve katmanları (devamı)

Çıkış parametreleri üzerine LSTM uygulandığında alınan sonuçlar Tablo 4.2’de verilmiştir. Tabloda kalın değerler en iyi sonuçları, altı çizili değerler ise en kötü sonuçları göstermektedir.


Tablo 4.2. Çıkış Parametreleri üzerinde LSTM sonuçları

Parametre	MSE	RMSE	MAE	MAPE	MGD	MPD	EVS	R ²
Debi	<u>127065.4206</u>	<u>356.4623</u>	<u>280.1344</u>	0.0094	0.0001	4.2615	0.4986	0.4943
Sıcaklık	4.4124	2.1005	1.5912	0.0922	0.0136	0.2423	0.9066	0.8540
pH	0.0177	0.1330	0.0861	0.0109	0.0002	0.0022	<u>0.3746</u>	<u>0.3613</u>
AKM	307.4506	17.5342	14.7980	<u>0.5290</u>	<u>0.1785</u>	6.7402	0.7108	0.4242
BOI₅	422.4196	20.5528	13.8619	0.4546	0.1580	7.1971	0.7133	0.6036
KOI	2002.3747	44.7479	15.5568	0.1366	0.0859	<u>10.6840</u>	0.7219	0.7210


LSTM modelinin eğitim ve test verileri üzerindeki kayıp fonksiyonu grafiği Şekil 4.6’te verilmiştir.




a) Debi




b) Sıcaklık




c) pH



d) AKM




e) BOI₅




f) KOİ

Şekil 4.6. LSTM modelinde eğitim ve test kayıp fonksiyonu


LSTM modelinin eğitim ve test verileri üzerindeki tahmin başarısı ile gerçek verilerin karşılaştırmalı grafiği Şekil 4.7'te verilmiştir.



a) Debi




b) Sıcaklık




c) pH


Şekil 4.7. LSTM modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması



d) AKM




e) BOI₅



f) KOI

Şekil 4.7. LSTM modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması
(devamı)

LSTM modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı Şekil 4.8’de verilmiştir.



Şekil 4.8. LSTM modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı

4.2.3. GRU modelinin uygulanması

GRU modeli, dört adet GRU katmanı, her bir katmanda 64 birim, bir adet yoğun (dense) katmanı ve aşırı öğrenmeyi engelleyebilmek adına her GRU katmanından hemen sonra

%50'lik Dropout katmanı olacak şekilde tasarlanmıştır. Hata metriği olarak ‘ortalama karekök hata (mean squared error – mse)’, optimizasyon olarak “Adam” (Adaptif Momentum) tercih edilmiştir. Uygulanan GRU modelinin yapısı Görsel 4.3’te görülmektedir. Model, 100 epochs ve 16 parti boyutu (batch_size) ile eğitilmiştir.

```

1 tf.keras.backend.clear_session()
2 model=Sequential()
3
4 model.add(GRU(64,return_sequences=True,input_shape=(time_step,1)))
5 model.add(Dropout(0.5))
6
7 model.add(GRU(64,return_sequences=True))
8 model.add(Dropout(0.5))
9
10 model.add(GRU(64,return_sequences=True))
11 model.add(Dropout(0.5))
12
13 model.add(GRU(64))
14 model.add(Dropout(0.5))
15
16 model.add(Dense(1))
17
18 model.compile(loss='mean_squared_error',optimizer='adam')
19
20 model.summary()

```

a) GRU modelinin katman yapısı

Layer (type)	Output Shape	Param #
gru (GRU)	(None, 15, 64)	12864
dropout (Dropout)	(None, 15, 64)	0
gru_1 (GRU)	(None, 15, 64)	24960
dropout_1 (Dropout)	(None, 15, 64)	0
gru_2 (GRU)	(None, 15, 64)	24960
dropout_2 (Dropout)	(None, 15, 64)	0
gru_3 (GRU)	(None, 64)	24960
dropout_3 (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65
Total params: 87,809		
Trainable params: 87,809		
Non-trainable params: 0		

b) GRU katmanlarının özeti


Görsel 4.3. GRU mimarisinin parametreleri ve katmanları

Çıkış parametreleri üzerine GRU uygulandığında alınan sonuçlar Tablo 4.3'te verilmiştir. Tabloda kalın değerler en iyi sonuçları, altı çizili değerler ise en kötü sonuçları göstermektedir.


Tablo 4.3. Çıkış Parametreleri üzerinde GRU sonuçları

Parametre	MSE	RMSE	MAE	MAPE	MGD	MPD	EVS	R ²
Debi	<u>126258.1531</u>	<u>355.3282</u>	<u>277.4599</u>	0.0093	0.0001	4.2329	<u>0.5000</u>	<u>0.4975</u>
Sıcaklık	1.6184	1.2721	0.9164	0.0450	0.0044	0.0824	0.9587	0.9464
pH	0.0163	0.1280	0.0842	0.0106	0.0002	0.0020	0.4374	0.4085
AKM	249.8925	15.8079	13.2770	<u>0.4807</u>	<u>0.1578</u>	5.7180	0.7500	0.5320
BOI ₅	372.2586	19.2940	10.7664	0.3577	0.1266	5.9253	0.7118	0.6507
KOI	1969.2935	44.3767	19.7002	0.2188	0.0817	<u>10.5530</u>	0.7379	0.7256


GRU modelinin eğitim ve test verileri üzerindeki kayıp fonksiyonu grafiği Şekil 4.9'da verilmiştir.



Şekil 4.9. GRU modelinde eğitim ve test kayıp fonksiyonu




e) BOİ₅




f) KOİ

Şekil 4.9. GRU modelinde eğitim ve test kayıp fonksiyonu (devamı)

GRU modelinin eğitim ve test verileri üzerindeki tahmin başarısı ile gerçek verilerin karşılaştırmalı grafiği Şekil 4.10'da verilmiştir.




a) Debi




b) Sıcaklık


Şekil 4.10. GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması



c) pH




d) AKM



e) BOI₅


Şekil 4.10. GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması
(devamı)




f) KOİ

Şekil 4.10. GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması (devamı)


GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı Şekil 4.11’de verilmiştir.




a) Debi



b) Sıcaklık




c) pH




d) AKM

Şekil 4.11. GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı



e) BOI₅



f) KOI

Şekil 4.11. GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı

4.2.4. LSTM/GRU modelinin uygulanması

Derin öğrenme modelleri içerisindeki GRU mimarisi, LSTM’in daha basitleştirilmiş bir formu olduğundan burada LSTM ile GRU modelleri birleştirilerek bir LSTM/GRU modeli oluşturulmuştur. Oluşturulan model, iki adet LSTM katmanı, iki adet GRU katmanı, her bir katmanda 64 birim, bir adet yoğun (dense) katmanı ve aşırı öğrenmeyi engelleyebilmek adına her LSTM ve GRU katmanlarından hemen sonra %50’lik Dropout katmanı olacak şekilde tasarlanmıştır. Hata metriği olarak ‘ortalama karekök hata (mean squared error – mse)’, optimizasyon olarak “Adam” (Adaptif Momentum) tercih edilmiştir. Uygulanan LSTM/GRU modelinin yapısı Görsel 4.4’te görülmektedir. Model, 100 epochs ve 16 parti boyutu (batch_size) ile eğitilmiştir.

```

1 tf.keras.backend.clear_session()
2 model=Sequential()
3
4 model.add(LSTM(64,return_sequences=True,input_shape=(time_step,1)))
5 model.add(Dropout(0.5))
6
7 model.add(LSTM(64,return_sequences=True))
8 model.add(Dropout(0.5))
9
10 model.add(GRU(64,return_sequences=True))
11 model.add(Dropout(0.5))
12
13 model.add(GRU(64))
14 model.add(Dropout(0.5))
15
16 model.add(Dense(1))
17
18 model.compile(loss='mean_squared_error',optimizer='adam')
19
20 model.summary()

```

a) LSTM/GRU modelinin katman yapısı

Görsel 4.4. LSTM/GRU mimarisinin parametreleri ve katmanları

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 15, 64)	16896
dropout (Dropout)	(None, 15, 64)	0
lstm_1 (LSTM)	(None, 15, 64)	33024
dropout_1 (Dropout)	(None, 15, 64)	0
gru (GRU)	(None, 15, 64)	24960
dropout_2 (Dropout)	(None, 15, 64)	0
gru_1 (GRU)	(None, 64)	24960
dropout_3 (Dropout)	(None, 64)	0
dense (Dense)	(None, 1)	65
Total params: 99,905		
Trainable params: 99,905		
Non-trainable params: 0		

b) LSTM/GRU katmanlarının özeti


Görsel 4.4. LSTM/GRU mimarisinin parametreleri ve katmanları (devamı)

Çıkış parametreleri üzerine LSTM/GRU uygulandığında alınan sonuçlar Tablo 4.4'te verilmiştir. Tabloda kalın değerler en iyi sonuçları, altı çizili değerler ise en kötü sonuçları göstermektedir.


Tablo 4.4. Çıkış parametreleri üzerinde LSTM/GRU sonuçları

Parametre	MSE	RMSE	MAE	MAPE	MGD	MPD	EVS	R ²
Debi	<u>131324.6724</u>	<u>362.3874</u>	<u>283.4440</u>	0.0095	0.0001	4.4015	<u>0.4850</u>	0.4774
Sıcaklık	1.6392	1.2803	0.8829	0.0436	0.0045	0.0839	0.9525	0.9457
pH	0.0160	0.1265	0.0832	0.0100	0.0002	0.0020	0.4425	<u>0.4219</u>
AKM	256.3692	16.0115	13.0351	<u>0.4608</u>	<u>0.1498</u>	5.5664	0.7181	0.5199
BOI₅	384.9964	19.6213	11.5653	0.3665	0.1270	6.0965	0.7073	0.6387
KOI	2266.7312	47.6102	25.9369	0.2834	0.0983	<u>12.4957</u>	0.7119	0.6842


GRU modelinin eğitim ve test verileri üzerindeki kayıp fonksiyonu grafiği Şekil 4.12'de verilmiştir.




a) Debi




b) Sıcaklık




c) pH



d) AKM




e) BOI₅




f) KOİ

Şekil 4.12. LSTM/GRU modelinde eğitim ve test kayıp fonksiyonu


LSTM/GRU modelinin eğitim ve test verileri üzerindeki tahmin başarısı ile gerçek verilerin karşılaştırmalı grafiği Şekil 4.13'te verilmiştir.



a) Debi




b) Sıcaklık




c) pH


Şekil 4.13. LSTM/GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması



d) AKM




e) BOİ₅




f) KOİ

Şekil 4.13. LSTM/GRU modelinde eğitim ve test tahminlerinin gerçek verilerle karşılaştırması (devamı)


LSTM/GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı Şekil 4.14'te verilmiştir.




a) Debi




b) Sıcaklık




c) pH



d) AKM



e) BOİ₅



f) KOİ

Şekil 4.14. LSTM/GRU modelinin önceki 15 günlük verilere bakarak sonraki 10 gün için tahmin performansı

4.2.5. Performans değerlendirme ölçütlerine göre sonuçlar

Performans değerlendirme ölçütleri bazında, çıkış parametrelerinin uygulanan modellere göre, sonuçları Tablo 4.5 ile Tablo 4.12 arasında verilmiştir. Tablolarda kalın değerler en iyi sonuçları göstermektedir.

Tablo 4.5. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MSE'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	170506.9191	127065.4206	126258.1531	131324.6724
Sıcaklık	13.6041	4.4124	1.6184	1.6392
pH	0.0274	0.0177	0.0163	0.0160
AKM	359.5929	307.4506	249.8925	256.3692
BOI ₅	1412.4466	422.4196	372.2586	384.9964
KOI	3499.3238	2002.3747	1969.2935	2266.7312

Tablo 4.6. Çıkış parametrelerinin uygulanan modellere göre sonuçları (RMSE'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	412.9248	356.4623	355.3282	362.3874
Sıcaklık	3.6883	2.1005	1.2721	1.2803
pH	0.1656	0.133	0.128	0.1265
AKM	18.9629	17.5342	15.8079	16.0115
BOI ₅	37.5825	20.5528	19.2940	19.6213
KOI	59.1550	44.7479	44.3767	47.6102

Tablo 4.7. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MAE'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	317.8423	280.1344	277.4599	283.444
Sıcaklık	3.2221	1.5912	0.9164	0.8829
pH	0.122	0.0861	0.0842	0.0832
AKM	12.4655	14.798	13.277	13.0351
BOI ₅	30.5799	13.8619	10.7664	11.5653
KOI	27.14196	15.5568	19.7002	25.9369

Tablo 4.8. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MAPE'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	0.0106	0.0094	0.0093	0.0095
Sıcaklık	0.163	0.0922	0.045	0.0436
pH	0.0154	0.0109	0.0106	0.0100
AKM	0.3864	0.529	0.4807	0.4608
BOI ₅	0.9598	0.4546	0.3577	0.3665
KOI	0.2589	0.1366	0.2188	0.2834

Tablo 4.9. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MGD'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	0.0001	0.0001	0.0001	0.0001
Sıcaklık	0.0545	0.0136	0.0044	0.0045
pH	0.0004	0.0002	0.0002	0.0002
AKM	0.1253	0.1785	0.1578	0.1498
BOI ₅	--	0.158	0.1266	0.127
KOI	0.1144	0.0859	0.0817	0.0983

Tablo 4.10. Çıkış parametrelerinin uygulanan modellere göre sonuçları (MPD'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	5.7159	4.2615	4.2329	4.4015
Sıcaklık	0.8318	0.2423	0.0824	0.0839
pH	0.0034	0.0022	0.002	0.002
AKM	5.7323	6.7402	5.718	5.5664
BOI ₅	--	7.1971	5.9253	6.0965
KOI	17.2948	10.684	10.553	12.4957

Tablo 4.11. Çıkış parametrelerinin uygulanan modellere göre sonuçları (EVS'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	0.3243	0.4986	0.5	0.485
Sıcaklık	0.4986	0.9066	0.9587	0.9525
pH	0.5	0.3746	0.4374	0.4425
AKM	0.485	0.7108	0.7500	0.7181
BOI ₅	0.2484	0.7133	0.7118	0.7073
KOI	0.5182	0.7219	0.7379	0.7119

Tablo 4.12. Çıkış parametrelerinin uygulanan modellere göre sonuçları (R²'ye göre)

Parametre	RNN	LSTM	GRU	LSTM/GRU
Debi	0.3215	0.4943	0.4975	0.4774
Sıcaklık	0.5501	0.854	0.9464	0.9457
pH	0.0104	0.3613	0.4085	0.4219
AKM	0.3266	0.4242	0.532	0.5199
BOI ₅	-0.1001	0.6036	0.6507	0.6387
KOI	0.5125	0.7210	0.7256	0.6842

Performans değerlendirme ölçütleri bazında, uygulanan derin öğrenme modellerinin çıkış parametrelerine göre sonuçları Tablo 4.13 ile Tablo 4.20 arasında verilmiştir. Tablolarda kalın değerler en iyi sonuçları göstermektedir.

Tablo 4.13. Uygulanan modellerin çıkış parametrelerine göre sonuçları (MSE'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	170506.92	13.6041	0.0274	359.5929	1412.4466	3499.3238
LSTM	127065.42	4.4124	0.0177	307.4506	422.4196	2002.3747
GRU	126258.15	1.6184	0.0163	249.8925	372.2586	1969.2935
LSTM/GRU	131324.67	1.6392	0.016	256.3692	384.9964	2266.7312

Tablo 4.14. Uygulanan modellerin çıkış parametrelerine göre sonuçları (RMSE'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	412.9248	3.6883	0.1656	18.9629	37.5825	59.1550
LSTM	356.4623	2.1005	0.1330	17.5342	20.5528	44.7479
GRU	355.3282	1.2721	0.1280	15.8079	19.294	44.3767
LSTM/GRU	362.3874	1.2803	0.1265	16.0115	19.6213	47.6102

Tablo 4.15. Uygulanan modellerin çıkış parametrelerine göre sonuçları (MAE'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	317.8423	3.2221	0.122	12.4655	30.5799	27.14196
LSTM	280.1344	1.5912	0.0861	14.798	13.8619	15.5568
GRU	277.4599	0.9164	0.0842	13.277	10.7664	19.7002
LSTM/GRU	283.444	0.8829	0.0832	13.0351	11.5653	25.9369

Tablo 4.16. Uygulanan modellerin çıkış parametrelerine göre sonuçları (MAPE'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	0.0106	0.1630	0.0154	0.3864	0.9598	0.2589
LSTM	0.0094	0.0922	0.0109	0.5290	0.4546	0.1366
GRU	0.0093	0.0450	0.0106	0.4807	0.3577	0.2188
LSTM/GRU	0.0095	0.0436	0.0100	0.4608	0.3665	0.2834

Tablo 4.17. Uygulanan modellerin çıkış parametrelerine göre sonuçları (MGD'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	0.0001	0.0545	0.0004	0.1253	--	0.1144
LSTM	0.0001	0.0136	0.0002	0.1785	0.158	0.0859
GRU	0.0001	0.0044	0.0002	0.1578	0.1266	0.0817
LSTM/GRU	0.0001	0.0045	0.0002	0.1498	0.127	0.0983

Tablo 4.18. Uygulanan modellerin çıkış parametrelerine göre sonuçları (MPD'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	5.7159	0.8318	0.0034	5.7323	--	17.2948
LSTM	4.2615	0.2423	0.0022	6.7402	7.1971	10.684
GRU	4.2329	0.0824	0.002	5.718	5.9253	10.553
LSTM/GRU	4.4015	0.0839	0.002	5.5664	6.0965	12.4957

Tablo 4.19. Uygulanan modellerin çıkış parametrelerine göre sonuçları (EVS'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	0.3243	0.6062	0.0732	0.453	0.2484	0.5182
LSTM	0.4986	0.9066	0.3746	0.7108	0.7133	0.7219
GRU	0.5	0.9587	0.4374	0.75	0.7118	0.7379
LSTM/GRU	0.485	0.9525	0.4425	0.7181	0.7073	0.7119

Tablo 4.20. Uygulanan modellerin çıkış parametrelerine göre sonuçları (R²'ye göre)

Parametre	Debi	Sıcaklık	pH	AKM	BOI ₅	KOI
RNN	0.3215	0.5501	0.0104	0.3266	-0.1001	0.5125
LSTM	0.4943	0.8540	0.3613	0.4242	0.6036	0.721
GRU	0.4975	0.9464	0.4085	0.532	0.6507	0.7256
LSTM/GRU	0.4774	0.9457	0.4219	0.5199	0.6387	0.6842

4.3.Araştırma Bulguları

Derin öğrenme yöntemlerinden RNN, LSTM, GRU ve GRULSTM modelleri, ileri atıksu arıtma tesisi çıkış parametreleri üzerinde uygulamıştır. Çıkış parametrelerine göre değerlendirildiğinde modeller en iyi sonucu pH parametresinde, en kötü sonucu ise debi parametresinde elde etmişlerdir. Tesis verilerine bakıldığında debi parametresinin düzgün bir dağılıma sahip olmadığı görülmektedir. Sonuçların kötü çıktığı diğer parametrelerde de durum yine aynıdır.

Uygulanan modellere göre GRU, LSTM ve LSTM/GRU modelleri başarılı sonuçlar verirken, en kötü sonuç veren model RNN olmuştur.

Performans ölçütlerine göre değerlendirildiğinde;

MSE, RMSE, MAE ve MPD ölçütlerine göre sonucun en iyi olduğu parametre pH olurken, en başarılı model LSTM/GRU olmuştur.

MAPE ölçütüne göre en iyi sonuç LSTM modeliyle debi parametresinde elde edilmiştir.

EVS ve R^2 ölçütlerine göre, uygulanan tüm modellerde sıcaklık parametresi en iyi sonucu vermiştir. En başarılı model ise yine sıcaklık parametresinde GRU modeli olmuştur.

Çıkış parametreleri özelinde değerlendirildiğinde;

Debi parametresi için, performans kriterlerine göre en başarılı modelin GRU olduğu görülmüştür.

Sıcaklık parametresi için; MAE ve MAPE ölçütlerine göre en iyi değerler LSTM/GRU modelinde, diğer tüm ölçütler için GRU modelinde en iyi değerler elde edilmiştir.

pH parametresi için tüm değerlendirme ölçütlerinde LSTM/GRU diğer modellere göre daha iyi sonuçlar çıkarmıştır.

AKM parametresi için; değerlendirme ölçütlerine göre farklı derin öğrenme modellerinin öne çıktığı görülmüştür. MSE, RMSE ve EVS ölçütlerine göre GRU modeli öne çıkarken, MAE, MAPE ve MGD ölçeklerine göre RNN modeli, R^2 ve MPD ölçeklerine göre LSTM/GRU modeli diğer modellere göre daha başarılı sonuç elde etmişlerdir.

BOI₅ parametresi için; MSE, RMSE, MAE, MGD ve R^2 ölçütlerine göre GRU modeli daha iyi sonu verirken MAPE ölçütünde LSTM/GRU, MGD ve EVS'ye göre LSTM modeli daha başarılı olmuştur

KOI parametresi için; MAE VE MAPE ölçütlerine göre LSTM, diğer tüm ölçütlerde GRU modeli daha iyi sonuç vermiştir.

5. SONUÇ VE ÖNERİLER

Yapılan bu tez çalışmasında, farklı derin öğrenme modelleri, ileri biyolojik atıksu arıtma tesisi çıkış parametreleri üzerine uygulanmış, debi, sıcaklık, pH, AKM, BOİ₅ ve KOİ parametreleri üzerinde derin öğrenme modellerinin uygulanabilirliği araştırılmıştır. Çıkış parametrelerine ait gerçek veriler üzerine RNN, LSTM, GRU ve LSTM/GRU tahmin modelleri tasarlanmıştır.

Elde edilen sonuçlar değerlendirildiğinde, yeterli ve düzenli verilere sahip parametrelerde uygulanan modellerin başarılı sonuç verdiği gözlenmiştir. Mevcut veri集中的 parametrelerden debi parametresine ait veriler yapısal olarak düzensiz olduğundan tüm derin öğrenme modelleri bu parametre üzerinde başarısız olmuştur. En başarılı sonuçlar pH ve sıcaklık parametresinde elde edilmiştir.

Yapılan çalışmada zaman serisi analizinde yaygın kullanılan derin öğrenme modellerinin atıksu arıtma tesisi verileri üzerindeki başarısı değerlendirilmiştir. Tekrarlayan Sinir Ağları (RNN)'lerin, yapısı gereği her ne kadar belirli ölçekte hafıza birimine sahip olsa da, çok geçmiş bilgileri hatırlayamadığı, ayrıca kaybolan gradyan problemlerine sahip olduğu tezin ilgili bölümünde açıklanmıştı. Deneysel çalışmalarda da, RNN modelinin olumsuz olabilecek bu özelliği sonuca yansımış ve diğer modeller arasında en kötü sonuçlar RNN modelinden elde edilmiştir.

LSTM modeli, RNN mimarisindeki bahsedilen olumsuz durumların üstesinden gelmek için tasarlanmış bir mimaridir. Uzun dönem geçmiş bilgileri hatırlayabilme kabiliyeti bu çalışmada kendini göstermiş, elde edilen değerler, LSTM'in zaman serisi tahmin problemlerinde başarılı bir şekilde uygulanabileceğini göstermiştir.

GRU modeli, LSTM modelinin yapısal olarak değiştirilip basitleştirilmesiyle oluşturulmuştur. Tüm çalışmalar sırasında GRU modelinden elde edilen sonuçlar, LSTM modeline çok yakın olmakla birlikte daha iyi sonuçlar vermiştir.

LSTM ve GRU modelleri birbirine çok benzer yapılar olduğundan bu çalışmada farklı bir model olarak LSTM ve GRU modellerinin birleşiminden oluşan bir LSTM/GRU modeli denenmiştir. Tasarlanan modelle, LSTM ve GRU modellerine çok yakın sonuçlar elde edilmiştir.

Atıksu arıtma tesisi çıkış parametrelerinin tahminine yönelik uygulanan derin öğrenme modellerinin birbirleriyle kıyaslanabilmesi için tüm modeller aynı yapıda tasarlanmışlardır. Yapılan deneysel uygulamalarda bu şekilde genel bir tasarımda bile modeller üstün performans göstermişlerdir. Modellerin parametrelere uygulanması sonucunda, özellikle pH ve sıcaklık parametrelerinde 0.97 ile 0.99 arasında regresyon değerleri hesaplanmıştır. Elde edilen sonuçlara göre, her bir parametre için ayrı ayrı optimum model tasarımları yapıldığında, bu tez çalışmasında düşük regresyon değeri elde edilen parametrelerde bile çok iyi sonuçların alınabileceği düşünülmektedir.

Yapılan bu tez çalışmasıyla, atıksu arıtma tesislerinde çıkış parametrelerinin ileriye yönelik tahmin değerlendirmelerinde, derin öğrenme yöntemlerinden LSTM, GRU ve bunların kendi aralarındaki kombinasyonlarından oluşturulacak modellerle başarılı sonuçlar elde edilebileceği görülmüştür.

6. KAYNAKLAR

- Alpaslan, S. (2021). Arıtılmış Atıksuların Geri Kazanımı, Yeniden Kullanımı. Artemis Arıtım. <https://www.artemisaritim.com/aritilmis-atiksularin-geri-kazanimi-yeniden-kullanimi>. Erişim tarihi: 20.12.2021
- Kurtkulak, H. (2014). Kentsel atıksuların geri kazanımı ve yeşil alanların sulanmasında yeniden kullanımı: Konya kenti örneği (Yayımlanmamış Doktora Tezi, Samsun Ondokuz Mayıs Üniversitesi). Yüksek Öğretim Kurumu Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.
- Ang, W.L. & Mohamad, A.W. (2020). State of the art and sustainability of natural coagulants in water and wastewater treatment. *Journal of Cleaner Production*, 262, 1-18. <https://doi.org/10.1016/j.jclepro.2020.121267>.
- Newhart, K.B., Holloway, R.W., Hering, A.S. & Cath, T.Y. (2019). Data-driven performance analyses of wastewater treatment plants: A review. *Water Research*, 157, 1-16. <https://doi.org/10.1016/j.watres.2019.03.030>.
- Lotfi, K., Bonakdaria, H., Ebtehaja, I., Mjallie, F. S., Zeynoddina, M., Delatollad, R. & Gharabaghie, B. (2019). Predicting wastewater treatment plant quality parameters using a novel hybrid linear-nonlinear methodology. *Journal of Environmental Management*, 240, 463-479. <https://doi.org/10.1016/j.jenvman.2019.03.137>.
- Kavak, N. (2016). Kayseri ili örneğinde, atıksu arıtma tesislerinde uygulanan arıtma yöntemlerinin incelenmesi ve optimum yöntemlerinin belirlenmesi (Yayımlanmamış Yüksek Lisans Tezi, Nevşehir Hacı Bektaş Veli Üniversitesi). Yüksek Öğretim Kurumu Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.
- Sağlam, M., N. (2019). Mardin ili Kızıltepe ilçesi ileri biyolojik atıksu arıtma tesisinin işletme verimliliği, işletme problemleri ve çözüm önerileri (Yayımlanmamış Yüksek Lisans Tezi, Tunceli Munzur Üniversitesi). Yüksek Öğretim Kurumu Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.

- Durak, A. (2020). Evsel atıksuların arıtılmasında biyolojik arıtma yönteminin uygulanması ve işletme sorunlarının incelenmesi Van ili örneği (Yayımlanmamış Yüksek Lisans Tezi, Van Yüzüncü Yıl Üniversitesi). Yüksek Öğretim Kurumu Tez Merkezi.
<https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.
- Demirkol, M., R. (2021). Evsel ve endüstriyel atıksu tesislerinin enerji verimlilikleri (Yayımlanmamış Yüksek Lisans Tezi, Karabük Üniversitesi). Yüksek Öğretim Kurumu Tez Merkezi.
<https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.
- Azman, H., E. (2005). Evsel atıksuların arıtılmasında arıtma verimi-enerji ilişkisinin incelenmesi (Yayımlanmamış Yüksek Lisans Tezi, Adana Çukurova Üniversitesi). Yüksek Öğretim Kurumu Tez Merkezi.
<https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>.
- Çelikkol, L. (2019). BOİ ve KOİ parametreleri nedir ne değildir? Artemis Arıtım. <https://www.artemisaritim.com/boi-ve-koi-parametreleri-nedir-ne-degidir>.
Erişim tarihi: 20.12.2021.
- Simsek, E.B. & Alkay, T. (2020). Artificial neural network approach for the prediction of effluents streams from a wastewater treatment plant: A case study in Kocaeli (Turkey). *Mugla Journal of Science and Technology*, 6(1), 164–171.
<https://doi.org/10.22531/muglajsci.618373>.
- Elmaadawy K., Abd Elaziz, M., Elsheikh, A. H., Moawad, A., Liu, B. & Lu, S. (2021). Utilization of random vector functional link integrated with manta ray foraging optimization for effluent prediction of wastewater treatment plant. *Journal of Environmental Management*, 298, 1-9.
<https://doi.org/10.1016/j.jenvman.2021.113520>.
- Wang, D., Thunell, S., Lindberg, U., Jiang, L., Trygg, J., Tysklind, M. & Souihi, N. (2021). A machine learning framework to improve effluent quality control in wastewater treatment plants. *Science of the Total Environment*, 784, 1-11.
<https://doi.org/10.1016/j.scitotenv.2021.147138>.

- Wang, G., Jia, Q. S., Zhou, M. C., Bi, J. & Qiao, J (2021). Soft-sensing of Wastewater Treatment Process via Deep Belief Network with Event-triggered Learning. *Neurocomputing*, 436, 103–113. <https://doi.org/10.1016/j.neucom.2020.12.108>.
- Wang, R., Yu, Y., Chen, Y., Pan, Z., Li, X., Tan, Z. & Zhang, J. (2022). Model construction and application for effluent prediction in wastewater treatment plant: Data processing method optimization and process parameters integration. *Journal of Environmental Management*, 302, 1-7. <https://doi.org/10.1016/j.jenvman.2021.114020>
- Li, G., Ji, J., Ni, J. Wang, S., Guo, Y., Hud, Y., Liu, S., Huang, S.F. & Li, Y.Y. (in press). Application of deep learning for predicting the treatment performance of real municipal wastewater based on one-year operation of two anaerobic membrane bioreactors. *Science of the Total Environment*, 813, 1-13. <http://dx.doi.org/10.1016/j.scitotenv.2021.151920>.
- Tan, F. G., Yüksel, A. S., Aydemir, E. & Ersoy, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*, 25, 159-171. <https://doi.org/10.31590/ejosat.878552>.
- İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104. <https://dergipark.org.tr/tr/pub/gbad/issue/31228/330663>.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929-1958. <https://www.jmlr.org/papers/v15/srivastava14a.html>.
- Gavcar, E., Metin, H.M. (2021). Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) ile Tahmini. *Ekonomi ve Yönetim Araştırmaları Dergisi*, 10(2), 1-11. <https://dergipark.org.tr/tr/pub/eyad/issue/68049/1056795>.
- ODSC Community (2020, December 15). Understanding the Mechanism and Types of Recurrent Neural Networks. *Open Data Science*.

<https://opendatascience.com/understanding-the-mechanism-and-types-of-recurring-neural-networks/>.

Stanford Üniversitesi, Tekrarlayan Yapay Sinir Ağları el kitabı.
<https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks>.

Şahin, M.E. & Akın, E. (2024). Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. EMO Bilimsel Dergi, 14(1), 27-38.
<https://dergipark.org.tr/tr/pub/emobd/issue/83029/1338066>.

Haskol, T. (2023, Mayıs 3). Yinelenen Sinir Ağları Nedir? Data Kapital.
<https://datakapital.com/blog/yinelenen-sinir-aglari-nedir/>.

Doğan, F, Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendislik Dergisi, 10 (2) 409-445.
<https://doi.org/10.24012/dumf.411130>.

Karcı, Ş. (2021). Farklı Otokodlayıcı Modelleri ile Sentetik Beyin MR Görüntülerinin Çoğaltılması. Muş Alparslan Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 2(1), 29-34.
<https://dergipark.org.tr/tr/pub/maummfd/issue/65869/1027050>.

Uçar, M. & Uçar, E. (2019). Derin Otomatik Kodlayıcı Tabanlı Özellik Çıkarımı İle Android Kötücül Yazılım Uygulamalarının Tespiti. Yönetim Bilişim Sistemleri Dergisi, 5(2), 21-28. <https://dergipark.org.tr/tr/pub/ybs/issue/51328/639530>.

Yapıcı, M., M., Tekerek, A. & Topaloğlu, N. (2019). Literature Review of Deep Learning Research Areas. Gazi Mühendislik Bilimleri Dergisi, 5(3) 188-215.
<https://dx.doi.org/10.30855/gmbd.2019.03.01>.

Küçük, D. & Arıcı, N. (2018). Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine Bir Literatür Çalışması. Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi, 2(2), 76-86.
<https://dergipark.org.tr/tr/pub/uybisbbd/issue/41787/443574>.

Emeç, M. & Özcanhan, M.E. (2023). Makine Öğrenmesi Algoritmalarında Hiper Parametre Belirleme. E. Yiğit ve U. Özkaya (Ed.), Mühendislikte Öncü ve Çağdaş Çalışmalar içinde, (ss. 71-98). Duvar Yayınları.

Kara, R. (2020, Aralık 20). ML ve AI için Popüler Python Kütüphaneleri. Medium. <https://medium.com/machine-learning-t%C3%BCrkiye/ml-ve-ai-i%C3%A7in-pop%C3%BCler-python-k%C3%BCt%C3%BCphaneleri-c08d09e08432>

Öztürk, M. (2020, Kasım 21). Python Kütüphaneleri. <https://miracozturk.com/python-kutuphaneleri-ve-ozellikleri/>. Erişim tarihi: 12.04.2023

Karakaş, S. (2024, Mart 04). Makine Öğrenmesinde Başarıyı Tartmak: Temel Metrikler ve Anlamları. <https://ilge.com.tr/makine-ogrenmesinde-basariyi-tartmak--temel-metrikler-ve-anlamlari>. Erişim tarihi: 02.07.2024

ÖZGEÇMİŞ

1. KİŞİSEL BİLGİLER			
Adı Soyadı	:	Ercan UYGUN	
Unvanı	:		
ORCID	:	0009-0004-0763-0731	
Doğum tarihi	:		
Doğum yeri	:		
E mail	:		
2. ÖĞRENİM BİLGİLERİ			
Derece	Alan	Üniversite	Yıl
Lisans			
Lisans			
Yüksek lisans			
3. YABANCI DİL BİLGİSİ			
1-)			
2-)			
3-)			
4. MESLEKİ DENEYİM VE ÜYELİKLER			
1-)			
2-)			
3-)			
5. YAYINLAR VE ÖDÜLLER			
1-)			
2-)			
3-)			