

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENME ALGORİTMALARI İLE SU TÜKETİM
MİKTARLARININ TAHMİNİ: KOCAELİ ÖRNEĞİ

DOKTORA TEZİ

Kasım GÖRENEKLİ

Bilişim Sistemleri Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

MAYIS 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENME ALGORİTMALARI İLE SU TÜKETİM
MİKTARLARININ TAHMİNİ: KOCAELİ ÖRNEĞİ

DOKTORA TEZİ

Kasım GÖRENEKLİ

Bilişim Sistemleri Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

Tez Danışmanı: Doç.Dr. Ali GÜLBAĞ

MAYIS 2025

Kasım GÖRENEKLİ tarafından hazırlanan “Makine Öğrenme Algoritmaları ile Su Tüketim Miktarlarının Tahmini: Kocaeli Örneği” adlı tez çalışması 15.05.2025 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilişim Sistemleri Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Doç.Dr. Ali GÜLBAĞ** (Danışman)
Sakarya Üniversitesi

Jüri Üyesi : **Doç.Dr. Alparslan Serhat DEMİR**
Sakarya Üniversitesi

Jüri Üyesi : **Dr.Öğr.Üyesi Seçkin ARI**
Sakarya Üniversitesi

Jüri Üyesi : **Prof.Dr. Halit ÖZTEKİN**
Sakarya Uygulamalı Bilimler Üniversitesi

Jüri Üyesi : **Doç.Dr. Selman HIZAL**
Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Makine Öğrenme Algoritmaları ile Su Tüketim Miktarlarının Tahmini: Kocaeli Örneği” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(...../...../20.....).

Kasım GÖRENEKLİ





Merhum Babam ve Anneme, bize sürekli öğrenmeyi aşıladıkları için...



TEŞEKKÜR

Bu uzun ve zorlu yolculuğu başarıyla tamamlamamı sağlayan sağlık ve gücü bana bahsettiği için Allah'a şükürlerimi sunarım.

Danışmanım Doç.Dr. Ali Gülbağ'a en derin minnettarlığımı sunarım. Araştırma sürecindeki sürekli desteğiniz, rehberliğiniz ve sabrınız benim için son derece kıymetliydi.

Ayrıca, tez izleme jüri üyeleri Doç. Dr. Alparslan Serhat Demir ve Dr. Öğr. Üyesi Seçkin Arı'ya, bu çalışmanın şekillenmesine yardımcı olan değerli geri bildirimleri için teşekkür ederim.

Bu çalışmaya önemli katkılarda bulunanlara teşekkürlerimi sunarım. Özellikle, Kocaeli Su ve Kanalizasyon İdaresi Genel Müdürlüğü Abone İşleri Daire Başkanı Hakan Kütük'e veri erişimi sağladığı için teşekkür ederim. Kocaeli Üniversitesi'nden Prof. Dr. M. Melih İnal ve Sakarya Üniversitesi'nden Prof. Dr. Devrim Akgün'e değerli görüşleri için minnettarım. Burak Kızılöz, Sinan Acun, Amer Mirkhan ve Emre Aksel'in yardımları için teşekkür ederim.

Son olarak, sevgili eşim Viktoriia Tymoshenko'ya gösterdiği sonsuz destek, sabır ve anlayış için içten teşekkürlerimi sunarım. Desteğiniz, bu zorlu süreç boyunca bana güç verdi ve karşılaştığım zorlukları aşmamda beni cesaretlendirdi.

Akademik ve profesyonel hayatımda rol oynayan herkese teşekkür ederim.

Kasım GÖRENEKLİ



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xv
SİMGELER	xvii
TABLO LİSTESİ	xix
ŞEKİL LİSTESİ	xxi
ÖZET	xxiii
SUMMARY	xxv
1. GİRİŞ	1
1.1. Tezin Amacı ve Kapsamı	1
1.2. Problem Tanımı	2
1.3. Çalışmanın Önemi	3
1.4. Hipotezler	4
1.5. Araştırma Soruları	5
1.6. Tezin Yapısı	5
2. LİTERATÜR TARAMASI	7
2.1. Yapay Zeka Teknikleri ve Su Tüketimi Tahmini	7
2.2. Türkiye’deki Su Yönetimi ve Kaynaklar	10
2.3. Yapay Zeka Teknikleri ile Su Tüketimi Tahmini Çalışmaları	10
2.3.1. Yapay zeka tekniklerinin su tüketimi tahmininde kullanımı	11
2.3.2. Derin öğrenme modelleri ve su tüketimi tahmini	11
2.3.3. Yapay zeka ile su yönetimi ve gelecekteki perspektifler	12
2.4. Yapay Zeka ve Derin Öğrenme	12
2.4.1. Yapay zeka (AI)	12
2.4.2. Makine öğrenimi (ML)	13
2.4.3. Derin öğrenme (DL)	13
2.5. Yapay Sinir Ağları (ANN)	13
2.5.1. Girişler ve çıkışlar	13
2.5.2. Gizli katmanlar ve aktivasyon fonksiyonları	14
2.5.3. İleri besleme ve geri yayılım	18
2.5.4. Hiperparametreler ve optimizasyon	18
2.6. Derin Öğrenme Modellerinde Performans Artışı	19
2.7. COVID-19’un su Tüketimi Üzerindeki Etkileri	19
2.8. Su Yönetimi ve Gelecek Perspektifler	20
2.9. Farklı Yapay Zeka Modelleri ve Optimizasyon Teknikleri	20
2.9.1. Makine öğrenimi ve derin öğrenme modelleri	20
2.9.2. Optimizasyon algoritmaları	21
2.9.3. Parçacık sürü optimizasyonu (PSO) ve yapay zeka modellerine etkisi ...	21
2.10. İSU Genel Müdürlüğü: Tarihçe ve Yapı	23
3. MATERYAL VE YÖNTEM	25

3.1. Çalışma Alanı: Kocaeli.....	25
3.2. Veri Seti.....	26
3.2.1. Su tüketim verileri ve abone türleri.....	26
3.2.2. Meteorolojik ve sosyo-ekonomik veriler	28
3.2.3. COVID-19 pandemisinin etkileri	32
3.2.4. Günlük su tüketim verileri	35
3.3. Veri Ön İşleme Adımları	36
3.3.1. Eksik verilerin tamamlanması.....	36
3.3.2. Anormal verilerin tespiti ve çıkarılması.....	37
3.3.3. Veri Normalizasyonu ve Standardizasyonu	38
3.3.4. Veri bölme ve çapraz doğrulama	39
3.4. SVM, RF, GBM, LSTM ve GRU Modelleri.....	40
3.4.1. Destek vektör makineleri (SVM)	40
3.4.2. Random forest (RF).....	41
3.4.3. Gradient boosting machines (GBM)	41
3.4.4. Uzun kısa süreli bellek (LSTM).....	42
3.4.5. Kapalı tekrarlayan birimler (GRU)	43
3.4.6. Modellerinin karşılaştırılması	43
3.5. Modelin Eğitimi ve Parametre Optimizasyonu	44
3.5.1. Eğitim ve test setleri.....	44
3.5.2. Performans Metrikleri	45
3.5.3. Hiperparametre optimizasyonu	46
3.5.4. Aşırı öğrenmeyi (Overfitting) önleme yöntemleri	48
3.5.5. Korelasyon (Correlation).....	49
3.5.6. Rassal başlangıç noktaları ve T-testi.....	52
3.6. Çapraz Doğrulama ve Model Değerlendirme.....	52
3.7. Su Kaynakları ve Yönetim Stratejileri	53
3.7.1. Barajlar ve su kaynakları.....	53
3.7.2. Kayıp kaçak ve temin miktarları	55
3.7.3. Yıllık grafik ve değerlendirmeler	57
3.7.4. Su yönetim teknolojileri	59
3.7.5. Hedeflenen noktalar ve gelecek projeler	60
4. BULGULAR	63
4.1. Su Tüketimi Tahmin Modelinin Performansı.....	63
4.1.1. Ticari aboneler için sonuçlar	67
4.1.2. Resmi aboneler için sonuçlar	69
4.1.3. Konut aboneleri için sonuçlar	72
4.1.4. Konut aboneleri için günlük verilere dayalı sonuçlar	75
4.1.5. İyileştirilmiş model performans sonuçları.....	83
4.1.6. Günlük tüketim tahminin model performansı	84
4.2. COVID-19'un Su Tüketimine Etkisi.....	85
4.2.1. Pandemi süresince konut aboneleri	85
4.2.2. Pandemi süresince ticari ve resmi aboneler	86
4.3. Diğer Faktörlerin (İklim, Abone Türü vb.) Etkileri	86
4.3.1. İklim verilerinin etkisi	87
4.3.2. Abone türlerinin su tüketimi üzerindeki etkileri	88
4.4. Performans Değerlendirme ve Karşılaştırmalar	88
5. TARTIŞMA	95
5.1. Literatür ile Karşılaştırma.....	95
5.2. Yapay Zeka Yöntemlerinin Su Tüketimi Yönetimine Katkısı	97

5.3. Modelin Limitasyonları ve Gelecek Çalışmalar.....	98
6. SONUÇLAR VE ÖNERİLER	101
6.1. Genel Sonuçlar	101
6.2. Öneriler.....	104
6.2.1. Veri setlerinin genişletilmesi	104
6.2.2. Sosyo-ekonomik verilerin entegrasyonu.....	104
6.2.3. Farklı yapay zeka tekniklerinin uygulanması	105
6.2.4. Olağanüstü durumlar için kriz yönetimi modelleri	105
6.2.5. Su ve enerji yönetiminin entegrasyonu.....	105
6.2.6. Yapay zeka ve veri gizliliği	106
6.2.7. Mekansal ve zaman serisi verilerin kullanımı.....	106
6.2.8. Model genelleme kapasitesinin test edilmesi.....	106
6.2.9. Abone su tüketim alışkanlıklarının yönetiminde ileri adımlar.....	107
KAYNAKLAR	109
EKLER.....	115
ÖZGEÇMİŞ.....	121



KISALTMALAR

AI	: Yapay Zeka (Artificial Intelligence)
ANN	: Yapay Sinir Ağları (Artificial Neural Networks)
BES	: Biyokütle Enerji Santralleri
COVID-19	: Koronavirus Hastalığı 2019
DAN2	: Dinamik Yapay Sinir Ağları
DL	: Derin Öğrenme (Deep Learning)
DT	: Karar Ağaçları (Decision Tree)
FWGKNN	: Özellik Ağırlıklı Gri K-En Yakın Komşu (Feature Weighted Grey KNN)
GBM	: Gradyan Artırmalı Modeller (Gradient Boosting Machines)
GES	: Güneş Enerjisi Santralleri
GRU	: Kapalı Tekrarlayan Birimler (Gated Recurrent Unit)
HES	: Hidroelektrik Santralleri
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
LM	: Doğrusal Modeller (Linear Models)
LSTM	: Uzun Kısa Süreli Bellek (Long Short Term Memory)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	: Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error)
MedAE	: Medyan Mutlak Hata (Median Absolute Error)
ML	: Makine Öğrenimi (Machine Learning)
MSE	: Ortalama Kare Hatası (Mean Squared Error)
PSO	: Parça Sığırcık Optimizasyonu (Particle Swarm Optimization)
ReLU	: Doğrultulmuş doğrusal Birim (Rectified Linear Unit)
RF	: Rastgele Orman (Random Forest)
RMSE	: Karekök Ortalama Hata (Root Mean Squared Error)
RNN	: Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
R²	: Determinasyon Katsayısı (R-Squared)
SCADA	: Denetleyici Kontrol ve Veri Toplama (Supervisory Control and Data Acquisition)
SSE	: Hata Karelerinin Toplamı (Sum of Squared Error)
SVM	: Destek Vektör Makineleri (Support Vektör Machine)
TÜİK	: Türkiye İstatistik Kurumu

WWF : Dünya Doğal Hayatı Koruma Vakfı (World Wide Fund for Nature)

YZ : Yapay Zeka



SİMGELER

$X_{\min}$	: Verideki minimum değer
$X_{\max}$	: Verideki maksimum değer
X_{new}	: Normalleştirilmiş yeni değer
α	: Aktivasyon fonksiyonunda kullanılan bir katsayıdır
e^x	: e tabanında üstel bir artış veya azalışı temsil eder
Σ	: Sigma, bir dizideki terimlerin toplamını gösterir



TABLO LİSTESİ

Sayfa

Tablo 3.1. Aylık Veri Setinde Kullanılan Girdiler (Değişkenler).	27
Tablo 3.2. 2016 yılına ait günlük maksimum sıcaklık değerlerini göstermektedir. ...	31
Tablo 3.3. 2016-2022 Yıllarına ait Aylara Göre Hafta Sonu ve Tatil Gün Sayılarının bir kısmı.	32
Tablo 3.4. Modeller ve Optimize Edilen Hiperparametreler.	48
Tablo 3.5. Özellikler Arası Korelasyon.	50
Tablo 4.1. Abone ve Pandemi Dönemine Göre Bazı ANN Sonuçları.	63
Tablo 4.2. LSTM ile Pandemi Durumuna Göre Performans.	64
Tablo 4.3. GRU ile Pandemi Durumuna Göre Performans.	64
Tablo 4.4. PSO-RF ile Pandemi Durumuna Göre Performans.	65
Tablo 4.5. GBM ile Pandemi Durumuna Göre Performans.	65
Tablo 4.6. SVM ile Pandemi Durumuna Göre Performans.	65
Tablo 4.7. Abone Türlerine Göre Mevcut Ay Su Tüketim Tahmin Performansı.	66
Tablo 4.8. Abone Türlerine Göre Gelecek Ay Su Tüketim Tahmin Performansı. ...	67
Tablo 4.9. Günlük Tüketim Model Performans Tablosu.	76
Tablo 4.10. İyileştirmeden Sonraki ANN Sonuçları.	84
Tablo 4.11. Farklı Modellerin Resmi Aboneler Performans Metrikleri.	88
Tablo 4.12. Pandemi Öncesi Farklı Modellerin Resmi Aboneler Performans Metrikleri.	89
Tablo 4.13. Pandemi Sonrası Farklı Modellerin Resmi Aboneler Performans Metrikleri.	90
Tablo 4.14. 3 Tür Abonenin Mevcut ve Bir Sonraki Ay İçin Performans Metrikleri.	91
Tablo 4.15. ANN'nin Ticari ve Resmi Aboneler İçin Diğer Modellerle Karşılaştırılması.	92
Tablo 4.16. Meteorolojik Verilerin Modele Entegrasyonunun Resmi ve Ticari Aboneler İçin Performansa Etkisi.	93
Tablo 4.17. Pandemi Öncesi ve Sonrası Tüm Modellerin Karşılaştırılması.	94



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. İklim değişikliğinin su kaynaklarına etkisini gösteren grafik, bu çalışma bağlamında, su tüketimi tahminlerini iyileştirme ihtiyacının temelini oluşturmaktadır (Ayva ve ark., 2023).	2
Şekil 2.1. ANN Modelinin Genel Mimarisi.....	8
Şekil 2.2. Sigmoid Fonksiyonu.....	14
Şekil 2.3. Tanh (Hiperbolik Tanjant) Fonksiyonu.....	15
Şekil 2.4. ReLU (Rektifiye Edilmiş Doğrusal Birim) Fonksiyonu.....	15
Şekil 2.5. Leaky ReLU Fonksiyonu.....	16
Şekil 2.6. ELU (Üstel Doğrusal Birim) Fonksiyonu.....	16
Şekil 2.7. Swish Fonksiyonu.....	17
Şekil 2.8. Softmax Fonksiyonu.....	17
Şekil 2.9. Parçacık Sürü Optimizasyonu.....	23
Şekil 3.1. Kocaeli'nin haritadaki yeri.	25
Şekil 3.2. Aylık Veriler Korelasyon Isı Tablosu.....	29
Şekil 3.3. Pandemi öncesine ait karşılaştırma.....	33
Şekil 3.4. Pandemi öncesi, pandemi süresi, ve sonrasına ait karşılaştırma.	33
Şekil 3.5. Pandemi öncesi ile sonrasına ait karşılaştırma.	34
Şekil 3.6. Grid Search ile Hiperparametre Optimizasyonu Sonuçları.	47
Şekil 3.7. Yıllık Su Temin Değişimleri.	54
Şekil 3.8. 2024 Ocak-Ekim Arası Kümülatif Su Denge Formu.	56
Şekil 3.9. Aylık Su Temin Miktarlarının Dağılımı.	58
Şekil 3.10. Yıllık Kayıp Kaçak Oranlarının Kıyaslanması.....	58
Şekil 3.11. Geri Kazanım Suyu Kullanım Miktarları.	59
Şekil 4.1. Tüketim gruplarına göre ortalama aylık su tüketimi ve abone sayıları (Konut, Ticari ve Resmi Aboneler için ayrı ayrı gösterilmiştir).	66
Şekil 4.2. Ticari Abonelerde Su Tüketimi ve Yağış Arasındaki İlişki.	68
Şekil 4.3. Resmi Abonelerde Su Tüketimi ve Yağış Arasındaki İlişki.....	71
Şekil 4.4. Konut Abonelerde Su Tüketimi ve Yağış Arasındaki İlişki.....	74
Şekil 4.5. Farklı Abone Türlerine Göre Su Tüketimi ve Yağış Arasındaki İlişki.	75
Şekil 4.6. Günlük Veriler Korelasyon Isı Tablosu.....	77
Şekil 4.7. Hane Günlük Ortalama Tüketim Grafiği.....	78
Şekil 4.8. Günlük Tüketim Zaman Serisi Analizi.....	78
Şekil 4.9. Pandemi Öncesi ve Sonrası Günlük Tüketim Kutu Grafiği.....	79
Şekil 4.10. Pandemi Öncesi ve Sonrası Saatlik Tüketim Karşılaştırılması.	79
Şekil 4.11. (a,b) Sayısal değişkenlerin Histogramları.....	82
Şekil 4.12. Abone Türlerine göre Aylık Su Tüketimi ve COVID-19 Pandemisi Başlangıcındaki Değişimler (Şubat-Mayıs 2020 dönemi gölgelenmiştir).85	
Şekil 4.13. Değişkenler Arası İlişkiler (Tüketim, Yağış, Son 4 Ay Tüketimi, Maksimum Sıcaklık).	87
Şekil 4.14. Modellerin Resmi Aboneler R ² Değerleri.	89



MAKİNE ÖĞRENME ALGORİTMALARI İLE SU TÜKETİM MİKTARLARININ TAHMİNİ: KOCAELİ ÖRNEĞİ

ÖZET

Su kaynaklarının etkin yönetimi ve sürdürülebilir kullanımı, günümüzün en kritik çevresel ve ekonomik sorunlarından biridir. Su kaynaklarının yönetimi, sadece mevcut ihtiyaçları karşılamakla sınırlı olmayıp, gelecekteki nesillerin de suya erişimini garanti altına almayı hedeflemektedir. Bununla birlikte, iklim değişikliği, aşırı hava olayları ve su talebindeki artış, bu yönetimi daha karmaşık hale getirmektedir. Su yönetimi, tarım, endüstri ve evsel kullanım gibi farklı sektörlerin ihtiyaçlarına yanıt vermek zorundadır ve bu da karmaşık bir planlama sürecini gerektirir.

Artan nüfus, kentleşme ve iklim değişikliği gibi faktörler, su kaynaklarının yönetimini giderek daha karmaşık hale getirmektedir. Bu bağlamda, su tüketim miktarlarının doğru tahmini, su dağıtım sistemlerinin planlanması ve yönetimi açısından büyük önem taşımaktadır. Doğru tahminler, su kaynaklarının optimal kullanımı ve gereksiz israfın önlenmesi açısından hayati önem taşır. Su dağıtım ağlarında yaşanabilecek kayıpların önceden belirlenmesi ve su talebindeki ani değişimlere hızlı cevap verebilmek, su yönetiminin sürdürülebilirliğini artıran unsurlar arasındadır. Ayrıca, su tüketim tahminleri, altyapı yatırımlarının planlanması ve uzun vadeli stratejik kararların alınmasında önemli bir rol oynar. Bu çalışma, yapay zeka tekniklerini kullanarak su tüketim miktarlarının tahmin edilmesini amaçlamaktadır. Çalışmanın temel amacı, Kocaeli ilindeki farklı abone türlerinin (konut, ticari, resmi) su tüketim davranışlarını modelleyerek, daha doğru ve güvenilir tahminler üretmektir.

Araştırmada, Kocaeli Su ve Kanalizasyon İdaresi Genel Müdürlüğü'nden (İSU) elde edilen veriler kullanılmıştır. Bu veriler, bölgedeki su tüketim alışkanlıklarını yansıtan kapsamlı bir veri seti sunmaktadır. 2016 Ocak ile 2022 Ağustos arasındaki dönemde, 5000 abonenin (3447 konut, 1422 ticari ve 131 resmi) aylık su tüketim verileri analiz edilmiştir. Bu abonelerin su tüketim alışkanlıkları, farklı özelliklerine (abone türü, tarife tipi, faaliyet alanı vb.) göre incelenmiştir. Özellikle konut abonelerinin aylık su tüketim tahminlerinin diğer gruplara göre daha düşük performans göstermesi nedeniyle, bu abone grubuna odaklanılmıştır. Konut abonelerinin tahmin performansını iyileştirmek amacıyla, günlük su tüketimi verilerine sahip 33 konut abonesine ait 3 Eylül 2019 ile 5 Kasım 2021 tarihleri arasındaki veriler de çalışmaya dahil edilmiştir. Günlük veriler, su tüketimindeki kısa vadeli değişimleri daha doğru bir şekilde yakalayabilmek ve tahmin performansını artırmak için kullanılmıştır. Bu veri seti, her aboneye ait günlük toplam su tüketim değerlerini, meteorolojik (sıcaklık, yağış, nem vb.) ve sosyo-ekonomik verileri (hafta sonları, tatil günleri, COVID-19 pandemisi vb.) içermektedir. Veri kalitesini sağlamak amacıyla, eksik veya tutarsız verilere sahip aboneler analiz dışı bırakılmıştır. Veriler, tahmin modellerine uygun şekilde hazırlanarak günlük tüketim tahminlerinde kullanılabilir hale getirilmiştir.

Veri seti, farklı abone türlerini (konut, ticari, resmi) içermekte ve çeşitli faktörleri kapsamaktadır. Bu faktörler arasında tarife türleri, faaliyet türleri, hava durumu verileri, mevsimsellik ve COVID-19 pandemi verileri yer almaktadır. Çalışmada, bu

faktörlerin su tüketimi üzerindeki önem dereceleri analiz edilmiş ve su tüketimini etkileyen en kritik unsurlar belirlenmiştir. Ayrıca, su talebinin mevsimsel olarak nasıl değiştiğini anlamak için sıcaklık, yağış miktarı ve nem oranı gibi meteorolojik değişkenler değerlendirilmiştir. Pandemi süresince değişen su tüketim alışkanlıkları ise özellikle konut aboneleri üzerinde belirgin bir etki yaratmış, ticari ve resmi aboneler arasında su kullanımında düşüslere yol açmıştır.

Çalışmada, Yapay Sinir Ağları (ANN) başta olmak üzere, Uzun Kısa Vadeli Bellek (LSTM) ve Kapılı Tekrarlayan Birimler (GRU) gibi çeşitli yapay zeka teknikleri uygulanmıştır. ANN modeli, girdi değişkenleri arasındaki karmaşık ilişkileri modelleme yeteneği ve farklı aktivasyon fonksiyonları ile ağ yapılarıyla uyarlanabilir olması nedeniyle tercih edilmiştir. Derin Öğrenme (DL) yaklaşımları da değerlendirilmiş, ancak ana odak noktası ANN modeli olmuştur. Veri artırma (data augmentation) teknikleri kullanılarak modelin farklı senaryolara uyum sağlaması ve daha tutarlı tahminler yapabilmesi hedeflenmiştir. Geliştirilen modeller, su tüketimini etkileyen faktörleri girdi olarak kullanarak, gelecekteki su tüketim miktarlarını tahmin etmek üzere eğitilmiştir. Veri ön işleme aşamasında, eksik verilerin tamamlanması, aykırı değerlerin tespiti ve giderilmesi, ve veri normalizasyonu gibi teknikler uygulanmıştır. Modellerin eğitimi için veri seti, eğitim, doğrulama ve test setlerine ayrılmıştır.

Modellerin performansı, çeşitli istatistiksel metrikler (R^2 , MSE, RMSE, MAE) kullanılarak değerlendirilmiştir. Sonuçlar, özellikle ANN modelinin, ticari ve resmi aboneler için yüksek doğrulukta tahminler yapabildiğini göstermiştir. Konut aboneleri için tahmin performansı nispeten daha düşük olmakla birlikte, yine de anlamlı sonuçlar elde edilmiştir. Pandemi döneminde, konut abonelerinin su tüketiminde belirgin bir artış gözlemlenirken, ticari ve resmi abonelerde düşüş yaşanmıştır. Çalışma kapsamında, farklı yapay zeka tekniklerinin performansları karşılaştırılmış ve her bir tekniğin güçlü ve zayıf yönleri analiz edilmiştir.

ESTIMATION OF WATER CONSUMPTION AMOUNTS USING MACHINE LEARNING ALGORITHMS: THE CASE STUDY OF KOCAELI

SUMMARY

The efficient management and sustainable use of water resources is one of the most critical environmental and economic issues of our time. Water resource management is not just about meeting current needs, but also about ensuring access to water for future generations. However, climate change, extreme weather events, and increasing water demand are making this management more complex. Water management must respond to the needs of different sectors, such as agriculture, industry, and domestic use, which requires a complex planning process.

Factors such as increasing population, urbanization, and climate change are making the management of water resources increasingly complex. In this context, accurate prediction of water consumption amounts is of great importance for the planning and management of water distribution systems. Accurate predictions are vital for the optimal use of water resources and the prevention of unnecessary waste. Determining potential losses in water distribution networks in advance and being able to respond quickly to sudden changes in water demand are among the elements that increase the sustainability of water management. In addition, water consumption predictions play an important role in planning infrastructure investments and making long-term strategic decisions. This study aims to estimate water consumption amounts using various artificial intelligence techniques, with a primary focus on Artificial Neural Networks (ANN). While other models like Long Short-Term Memory (LSTM) and Gated Recurrent Units (GRU) were considered, the emphasis is on ANN due to its robustness and adaptability to complex data structures.

The research utilizes data obtained from the Kocaeli Water and Sewerage Administration General Directorate. This dataset provides a comprehensive view of regional water consumption patterns. The study analyzes the monthly water consumption data of 5000 subscribers, consisting of 3447 residential, 1422 commercial, and 131 public subscribers, between January 2019 and August 2022. Additionally, to improve the prediction performance for residential subscribers, daily water consumption data from 33 residential subscribers between September 3, 2019, and November 5, 2021, were used. Daily data were chosen to more accurately capture short-term variations in water consumption and enhance predictive accuracy. This dataset includes daily total water consumption values for each subscriber, as well as meteorological and socio-economic data. Subscribers with missing or inconsistent data were excluded from the analysis to ensure data quality. The data were pre-processed and prepared for use in daily consumption predictions, optimizing the models for higher accuracy.

The dataset includes different subscriber types (residential, commercial, public) and various factors, including tariff types, activity types, weather data, seasonality, and COVID-19 pandemic data. The study analyzed the importance of these factors on water consumption and identified the most critical variables influencing water

demand. Additionally, meteorological variables such as temperature, precipitation, and humidity were evaluated to understand seasonal changes in water consumption. The impact of the COVID-19 pandemic was particularly significant for residential subscribers, leading to an increase in water usage, while commercial and public subscribers experienced a decline. This shift in consumption patterns underscores the need for adaptive and responsive water management strategies.

Various artificial intelligence techniques were applied in the study, with Artificial Neural Networks (ANN) being the primary method. Other machine-learning models, such as Support Vector Machines (SVM) and Random Forest (RF), were also explored for comparative analysis. While Deep Learning algorithms were considered, ANN was chosen for its balance between complexity and computational efficiency. Data augmentation techniques were employed to enable the model to adapt to different scenarios and provide more consistent predictions, particularly in the face of unforeseen events like the pandemic. These algorithms are capable of analyzing numerous variables simultaneously, and they excel in handling large datasets.

The developed models were designed and trained to predict future water consumption amounts using factors affecting water consumption as inputs. Data preprocessing techniques such as filling in missing values, detecting and removing outliers, and data normalization were applied to ensure data quality and model accuracy. For model training, the dataset was divided into training, validation, and test sets, following standard machine learning practices. This approach allowed for rigorous evaluation and optimization of the models' performance.

The models' performance was evaluated using various statistical metrics (R^2 , MSE, RMSE, MAE). The results showed that the ANN model, in particular, was able to make high-accuracy predictions for commercial and official subscribers. Although the prediction performance for residential subscribers was relatively lower, meaningful results were still obtained, demonstrating the model's overall effectiveness. These metrics provide a quantitative basis for assessing the reliability and accuracy of the predictions.

The study compared the performance of different artificial intelligence techniques and analyzed the strengths and weaknesses of each. Additionally, the importance levels of factors affecting water consumption were determined, and the effects of these factors on prediction performance were examined. Tariff types, activity types, seasonality, and the COVID-19 pandemic were found to have a significant impact on water consumption. It was found that tariff types, activity types, seasonality, and the COVID-19 pandemic had significant effects on water consumption.

To increase the generalization ability of the models, cross-validation techniques were used, and hyperparameter optimization was performed. Feature importance analysis was conducted to enhance the interpretability of the models, allowing for the identification of which factors have the most significant impact on water consumption. This rigorous approach ensures that the models are robust and reliable for real-world applications.

This research demonstrates the potential of artificial intelligence techniques, particularly ANN, in predicting water consumption and provides a valuable tool for water resource management. The findings can be used for planning water distribution systems, developing demand management strategies, and promoting sustainable water use. The results of the study also offer new perspectives for future research and provide

a foundation for further development of artificial intelligence applications in water consumption estimation. Additionally, the results offer new perspectives for future research and lay the foundation for further development of artificial intelligence applications in the field of water consumption prediction.

For future studies, it is recommended to improve model performance using larger datasets, develop real-time prediction systems, and test the model in other geographical regions. Additionally, examining the potential effects of climate change scenarios on water consumption could be among future research topics. The integration of advanced artificial intelligence techniques in water resource management highlights the importance of this study and offers a more dynamic and adaptive approach to water consumption estimation.

Moreover, this study highlights the importance of integrating advanced artificial intelligence techniques into water resource management, offering a more dynamic and adaptive approach to water consumption forecasting. The integration of such technologies could significantly improve the efficiency of water distribution networks, ensuring sustainable water use even during periods of high demand. Future advancements in AI models, especially in real-time data processing and climate change adaptation, will be essential to tackle the growing challenges of water scarcity worldwide.



1. GİRİŞ

1.1. Tezin Amacı ve Kapsamı

Bu tez çalışması, yapay sinir ağları (ANN) temelli bir model geliştirerek Kocaeli ilindeki su tüketim tahminlerinin doğruluğunu artırmayı ve mevcut yöntemlerden daha etkin bir çözüm sunmayı amaçlamaktadır. Çalışmanın temel odak noktası, konut, ticari ve resmi abonelerin farklı tüketim dinamiklerini tek bir entegre modelle açıklayabilen, pandemi gibi olağanüstü durumlara adapte olabilen bir tahmin sisteminin tasarlanmasıdır.

Çalışma kapsamında, Kocaeli Su ve Kanalizasyon İdaresi'nden (İSU) temin edilen 5.000 abonenin (3.447 konut, 1.422 ticari, 131 resmi) 2019-2022 dönemine ait aylık ve günlük tüketim verileri, meteorolojik (sıcaklık, yağış, nem), sosyo-ekonomik (tatil günleri, pandemi) ve abone profili (tarife tipi, aktivite türü) değişkenleri kullanılarak analiz edilmiştir.


ANN, uzun-kısa vadeli ilişkileri yakalama kapasitesi ve doğrusal olmayan veri yapılarına uyum yeteneği nedeniyle ana model olarak benimsenmiştir. Karşılaştırma için LSTM, GRU gibi derin öğrenme modelleri ve Random Forest (RF) gibi geleneksel makine öğrenimi yöntemleri ikincil düzeyde test edilmiştir. COVID-19'un etkisi, T-testi ve hipotez doğrulama (H_0/H_a) ile istatistiksel olarak incelenmiş; pandemi verileri, modelin girdi katmanına dinamik bir faktör olarak entegre edilmiştir.

Abone türlerine özgü saatlik/günlük/aylık tüketim verileri için tek bir mimaride birleştirilmiş özelleştirilmiş ANN yapısı, veri artırma teknikleriyle modelin mevsimsel ve anomali durumlarına karşı genelleme kapasitesinin güçlendirilmesi ve tahmin sonuçlarının R^2 , MAE, RMSE metrikleriyle abone kategorileri ve zaman dilimleri bazında tablollaştırılarak şeffaf bir performans değerlendirmesi sağlanmıştır. Çalışma, İSU'nun sağladığı abone verileriyle sınırlıdır. Diğer makine öğrenimi modelleri (SVM, GBM vb.) yalnızca ANN'nin performansını kıyaslamak amacıyla sınırlı bir şekilde kullanılmıştır. Pandemi etkisi, tüketim verilerindeki makro değişimler üzerinden analiz edilmiş olup bireysel davranışsal faktörler (örn. hijyen alışkanlıkları) dahil edilmemiştir. Bu çalışma, su yönetiminde yapay zeka tabanlı karar destek

sistemlerinin pratik uygulanabilirliğini kanıtlayarak, kaynak optimizasyonu ve kriz yönetimi için yenilikçi bir çerçeve sunmaktadır.

1.2. Problem Tanımı

Dünya genelinde ve özellikle Türkiye’de, artan su tüketimi ve iklim değişikliklerine bağlı olarak su kaynakları üzerindeki baskı her geçen gün artmaktadır. İklim değişikliği, su kaynakları üzerinde doğrudan etkilidir ve bu durum, su tüketimi tahminlerinde daha hassas modeller geliştirme gerekliliğini artırmaktadır (Ayva ve ark., 2023). Artan sıcaklık, yağış düzensizlikleri ve diğer meteorolojik faktörler, su talebinin mevsimsel dalgalanmalarına yol açmaktadır.



Şekil 1.1. İklim değişikliğinin su kaynaklarına etkisini gösteren grafik, bu çalışma bağlamında, su tüketimi tahminlerini iyileştirme ihtiyacının temelini oluşturmaktadır (Ayva ve ark., 2023).

Şekil 1.1, bu etkilerin su kaynakları üzerindeki değişimlerini göstererek su talebini nasıl etkilediğini net bir şekilde gözler önüne sermektedir.

Türkiye, küresel su kıtlığı endeksine göre su stresi yaşayan ülkeler arasında yer almakta olup, kişi başına düşen su miktarı dünya ortalamasının altında kalmaktadır. Türkeş (2022), IPCC'nin yeni yayımlanan raporunda iklim değişikliğinin su kaynakları üzerindeki etkilerini kapsamlı bir şekilde ele almıştır. Rapor, su kaynaklarının azalması ve uyum stratejileri üzerine önemli bilgiler sunmaktadır. Özellikle şehirlerdeki nüfus artışı ve endüstriyel faaliyetlerin genişlemesi, su talebini sürekli olarak artırmaktadır. Kocaeli ili, Türkiye'nin sanayi merkezlerinden biri olarak hem konut hem de endüstriyel su tüketiminde önemli bir bölgedir. Bu durum, su tüketim tahminlerinin güvenilir ve isabetli olmasını gerektirmektedir. Ancak, geleneksel yöntemlerle yapılan su tüketimi tahminleri, genellikle günümüzün karmaşık su tüketim dinamiklerini yeterince yansıtamamakta ve su yönetimi süreçlerinde yetersiz kalmaktadır.

Bu çalışmada, su tüketim tahminlerinin doğruluğunu artırmak amacıyla Ocak 2016 - Ağustos 2022 tarihleri arasında 80 aylık veri içeren büyük ölçekli bir veri seti kullanılmıştır. Toplamda 5000 aboneye (konut: 3447, ticari: 1422, resmi: 131) ait 400.000 su tüketim kaydı, hava durumu (yağış, sıcaklık, nem, güneşlenme süresi, rüzgar hızı) ve sosyo-ekonomik faktörlerle (hafta sonları, tatiller, COVID-19 pandemisi) ilişkilendirilerek analiz edilmiştir. COVID-19 pandemisinin su talebi üzerindeki etkileri de dikkate alınmış, pandemi döneminde konut abonelerinin su tüketiminde belirgin bir artış yaşanırken, ticari ve resmi abonelerin su tüketiminde düşüşler gözlemlenmiştir (Cahill ve ark., 2021; Campos ve ark., 2021; Sung ve Chung, 2023). Bu büyük ölçekli veri seti, modelin genelleme yeteneği artmakta ve tahmin doğruluğu iyileştirilmektedir.

1.3. Çalışmanın Önemi

Bu tez, yapay zeka yöntemlerini kullanarak su tüketimi tahminlerinde doğruluğu artırmayı ve su kaynaklarının etkin yönetimine katkıda bulunmayı hedeflemektedir. Yapay zeka teknikleri, geleneksel yöntemlere kıyasla daha yüksek doğruluk ve genelleme kapasitesi sunarak, su yönetimi süreçlerinde yenilikçi çözümler sağlayabilir. Özellikle Kocaeli ili gibi sanayi yoğun bölgelerde, su tüketim tahminlerinin doğruluğu, hem konut hem de endüstriyel su kaynaklarının daha verimli kullanılmasını mümkün kılacaktır.

Bu çalışmanın sunduğu tahmin modelleri, yalnızca yerel yönetimler için değil, ulusal düzeyde su yönetimi politikalarının geliştirilmesine de katkı sağlayabilecek niteliktedir. Su tüketimi, hava durumu, tatil günleri ve sosyo-ekonomik koşullar gibi birçok değişkene bağlı olarak doğrusal olmayan bir yapıya sahiptir. Geleneksel istatistiksel yöntemler bu karmaşık ilişkileri tam olarak yansıtmakta yetersiz kalabilmektedir. Bu nedenle, daha yüksek doğruluk ve genelleme kapasitesi sunduğu için bu tezde yapay zeka teknikleri tercih edilmiştir. Doğru tahmin modelleri sayesinde, su kayıplarını azaltma stratejileri geliştirilebilir, altyapı iyileştirme planları optimize edilebilir ve su dağıtım sistemlerinin daha etkin bir şekilde çalışması sağlanabilir.

Ayrıca, bu çalışma, meteorolojik değişkenlerin (örneğin, sıcaklık, yağış, nem) ve sosyo-ekonomik faktörlerin (örneğin, COVID-19 pandemisi, hafta sonu ve tatil günleri) su tüketimi üzerindeki etkilerini incelemekte ve bu faktörlerin doğru şekilde modele entegre edilmesinin faydalarını göstermektedir. Özellikle pandemi gibi olağanüstü durumların su tüketim alışkanlıklarında yarattığı değişiklikler, gelecekteki kriz durumlarında daha esnek ve doğru tahmin modellerinin gerekliliğini ortaya koymaktadır.

Bu tez çalışması kapsamında yapay zeka temelli tahmin modellerinden elde edilen bulgular, hem bilimsel anlamda bir yenilik sunacak hem de suyun verimli kullanımı ve kaynakların korunması açısından uzun vadeli çözümler üretilmesine katkı sağlayacaktır. Bu kapsamda, araştırmanın yerel ve ulusal su yönetimi stratejilerine doğrudan fayda sağlaması beklenmektedir.

1.4. Hipotezler

Bu tez çalışması, aşağıdaki temel hipotezlere dayanarak su tüketim tahmini ve yapay zeka yöntemlerinin etkinliğini sorgulamaktadır:

- **Hipotez 1:** ANN modeli, Kocaeli ili için ticari ve resmi abonelerin su tüketim tahminlerinde RF, SVM ve GBM gibi diğer yapay zeka tekniklerine kıyasla daha yüksek doğruluk oranları sağlamaktadır.
- **Hipotez 2:** Meteorolojik verilerin (sıcaklık, yağış, nem gibi) tahmin modellerine entegre edilmesi, su tüketimi tahmin performansını önemli ölçüde iyileştirmektedir.

- **Hipotez 3:** COVID-19 pandemisi gibi olağanüstü dönemlerde (pandemi öncesi ve sonrası) su tüketim tahmin modellerinin performanslarında istatistiksel olarak anlamlı farklar oluşmaktadır.

1.5. Araştırma Soruları

Bu hipotezleri test etmek amacıyla, çalışma aşağıdaki araştırma sorularına yanıt aramaktadır:

1. Kocaeli ilindeki ticari ve resmi abonelerin su tüketimini tahmin etmede, ANN modeli diğer yapay zeka modellerine (RF, SVM, GBM, vs.) göre ne ölçüde daha yüksek doğruluk oranları sağlar? ANN modelinin üstünlüğü hangi performans metrikleri ile ifade edilebilir?
2. Meteorolojik verilerin (sıcaklık, yağış, nem gibi) modele dahil edilmesi, su tüketimi tahmin performansını hangi düzeyde ve hangi performans metrikleri temelinde artırmaktadır?
3. COVID-19 pandemisinin etkisiyle pandemi öncesi ve sonrası dönemde su tüketim tahmin modellerinin performansları arasında anlamlı farklılıklar var mıdır? Bu farklılıklar hangi performans metrikleri (örneğin R^2 , RMSE, MAE) üzerinden nasıl ölçülebilir?

1.6. Tezin Yapısı

Tez çalışması toplam altı ana bölümden oluşmaktadır:

- **Birinci Bölüm (Giriş)** içerisinde tezin amacı ve kapsamı belirtilmiş, çalışmanın önemi vurgulanmış, problem tanımı ortaya konmuş, tezin temel hipotezleri ve bu hipotezlerle ilişkili araştırma soruları sunulmuştur.
- **İkinci Bölüm (Literatür Taraması)** kapsamında yapay zeka tekniklerinin genel olarak tanımı yapılmış, bu tekniklerin su tüketimi tahminindeki mevcut kullanım alanları incelenmiş ve literatürdeki güncel çalışmalar detaylandırılarak değerlendirilmiştir.
- **Üçüncü Bölüm (Materyal ve Yöntem)** içerisinde çalışmada kullanılan veri seti tanımlanmış, veri ön işleme adımları açıklanmış ve tezde kullanılan yapay zeka modellerinin (özellikle ANN, RF, SVM ve GBM) geliştirilme, eğitim ve değerlendirme süreçleri ayrıntılı olarak aktarılmıştır.

- **Dördüncü Bölüm (Bulgular)** kapsamında, ANN modelinin diğer yapay zeka tekniklerine göre performans karşılaştırmaları yapılmış, meteorolojik verilerin modele entegrasyonunun etkisi değerlendirilmiş ve COVID-19 pandemisinin su tüketimi tahmin modelleri üzerindeki etkisi analiz edilmiştir. Tüm bu analizlere ilişkin sonuçlar grafikler ve tablolar eşliğinde sunulmuştur.
- **Beşinci Bölüm (Tartışma)** bölümünde elde edilen bulgular, araştırma sorularına ve ilgili literatüre göre değerlendirilmiş, elde edilen sonuçların literatürle benzerlikleri ve farklılıkları tartışılmıştır.
- **Altıncı Bölüm (Sonuçlar ve Öneriler)** kapsamında, çalışmanın genel sonuçları özetlenmiş, araştırmadan elde edilen çıkarımlar vurgulanmış ve gelecekte yapılabilecek çalışmalar için öneriler sunulmuştur.

2. LİTERATÜR TARAMASI

2.1. Yapay Zeka Teknikleri ve Su Tüketimi Tahmini

Yapay zeka (AI) teknikleri, özellikle son yıllarda su tüketimi tahmininde önemli bir araç haline gelmiştir. Literatürdeki birçok çalışma, yapay zeka yöntemlerinin, özellikle karmaşık veri yapılarını işleyebilme yeteneğiyle su tüketim tahminlerinde geleneksel istatistiksel yöntemlere kıyasla daha başarılı olduğunu göstermektedir. Al-Zahrani ve Abo-Monasar (2015), ANN ve zaman serisi modellerini birleştirerek su tüketim tahmininde önemli başarılar elde etmiştir. Bu çalışmada kullanılan ANN modeli, yüksek veri hacmine sahip şehrsel bölgeler için önerilmiş ve su tüketim tahminlerinde doğruluğu artırmada başarılı olduğu rapor edilmiştir. Almanjahie ve ark. (2019), Suudi Arabistan'daki hane halkı su tüketimini modellemek ve tahmin etmek için çeşitli yapay zeka tekniklerini kullanmışlardır. Araştırmacılar, ANN, Destek Vektör Makineleri (SVM) ve Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) gibi yöntemleri karşılaştırmış ve ANN modelinin en iyi performansı gösterdiğini tespit etmişlerdir. Bu çalışma, yapay zeka tekniklerinin su tüketimi tahmininde etkili bir araç olabileceğini ve su kaynaklarının yönetiminde önemli bir rol oynayabileceğini ortaya koymuştur.


Ghiassi ve ark. (2008), Dinamik Yapay Sinir Ağları (DAN2) kullanarak kentsel su talebini yüksek doğruluk oranlarıyla tahmin etmiştir. Boudhaouia ve Wira (2022), günlük su tüketimini tahmin etmek için SARIMA ve yapay sinir ağı modellerini birleştirmiştir. SARIMA ve ANN kombinasyonları, mevsimsel etkilerin tahmin doğruluğunu artırmadaki rolü ile dikkat çekmektedir. Çalışma, zaman serisi tahmininde bu modellerin kombinasyonunun etkinliğini göstermiştir. Bu tez çalışması da, su tüketimi tahmininde yapay zeka tekniklerinin (ANN, RF, SVM ve GBM gibi) doğruluğunu test etmekte ve Kocaeli ili örneğinde bu yöntemlerin uygulanabilirliğini araştırmaktadır.

Bakker ve ark. (2014), model değerlendirme ve analizinin önemini vurgulanmıştır. Bu konuda kapsamlı bir çalışma yaparak, su tüketimi tahminlerinin güvenilirliğini artırmanın gerekliliğini ortaya koymuşlardır. Bunun yanı sıra, model değerlendirme

sürecinde R^2 , RMSE gibi metriklerin kullanımının tahmin doğruluğunu artırmadaki önemi belirtilmiştir. Kısa vadeli su talebi tahmini için ileri düzey derin öğrenme yöntemleri tanıtılmıştır ve Guo ve ark. (2018), bu alanda geliştirdikleri yöntemlerle tahmin doğruluğunu önemli ölçüde artırmayı başarmışlardır.

Literatürde, yapay zeka tekniklerinin su tüketimi tahminindeki etkinliği üzerine birçok çalışma bulunmaktadır. Örneğin, ANN, karmaşık veri yapılarını işleme ve doğrusal olmayan ilişkileri öğrenme yeteneğiyle dikkat çekmektedir (Yeşilyurt ve ark., 2024). Benzer şekilde, RF gibi algoritmalar, özellikle değişken önem analizi ve yorumlanabilirlik açısından avantajlar sunmaktadır. Bu teknikler, su tüketimi tahmininde farklı avantajlar sağlayarak, geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları elde edilmesine olanak tanımaktadır.

Yapay zeka tekniklerinin temel çalışma prensipleri, genellikle verilerin işlenmesi ve analiz edilmesi üzerine kuruludur. Özellikle ANN, insan beyindeki sinir hücrelerinin işleyişini taklit eden bir yapıya sahiptir. Bu yapı, giriş katmanı, gizli katmanlar ve çıkış katmanından oluşur. Giriş katmanı, verilerin alındığı ve işlendiği kısımdır. Gizli katmanlar, verilerdeki karmaşık ilişkileri öğrenirken, çıkış katmanı ise tahmin edilen sonuçları üretir. ANN'nin genel mimarisi Şekil 2.1'de gösterilmiştir.



Şekil 2.1. ANN Modelinin Genel Mimarisi.

Model, giriş, gizli katmanlar ve çıkış katmanından oluşmaktadır. Giriş katmanında, su tüketimi üzerinde etkili olan sıcaklık, yağış, nem, abone türü gibi değişkenler bulunmaktadır. Bu girdiler, yapay sinir ağına beslenerek gizli katmanlarda işlenir ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonu sayesinde doğrusal olmayan ilişkiler öğrenilir. Bu sayede, karmaşık veri yapıları etkin bir şekilde modellenir ve ağın daha hızlı öğrenmesi sağlanır. Çalışma kapsamında ReLU'nun yanı sıra, Leaky ReLU, Sigmoid ve Tanh gibi diğer aktivasyon fonksiyonları da modellenmiş ve performansları karşılaştırılmıştır. ReLU, modelin doğruluğu ve hesaplama verimliliği açısından üstün performans gösterirken, negatif girdilerde nöronları tamamen devre dışı bırakabilmesi nedeniyle bazı durumlarda Leaky ReLU'nun tercih edilmesi gerekmiştir.

Eğitim sürecinde, geri yayılım (backpropagation) algoritması kullanılmıştır. Geri yayılım algoritması, modelin tahmin ettiği su tüketim değerleri ile gerçek değerler arasındaki hatayı hesaplar ve bu hataları minimize etmek için ağırlıkları günceller. Bu süreç, her eğitim adımında tekrar eder ve modelin tahmin doğruluğunu artırır. Özellikle, ANN modelinin ticari ve resmi aboneler için yüksek doğrulukta tahminler yaptığı, konut aboneleri içinse tahmin doğruluğunun nispeten daha düşük olduğu gözlemlenmiştir. Konut aboneleri içinse tahmin doğruluğunun nispeten daha düşük olduğu gözlemlenmiştir, konut aboneleri için ise eğitim sürecinin daha fazla parametre optimizasyonu gerektirdiği belirtilmiştir. Abu Talib ve ark. (2023) özellikle pandemi gibi hassas tahminlerin gerekli olduğu senaryolarda, topluluk modellerinin etkinliğini vurgulamıştır.

Ayrıca, modelin genel performansını artırmak ve aşırı öğrenmeyi önlemek amacıyla çapraz doğrulama (cross-validation) teknikleri uygulanmıştır. Hiperparametre optimizasyonu ise, modelin öğrenme oranı, katman sayısı ve nöron sayısı gibi parametrelerinin optimize edilmesini sağlamış ve modelin su tüketim tahminlerindeki doğruluğunu yükseltmiştir. Bunun yanı sıra, çapraz doğrulama sırasında veri setinin dengesizliği nedeniyle sonuçların etkilenebileceği ve sınıflandırma problemleri için bu dengesizliğin giderilmesinin önem arz ettiği belirtilmiştir. Özellik önem analizi ise, su tüketiminde en etkili faktörlerin belirlenmesine olanak tanımış, bu faktörler arasında sıcaklık, yağış miktarı ve abone türünün ön plana çıktığı tespit edilmiştir.

2.2. Türkiye’deki Su Yönetimi ve Kaynaklar

Türkiye, su kaynakları yönetimi açısından su stresi yaşayan ülkelerden biridir ve kişi başına düşen su miktarı dünya ortalamasının altındadır (WWF, 2024; Bilim ve Aydınlanma Akademisi, 2019). Ülkenin sınırlı su kaynakları, nüfus artışı, kentleşme ve sanayileşmenin birleşik etkisiyle daha fazla baskı altına girmektedir. Bu durum, su yönetimi stratejilerinin yalnızca mevcut kaynakları korumakla kalmayıp, gelecekteki ihtiyaçları da karşılayacak şekilde planlanmasını zorunlu kılmaktadır. Özellikle kentleşme, endüstriyel faaliyetler ve iklim değişiklikleri gibi faktörler, Türkiye'nin mevcut su kaynakları üzerindeki baskıyı arttırmaktadır. Kocaeli ili, Türkiye'nin önemli sanayi merkezlerinden biri olması nedeniyle su tüketimi açısından kritik bir bölgedir. Bu nedenle, su kaynaklarının sürdürülebilir yönetimi, ulusal kalkınma hedefleriyle uyumlu bir şekilde ele alınmalıdır.

Türkiye’de su kayıplarının %35 gibi yüksek oranlara ulaşması, su yönetiminde daha etkili politikaların geliştirilmesi gerektiğini ortaya koymaktadır (WWF, 2024; BUGÜN DÜNYA SU KAYIPLARI GÜNÜ,n.d.). Bu kayıpların büyük bir kısmı, eskiyen altyapılar, yetersiz bakım ve düşük teknoloji kullanımından kaynaklanmaktadır. Yeni teknolojiler ve modern su yönetim araçlarının benimsenmesi, bu kayıpların azaltılmasında kilit rol oynayabilir. Türkiye, su kaynakları yönetimi açısından su stresi yaşayan ülkelerden biridir ve kişi başına düşen su miktarı dünya ortalamasının altındadır; Dünya Sağlık Örgütü (WHO, n.d., 2020) ve Beuken ile ark. (2008) tarafından yapılan çalışmalar, Türkiye’nin su yönetimi zorluklarını anlamak ve uzun vadeli çözümler geliştirmek için önemli bir kaynak oluşturmaktadır.

2.3. Yapay Zeka Teknikleri ile Su Tüketimi Tahmini Çalışmaları

Literatürde, yapay zeka teknikleri su tüketimi tahmini konusunda yaygın olarak kullanılmaktadır. Bu çalışmalar, genellikle hava durumu, sosyo-ekonomik faktörler ve geçmiş su tüketimi verileri gibi değişkenlere dayanmaktadır. Su tüketimi tahmininin yalnızca teknik bir süreç olmadığı, aynı zamanda sosyal ve çevresel faktörlerle doğrudan ilişkili olduğu vurgulanmaktadır.

Örneğin, Willis ve ark. (2013) tarafından 151 hane üzerinde gerçekleştirilen bir araştırmada, sosyo-demografik faktörlerin su tüketimi üzerindeki etkileri incelenmiş ve gelir seviyeleri ile dış mekan su kullanımı arasında önemli korelasyonlar tespit

edilmiştir. House-Peters ve Chang (2011) ise, bireylerin su tüketim alışkanlıklarını ve bunun su yönetimi üzerindeki etkilerini analiz etmişlerdir.

Bununla birlikte, Brentan ve ark. (2018), yapay zeka tabanlı tahmin yöntemlerinin su yönetimindeki önemini vurgulamış ve su kayıplarını azaltma stratejilerinde yapay zeka modellerinin rolünü incelemiştir. Kozlowski ve ark. (2018), trend analizi ve harmonik analiz yöntemlerini kullanarak sıcaklık gibi çevresel faktörlerin su tüketimi tahminlerinde nasıl değerlendirilebileceğini göstermiştir.

2.3.1. Yapay zeka tekniklerinin su tüketimi tahmininde kullanımı

AI ve ML teknikleri, su tüketim tahminlerini daha doğru hale getirmek için geleneksel istatistiksel yöntemlere kıyasla daha başarılı sonuçlar vermektedir. Özellikle ANN, RF, SVM ve GBM gibi yöntemlerin tahmin performansı incelenmiştir.

- Al-Zahrani ve Abo-Monasar (2015), ANN ve zaman serisi modellerini birleştirerek su tüketim tahminlerinin doğruluğunu artırmıştır.
- Ghiassi ve ark. (2008), Dinamik Yapay Sinir Ağları (DAN2) kullanarak şehirselle su talebini yüksek doğrulukla tahmin etmiştir.
- Nguyen ve ark. (2018), ANN modellerinin geleneksel yöntemlere göre daha yüksek doğruluk sunduğunu göstererek Vietnam'daki su talebi tahminlerinde ANN'nin etkisini analiz etmiştir.

Bununla birlikte, Koo ve ark. (2021) tarafından yapılan çalışmada, Gelişmiş Ölçüm Altyapısı (Advanced Metering Infrastructure - AMI) sensörlerinden elde edilen su tüketimi verileri analiz edilerek kısa vadeli su talebi tahminleri yapılmıştır.

2.3.2. Derin öğrenme modelleri ve su tüketimi tahmini

ML yöntemlerinin ötesinde, DL algoritmaları, büyük ölçekli veri kümelerinin işlenmesi ve zamana bağlı su tüketim tahminlerinin geliştirilmesi açısından daha etkin çözümler sunmaktadır.

- Boudhaouia ve Wira (2022), günlük su tüketimini tahmin etmek için SARIMA ve ANN modellerini birleştirmiştir ve bu kombinasyonun mevsimsel değişkenlerin su tahminlerine entegrasyonunda başarılı olduğunu göstermiştir.
- LSTM ve GRU gibi Tekrarlayan Sinir Ağları (RNN) modelleri, zamana bağlı tüketim eğilimlerini daha iyi modelleyerek uzun vadeli tahminlerde ANN modellerine göre avantaj sağlamaktadır.

Bu tekniklerin su tüketimi tahmininde sağladığı avantajlar, aşağıdaki başlıca unsurlarla özetlenebilir:

- ANN ve DL modelleri, karmaşık veri yapılarındaki ilişkileri daha iyi öğrenme kapasitesine sahiptir.
- RF ve SVM gibi teknikler, değişken önem analizlerinde daha açıklanabilir ve yorumlanabilir sonuçlar sağlamaktadır.
- Özellikle derin öğrenme teknikleri, su tüketiminde uzun vadeli trendleri yakalamada önemli bir rol oynamaktadır.

2.3.3. Yapay zeka ile su yönetimi ve gelecekteki perspektifler

Yapay zeka teknikleri, yalnızca tahmin süreçlerini iyileştirmekle kalmaz, aynı zamanda su yönetimi stratejilerinin etkinliğini artırmada da önemli bir rol oynar.

- Mathew ve ark. (2020), su yönetimi politikalarının yapay zeka ile nasıl optimize edilebileceğini tartışmıştır.
- Su kayıplarının azaltılması, altyapı planlamalarının iyileştirilmesi ve dinamik su tahminlerinin geliştirilmesi, yapay zeka destekli modellerin sağladığı başlıca avantajlar arasındadır.

Sonuç olarak, yapay zeka ve makine öğrenimi tekniklerinin su tüketimi tahmini ve su yönetimi süreçlerine entegrasyonu, daha verimli, esnek ve sürdürülebilir bir su yönetimi stratejisi geliştirilmesine katkı sağlayacaktır.

2.4. Yapay Zeka ve Derin Öğrenme

2.4.1. Yapay zeka (AI)

Yapay zeka (AI), makinelerin insanlar gibi düşünmesini ve belirli görevleri yerine getirmesini sağlayan teknolojilerdir. AI'nin temel bileşenleri, veri işleme, öğrenme ve karar verme yeteneklerini içermektedir. AI, problem çözme, karar verme ve öğrenme gibi yetenekleri simüle eden yazılım sistemleri aracılığıyla geliştirilmiştir. Ayrıca, uzman sistemler ve genetik algoritmalar gibi AI dalları, özel problemlerin çözümünde yaygın olarak kullanılmaktadır. AI'nin alt dalları arasında makine öğrenimi (ML) ve derin öğrenme (DL) yer alır. AI, sağlık, finans, mühendislik ve mimarlık gibi birçok alanda yaygın olarak kullanılmaktadır.

2.4.2. Makine öğrenimi (ML)

Makine öğrenimi, verilerden öğrenerek tahmin yapma ve gelecekteki sonuçları öngörme yeteneği sağlayan algoritmalar. Eğitimli öğrenme (supervised learning) ve eğitimsiz öğrenme (unsupervised learning) gibi iki ana kategoriye ayrılır:

- **Eğitimli Öğrenme (Supervised Learning):** Etiketli veriler (giriş ve doğru sonuçlar) kullanılarak model eğitilir. Model, geçmiş verilerdeki örüntüleri öğrenir ve yeni verilerle gelecekteki sonuçları tahmin eder.
- **Eğitimsiz Öğrenme (Unsupervised Learning):** Etiketlenmemiş veriler üzerinde çalışır ve veriler arasındaki gizli yapıları öğrenir. Özellikle kümeleme ve boyut indirgeme gibi tekniklerde kullanılır.

2.4.3. Derin öğrenme (DL)

Derin öğrenme, veriler arasındaki karmaşık ilişkileri öğrenen ve bu sayede daha iyi tahminler yapabilen çok katmanlı ANN kullanan bir makine öğrenimi alt dalıdır. Derin öğrenme, büyük veri setleri ve yüksek hesaplama gücü gerektiren problemler için ideal bir yöntemdir. Görüntü tanıma, ses işleme ve doğal dil işleme gibi alanlarda başarılı bir şekilde uygulanmaktadır.

2.5. Yapay Sinir Ağları (ANN)

ANN, biyolojik sinir sistemlerinden esinlenerek geliştirilmiş matematiksel modellerdir. ANN'nin temel avantajları arasında, karmaşık veri yapılarını öğrenme kapasitesi ve çok boyutlu verilerle çalışabilme yeteneği yer alır. Ancak, yüksek veri ihtiyacı ve aşırı öğrenme riski gibi sınırlamaları da bulunmaktadır. ANN, giriş katmanı, gizli katmanlar ve çıkış katmanından oluşur. Bu katmanlar, birbirine bağlı nöronlar aracılığıyla verileri işler ve nihai sonuçlar üretir.

2.5.1. Girişler ve çıkışlar

ANN, veri setindeki özellikleri giriş katmanında alır, gizli katmanlarda işler ve çıkış katmanında nihai tahminleri üretir. Giriş katmanında, su tüketimi üzerinde etkili olan sıcaklık, yağış, nem, abone türü gibi çeşitli parametreler bulunur. Çıkış katmanında ise, tahmin edilen aylık su tüketimi miktarı yer alır. Bu katmanların doğru yapılandırılması, modelin performansı üzerinde kritik bir rol oynar. Gizli katmanlarda kullanılan aktivasyon fonksiyonları ve katman sayısının dikkatli bir şekilde optimize edilmesi, modelin doğruluğu ve işlem süresi üzerinde belirleyici bir etkiye sahiptir.


- **Giriş Katmanı:** Modelin çalışması için gerekli olan verileri alır ve gizli katmanlara aktarır.
- **Çıkış Katmanı:** Modelin tahmin sonuçlarını üretir. Örneğin, su tüketimi tahmininde çıkış katmanı, tahmin edilen aylık su tüketimi miktarını verir.

2.5.2. Gizli katmanlar ve aktivasyon fonksiyonları

Gizli katmanlar, sinir ağlarının öğrenme yeteneğini artıran kritik katmanlardır. Her gizli katmanda aktivasyon fonksiyonları kullanılarak veriler işlenir. Aktivasyon fonksiyonları, verilerin doğrusal olmayan ilişkilerini öğrenmeye olanak tanır. Aktivasyonun kaynak kodları için (Bkz. EK B).

- **Sigmoid Fonksiyonu:** Şekil 2.2’de görüldüğü gibi, çıktıları 0 ile 1 arasında sınırlar. Sigmoid fonksiyonu, sınıflandırma problemlerinde yaygın olarak kullanılır. Ancak 2.1 formülde belirtildiği üzere, büyük veri setlerinde vanishing gradient (kaybolan gradyan) problemi nedeniyle tercih edilmeyebilir.


$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$



Şekil 2.2. Sigmoid Fonksiyonu.

- **Tanh (Hiperbolik Tanjant) Fonksiyonu:** Sigmoid fonksiyonuna benzer, ancak çıktı değerlerini şekil 2.3’de ve 2.2 nolu formülde görüldüğü gibi, -1 ile 1 arasında sınırlar. Tanh fonksiyonu, negatif girdiler için negatif çıkışlar üretir, bu da bazı durumlarda daha iyi sonuçlar verir.


$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$



Şekil 2.3. Tanh (Hiperbolik Tanjant) Fonksiyonu.

- **ReLU (Rektifiye Edilmiş Doğrusal Birim):** En yaygın kullanılan aktivasyon fonksiyonlarından biridir. Şekil 2.4 de görüldüğü gibi, girdi negatifse çıkışı 0 yapar, pozitifse aynı değeri geçirir. ReLU, özellikle derin öğrenme modellerinde sıkça kullanılır ve kaybolan gradyan problemini büyük ölçüde azaltır. 2.3 nolu formülde tanımlandığı gibi, bazı durumlarda ölü nöron problemi (dead neurons) yaşanabilir.

$$f(x) = \max(0, x) \quad (2.3)$$




Şekil 2.4. ReLU (Rektifiye Edilmiş Doğrusal Birim) Fonksiyonu.

- **Leaky ReLU:** ReLU'nun geliştirilmiş versiyonudur. ReLU, negatif girdileri sıfırlarken, Şekil 2.5 ve 2.4 nolu formülde görüldüğü gibi, Leaky ReLU negatif

girdilere küçük bir eğim (genelde 0.01) uygular, bu da ölü nöron problemini azaltmaya yardımcı olur.


$$f(x) = \max(0.01x, x) \quad (2.4)$$



Şekil 2.5. Leaky ReLU Fonksiyonu.

- **ELU (Üstel Doğrusal Birim):** Şekil 2.6 da gösterilen ELU, ReLU'ya benzer, ancak negatif değerler için daha düzgün bir eğim sağlar. Bu sayede ağırlıkların sıfır etrafında daha iyi dengeye gelmesine yardımcı olur. 2.5 nolu formülde görüldüğü üzere, ELU, ReLU'nun bazı eksikliklerini giderir.

$$f(x) = x \text{ if } x > 0; \alpha(e^x - 1) \text{ if } x \leq 0 \quad (2.5)$$




Şekil 2.6. ELU (Üstel Doğrusal Birim) Fonksiyonu.

- **Swish:** Şekil 2.7 de görülen ve google tarafından önerilen bir aktivasyon fonksiyonudur. Swish, sigmoid ve giriş değerinin çarpımından oluşur ve belirli

görevlerde ReLU'dan daha iyi performans gösterebilir. 2.6 nolu formüldende anlaşılacağı gibi, yumuşak geçişler sağlar ve negatif değerlerde küçük pozitif sonuçlar verir.


$$f(x) = x \cdot \frac{1}{1 + e^{-x}} \quad (2.6)$$



Şekil 2.7. Swish Fonksiyonu.

- **Softmax Fonksiyonu:** Şekil 2.8 ve 2.7 nolu formülde görüldüğü gibi, özellikle çok sınıflı sınıflandırma problemlerinde kullanılır. Softmax, her sınıf için olasılıkları hesaplar ve tüm sınıfların toplamı 1 olacak şekilde normalize eder.

$$f(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (2.7)$$



Şekil 2.8. Softmax Fonksiyonu.

2.5.3. İleri besleme ve geri yayılım

ANN, iki temel işlem ile öğrenir:

- **İleri Besleme (Feedforward):** Veriler, giriş katmanından gizli katmanlara doğru ilerleyerek işlenir ve çıkış katmanında sonuçlar üretilir.
- **Geri Yayılım (Backpropagation):** Modelin tahminleri ile gerçek sonuçlar arasındaki hatalar geriye doğru iletilir. Bu süreç, ileri besleme sırasında yapılan tahmin hatalarını düzeltmek için kullanılır. Sinir ağlarının ağırlıkları bu hatalar temel alınarak güncellenir ve modelin doğruluğu artırılır.

Bu çalışmada, ANN'nin geri yayılım algoritmasıyla eğitimi sırasında Levenberg-Marquardt optimizasyon algoritması kullanılmıştır. Levenberg-Marquardt algoritması, hem gradyan inişi hem de Newton yöntemlerini birleştirerek hızlı bir optimizasyon sağlar. Ancak, büyük veri setlerinde hafıza kullanımı açısından sınırlamaları bulunmaktadır ve bu durum daha karmaşık problemler için alternatif yöntemlerin araştırılmasını gerektirebilir. Bu algoritma sayesinde, modelin eğitim süreci hızlanmakta ve yüksek doğrulukta tahmin sonuçları elde edilmektedir.

2.5.4. Hiperparametreler ve optimizasyon

ANN çeşitli hiperparametreler ile yönetilir. Bu parametreler, modelin eğitim sürecini ve performansını doğrudan etkiler.

- **Hiperparametreler:** Sinir ağı yapılandırması, katman sayısı, nöron sayısı ve öğrenme hızı gibi faktörlerden oluşur. Bu parametrelerin doğru ayarlanması model performansı için kritiktir. Hiperparametre optimizasyonu sürecinde, lambda değeri, iterasyon sayısı, öğrenme hızı gibi parametrelerin en uygun değerleri bulunurken Grid Search yöntemi kullanılmıştır. Grid Search, tüm olası parametre kombinasyonlarını sistematik olarak denediği için kapsamlı bir yöntemdir; ancak, yüksek hesaplama maliyeti nedeniyle büyük veri setlerinde alternatif yöntemler (ör. Random Search veya Bayes Optimizasyonu) tercih edilebilir.
- **Optimizasyon Algoritmaları:** Yapay sinir ağlarının eğitimi sırasında ağırlıkların güncellenmesi için optimizasyon algoritmaları kullanılır. Levenberg-Marquardt gibi algoritmalar, geri yayılım sürecini hızlandırarak modelin daha hızlı öğrenmesini sağlar. Ayrıca, Adam ve RMSProp gibi

optimizasyon yöntemleri de yaygın olarak kullanılmaktadır. Bu algoritmalar, dinamik öğrenme hızı ayarlamasıyla daha verimli eğitim süreçleri sunar.

2.6. Derin Öğrenme Modellerinde Performans Artışı

Derin öğrenme modellerinde performansı artırmak için çeşitli stratejiler kullanılabilir:

- **Veri Çoğaltma (Data Augmentation):** Veri setini artırmak için uygulanan bir tekniktir. Eğitim verileri üzerinde yapılan çeşitli dönüşümler (döndürme, yakınlaştırma, parlaklık ayarları vb.) veri setinin çeşitliliğini artırarak modelin daha iyi genelleme yapmasını sağlar.
- **Dropout:** Aşırı öğrenmeyi (overfitting) önlemek amacıyla, her eğitim iterasyonunda rastgele nöronlar devre dışı bırakılır. Bu yöntem, modelin aşırı uyumunu önleyerek genelleme kapasitesini artırır.
- **Hiperparametre Optimizasyonu:** Modelin en iyi performansı göstermesi için hiperparametre optimizasyonu yapılır. **Grid Search** ve **Random Search** gibi yöntemler, hiperparametrelerin optimal değerlerini bulmak için kullanılır.

2.7. COVID-19'un su Tüketimi Üzerindeki Etkileri

COVID-19 pandemisi, dünya genelinde su tüketim alışkanlıklarını önemli ölçüde değiştirmiştir. Pandemi nedeniyle uygulanan sokağa çıkma kısıtlamaları ve hijyen önlemleri, hem evsel hem de endüstriyel su tüketiminde kayda değer değişikliklere neden olmuştur (Bakchan ve ark., 2022). Türkiye’de ise pandemi sürecinde, özellikle evde kalma sürelerinin artması ve hijyen önlemlerinin yoğunlaşması, su tüketiminde belirgin artışlara neden olmuştur. Bu tez çalışmasında, Kocaeli ilinde COVID-19 pandemisi sırasında ve sonrasındaki su tüketimi verileri incelenmiş, bu olağanüstü durumun su tüketim tahmin modellerine nasıl entegre edilebileceği araştırılmıştır. Kalbusch ve ark. (2020), Brezilya’da COVID-19'un su tüketimine etkisini analiz etmiş ve endüstriyel su tüketiminde %53'e varan düşüşler gözlemlenmiştir. Benzer şekilde, Türkiye’de de pandeminin etkileri, su tüketim modellerinde kayda değer değişikliklere yol açmıştır.

Yapay zeka tabanlı modellerin bu değişiklikleri yakalayabilme kapasitesi, gelecekteki su yönetimi kararlarına rehberlik edebilecek stratejik bir araç sunmaktadır. Özellikle pandeminin neden olduğu tüketim değişimlerinin modellenmesinde, veri temizleme

ve dönüştürme adımları kritik bir rol oynamıştır. Bu tez, yapay zeka modellerinin COVID-19'un su tüketimi üzerindeki etkilerini nasıl yansıtabileceğini incelemekte ve pandemiye karşı daha esnek su tahmin modelleri geliştirilmesine yönelik bir adım atmaktadır.

2.8. Su Yönetimi ve Gelecek Perspektifler

Su yönetimi, artan nüfus, şehirleşme ve iklim değişiklikleri nedeniyle giderek daha önemli hale gelmektedir. Literatürdeki araştırmalar, su tüketimi tahmininde yapay zeka tekniklerinin geleneksel yöntemlere kıyasla daha başarılı olduğunu göstermektedir. Yapay zeka teknikleri, su yönetimi kararlarını destekleyerek, su kaynaklarının sürdürülebilir kullanımına yönelik çözüm önerileri sunmaktadır (Nguyen vd., 2018). Baker ve ark. (2020), COVID-19'un hane halkı harcama davranışları üzerindeki etkilerini incelemiş ve pandemi dönemindeki davranış değişimlerinin su tüketimi alışkanlıklarını da dolaylı olarak etkileyebileceğini öne sürmüştür. Türkiye'de su yönetiminin iyileştirilmesi, yalnızca mevcut kaynakların korunması için değil, aynı zamanda gelecekteki su talebine yanıt verebilmek için de kritik öneme sahiptir.

Aurora, Colorado'da gerçekleştirilen bir çalışma, fiyatlandırma ve dış mekan su kısıtlama politikalarının etkileşiminin, toplam su tasarrufu üzerindeki etkisini incelemiştir. Bu çalışmada, bu politikaların birlikte uygulanmasının, her bir programın bağımsız olarak uygulanmasından daha fazla tasarruf sağlamadığı tespit edilmiştir (Kenney ve ark., 2008). Su yönetiminde ileri düzey teknikler, hedefli kampanyalar için müşteri kümelenmesi gibi yöntemleri içermektedir (Malinowski ve Povinelli, 2022). Ayrıca, Brezilya'da pandemi süresince konut su tüketim desenlerinin analiz edildiği çalışmalar da bulunmaktadır (Cominato ve ark., 2022).

2.9. Farklı Yapay Zeka Modelleri ve Optimizasyon Teknikleri

Su tüketimi tahmininde farklı yapay zeka teknikleri kullanılmaktadır. SVM, RF, LSTM ve GRU gibi yöntemler ile Levenberg-Marquadt ve PSO gibi optimizasyon algoritmaları, literatürde başarıyla uygulanmıştır.

2.9.1. Makine öğrenimi ve derin öğrenme modelleri

- **SVM:** SVM, verileri sınıflandırmak ve regresyon problemlerinde kullanılır. Su tüketimi tahmininde, SVM, doğru sınırlayıcılar belirleyerek tahmin hatalarını

minimize etmede etkili olabilir. Non-lineer verilerde bile iyi performans göstermesiyle öne çıkar (Hassan ve ark., 2023).

- **RF:** Karar ağaçlarının birleştirilmesiyle çalışan RF, özellikle büyük veri setlerinde yüksek doğruluk sunar. Hassan ve ark. (2023), RF modelinin su tüketimini etkileyen faktörleri belirlemede önemli bir araç olduğunu vurgulamaktadır.
- **LSTM ve GRU:** Zaman serisi verilerinde uzun vadeli bağımlılıkları öğrenme yeteneğine sahip bu modeller, ANN ve RF gibi yöntemlere kıyasla daha başarılı tahmin sonuçları sunabilir. Mahjoub ve ark. (2022), su tüketim tahmininde LSTM'nin geleneksel modellere göre üstün olduğunu belirtmektedir.
- **GBM:** Ardışık modellerin hatalarını düzelterek güçlü tahmin modelleri oluşturmak amacıyla kullanılan bir makine öğrenimi tekniğidir. Bu yöntem, zayıf tahminciler (genellikle karar ağaçları) kullanarak iteratif olarak model doğruluğunu artırır. GBM, su tüketim tahmininde ve diğer regresyon problemlerinde yüksek performans göstermesiyle bilinir. Ayrıca, karmaşık veri setlerinde etkileşimleri ve doğrusal olmayan ilişkileri iyi yakalayabilir (Sarigöl ve Katipoğlu, 2023).

2.9.2. Optimizasyon algoritmaları

- **Parçacık Sürü Optimizasyonu (PSO):** Yapay sinir ağlarının hiperparametrelerini optimize etmek ve modelin doğruluğunu artırmak için kullanılan sezgisel bir algoritmadır. Chang ve ark. (2013), PSO'nun su tüketimi tahminlerinde parametre ayarlamalarını iyileştirerek tahmin doğruluğunu artırdığını göstermiştir.
- **Levenberg-Marquardt Algoritması:** ANN modelinin eğitim sürecini hızlandıran bu yöntem, doğrusal olmayan regresyon problemlerinde başarılıdır. Piotrowski ve Napiorkowski (2011), Adeloje ve Munari (2006), ile Moura ve ark. (2018), bu algoritmanın su tüketimi tahminlerinde ANN'nin doğruluk oranını artırdığını belirtmişlerdir.

2.9.3. Parçacık sürü optimizasyonu (PSO) ve yapay zeka modellerine etkisi

PSO, doğadan ilham alan sezgisel bir optimizasyon algoritmasıdır. Kennedy ve Eberhart (1995) tarafından geliştirilen bu yöntem, kuş ve balık sürülerinin kolektif hareketlerinden esinlenerek tasarlanmıştır.

PSO'nun Çalışma Prensipleri:

- Algoritma, "parçacık" adı verilen çözüm adaylarından oluşan bir sürü kullanır.
- Her parçacık, çözüm uzayında en iyi pozisyonunu (personal best) ve sürünün en iyi pozisyonunu (global best) kullanarak hareket eder.
- Newton'un hareket yasalarına benzer şekilde, hız ve konum güncellemeleri yapılır.
- Hedef, optimal çözüme mümkün olan en hızlı ve verimli şekilde ulaşmaktır.


Şekil 2.9'da görüldüğü gibi, PSO algoritması her bir parçacığın en iyi çözümü bulmasını sağlamak için iteratif bir süreç izler. Her parçacık, sürünün genel en iyi konumuna ve kendi en iyi deneyimine göre yönlendirilerek çözüm uzayında optimal bir noktaya ulaşmaya çalışır.

PSO'nun Su Tüketimi Tahmininde Kullanımı:

PSO, yapay zeka modellerinin hiperparametre optimizasyonunda yaygın olarak kullanılmaktadır. Chang ve ark. (2013) ile Noory ve ark. (2012), PSO algoritmasının ANN'nin doğruluğunu artırmada etkili olduğunu göstermiştir.

Algoritma, her bir parçacığın bireysel en iyi konumuna (personal best) ve sürünün genel en iyi konumuna (global best) doğru hareket ederek optimum çözüme ulaşmasını sağlar. Bu süreç, doğadan ilham alan sezgisel bir yaklaşımdır.

PSO, kuş ve balık sürülerinin kolektif davranışlarını taklit eden, doğadan ilham alan bir sezgisel algoritmadır. Sürü zekası (swarm intelligence) tabanlı bu yöntem, çözüm uzayında çok sayıda çözüm adayını (parçacıkları) değerlendirilerek en uygun olanı bulmaya odaklanır.



Şekil 2.9. Parçacık Sürü Optimizasyonu.

2.10. İSU Genel Müdürlüğü: Tarihçe ve Yapı

İzmit Su ve Kanalizasyon İdaresi (İSU) Genel Müdürlüğü, 1995 yılında 2560 sayılı Kanun'un Geçici 10. Maddesi'ne dayanarak Kocaeli Büyükşehir Belediyesi'ne bağlı bir kamu tüzel kişiliği olarak kurulmuştur. İlk etapta İzmit merkezde faaliyet gösteren İSU, 2004 yılında Büyükşehir Belediyesi Kanunu'nun yürürlüğe girmesiyle birlikte Kocaeli il sınırlarının tamamında hizmet vermeye başlamıştır. Bu genişleme, Kocaeli'nin tüm ilçelerinde su ve kanalizasyon hizmetlerinin tek bir kurum tarafından koordine edilmesini sağlamıştır.

İSU'nun misyonu, yaşam kaynağı suyu en yüksek standartlarda temin ederek insana ve doğaya saygılı bir şekilde yönetmek, gelecek nesillere güvenle aktarılmasını sağlamaktır. Vizyonu ise etkin, sürdürülebilir ve örnek bir yönetim anlayışıyla su kaynaklarının korunması ve etkin kullanımında öncü bir kurum olmaktır.

Kurum, 2560 sayılı Kanun'un yetkilendirdiği çerçevede:

- Su temini ve dağıtımı,
- Atık su toplanması, arıtılması ve geri kazanımı,
- Su kaynaklarının korunması ve sürdürülebilir şekilde yönetimi gibi sorumlulukları yerine getirmektedir.

2023 itibarıyla İSU, 13 içme suyu arıtma tesisi, 23 atık su arıtma tesisi, 678 içme suyu deposu ve 66 atık su terfi merkezi gibi güçlü bir altyapıya sahiptir. Ayrıca, SCADA sistemleriyle 7/24 izleme ve yönetim imkanı sağlayarak hizmetlerini modern teknolojilerle sürdürmektedir. Kurum, yaklaşık 1.870 personeli ile faaliyet göstermektedir. Kurumun 1995 yılında kurulmuş olması ve kapsamının 2004 yılında genişlemesi gibi bilgiler, İSU'nun resmi internet sitesinde belirtilmektedir (İSU Genel Müdürlüğü, t.y.).




3. MATERYAL VE YÖNTEM

Bu bölümde, araştırma kapsamında kullanılan veri setleri, uygulanan yapay zeka teknikleri, model eğitimi ve performans değerlendirme süreçleri detaylandırılacaktır. Tezde sunulan yöntemler, su tüketim tahmini için yapay zeka modellerinin (ANN, LSTM, GRU gibi) nasıl kullanıldığını açıklamakta ve veri analizinin hangi adımlar üzerinden gerçekleştirildiğini ortaya koymaktadır.

3.1. Çalışma Alanı: Kocaeli

Su tüketimi tahmin modellerinin uygulanacağı bölge olarak Kocaeli ili seçilmiştir. Bu seçimin gerekçesi, veri zenginliği ve bölgenin su tüketim dinamiklerinin çeşitliliği ile ilişkilidir. Çalışma alanına dair detaylar aşağıda sunulmuştur.

Şekil 3.1. Kocaeli ilinin coğrafi konumunu ve sınırlarını göstermektedir. Kocaeli ili, Marmara Bölgesi'nin doğusunda yer almakta olup, Türkiye'nin önemli sanayi ve ticaret merkezlerinden biridir. 2.3 milyonluk nüfusu ve İstanbul'a olan yakınlığı ile önemli bir yerleşim ve sanayi bölgesidir. Kocaeli ili, farklı abone türleri (konut, ticari, resmi) ve meteorolojik koşullarıyla su tüketim dinamiklerinde çeşitlilik göstermektedir.



Şekil 3.1. Kocaeli'nin haritadaki yeri.

Çalışmada Kocaeli'nin seçilmesinin ana nedenlerinden biri, bu çeşitlilikle birlikte su tüketim tahminlerinin geniş bir veri kümesiyle daha doğru yapılabileceği varsayımdır. Kocaeli'deki su kaynakları (Gebze Gölü, Sakarya Nehri) ve şehrin coğrafi yapısı, su tüketim tahmin modellerine entegre edilecek verilerin zenginliği açısından çalışmanın temelini oluşturmaktadır.

3.2. Veri Seti

Çalışmada kullanılan veri seti, Ocak 2016 ile Ağustos 2022 tarihleri arasında Kocaeli'ndeki abonelerin 80 aylık su tüketim verilerini, meteorolojik verileri, pandemi dönemi olup olmadığını, hafta sonu ve tatil günlerini içermektedir. Bu veriler, su tüketim tahmin modellerinde kullanılmak üzere hazırlanmıştır.

3.2.1. Su tüketim verileri ve abone türleri

Veriler, belirtilen dönemdeki aylık su tüketim miktarlarını içermektedir. Toplamda, söz konusu tarihler arasında adresi değişmemiş 5.000 abone (konut: 3447, ticari: 1422, resmi: 131) analiz edilmiş olup, Kocaeli genelindeki 800.000 aboneyi temsil eden daha geniş bir veri kümesinden seçilmiştir (ISU Genel Müdürlüğü, n.d.). Veri seti, su tüketim tahmin modellerinde kullanılmak üzere işlenmiştir.

Veri Seti Detayları:

Bu çalışma kapsamında kullanılan veri seti, aşağıdaki bilgileri içermektedir:

- **Abone Türü:** Konut, ticari ve resmi aboneler.
- **Faaliyet Türü:** İşletmelerin faaliyet alanları (berber, fırın, lokanta vb.).
- **Tarife Türü:** Mesken, Engelli%50, sağlık ocağı gibi abone tarifeleri.
- **Meteorolojik Veriler:** Sıcaklık, yağış, nem, rüzgar hızı gibi çevresel değişkenler.
- **Sayaç Çapı:** Sayaçların giriş çıkış çapları (DN15, DN20, vs.).
- **Tatiller:** Hafta sonu, resmi tatil ve dini tatil günlerinin toplamı.
- **Sosyo-ekonomik Durum:** COVID-19 pandemisi gibi ulusal/uluslararası sağlık krizleri ve ilgili etkiler.

Abone türlerine göre faaliyet ve tarife tür sayıları değişmektedir. Örneğin faaliyet türlerin sayısı, resmi abonelerde 21, konutta 8 ve ticari yerlerde ise 101 adettir.

Yukarıda açıklanan değişkenler, su tüketimi tahmin modellerinin doğruluğunu artırmak amacıyla analiz edilmiş ve modele entegre edilmiştir.

Tablo 3.1’de, aylık veri setinde kullanılan tüm değişkenler, türleri ve alt sınıf sayıları ile birlikte özetlenmiştir. Bu değişkenler, 2016–2022 yılları arasında Kocaeli ilindeki 5000 aboneden (konut, ticari, resmi) elde edilen su tüketim verilerinden türetilmiş ve modelleme sürecinde girdi olarak kullanılmıştır. Pandemi değişkeni, Mart 2020 ile Aralık 2021 arasını “pandemi süreci”, öncesini ve sonrasını ise ayrı dönemler olarak temsil edecek biçimde üç sınıfa ayrılmıştır.

Tablo 3.1. Aylık Veri Setinde Kullanılan Girdiler (Değişkenler).

Değişken Adı	Açıklama	Türü	Alt Sınıf / Örnek
Abone Türü	Abonenin türünü belirtir (konut, ticari, resmi)	Kategorik	3 Konut: 8
Faaliyet Türü	Ticari/resmi abonelerin iş/fonksiyon kategorisi	Kategorik	Ticari: 101 Resmi: 21
Tarife Türü	Tarifeye göre sınıflama (mesken, sağlık ocağı, vb.)	Kategorik	15+
Sayaç Çapı	Abonenin kullandığı sayaç tipi (DN15, DN20, vs.)	Kategorik	5+
Tüketim (m ³)	Aylık toplam su tüketimi	Sürekli	-
Ay	Verinin ait olduğu ay bilgisi	Zaman	1–12
Yıl	Verinin ait olduğu yıl bilgisi	Zaman	2016–2022
Sıcaklık (min/max/ort)	Aylık ortalama sıcaklık değerleri	Sürekli	°C biriminde
Yağış	Aylık toplam yağış miktarı	Sürekli	mm biriminde
Nem (min/max)	Aylık ortalama nem değerleri	Sürekli	% biriminde
Güneşlenme	Aylık toplam güneşlenme süresi	Sürekli	Saat
Rüzgar	Aylık ortalama rüzgar hızı	Sürekli	km/s
Tatil Günü Sayısı	O ay içerisindeki toplam hafta sonu ve resmi tatil günleri	Sayısal	8+
Pandemi Dönemi	Pandemi etkisini belirten sınıf	Kategorik	0 = Öncesi 1 = Süreci 2 = Sonrası

Abone Türleri: Veri seti üç ana abone kategorisinden oluşmaktadır:

- **Konut Aboneleri:** Evlerde kullanılan su miktarını temsil eder. Genellikle mevsimsel değişiklikler, günlük yaşam alışkanlıkları, hava koşulları ve sosyal etkinliklere bağlı olarak değişiklik gösterir.
- **Ticari Aboneler:** İşletmeler ve ticari faaliyetlerde kullanılan suyu kapsar. Ticari su tüketimi iş yoğunluğu ve ekonomik aktivitelerle ilişkilidir.

- **Resmi Aboneler:** Kamu binaları ve devlet dairelerinde kullanılan suyu içerir. Resmi su tüketimi genellikle çalışma saatlerine ve mevsimsel değişikliklere bağlıdır.

Bu çalışmada, su tüketimini etkileyen faktörlerin farklı dönemler ve abone türleri üzerindeki etkisini incelemek amacıyla, veri seti aşağıdaki farklı senaryolarla analiz edilmiştir:

- **Tam Veri Seti:** Ocak 2016 ile Ağustos 2022 tarihleri arasındaki tüm veriler, modelin genel performansını değerlendirmek için kullanılmıştır.
- **Pandemi Öncesi Dönem:** Mart 2020 öncesindeki veriler, pandemi etkisinin bulunmadığı "normal" dönemi analiz etmek için kullanılmıştır.
- **Pandemi Süreci:** Mart 2020 ile Aralık 2021 arasındaki pandemi dönemi verileri, pandemi sırasında su tüketiminde meydana gelen değişiklikleri analiz etmek için kullanılmıştır. Bu dönemde özellikle hijyen önlemleri ve evde kalma süresinin artışının etkileri değerlendirilmiştir.
- **Pandemi Sonrası Dönem:** Ocak 2022 sonrası veriler, pandemi etkilerinin azalmasıyla tüketim dinamiklerinin nasıl değiştiğini incelemek için kullanılmıştır.
- **Pandemi Öncesi ve Sonrası Karşılaştırması:** Pandemi öncesi ve sonrası veriler bir arada kullanılarak, bu iki dönemin tüketim dinamikleri karşılaştırılmıştır.
- **Abone Türlerine Göre Ayrı Analiz:** Veri seti, konut, ticari ve resmi abone türleri olmak üzere üç ana kategoriye ayrılmıştır. Her bir abone türü, su tüketimi üzerindeki farklı etkilerin analiz edilmesi için hem bireysel olarak hem de birlikte analiz edilmiştir.


Bu kategorilere ayrılan veri setleriyle, her bir senaryonun modelleme sürecine etkisi detaylı bir şekilde incelenmiş ve tahmin performansı karşılaştırılmıştır. Örneğin, pandemi sürecinde konut abonelerinin su tüketiminde artış gözlemlenirken, ticari ve resmi abonelerde önemli ölçüde azalma kaydedilmiştir. Bu ayrımlar, modelin her bir abone türü ve dönem için özelleştirilmiş tahminler yapabilmesini sağlamıştır.

3.2.2. Meteorolojik ve sosyo-ekonomik veriler

Su tüketimini etkileyen en önemli dışsal faktörlerden biri meteorolojik değişkenlerdir. Bu çalışmada, Türkiye Meteoroloji Genel Müdürlüğü'nden alınan günlük sıcaklık,

nem, yağış, güneşlenme süresi ve rüzgar hızı gibi meteorolojik veriler kullanılmıştır. Meteorolojik değişkenler, su talebinin mevsimsel olarak nasıl değiştiğini analiz etmeye yardımcı olmuştur (Yılmaz, 2022).

Şekil 3.2, veri setindeki sayısal meteorolojik değişkenler arasındaki korelasyonları göstermektedir.



Şekil 3.2. Aylık Veriler Korelasyon Isı Tablosu.

Korelasyon analizi, değişkenler arasındaki ilişkileri değerlendirerek modelleme sürecinde hangi değişkenlerin daha anlamlı olduğuna karar verilmesini sağlamıştır. Bu analiz sonucunda:

- **Yüksek Korelasyon:** Maksimum, minimum ve ortalama sıcaklık değişkenleri arasında yüksek bir korelasyon gözlemlenmiştir. Bu durumda, yalnızca maksimum sıcaklık değişkeni modele dahil edilmiş, diğerleri çıkarılmıştır. Benzer şekilde, düşük ve yüksek nem değişkenleri arasında da orta-yüksek bir korelasyon olduğu tespit edilmiştir. Her iki nem değişkeninin de tüketimle düşük korelasyona sahip olması nedeniyle, modelden çıkarılması uygun bulunmuştur.

- **Düşük Korelasyon:** Tüketim ile çok düşük korelasyona sahip diğer değişkenler (örneğin, rüzgar hızı) modelin performansına anlamlı bir katkı sağlamadığı için çıkarılmıştır.

Bu yaklaşım ile modele yalnızca anlamlı ve etkili değişkenler dahil edilerek, tahmin doğruluğunun artırılması ve gereksiz karmaşıklığın önlenmesi hedeflenmiştir.

Kocaeli ilinde, 20 farklı noktada bulunan baz istasyonlarından günlük olarak meteorolojik veriler toplanmaktadır. Bu veriler arasında maksimum sıcaklık, minimum sıcaklık, ortalama sıcaklık, nem, yağış miktarı ve güneşlenme süresi gibi parametreler bulunmaktadır. Bu çalışmada, bu kapsamlı veri setinden yararlanılmış olup, her bir parametrenin su tüketimi üzerindeki etkisi ayrı ayrı incelenmiştir.

2016 yılına ait günlük maksimum sıcaklık değerleri Tablo 3.2'de sunulmaktadır. Sıcaklık verileri, su tüketimi tahmin modellerinde meteorolojik faktörlerin etkilerini analiz etmek için kullanılmıştır. Bu veriler, yılın farklı dönemlerindeki sıcaklık değişimlerini net bir şekilde göstermekte olup, özellikle yaz aylarında (Haziran-Ağustos) sıcaklıkların belirgin şekilde yükseldiği gözlemlenmektedir. Bu sıcaklık artışları, su tüketiminde de paralel bir artışa işaret etmektedir.

Pandemi dönemi, tatil günleri ve hafta sonları gibi sosyo-ekonomik değişkenler de modele entegre edilmiştir. Pandemi sırasında su tüketiminde belirgin değişiklikler gözlenmiştir. Tatil günleri ve hafta sonlarında özellikle konut abonelerinde su tüketimi artarken, ticari abonelerde bu dönemlerde düşüş yaşanmıştır.

Tablo 3.3'de gösterilen hafta sonu ve tatil günleri verileri, su tüketim modellemesinde önemli bir rol oynamaktadır. Örneğin, 2016 yılının Mayıs ayında, 9 hafta sonu günü ve 2 resmi tatil günü bulunmaktadır. Bu bilgi, özellikle konut abonelerinin su tüketim desenlerini analiz ederken kritik öneme sahiptir. Çünkü tatil günlerinde evde geçirilen zamanın artması, su tüketimini doğrudan etkilemektedir.

Ayrıca, bu meteorolojik ve sosyo-ekonomik verilerin birlikte analiz edilmesi, su tüketim desenlerindeki karmaşık ilişkileri ortaya çıkarmada yardımcı olmaktadır. Örneğin, yaz aylarındaki yüksek sıcaklıkların hafta sonu günleriyle çakışması durumunda, su tüketiminde daha belirgin artışlar gözlemlenebilmektedir.

Bu kapsamlı veri seti, yapay zeka modellerinin eğitilmesinde ve su tüketim tahminlerinin doğruluğunun artırılması kritik bir rol oynamaktadır. Özellikle, farklı

abone türleri (konut, ticari, resmi) için ayrı ayrı analizler yapılarak, her bir grubun kendine özgü tüketim desenlerinin belirlenmesi mümkün olmaktadır.

Tablo 3.2. 2016 yılına ait günlük maksimum sıcaklık değerlerini göstermektedir.

Gün/Ay	1	2	3	4	5	6	7	8	9	10	11	12
1	1.7	16.1	25.0	22.5	19.7	28.6	30.5	35.2	27.7	28.9	11.3	3.7
2	2.7	16.2	19.4	18.0	20.6	31.3	30.9	31.5	27.4	26.1	14.0	11.5
3	0.6	21.0	12.1	18.2	18.6	29.5	28.4	30.5	27.0	26.7	18.6	11.5
4	9.4	19.1	17.6	19.9	18.1	26.0	30.6	31.3	28.0	25.5	13.2	9.6
5	10.4	15.2	13.2	22.9	16.5	27.0	28.3	32.6	29.5	17.3	15.5	9.6
6	17.6	4.1	17.6	26.0	17.6	27.7	28.5	33.2	30.9	20.9	20.0	9.8
7	20.6	7.4	22.2	27.8	21.7	22.3	29.5	34.7	29.8	25.0	24.9	7.8
8	8.0	10.6	22.7	28.7	24.0	19.8	27.6	34.8	31.5	25.0	27.3	7.3
9	13.6	12.2	26.1	27.1	24.5	20.1	28.2	34.1	29.5	20.5	27.0	11.3
10	16.7	17.0	18.1	21.4	19.7	25.0	28.9	34.2	29.3	21.2	25.4	12.8
11	20.0	14.9	18.2	20.2	22.7	26.0	28.9	35.4	29.1	25.0	20.0	13.8
12	24.9	18.1	18.0	15.9	28.0	30.3	30.4	34.0	25.7	28.2	21.6	13.0
13	19.1	19.8	11.4	20.9	27.8	31.1	31.1	23.5	23.0	22.0	19.5	7.2
14	10.4	23.0	8.9	26.5	28.6	25.8	32.0	26.1	28.2	20.1	14.1	3.7
15	11.2	25.7	8.6	22.4	26.5	26.8	33.9	27.7	28.1	18.9	7.3	3.9
16	17.6	26.0	10.5		24.8	28.9	36.6	30.4	27.5	20.6	8.2	3.0
17	20.1	23.0	8.7		18.5	30.5	32.2	29.8	29.6	14.5	11.1	5.0
18	6.0	14.0	12.0	29.3	19.9	32.1	24.6	31.5	32.8	15.8	15.4	4.9
19	1.3	9.4	13.6	29.8	22.0	32.6	24.0	31.8	34.2	16.3	16.7	6.3
20	4.3	9.3	9.2	27.0	25.7	34.4	29.9	30.2	27.6	18.8	16.7	6.0
21	6.9	8.1	16.1	16.2	23.7	32.8	28.0	30.2	17.9	19.3	14.6	2.8
22	4.0	13.3	22.2	21.6	18.0	31.7	30.6	30.5	18.7	22.2	15.2	6.6
23	0.9	20.6	24.9	22.1	20.7	32.1	31.2	30.5	19.3	20.9	14.8	5.3
24	0.5	18.0	23.6	24.0	26.0	31.7	32.5	29.5	20.7	18.8	14.8	6.6
25	-0.3	15.8	14.2	21.9	23.0	32.0	30.4	25.5	21.9	14.8	13.6	6.8
26	0.9	19.4	6.6	22.8	20.2	33.9	31.6	26.3	22.8	15.8	14.3	6.9
27	6.0	16.8	10.0	18.1	18.1	28.9	31.1	28.0	21.8	15.3	18.3	7.5
28	12.3	16.2	9.8	21.0	21.5	29.7	31.6	27.9	21.8	12.1	15.1	6.2
29	13.3	23.4	14.9	21.4	25.0	27.3	32.7	27.3	23.3	12.5	9.2	1.2
30	10.4		18.0	21.3	29.5	26.1	33.1	29.5	25.2	14.3	6.3	3.3
31	15.7		23.1		29.3		33.6	29.0		13.3		3.0

Çevresel faktörlerin su tüketimi üzerindeki etkisini anlamak da önemlidir. Bu bağlamda, Raju ve ark. (2022), Chennai kıyı bölgesinde uydu verileri kullanarak aerosol optik derinliği ile parçacık madde konsantrasyonlarını modellemeye odaklanmışlardır. Bu tür çalışmalar, su tüketimi tahmininde çevresel faktörlerin dikkate alınmasının önemini vurgulamaktadır ve gelecekteki su tüketim tahmin modellerinin geliştirilmesinde yol gösterici olabilir.

Çalışma yıllarına ait hafta sonu ve tatil günlerinin sayısının bir kısmı Tablo 3.3'de verilmiştir. Özellikle konut abonelerinde tatil günlerinde su tüketimi artış göstermiştir.

Tablo 3.3. 2016-2022 Yıllarına ait Aylara Göre Hafta Sonu ve Tatil Gün Sayılarının bir kısmı.


Yıl	Ay	Hafta sonu	Tatil
2016	01	10	1
2016	02	8	0
2016	03	8	0
2016	04	9	1
2016	05	9	2
...	...	...	...
2022	07	10	5
2022	08	8	1

3.2.3. COVID-19 pandemisinin etkileri

COVID-19 pandemisi, su tüketim dinamiklerinde büyük bir değişikliğe yol açmıştır. Mart 2020'den Aralık 2021'e kadar uygulanan karantina ve hijyen önlemleri, evsel su tüketiminde artışa neden olurken, ticari ve resmi kullanımda düşüşlere yol açmıştır. Bu çalışmada, pandemi etkileri üç dönemde (öncesi, sırası ve sonrası) analiz edilmiş ve tahmin modellerine entegre edilmiştir. Pandemi sürecinde evde kalma sürelerinin artması ve hijyen önlemlerinin yoğunlaşması, konut abonelerinde su tüketim artışına yol açmıştır. Bunun yanı sıra, iş yerlerinin kapanması ve uzaktan çalışma uygulamaları nedeniyle ticari su tüketimi azalmıştır. Bu kapsamda pandeminin su tüketimine olan etkileri, hem modelin doğruluğunu artırmış hem de gelecekte benzer kriz durumlarında su yönetimi stratejilerine katkı sağlamıştır.

Pandemi sürecinde, evde kalma süresinin artması ve hijyen önlemlerinin yoğunlaşması nedeniyle konut abonelerinin su tüketiminde belirgin bir artış gözlemlenmiştir. Öte yandan, iş yerlerinin kapanması ve uzaktan çalışma uygulamalarının yaygınlaşması sonucunda ticari ve endüstriyel su tüketiminde önemli düşüşler yaşanmıştır. Bu değişimler, su dağıtım sistemlerinin yönetiminde yeni zorluklar ortaya çıkarmış ve su talebinin tahmin edilmesini daha karmaşık hale getirmiştir.


Şekil 3.3, pandemi öncesi dönemi temsil eden 2017, 2018 ve 2019 yıllarına ait su tüketim modellerini göstermektedir. Şekil 3.4, 2019, 2020, 2021 ve 2022 yıllarına ait verilerle, pandemi öncesi, pandemi sırası ve pandemi sonrası dönemlerdeki su tüketim modellerini gözlemlememize olanak tanımaktadır.



Şekil 3.3. Pandemi öncesine ait karşılaştırma.


Bu grafikler, su tüketiminin yıllık döngülerdeki mevsimsel değişikliklerini ve pandemi sürecinin su tüketimi üzerindeki etkilerini açıkça ortaya koymaktadır. Pandemi sürecinin başlangıcı, tüketimdeki anormallikleri ve olağan dışı artışları daha belirgin hale getirmiştir. Özellikle, 2020 yılı, pandemi nedeniyle evde kalma sürelerinin uzaması ve hijyen önlemlerinin artması ile su tüketiminin arttığı yıl olmuştur. 2021 ve 2022 yıllarında ise pandemi etkilerinin azalmaya başlamasıyla su tüketiminde normale dönüş gözlemlenmiştir. Grafik, pandemi dönemi ile sonrasındaki su tüketimindeki değişimleri net bir şekilde gösterirken, aynı zamanda mevsimsel değişikliklerin de tüketim üzerindeki etkisini gözler önüne sermektedir.

Bu analiz, pandeminin su tüketim alışkanlıkları üzerinde yaratmış olduğu uzun vadeli etkileri anlamamıza yardımcı olmaktadır.



Şekil 3.4. Pandemi öncesi, pandemi süresi, ve sonrasına ait karşılaştırma.

Şekil 3.5'e göre, 2022 yılındaki su tüketim örüntüsü 2019'daki ile benzerlik göstererek pandemi öncesi normallere dönüşü işaret ediyor.



Şekil 3.5. Pandemi öncesi ile sonrasına ait karşılaştırma.

Özellikle Şekil 3.4, 2022 yılındaki su tüketim modelinin 2019 yılındakine benzer olduğunu göstermektedir. Bu durum, 2021 yılı sonuna gelindiğinde su kullanımının neredeyse normal haline döndüğüne işaret etmektedir (WHO,2020; CDC,2021).

Pandemi sürecinde su tüketimindeki değişimler, diğer temel hizmetlerde de benzer etkiler göstermiştir. Örneğin, Abdeen ve ark. (2021) Kanada'da yaptıkları araştırmada, pandeminin saatlik elektrik tüketimi üzerindeki etkisini incelemişlerdir. Araştırma sonuçları, günlük rutinlerde ve yaşam tarzlarında değişiklikler olduğunu, hafta içi elektrik kullanımında azalma ve hafta sonlarında ise artış gözlemlendiğini ortaya koymuştur. Benzer şekilde, Li ve ark. (2022), pandeminin etkilerini detaylı bir şekilde inceleyerek, ABD'nin beş farklı bölgesinde (California, Texas, Florida, New York, Tennessee) ve Almanya'da elektrik tüketimindeki değişimleri kapsamlı bir analizle ortaya koymuşlardır.

Bu çalışmalar, COVID-19 pandemisinin sadece su tüketimini değil, genel olarak temel hizmetlerin kullanım desenlerini nasıl etkilediğini göstermektedir. Su tüketimi tahmin modellerinin geliştirilmesinde, bu tür küresel kriz durumlarının etkilerinin dikkate alınması, modellerin daha esnek ve dayanıklı olmasını sağlayacaktır. Ayrıca, bu deneyimler gelecekte ortaya çıkabilecek benzer kriz durumlarında su yönetimi stratejilerinin oluşturulmasında değerli bilgiler sunmaktadır.

3.2.4. Günlük su tüketim verileri

Çalışmada kullanılan günlük veriler, su tüketim tahmin modellerinin geliştirilmesinde önemli bir yere sahiptir. 3 Eylül 2019 ile 8 Kasım 2021 tarihleri arasındaki veriler kullanılmıştır. Toplamda 33 konut abonesinin günlük su tüketim verileri analiz edilmiştir. Bu günlük veriler, meteorolojik verilerle desteklenmiş ve hane halkı bileşimi gibi faktörlerle zenginleştirilmiştir. Günlük verilerin amacı, daha kısa vadeli su tüketimi tahminlerinin yapılabilmesi ve aylık tahminlere göre daha yüksek doğruluk oranlarının elde edilmesidir.

Bu günlük veri setinin kullanımındaki temel motivasyon, aylık bazda özellikle konut abonelerinde elde edilen model performansının ($R^2 \approx \%60$) sınırlı kalmasıdır. Daha kısa vadeli ve yüksek çözünürlüklü veriyle çalışmanın, tahmin modellerinin doğruluğunu artırabileceği düşünülmüştür. Bu nedenle, elde mevcut olan 33 konut abonesine ait günlük veri seti, metodolojik bir deneme olarak çalışmaya dahil edilmiştir. Ancak bu örneklem büyüklüğü, kapsamlı genelleme yapmak için yeterli olmadığından, bu analiz yalnızca yöntem karşılaştırması ve kısa vadeli tahmin kapasitesinin gözlemlenmesi amacıyla değerlendirilmiştir.

Veri Seti Açıklamaları: Günlük veri setinde yer alan değişkenler şunlardır:

- **Abone:** Abonenin kimliği
- **Tüketim:** Günlük su tüketimi
- **Gelir:** Abonenin gelir sınıfı
- **Yetişkin, okulöncesi, ilköğretim:** Oturanların yaş sınıfı
- **Ay ve Gün:** Ay ve gün (Mevsim) etkisi
- **Tüketim_1gün:** Bir önceki günün su tüketimi
- **Tüketim_2gün:** İki önceki günün su tüketimi
- **Tüketim_3_7gün:** Son 3-7 günün ortalama su tüketimi
- **Minimum, Maksimum, Ortalama Sıcaklık:** Günlük sıcaklık
- **Minimum, Maksimum Nem:** Günlük nem oranı
- **Yağış:** Günlük yağış miktarı
- **Güneşlenme:** Günlük güneşlenme süresi

- **Rüzgar:** Günlük rüzgar hızı
- **Pandemi:** Pandemi dönemi ve öncesi
- **Hafta günü:** Haftanın gününün etkisi

Bu günlük veriler, modeldeki doğruluğu artırmaya yönelik önemli bir bileşendir. Meteorolojik veriler, özellikle sıcaklık ve nem, su tüketimini etkileyen en kritik faktörlerden biridir.

3.3. Veri Ön İşleme Adımları

Veri işleme, makine öğrenimi modellerinin doğruluğunu arttırmak için önemli bir adımdır. Özellikle eksik, yanlış, anormal verilerin işlenmesi, model performansı üzerinde doğrudan etkili olabilir. Literatürde yaygın olarak kullanılan bazı veri işleme teknikleri aşağıda sıralanmıştır.

3.3.1. Eksik verilerin tamamlanması

Eksik veriler, makine öğrenimi süreçlerinde önemli sorunlara yol açabilir ve modelin tahmin kapasitesini zayıflatabilir. Literatürde eksik verilerin tamamlanması için birkaç yöntem yaygın olarak kullanılmaktadır:

- **Ortalama ile Doldurma:** Eksik verilerin bulunduğu özellikler için veri setinin ortalama değeri kullanılarak boş alanlar doldurulur. Eksik verilerin bulunduğu bazı abone kayıtları, eksikliklerin yoğunluğu nedeniyle veri setinden çıkarılmıştır. Meteorolojik sensörlerden gelen eksik değerler, yakındaki sensörler arasındaki mesafe oranına göre hesap edilmiştir. Bu yöntemle eksik veri sorunu giderilmiş ve veri seti tamamlanmıştır.
- **Medyan ile Doldurma:** Özellikle aykırı değerlerin bulunduğu veri setlerinde, medyan değeri kullanılarak eksik veriler doldurulur. Bu yöntem, ortalamaya göre daha güvenilir olabilir.
- **En Yakın Komşu Yöntemi (K-Nearest Neighbors, KNN):** Eksik veriler, en yakın komşu algoritmasıyla doldurulur. KNN, eksik veriyi komşu verilerin benzerliklerine dayanarak tahmin eder ve genellikle daha doğru sonuçlar verir. Thomas ve Rajabi (2021), eksik verilerin KNN algoritması ile doldurulmasının sağlık veri setlerinde önemli iyileştirmeler sağladığını belirtmiştir. Pan ve ark. (2015), bu yöntemi geliştirerek, gri ilişkisel yapı ve karşılıklı bilgiye dayalı

KNN tabanlı bir yöntem (FWGKNN) önermişlerdir. Zhang ve ark. (2022) ise, KNN ve RF algoritmalarını birleştirerek, eksik verilerin daha etkili bir şekilde tamamlanmasını sağlamışlardır.

Bunun yanı sıra, Mallikharjuna Rao ve ark. (2023), eksik verilerin işlenmesinin yanı sıra kategorik özellik kodlama, aykırı değer tespiti ve veri ölçeklendirme gibi ön işleme tekniklerini kapsamlı bir şekilde incelemişlerdir. Ayrıca, García ve ark. (2016), büyük veri ön işleme tekniklerini değerlendirerek, eksik veri tamamlama gibi tekniklerin büyük veri bağlamındaki zorluklarına da dikkat çekmiştir.

- **Regresyon Yöntemi:** Literatürde sıkça kullanılan bir diğer yöntem, eksik verilerin diğer bağımsız değişkenlere dayalı olarak regresyon analizi ile tahmin edilmesidir. Bu yöntem, veri setinin genel trendini korumaya yardımcı olabilir.

3.3.2. Anormal verilerin tespiti ve çıkarılması

Anormal veya aykırı veriler, veri setinin genel yapısından sapmalar gösteren verilerdir. Bu veriler modelin tahmin performansını düşürebilir. Aykırı verilerin tespiti ve çıkarılması için literatürde kullanılan başlıca yöntemler şunlardır:

- **Z-Score Yöntemi:** Verilerin ortalamadan kaç standart sapma uzaklaştığını ölçen bu yöntemle, belirlenen eşik değerinin dışındaki veriler aykırı olarak kabul edilir ve çıkarılır.
- **IQR (Interquartile Range) Yöntemi:** Veri setinin yüzde 25'lik (Q1) ve yüzde 75'lik (Q3) dilimleri arasındaki fark kullanılarak aykırı veriler tespit edilir. Q1 ve Q3 aralığının dışında kalan veriler anormal kabul edilir.
- **Kümeleme Yöntemleri:** Özellikle büyük veri setlerinde, aykırı veriler kümeleme algoritmalarıyla (örneğin, k-means) tespit edilebilir. Kümenin dışında kalan veriler aykırı olarak değerlendirilebilir. Bu yöntemlerle tespit edilen aykırı veriler çıkarıldıktan sonra, veri setindeki kategorik değişkenler modele uygun hale getirilmek için uygun şekilde kodlanmıştır. Veri setindeki kategorik değişkenler, modele uygun hale getirilmek için kodlanmıştır. Aktivite türü ve tarife türü gibi kategorik veriler, yapay sinir ağına uygun şekilde sayısal verilere dönüştürülmek üzere ikili kodlama (one-hot encoding) yöntemi kullanılarak kodlanmıştır. Buna ek olarak, sayaç çapı gibi sıralı kategorik değişkenler için doğrusal kodlama (linear coding) yöntemi

uygulanmıştır. Bu kodlama işlemleri, modelin verileri daha iyi öğrenmesini sağlamak amacıyla yapılmıştır.

- **Mahalanobis Mesafesi:** Çok değişkenli aykırı verilerin tespiti için kullanılan bir yöntemdir. Mahalanobis mesafesi, her bir verinin ortalamaya olan uzaklığını ölçer ve aykırı verileri belirler.

3.3.3. Veri Normalizasyonu ve Standardizasyonu

Model eğitimi sırasında verilerin aynı ölçeğe getirilmesi, yapay zeka modellerinin performansı ve güvenilirliği açısından kritik öneme sahiptir. Veri normalizasyonu ve standardizasyonu, farklı ölçeklerdeki özelliklerin model tarafından eşit şekilde değerlendirilmesini sağlar ve öğrenme sürecini hızlandırır.

Bu çalışmada, veri setinin ölçeklendirilmesinde tutarlılığı sağlamak amacıyla çeşitli normalizasyon teknikleri göz önünde bulundurulmuştur. Bunlar arasında z-score, min-max, decimal scaling ve kök dönüşümü gibi yöntemler yer almaktadır. Sonuç olarak, verileri -1 ile +1 arasında yeniden ölçeklendiren Min-max normalizasyonu tercih edilmiştir.

Min-max normalizasyonu, her bir veriyi veri setindeki minimum ve maksimum değerler kullanılarak yeniden ölçeklendirir. Bu yöntemle, her bir veri noktası şu formül kullanılarak normleştirilmiştir (3,1).

$$X_{new} = \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) \times 2 - 1 \quad (3.1)$$

Bu formül, verinin mevcut değerini -1 ile +1 arasında bir aralığa dönüştürmektedir. Bu sayede, modelde kullanılan farklı özelliklerin aynı ölçek içerisinde değerlendirilmesi sağlanmıştır, bu da model performansını ve öğrenme kapasitesini olumlu yönde etkilemiştir.

Min-max normalizasyonunun yanı sıra, literatürde sıkça kullanılan diğer normalizasyon ve standardizasyon yöntemleri şunlardır:

Literatürde veri normalizasyonu için kullanılan başlıca yöntemler şunlardır:

- **Z-Score Standardizasyonu:** Veriler, ortalaması 0 ve standart sapması 1 olacak şekilde yeniden ölçeklendirilir. Bu yöntem, farklı ölçeklerdeki verilerin

ortalamadan ne kadar saptığını gösterir ve verilerin standart bir dağılım göstermesini sağlar.

- **Logaritmik Dönüşüm:** Özellikle büyük farklar içeren veri setlerinde, verilerin logaritmik dönüşümü kullanılarak daha sıkıştırılmış bir dağılım elde edilir. Bu yöntem, büyük değerler arasındaki farkları azaltarak daha dengeli bir veri seti oluşturur.
- **Decimal Scaling:** Bu yöntem, verileri 10'un katları ile bölerek normalize eder. Özellikle, verilerin büyüklük sıralarının korunması gerektiği durumlarda tercih edilir.

Bu çalışmada Min-max normalizasyonunun tercih edilmesinin nedeni, modelin öğrenme sürecini hızlandırması ve büyük sayısal farklardan kaynaklanabilecek öğrenme zorluklarını önlemesidir. Girdilerin aynı aralıkta tutulması, yapay zeka modellerinin daha dengeli bir şekilde öğrenmesine yardımcı olur.

Veri normalizasyonu ve standardizasyonu, model performansını artırmanın yanı sıra, özellik önem analizinde de daha doğru sonuçlar elde edilmesini sağlamıştır. Bu sayede, su tüketimini etkileyen faktörlerin göreceli önemi daha net bir şekilde ortaya konulabilmiştir.

3.3.4. Veri bölme ve çapraz doğrulama

Eğitim sürecinde modelin genelleme kapasitesini test etmek için veri seti bölünür.

Literatürde kullanılan başlıca veri bölme ve çapraz doğrulama yöntemleri şunlardır:

- **Eğitim/Test Seti Bölme:** Veri seti genellikle %70 eğitim ve %30 test seti olacak şekilde ikiye ayrılır. Eğitim seti, modelin öğrenmesi için kullanılırken, test seti modelin performansını değerlendirmek için kullanılır.
- **K-fold Çapraz Doğrulama:** Veri seti k katmanlı olarak bölünür ve her katman modelin eğitimi için kullanılır. Bu yöntem, modelin farklı veri kümelerinde nasıl performans gösterdiğini değerlendirmek ve aşırı öğrenmeyi önlemek için kullanılır. Refaeilzadeh ve ark. (2009), k-fold çapraz doğrulamanın model performansını değerlendirmek ve genelleme kapasitesini artırmak için yaygın olarak kullanıldığını belirtmiştir.
- **Hiperparametre Optimizasyonu:** Literatürde sıkça kullanılan bir diğer teknik de hiperparametre optimizasyonudur. Bu teknik, modelin en iyi performansı göstermesi için parametrelerin ayarlanmasını sağlar. Bischl ve ark. (2021),

hiperparametre optimizasyonunun temellerini, algoritmalarını ve en iyi uygulamalarını detaylı bir şekilde incelemiştir. Grid Search ve Random Search yöntemleri yaygın olarak kullanılmaktadır. Liashchynskyi ve Liashchynskyi (2019), Grid Search ve Random Search algoritmalarının performansını karşılaştırmıştır. Grid Search, belirlenen hiperparametrelerin sistematik olarak denenmesiyle en uygun kombinasyonu bulmaya çalışırken, Random Search rastgele bir şekilde farklı hiperparametre kombinasyonlarını denemektedir. Feurer ve Hutter (2019), makine öğrenimi ve derin öğrenme modellerinin performansını arttırmak için hiperparametre optimizasyonunun önemini vurgulamıştır.

3.4. SVM, RF, GBM, LSTM ve GRU Modelleri

Su tüketimi tahmininde, ANN dışında da birçok yapay zeka ve makine öğrenimi modeli kullanılmaktadır. Bu bölümde, SVM, RF, GBM, LSTM ve GRU modellerinin su tüketimi tahminindeki performansı ve bu modellerin avantajları ile sınırlamaları ele alınacaktır.

3.4.1. Destek vektör makineleri (SVM)

SVM, hem sınıflandırma hem de regresyon problemlerinde kullanılan güçlü bir makine öğrenimi algoritmasıdır. SVM, veri noktalarını bir hiper düzlemle ayırarak sınıflandırma veya tahmin yapar. SVM'nin temel avantajı, yüksek boyutlu veri setlerinde bile etkili bir şekilde çalışabilmesidir.

SVM'nin Su Tüketimi Tahminindeki Uygulaması:

- SVM, özellikle doğrusal olmayan veri setlerinde yüksek doğruluk oranları sunar. Su tüketimi tahmininde, meteorolojik veriler (sıcaklık, yağış, nem) ve sosyo-ekonomik faktörler (pandemi, tatil günleri) gibi çok boyutlu verilerin analizinde etkili sonuçlar verir.
- SVM, çekirdek (kernel) fonksiyonları kullanarak verileri daha yüksek boyutlu bir uzaya taşır ve burada doğrusal olmayan ilişkileri modelleyebilir.

SVM'nin Avantajları:

- Yüksek boyutlu veri setlerinde etkili performans.
- Doğrusal olmayan ilişkileri modelleme yeteneği.

- Aşırı öğrenme (overfitting) riskinin düşük olması.

SVM'nin Sınırlamaları:

- Büyük veri setlerinde hesaplama maliyetinin yüksek olması.
- Hiperparametre optimizasyonunun karmaşık olması.
- Modelin yorumlanabilirliğinin düşük olması.

3.4.2. Random forest (RF)

RF, karar ağaçlarının (Decision Tree) bir ensemble yöntemi olarak kullanılan bir makine öğrenimi algoritmasıdır. RF, birden fazla karar ağacı oluşturur ve bu ağaçların tahminlerini birleştirerek daha doğru ve istikrarlı sonuçlar elde eder.

RF'in Su Tüketimi Tahminindeki Uygulaması:

- RF, özellikle büyük veri setlerinde yüksek doğruluk oranları sunar. Su tüketimi tahmininde, farklı abone türleri (konut, ticari, resmi) ve meteorolojik faktörler gibi çok sayıda değişkenin analizinde etkili sonuçlar verir.
- RF, özellik önem analizi yaparak su tüketimini etkileyen en önemli faktörleri belirleyebilir.

RF'in Avantajları:

- Büyük veri setlerinde yüksek doğruluk oranları.
- Özellik önem analizi yapabilme yeteneği.
- Aşırı öğrenme (overfitting) riskinin düşük olması.

RF'in Sınırlamaları:

- Modelin eğitim süresinin uzun olması.
- Büyük veri setlerinde hafıza kullanımının yüksek olması.
- Modelin yorumlanabilirliğinin sınırlı olması.

3.4.3. Gradient boosting machines (GBM)

GBM, zayıf karar ağaçlarını ardışık olarak eğiterek hata oranlarını azaltan bir topluluk yöntemidir. GBM'nin avantajları arasında yüksek tahmin doğruluğu, düşük hata oranı ve değişkenlerin önem seviyelerini belirleme yeteneği bulunmaktadır. Çalışmamızda, GBM modeli su tüketim tahmini için kullanılmış ve diğer yöntemlerle kıyaslanmıştır.

Bu çalışmada kullanılan GBM modeli şu adımlarla eğitilmiştir:

- **Veri ön işleme:** Eksik verilerin giderilmesi, anormal verilerin temizlenmesi ve normalizasyon işlemleri gerçekleştirilmiştir.
- **Hiperparametre optimizasyonu:** Grid Search ve Randomized Search yöntemleri kullanılarak öğrenme oranı (learning rate), maksimum derinlik (max_depth), zayıf öğrencilerin sayısı (n_estimators) gibi parametreler optimize edilmiştir.
- **Model eğitimi ve değerlendirme:** GBM modeli, eğitim seti üzerinde eğitilmiş ve çapraz doğrulama (k-fold cross-validation) ile test edilmiştir. Modelin doğruluğunu belirlemek için R^2 , MSE, RMSE ve MAE gibi performans metrikleri kullanılmıştır.

Sonuç olarak, GBM modeli, RF ve SVM modelleri ile karşılaştırıldığında daha yüksek doğruluk sağlamış ve su tüketimi tahmininde en iyi sonuçları veren yöntemlerden biri olarak öne çıkmıştır.

3.4.4. Uzun kısa süreli bellek (LSTM)

LSTM, RNN'in geliştirilmiş bir versiyonudur ve özellikle zaman serisi tahminlerinde güçlü bir model olarak öne çıkmaktadır. Su tüketimi tahmininde, geçmiş tüketim verilerinin zamansal bağımlılığını öğrenerek gelecekteki tüketimi tahmin etmede etkin bir şekilde kullanılmıştır.

LSTM'nin Su Tüketimi Tahminindeki Uygulaması:

- Su tüketiminin geçmiş verilerine dayalı olarak gelecekteki tüketimi öngörmek için LSTM modeli uygulanmıştır.
- LSTM, uzun vadeli bağımlılıkları öğrenerek mevsimsel desenleri ve ani değişimleri yakalayabilmiştir.
- Modelin eğitimi sırasında, aşırı öğrenmeyi önlemek için dropout yöntemi uygulanmış ve hiperparametre optimizasyonu yapılmıştır.

LSTM'nin Avantajları:

- Zaman serisi analizlerinde güçlü performans gösterir.
- Uzun vadeli bağımlılıkları öğrenerek su tüketimi tahminlerini iyileştirir.
- Büyük veri setlerinde genelleme kapasitesi yüksektir.

LSTM'nin Sınırlamaları:

- Eğitim süresi diğer modellere kıyasla daha uzundur.
- Yüksek hesaplama gücü gerektirir.
- Hiperparametre optimizasyonu karmaşıktır.

3.4.5. Kapalı tekrarlayan birimler (GRU)

GRU, LSTM ile benzer bir yapıya sahip olmakla birlikte, daha az parametre içerdiği için hesaplama açısından daha verimli bir modeldir. GRU, zaman serisi verilerindeki bağımlılıkları öğrenerek su tüketimi tahmininde etkili sonuçlar vermektedir.

GRU'nun Su Tüketimi Tahminindeki Uygulaması:

- GRU modeli, LSTM gibi zaman serisi verilerindeki desenleri öğrenmek için kullanılmıştır.
- Su tüketimi tahminlerinde, değişkenlik gösteren verileri modelleyerek kısa ve uzun vadeli bağımlılıkları yakalamıştır.
- Aşırı öğrenmeyi önlemek için dropout tekniği uygulanmış, veri seti normalleştirilerek modelin doğruluğu artırılmıştır.

GRU'nun Avantajları:

- LSTM'e kıyasla daha hızlı eğitim süresi sunar.
- Daha az parametreye sahip olması nedeniyle düşük hesaplama maliyeti gerektirir.
- Zaman serisi verilerinde etkili performans gösterir.

GRU'nun Sınırlamaları:

- Uzun vadeli bağımlılıkları LSTM kadar iyi öğrenemeyebilir.
- Büyük veri setlerinde LSTM kadar başarılı olmayabilir.
- Modelin hiperparametre optimizasyonu önemlidir.

3.4.6. Modellerinin karşılaştırılması

SVM, RF, GBM, LSTM ve GRU modelleri, su tüketimi tahmininde farklı avantajlar ve sınırlamalar sunmaktadır:

- **SVM:** Doğrusal olmayan veri yapılarını modelleyebilir ancak büyük veri setlerinde hesaplama maliyeti yüksektir.
- **RF:** Veri setindeki değişkenlerin önem derecelerini belirleyebilir ve büyük veri setlerinde iyi performans gösterir, ancak eğitim süresi uzundur.
- **GBM:** Tahmin doğruluğunu artırır ve en iyi performans gösteren modeldir, ancak aşırı uyum (overfitting) riski taşımaktadır.
- **LSTM:** Uzun vadeli bağımlılıkları öğrenerek zamansal tahminlerde başarılıdır, ancak eğitim süresi uzundur.
- **GRU:** LSTM'e kıyasla daha hızlı ve düşük hesaplama maliyetine sahiptir, ancak uzun vadeli bağımlılıkları modelleme konusunda sınırlamaları vardır.

Bu karşılaştırmalar doğrultusunda, su tüketimi tahmininde GBM, LSTM ve GRU modelleri en iyi sonuçları sunmuş ve farklı abonelik türleri için en yüksek doğruluk oranlarına ulaşmıştır.

3.5. Modelin Eğitimi ve Parametre Optimizasyonu

Bu çalışmada, SVM, RF ve GBM gibi modeller kullanılarak su tüketimi tahmini yapılmıştır. Modelin eğitimi için veri seti, eğitim ve test veri seti olarak ikiye ayrılmıştır. Eğitim veri seti modelin öğrenme sürecini sağlarken, test veri seti modelin doğrulama aşamasında kullanılmıştır.

Hiperparametre optimizasyonu sürecinde manuel ayarlamalar ve Grid Search yöntemi kullanılmış, en iyi model parametreleri belirlenmiştir. Optimizasyon sırasında, gizli katman sayısı, nöron sayısı, öğrenme oranı, ağaç sayısı ve maksimum derinlik gibi kritik parametreler analiz edilmiştir (Bkz. EK A).

Modelin aşırı öğrenmesini (overfitting) engellemek için erken durdurma (early stopping) ve dropout teknikleri uygulanmıştır (Bkz. EK C). Modelin performansını değerlendirmek için R^2 skoru, Ortalama Karesel Hata (MSE), Ortalama Mutlak Hata (MAE), Medyan Mutlak Hata (MedAE) ve Log-Cosh Loss gibi metrikler kullanılmıştır.

3.5.1. Eğitim ve test setleri

Modelin eğitim sürecinde, değişik oranlarda veriler ayrılarak kullanılmıştır. Bunlardan bir tanesi, aşağıda belirtilmiştir:

- **%70 Eğitim Seti (Training Set):** Modelin öğrenmesi için kullanılmıştır.
- **%15 Doğrulama Seti (Validation Set):** Hiperparametre optimizasyonunda kullanılmıştır.
- **%15 Test Seti (Test Set):** Modelin bilinmeyen veriler üzerindeki başarısını ölçmek için ayrılmıştır.

Bu bölme işlemi sırasında, konut, ticari ve resmi abonelerin sayıları birbirinden farklı olduğu için eğitim/test setlerine dağıtım yapılırken stratified sampling (tabakalı örnekleme) yöntemi kullanılmamış, bunun yerine her abone grubu için ayrı oranlarda veri bölünerek homojen bir dağılım sağlanmıştır.

Ayrıca, modelin genelleme yeteneğini artırmak için 5 katlı çapraz doğrulama (5-Fold Cross-Validation) yöntemi uygulanmıştır.

3.5.2. Performans Metrikleri

Model performansını değerlendirmek için çeşitli metrikler kullanılmaktadır. Bu metrikler, modelin tahmin ettiği değerlerin gerçek değerlere ne kadar yakın olduğunu anlamak için önemli göstergeler sağlar. Aşağıda, literatürde sıkça karşılaşılan performans metrikleri anlatılmıştır. Çalışmamızda ise ilk 5 metrik kullanılmıştır.


- **MAE:** Ortalama Mutlak Hata, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını ölçer. MAE, tüm hatalara eşit önem verir ve aykırı değerlerden etkilenmez, bu da modelin genellikle ortalama sapmasını anlamaya yardımcı olur.
- **MAPE:** Ortalama Mutlak Yüzde Hatası, tahmin edilen değerlerin gerçek değerlere göre yüzdelik sapmalarını ölçer. MAPE, her bir tahmin hatasının yüzde cinsinden ifadesini alarak, tahmin hatalarının ölçeklenebilirliğini sağlar ve genel model performansını değerlendirmede kullanılır. Küçük değerler daha iyi performansı gösterir, ancak sıfıra yakın gerçek değerler olduğunda hesaplamada problemler ortaya çıkabilir.
- **MSE:** Ortalama Kare Hatası, tahmin edilen değerler ile gerçek değerler arasındaki farkların karesini alır ve ortalamasını hesaplar. Aykırı değerlere daha duyarlıdır, çünkü hatalar kare alındığı için daha büyük farklar daha yüksek cezalandırılır.

- **Karekök Ortalama Hata (RMSE):** RMSE, MSE'nin karekökünü alarak hesaplanan bir metriktir. Hataların büyüklüğünü daha doğrudan temsil eder ve birim düzeyinde anlamlı bir sonuç sunar. Aykırı değerlere karşı duyarlılığı, modelin aşırı tahminler yapıp yapmadığını belirlemede kullanışlıdır.
- **R²:** R² katsayısı, modelin tahmin ettiği değerlerin, ortalama değere kıyasla ne kadar iyi olduğunu ölçer. R² değeri 0 ile 1 arasında değişir; 1'e ne kadar yakınsa, modelin tahminleri o kadar isabetlidir. R², özellikle modelin genel performansını değerlendirmede önemli bir ölçüttür.
- **Medyan Mutlak Hata (MedAE):** Medyan Mutlak Hata, mutlak hata dağılımının medyanını hesaplar. Aykırı değerlere karşı daha dayanıklıdır ve verinin ortanca sapmasını daha iyi gösterir. Özellikle, aşırı hataların olduğu veri kümelerinde kullanılması tavsiye edilir.
- **Log-Cosh Loss:** Log-Cosh Loss, karesel hata gibi küçük hataları cezalandırırken, büyük hataları logaritmik olarak cezalandıran bir fonksiyondur. Bu, aşırı değerlerin etkisini yumuşatarak daha dengeli bir hata ölçüsü sağlar.
- **Hinge Loss:** Hinge Loss, özellikle sınıflandırma problemleri için kullanılır ve yanlış tahmin edilen sınıflar üzerinde odaklanır. Support Vector Machines (SVM) gibi sınıflandırma algoritmalarında yaygın olarak kullanılan bu metrik, yanlış sınıflandırmaları cezalandırmada etkilidir.
- **Hata Karelerinin Toplamı (SSE):** SSE, tüm hataların karesini alarak toplam hata miktarını ölçer. Genellikle regresyon modellerinin performansını değerlendirmede kullanılır. Daha düşük bir SSE, daha başarılı bir model anlamına gelir.

3.5.3. Hiperparametre optimizasyonu

Hiperparametre optimizasyonu, modelin performansını arttırmak amacıyla yapılmıştır. Bu çalışmada, öğrenme oranı, gizli katman sayısı ve nöron sayısı gibi hiperparametreler manuel olarak ayarlanmış ve en uygun parametreler belirlenmiştir. Hiperparametrelerin optimizasyonu, modelin doğruluğunu artırmada kritik bir rol oynamıştır. Hiperparametre ayarlamaları EK A'da daha ayrıntılı bir şekilde açıklanmaktadır.

Şekil 3.6'de, Grid Search yöntemi ile modelin hiperparametrelerinin (örneğin, ağaç sayısı ve maksimum derinlik) taranması sonucu elde edilen R^2 değerleri bir ısı haritası olarak sunulmuştur. Bu görselleştirme, farklı parametre kombinasyonlarının modelin doğruluk performansına etkisini açıkça göstermektedir. Haritada görüldüğü üzere, ağaç sayısı arttıkça ve maksimum derinlik belirli bir seviyeye ulaştıkça model performansında iyileşmeler kaydedilmiştir. Bu analiz sonucunda en yüksek R^2 değeri, 100 ağaç sayısı ve 15 maksimum derinlik parametreleri ile elde edilmiştir. Bu parametreler, modelin eğitimi sırasında nihai hiperparametreler olarak kullanılmıştır.



Şekil 3.6. Grid Search ile Hiperparametre Optimizasyonu Sonuçları.

Bu optimizasyon süreci, model performansını arttırmak ve genelleştirilebilirliği sağlamak için kritik bir adım olmuştur.

Grid Search, tüm olası hiperparametre kombinasyonlarını test ederek en iyi sonucu bulmaya yönelik sistematik bir yöntemdir. Ancak, büyük veri setlerinde hesaplama maliyetinin yüksek olması nedeniyle, bu çalışmada belirli hiperparametre aralıkları optimize edilmiştir. Tablo 3.4'de farklı modeller için optimize edilen hiperparametreler verilmiştir.

Grid Search yöntemi sistematik bir tarama sağlarken, özellikle büyük veri setlerinde hesaplama açısından maliyetli olabilir. Bu nedenle, bazı durumlarda Random Search veya Bayes Optimizasyonu gibi yöntemler daha verimli olabilir.

Ancak bu çalışmada Random Search yerine Grid Search'ün tercih edilme nedeni, belirli bir hiperparametre aralığında daha kesin sonuçlar elde etme gerekliliğidir.

Tablo 3.4. Modeller ve Optimize Edilen Hiperparametreler.

Model	Hiperparametre	Aralık	En iyi değer
ANN	Öğrenme oranı (learning rate)	0.001 - 0.1	0.01
ANN	Katman sayısı	2 - 5	3
ANN	Nöron sayısı	32 - 512	128
RF	Ağaç sayısı (n_estimators)	50 - 200	100
RF	Maksimum derinlik (max_depth)	5 - 20	15
SVM	C Parametresi	0.1 - 100	10
SVM	Kernel Türü	'linear', 'rbf'	'rbf'
LSTM	LSTM Katman Sayısı	1 - 3	2
LSTM	Zaman Penceresi (Time Step)	3 - 10	5
GRU	GRU Katman Sayısı	1 - 3	2
GRU	Zaman Penceresi (Time Step)	3 - 10	5
GBM	Öğrenme Oranı (Learning Rate)	0.01 - 0.3	0.05
GBM	Ağaç Sayısı (n_estimators)	50 - 500	150
GBM	Maksimum Derinlik (max_depth)	3 - 15	7

Bayes Optimizasyonu ise hesaplama açısından avantajlı olmasına rağmen, daha karmaşık bir yapı gerektirdiği için tercih edilmemiştir.

3.5.4. Aşırı öğrenmeyi (Overfitting) önleme yöntemleri

Aşırı öğrenme, modelin eğitim verisine fazla uyum sağlaması sonucu test verisinde düşük performans göstermesi durumudur. Bu çalışmada, aşırı öğrenmeyi önlemek için şu yöntemler kullanılmıştır:

- **Dropout (Bırakma):** Sinir ağlarında belirli oranlarda nöronları rastgele kapatarak modelin aşırı ezberlemesini önlemek için uygulanmıştır. Bu çalışmada Dropout oranı %20 olarak belirlenmiştir.
- **Early Stopping (Erken Durdurma):** Modelin doğrulama seti hatası belirli bir noktadan sonra düşmeyi durdurduğunda eğitim sürecini sonlandırmak için kullanılmıştır. Bu sayede gereksiz eğitim süreleri önlenmiş ve modelin genelleme gücü artırılmıştır.
- **L2 Regularizasyon (Ceza Fonksiyonu):** Ağırlıkların aşırı büyümesini önlemek için L2 normu kullanılmıştır. Bu yöntem, ANN ve LSTM modellerinde uygulanmıştır.
- **Veri Artırma (Data Augmentation):** Eğitim setini zenginleştirmek ve modelin farklı veri senaryolarına uyum sağlamasını artırmak için

uygulanmıştır. Özellikle LSTM ve GRU modellerinde veri artırma teknikleri kullanılmıştır.

3.5.5. Korelasyon (Correlation)

Korelasyon analizi, su tüketimi ile meteorolojik ve sosyo-ekonomik değişkenler arasındaki ilişkileri anlamak amacıyla yapılmıştır. Tablo 3.5’de, bu değişkenler arasındaki korelasyon katsayıları göstermektedir. Minimum sıcaklık, maksimum sıcaklık ve güneşlenme süresi arasında güçlü pozitif korelasyon gözlemlenmiştir. Bu, su tüketiminin sıcak hava koşullarında ve daha uzun güneşlenme sürelerinde artış gösterdiğini ortaya koymaktadır.

Buna karşılık, rüzgar hızı ve pandemi dönemi gibi değişkenler arasında zayıf korelasyonlar gözlemlenmiş ve bu tür değişkenler modelin tahmin doğruluğunu iyileştirmediği için çıkarılmıştır.

Tablo 3.5. Özellikler Arası Korelasyon.

	ay	yağmur	rüzgar	güneşlenme	min_rut	max_rut	min_sıc	max_sıc	ort_sıc	pandemi	tüketim
Ay	1	-0,0711	-0,5216	0,0671	0,0092	0,1552	0,3493	0,4221	0,3831	0	0,0314
yağmur	-0,0711	1	0,0675	-0,3557	0,3071	0,3666	-0,3951	-0,3551	-0,3746	-0,191	-0,0164
rüzgar	-0,5216	0,0675	1	0,1643	0,0581	-0,1638	-0,0617	-0,13	-0,0912	-0,055	-0,0186
güneşlenme	0,0671	-0,3557	0,1643	1	-0,1257	-0,632	0,8621	0,7917	0,8355	0,0111	0,047
min_rutubet	0,0092	0,3071	0,0581	-0,1257	1	0,5265	-0,0755	-0,1207	-0,1073	-0,4138	-0,0155
max_rutubet	0,1551	0,3666	-0,1638	-0,632	0,5265	1	-0,4662	-0,3803	-0,4312	-0,198	-0,0147
min_sıcaklık	0,3493	-0,3951	-0,0617	0,8621	-0,0755	-0,4662	1	0,9782	0,9939	0,0872	0,0634
max_sıcaklık	0,4221	-0,3551	-0,13	0,7917	-0,1207	-0,3803	0,9782	1	0,9947	0,088	0,0704
ort_sıcaklık	0,3831	-0,3746	-0,0912	0,8355	-0,1073	-0,4312	0,9939	0,9947	1	0,0885	0,0672
pandemi	0	-0,191	-0,055	0,0111	-0,4138	-0,198	0,0872	0,088	0,0885	1	0,0014
tüketim	0,0314	-0,0164	-0,0186	0,047	-0,0155	-0,0147	0,0634	0,0704	0,0672	0,0014	1

Korelasyon katsayıları 0.1'in altında olan değişkenler düşük ilişki düzeyine sahip olduğundan modelde anlamlı bir katkı sağlamamaktadır. Bu analiz, modelin tahmin doğruluğunu artırmak ve genelleme kapasitesini geliştirmek için önemli bir adım olmuştur.

Tablo 3.5, veri setindeki değişkenler arasındaki ikili korelasyonları göstermektedir. Bu analiz, değişkenler arasındaki ilişkileri değerlendirerek modelleme sürecinde hangi değişkenlerin daha anlamlı olduğuna karar verilmesini sağlamıştır.

İkili korelasyonların yanı sıra, çoklu bağıntıyı tespit etmek amacıyla Varyans Şişirme Faktörü (VIF) analizi gerçekleştirilmiştir. VIF analizine göre, VIF değeri 10'un üzerinde olan değişkenler modelden çıkarılmıştır. Bu süreçte, maksimum, minimum ve ortalama sıcaklık değişkenleri arasında yüksek düzeyde bir bağıntı gözlemlenmiş ve bu değişkenlerden yalnızca maksimum sıcaklık modele dahil edilmiştir.

Ayrıca, değişkenlerin model üzerindeki etkilerini daha ayrıntılı olarak inceleyebilmek için SHAP (SHapley Additive exPlanations), LIME (Local Interpretable Model-agnostic Explanations) veya Permutation Importance gibi model-temelli açıklayıcı yöntemler de kullanılabilir. Ancak bu tez çalışmasının kapsamı, tahmin performansı odaklı bir karşılaştırmaya dayandığından, ilgili yöntemlerin uygulaması bu çalışma kapsamında gerçekleştirilmemiştir. Bu tür yorumlayıcı analizler, özellikle model çıktılarının anlaşılabilirliğini artırmak amacıyla, gelecekte yapılacak araştırmalar için önerilmektedir.

Benzer şekilde, minimum ve maksimum nem değişkenleri arasındaki orta-yüksek düzeyde korelasyon nedeniyle, yalnızca maksimum nem modele dahil edilmiş, minimum nem çıkarılmıştır. Ayrıca, tüketimle düşük korelasyona sahip değişkenler (örneğin, rüzgar hızı ve pandemi), modelin performansına anlamlı bir katkı sağlamadığı için modelleme sürecinde kullanılmamıştır.

Bu yaklaşım, modelin tahmin doğruluğunu artırmayı ve gereksiz karmaşıklığı önlemeyi hedeflemiştir. Değişkenlerin seçimi sırasında ikili korelasyon analizleri ile birlikte çoklu bağıntının da dikkate alınması, modelin daha yalın ve güvenilir bir yapıya sahip olmasına katkı sağlamıştır.

3.5.6. Rassal başlangıç noktaları ve T-testi

Bu bölüm, Hipotez 1 kapsamında, ANN modelinin diğer yapay zeka tekniklerine kıyasla daha yüksek doğruluk sunup sunmadığını değerlendirmek amacıyla gerçekleştirilmiştir.

Çalışmada kullanılan modeller şunlardır: ANN, SVM, GBM, RF, LSTM ve GRU.

Her bir model, 10 farklı rassal başlangıç noktası (random seed) ile eğitilerek performans değerlendirmeleri gerçekleştirilmiştir. Bu yaklaşım, modellerin farklı başlangıç koşullarında ne kadar tutarlı sonuçlar verdiğini incelemeye olanak tanımaktadır.

Eğitimlerden elde edilen performans metrikleri (R^2 , MSE, RMSE, MAE) üzerinde bağımlı örneklem T-testi uygulanmış ve ANN modeli ile diğer modeller arasındaki farkların istatistiksel anlamlılığı test edilmiştir.

T-testi sonuçlarına göre, ANN modeli çoğu durumda daha yüksek doğruluk oranları üretmiş olsa da, diğer modellerle (GBM, RF, SVM, LSTM, GRU) yapılan karşılaştırmalarda bu farklar istatistiksel olarak anlamlı bulunmamıştır ($p > 0.05$). Bu durum, ANN'nin üstün performans potansiyeline rağmen, bu farkların rastlantısal olabileceğini göstermektedir.

Dolayısıyla, Hipotez 1 istatistiksel olarak desteklenememiştir.

Bu karşılaştırmalar aşağıdaki hipotez yapısıyla test edilmiştir:

- **H₀**: ANN modeli ile karşılaştırılan model arasında anlamlı bir performans farkı yoktur.
- **H₁**: ANN modeli ile karşılaştırılan model arasında anlamlı bir performans farkı vardır.

Bu yöntem, model seçim sürecinin bilimsel temele dayandırılmasına ve sonuçların genellenebilirliğinin artırılmasına katkı sağlamıştır.

3.6. Çapraz Doğrulama ve Model Değerlendirme

Modelin performansını değerlendirmek için çapraz doğrulama yöntemi kullanılmıştır. Bu yöntem, veri setinin birden fazla alt kümeye bölünerek her bir alt kümenin model eğitimi ve doğrulama için kullanılması prensibine dayanmaktadır. Böylece modelin

farklı veri setlerinde nasıl performans gösterdiği değerlendirilmiş ve genelleme yeteneği artırılmıştır.

Görenekli ve Gülbağ (2025)'in belirttiği gibi, modelin performansı, çeşitli hata ölçütleri ile değerlendirilmiştir. Özellikle, MSE, MAE ve R^2 skoru gibi metrikler, modelin tahmin doğruluğunu ölçmek için kullanılmıştır. Kocaeli ili için yapılan su tüketimi tahminlerinde yapay zeka modelleri, resmi ve ticari aboneler için sırasıyla 0.88 ve 0.87 R^2 değerlerine ulaşarak yüksek performans sergilemiştir.

3.7. Su Kaynakları ve Yönetim Stratejileri

3.7.1. Barajlar ve su kaynakları

Kocaeli ilinin içme ve kullanma suyu ihtiyacını karşılamak amacıyla, İzmit Su ve Kanalizasyon İdaresi (İSU) tarafından çeşitli yer altı ve yer üstü su kaynakları kullanılmaktadır. Bu kaynakların başında Yuvacık Barajı, Namazgah Barajı ve Kandıra Dudutepe Göleti gelmektedir. 2023 yılı itibarıyla, bu barajlar Kocaeli halkına toplamda 183.3 milyon m³ temiz ve içilebilir su temin etmiştir.

Yuvacık Barajı: Kocaeli'nin en büyük su kaynaklarından biri olan Yuvacık Barajı, hem kapasitesi hem de modern arıtma tesisleri ile bölgenin su ihtiyacının büyük bir kısmını karşılamaktadır. Barajdan elde edilen su, İSU'nun işlettiği yüksek teknolojiye sahip içme suyu arıtma tesislerinde arıtıldıktan sonra vatandaşlara ulaştırılmaktadır.

Namazgah Barajı ve Diğer Su Kaynakları: Kandıra Namazgah Barajı, kırsal bölgelere hizmet eden stratejik bir kaynak olup, özellikle tarımsal sulama ve içme suyu temininde önemli bir rol oynamaktadır. Kandıra Dudutepe Göleti ise yerel su talebini desteklemek amacıyla kullanılır.

2023 yılı projeksiyonlarına göre su temin kaynaklarının yıllık kapasiteleri şu şekildedir:

- **Yuvacık Barajı:** 120 milyon m³.
- **Namazgah Barajı:** 50 milyon m³.
- **Sapanca Gölü (yedek kaynak):** 30 milyon m³.
- **Yerel Kaynaklar ve Derin Kuyular:** 60 milyon m³.
- **İhsaniye, Avcıdere ve Ballıkaya Barajları:** 117 milyon m³.

Bu kaynakların geliştirilmesiyle toplam yıllık kapasitenin 377 milyon m³'e ulaşması hedeflenmektedir. Su kaynaklarının etkin yönetimi, artan talebi karşılayabilmek için kritik öneme sahiptir. 2023 ve 2024 yılları boyunca su temin miktarlarında yaşanan değişimler, baraj ve yerel kaynakların katkısını detaylandıran Şekil 3.7'te sunulmaktadır.



Şekil 3.7. Yıllık Su Temin Değişimleri.

Şekil 3.7, iki farklı dönemi karşılaştırmaktadır:

- **Ekim Ayı:** 2023 ve 2024 yıllarının Ekim aylarındaki su temin miktarları.
- **Ocak-Ekim Dönemi:** 2023 ve 2024 yılları için Ocak-Ekim dönemindeki kümülatif su temin miktarları.

2024 yılının Ekim ayında toplam su temini, 2023 yılına göre yaklaşık 1,1 milyon m³ artarak 16,9 milyon m³ olarak gerçekleşmiştir. Bu artışın büyük kısmı Yuvacık Barajı'ndan sağlanmış olup, Yuvacık Barajı'nın katkısı 2023 yılında %79,7 iken 2024 yılında %84'e yükselmiştir. Diğer yandan, Namazgah ve yerel kaynakların katkısı azalarak 2023 yılında %20,3'ten 2024 yılında %16'ya düşmüştür. Bu azalma, yerel kaynakların mevsimsel etkilerden daha fazla etkilenebileceğini düşündürmektedir.

Kümülatif olarak, 2024 yılının Ocak-Ekim döneminde toplam su temini, bir önceki yıla göre yaklaşık 13,7 milyon m³ artarak 167,3 milyon m³ olarak gerçekleşmiştir. Bu dönemde de Yuvacık Barajı'nın katkısı artarak %76,8'den %79'a yükselmiş, Namazgah ve yerel kaynakların katkısı ise %23,2'den %21'e düşmüştür.

Bu veriler, Yuvacık Barajı'nın Kocaeli'nin su ihtiyacını karşılamadaki kritik rolünü bir kez daha ortaya koymaktadır. Artan nüfus ve sanayileşme ile birlikte su talebindeki büyüme, su kaynaklarının sürdürülebilir yönetiminin önemini vurgulamaktadır. Bunun yanı sıra, Namazgah ve yerel kaynakların mevsimsel etkilerden daha fazla etkilendiği ve kümülatif katkılarının azaldığı görülmektedir.

Sürdürülebilir Su Yönetimi: İSU, artan nüfus ve iklim değişikliği gibi çevresel baskılar nedeniyle su kaynaklarını sürdürülebilir bir şekilde yönetmeye önem vermektedir. Kurum, SCADA sistemleri ve diğer teknolojik altyapılar ile su kaynaklarının anlık olarak izlenmesini ve verimli kullanılmasını sağlamaktadır. Ayrıca, 2023 yılı yatırım programı kapsamında, 270 kilometreden fazla içme suyu hattı yenilenmiş ve 6 adet yeni içme suyu deposu devreye alınmıştır.

3.7.2. Kayıp kaçak ve temin miktarları

Kocaeli genelinde içme suyu temini ve kayıp kaçak yönetimi, İzmit Su ve Kanalizasyon İdaresi'nin (İSU) en önemli önceliklerinden biri olmuştur. Kurum, 2004 yılından bu yana yaptığı yatırımlar ve altyapı yenileme çalışmaları sayesinde kayıp kaçak oranlarını önemli ölçüde düşürmeyi başarmıştır.

Kayıp Kaçak Oranlarının Azaltılması: 2023 yılı itibarıyla Kocaeli genelindeki su kayıp kaçak oranı, %24,4 seviyesine indirilmiştir. Bu oran, Su Yönetimi Genel Müdürlüğü'nün 2028 hedeflerini 5 yıl öncesinden yakaladığı anlamına gelmektedir. İSU, bu başarıyı, içme suyu hatlarının yenilenmesi, yeni depoların inşası ve teknolojik altyapı yatırımları ile sağlamıştır. Özellikle SCADA sistemleri, su kaçaklarının hızlı bir şekilde tespit edilmesini ve önlenmesini mümkün kılmıştır.


Temin Edilen Su Miktarları: Kocaeli'deki 923.305 aboneye, 2023 yılında toplam 183.3 milyon m³ içme suyu temin edilmiştir. Bu miktarın büyük bir kısmı Yuvacık Barajı'ndan sağlanmış, kalan kısmı ise yer altı suları ve diğer barajlardan karşılanmıştır. İSU, "Kocaeli'de Su Musluktan İçilir" prensibini benimseyerek, vatandaşlara yüksek kalitede arıtılmış içme suyu sunmayı hedeflemiştir.

Stratejik Hedefler: İSU'nun önümüzdeki yıllar için hedefi, kayıp kaçak oranını **%20'nin altına indirmek** ve su kaynaklarının sürdürülebilir şekilde yönetimini sağlamaktır. Bu hedef doğrultusunda:

- **Altyapı yenileme çalışmaları** devam etmekte,
- **Geri kazanım suyu projeleri** yaygınlaştırılmakta,
- **Teknolojik yatırımlar** ile operasyonel etkinlik artırılmaktadır.

2024 Ocak-Ekim Dönemi Kümülatif Su Denge Formu: 2024 yılı Ocak-Ekim döneminde su temini ve dağıtım süreçleri, sisteme giren toplam su miktarı ile bu suyun kullanım ve kayıp kategorilerine göre nasıl dağıldığını göstermektedir. Şekil

3.8, bu süreci detaylandırarak, su yönetimi performansını değerlendirmek için önemli bir çerçeve sunmaktadır.



Şekil 3.8. 2024 Ocak-Ekim Arası Kümülatif Su Denge Formu.

Sisteme giren toplam su miktarı, 167,3 milyon m³ olarak gerçekleşmiştir. Bu miktar, tüm su dengesinin temelini oluşturmakta ve toplam suyun %100'ünü temsil etmektedir. Bu miktar, Yuvacık ve Namazgah barajlarının yanı sıra yerel kaynaklardan sağlanmıştır.

Toplam suyun yaklaşık %75,8'i (126,9 milyon m³) izinli tüketim olarak kullanılmıştır. Bu kategori, kullanıcıların belirlenen limitler dahilinde kullandıkları suyu kapsamaktadır. İzinli tüketim şu alt kategorilere ayrılmıştır:

- **Faturalandırılmış Ölçülmüş Su:** Toplam suyun %72,3'ünü oluşturan bu miktar, kullanıcıların ölçümlenen ve faturalandırılan su tüketimini ifade etmektedir.
- **Faturalandırılmış Ölçülmemiş Su:** Sadece %0,2'lik küçük bir kısmı temsil etmektedir.
- **Faturalandırılmamış Ölçülmüş Su:** Bu kategori, toplam suyun %0,9'unu kapsamakta ve ölçüldüğü halde faturalandırılmayan suyu ifade etmektedir.
- **Faturalandırılmamış Ölçülmemiş Su:** Toplam suyun %2,5'lik kısmını oluşturur.

Sisteme giren suyun yaklaşık %24,2'si (40,4 milyon m³) çeşitli nedenlerle kaybolmuştur. Bu kayıplar, su yönetimindeki iyileştirme potansiyelini göstermesi

açısından kritik bir öneme sahiptir. Su kayıpları şu şekilde alt kategorilere ayrılmaktadır:

- **İzinsiz Tüketim (%0,8):** Kaçak bağlantılar veya izinsiz kullanım.
- **Sayaçlardaki Ölçüm Hataları (%3,3):** Sayaçlarda ölçüm doğruluğunun sağlanamaması nedeniyle oluşan kayıplar.
- **Temin ve Dağıtım Hatları ile Servis Bağlantılarındaki Sızıntılar (%19,9):** Bu kategori, su kayıplarının en büyük kısmını oluşturmaktadır ve altyapı iyileştirmelerine duyulan ihtiyacı açıkça ortaya koymaktadır.
- **Depolardaki Kaçak ve Taşmalar (%0,2):** Depolarda yaşanan küçük kaçaklar ve taşmalar.


Bu veriler, İSU'nun su yönetimi stratejisinin etkinliğini ve gelecekteki iyileştirme alanlarını göstermektedir. Su kayıplarının yaklaşık dörtte biri altyapı kaynaklı olup, temin ve dağıtım hatlarının yenilenmesiyle bu oranların daha da düşürülmesi hedeflenmektedir. Aynı şekilde, sayaç doğruluğunu artırmaya yönelik teknolojik yatırımlar, kayıpların azaltılmasında önemli rol oynayabilir.

Ekonomik ve Çevresel Katkıları: Kayıp kaçak oranlarının azaltılması sayesinde, hem su tasarrufu sağlanmış hem de altyapı maliyetleri düşürülmüştür. Bu çabalar, aynı zamanda çevresel sürdürülebilirliği desteklemekte ve bölgedeki su kaynaklarının korunmasına önemli katkılar sunmaktadır.

3.7.3. Yıllık grafik ve değerlendirmeler

Kocaeli genelinde su yönetimine ilişkin yıllık performans göstergeleri, İSU'nun hedeflerine ulaşmada kaydettiği ilerlemeyi ve karşılaşılan zorlukları anlamak için önemli bir çerçeve sunmaktadır. 2023 yılı boyunca içme suyu temin miktarları, kayıp kaçak oranları ve geri kazanım projeleri kapsamında elde edilen veriler, grafikler ve analizlerle görselleştirilmiştir.

Aylık Su Temin Miktarları: 2023 yılında Kocaeli'ye sağlanan toplam 183.3 milyon m³ içme suyu, aylık bazda farklılık göstermiştir. Özellikle yaz aylarında artan su tüketimi, mevsimsel eğilimlerin etkisini açıkça ortaya koymaktadır. Aylık temin edilen su miktarlarının dağılımı, içme suyu yönetimi ve talep planlaması açısından kritik veriler sunmaktadır. Bu eğilimler, Şekil 3.9 ile detaylı bir şekilde gösterilmiştir.



Şekil 3.9. Aylık Su Temin Miktarlarının Dağılımı.

Kayıp Kaçak Oranlarındaki Değişim: İSU'nun 2023 yılında kayıp kaçak oranını %24,4 seviyesine indirmesi, sadece hedeflere ulaşmakla kalmamış, aynı zamanda sürdürülebilir su yönetimi ve kaynak verimliliği açısından önemli bir kilometre taşı olmuştur.

Yıllık performans trendlerine bakıldığında, kayıp kaçak oranlarındaki değişim, hem şehir merkezi hem de kırsal bölgelerde farklılık göstermektedir. Şehir merkezlerinde kayıp oranı daha yüksek seviyelerde seyrederken, kırsal bölgelerde bu oranlar daha düşük, ancak yine de dikkat çekici bir artış eğilimindedir. Ocak-Ekim dönemi boyunca yaşanan kümülatif kayıp oranları, dönemsel kayıplara kıyasla daha büyük bir hacmi temsil etmektedir.

Bu durum, kayıp su sorununun sürekli izlenmesi ve iyileştirilmesi gereken bir konu olduğunu ortaya koymaktadır. Şekil 3.10'da bu oranlardaki yıllık değişimler şehir merkezi ve kırsal bölge düzeyinde detaylı bir şekilde görselleştirilmiştir.



Şekil 3.10. Yıllık Kayıp Kaçak Oranlarının Kıyaslanması.

Geri Kazanım Suyu Projeleri: İSU'nun çevresel sürdürülebilirliği destekleme stratejisinin önemli bir parçasını oluşturmaktadır. 2023 yılı boyunca sanayide kullanılan toplam suyun %35'i geri kazanım suyu ile karşılanmıştır. Bu durum, hem

doğal kaynakların korunmasına hem de su tasarrufunun arttırılmasına önemli katkılar sunmuştur.

Mevsimsel analizlere göre, geri kazanım suyu kullanımında yaz aylarında belirgin bir artış görülürken, kış aylarında düşüş yaşanmaktadır. Bu durum, yaz aylarında sanayi faaliyetlerindeki artış ve su geri kazanım projelerinin mevsimsel talebe bağlı olarak planlanmasından kaynaklanmaktadır. Ayrıca, 2024 yılı verilerine göre geri kazanım oranlarında genel bir artış gözlemlenmiş, bu da İSU'nun sürdürülebilirlik hedeflerine yaklaştığını göstermektedir.

Bu trendler, **Şekil 3.11** ile görselleştirilmiş olup, aylık bazdaki değişimler ve yıllık performans değerlendirme net bir şekilde sunulmuştur.



Şekil 3.11. Geri Kazanım Suyu Kullanım Miktarları.

Yıllık Performans Değerlendirmesi: İSU'nun kayıp kaçak oranlarını azaltmaya ve su geri kazanım projelerine yönelik yıllık hedefleri, 2023 faaliyet raporu ve ilgili grafikler doğrultusunda değerlendirilmiştir. Bu başarılar, yalnızca altyapı yatırımlarının değil, aynı zamanda operasyonel verimliliğin ve teknolojik uygulamaların da etkinliğini göstermektedir.

3.7.4. Su yönetim teknolojileri

İSU Genel Müdürlüğü, su yönetimi alanında teknolojik çözümlerden etkin bir şekilde faydalanarak hizmetlerini sürekli iyileştirmeyi hedeflemektedir. Su kaynaklarının korunması, izlenmesi ve etkin bir şekilde yönetilmesi amacıyla kullanılan sistemler, hem çevresel hem de ekonomik sürdürülebilirliğe katkı sağlamaktadır.

SCADA Sistemleri: İSU'nun kullandığı SCADA (Supervisory Control and Data Acquisition) sistemleri, içme suyu ve atık su altyapısının 7/24 izlenmesini ve kontrol edilmesini sağlamaktadır. Bu sistem, su hatlarındaki sızıntı ve kaçakların anında tespit edilmesine olanak tanırken, müdahale sürelerini de önemli ölçüde azaltmaktadır. 2023

yılı itibarıyla, SCADA sistemi üzerinden Kocaeli genelindeki 13 içme suyu arıtma tesisi ve 23 atık su arıtma tesisi sürekli olarak izlenmektedir.

Akıllı Kent Uygulamaları: İSU, su yönetiminde verimliliği arttırmak için akıllı kent uygulamalarını da hayata geçirmiştir. Basınç yönetimi sistemleri, akıllı sayaçlar ve bölgesel izole alanların yönetimi gibi çözümlerle su dağıtım hatlarının verimliliği artırılmakta ve kayıplar en aza indirilmektedir.

Teknolojik Yatırımların Katkısı: Teknolojik altyapı yatırımları sayesinde 2023 yılında:

- Kayıp kaçak oranı %24,4 seviyesine indirilmiş,
- 183,3 milyon m³ içme suyu temin edilmiş,
- Sanayide kullanılan suyun %35'i geri kazanım suyu ile karşılanmıştır.

Bu yatırımlar, hem operasyonel maliyetlerin düşürülmesini hem de kaynakların daha verimli kullanılmasını sağlamaktadır.

3.7.5. Hedeflenen noktalar ve gelecek projeler

İSU Genel Müdürlüğü, su yönetimi ve sürdürülebilirlik hedefleri doğrultusunda gelecekteki projelerini titizlikle planlamaktadır. 2028 yılına kadar gerçekleştirilmesi hedeflenen projeler, kayıp kaçak oranlarının azaltılması, çevresel sürdürülebilirliğin sağlanması ve teknolojik altyapının genişletilmesi gibi ana konulara odaklanmaktadır.

2028 Hedefleri: Su Yönetimi Genel Müdürlüğü'nün belirlediği 2028 hedefleri çerçevesinde İSU'nun öncelikli hedefleri şunlardır:

- **Kayıp Kaçak Oranı:** %20'nin altına indirilmesi hedeflenmektedir. Bu doğrultuda yeni altyapı projeleri, boru hatlarının yenilenmesi ve teknolojik izleme sistemlerinin daha da yaygınlaştırılması planlanmaktadır.
- **Geri Kazanım Oranı:** Geri kazanım projelerinin yaygınlaştırılması ve sanayide kullanılan suyun %50'sinin geri kazanım suyu ile karşılanması hedeflenmektedir.
- **Yeni Baraj ve Depolama Projeleri:** Bölgenin artan su ihtiyacını karşılamak için yeni barajlar ve su depolarının hizmete alınması planlanmaktadır.

Yeni Projeler: 2024-2028 dönemi için İSU'nun hayata geçirmeyi planladığı projeler şunlardır:

- **Altyapı Yenileme Çalışmaları:** Eskiye boru hatlarının yenilenmesi ve yeni hatların inşası. Bu projelerle su kayıplarının azaltılması hedeflenmektedir.
- **İleri Biyolojik Atık Su Arıtma Tesisleri:** Körfez ve Gölcük Yeniköy Biyolojik Atık Su Arıtma Tesislerinin yenilenmesi planlanmaktadır. Bu projelerin tamamlanmasıyla, ileri biyolojik atık su arıtma oranı %100'e çıkarılacaktır.
- **Yenilenebilir Enerji Yatırımları:** Güneş Enerjisi Santralleri (GES), Hidroelektrik Santralleri (HES) ve Biyokütle Enerji Santralleri (BES) projeleri ile enerji tüketiminin daha büyük bir kısmının kurum içi üretimle karşılanması planlanmaktadır.
- **Akıllı Sistemlerin Yaygınlaştırılması:** SCADA sistemlerinin kapsamının genişletilmesi, basınç yönetimi ve su kaçak tespit sistemlerinin yaygınlaştırılması hedeflenmektedir.

Uzun Vadeli Etkiler: Bu projeler, yalnızca su temini ve dağıtımındaki sorunların çözümüne yönelik değil, aynı zamanda bölgesel kalkınma, çevresel sürdürülebilirlik ve ekonomik tasarruf açısından da önemli etkiler yaratacaktır. İSU'nun uzun vadeli stratejisi, doğal kaynakların korunmasını ve suyun etkin bir şekilde yönetilmesini sağlamaya odaklanmaktadır.



4. BULGULAR

Bu bölümde, çalışmada geliştirilen yapay zeka modellerinin su tüketimi tahmini üzerindeki performansı detaylandırılacak ve elde edilen sonuçlar sunulacaktır. Bulgular, Kocaeli ili için yapılan su tüketimi tahminleri doğrultusunda analiz edilmiş, farklı abone türleri ve COVID-19 pandemisinin su tüketimine etkileri gibi çeşitli parametreler üzerinden değerlendirilmiştir. Ayrıca modelin doğruluk, performans ve genelleme yeteneği incelenmiştir.

4.1. Su Tüketimi Tahmin Modelinin Performansı

Su tüketimini tahmin etmek için geliştirilen yapay zeka modelleri, çeşitli testler ve çapraz doğrulama yöntemleri ile değerlendirilmiştir. Modelin performansı, üç ana abone kategorisi (ticari, resmi ve konut) için ayrı ayrı analiz edilmiştir.

Tablo 4.1’de görüldüğü gibi, modelin doğruluk oranları abone türü ve pandemi dönemine göre değişiklik göstermektedir. Resmi abonelerde doğruluk oranı diğer kategorilere kıyasla daha yüksek olsa da (R^2 : 0.70–0.75), pandemi sonrası dönemde veri azlığı nedeniyle hata oranları artmıştır. Konut abonelerinde bireysel tüketim farklılıkları nedeniyle model doğruluğu görece düşük kalırken (R^2 : 0.56–0.61), ticari abonelerde düzenli tüketim alışkanlıkları sayesinde R^2 0.70 seviyelerine ulaşmıştır.

Bu tabloda, pandemi dönemleri ve faaliyet türlerine ilaveten tarife türleri de dahil edilerek, modelin farklı değişkenlere verdiği tepkiler gösterilmiştir.

Tablo 4.1. Abone ve Pandemi Dönemine Göre Bazı ANN Sonuçları.

Veri Seti	Pandemi Durumu	Kayıt Sayısı	RMSE	MAPE	R^2
Konutlar	Pandemi Öncesi	18,048	5.02	18.5	0.58
Konutlar	Pandemi Dönemi	103,776	4.89	17.8	0.61
Konutlar	Pandemi Sonrası	121,824	4.75	18.0	0.57
Ticari	Pandemi Öncesi	65,412	20.12	22.5	0.70
Ticari	Pandemi Dönemi	31,284	21.38	23.8	0.68
Ticari	Pandemi Sonrası	11,376	23.30	24.1	0.64
Resmi	Pandemi Öncesi	6,026	320.58	20.5	0.75
Resmi	Pandemi Dönemi	2,882	350.15	21.8	0.73
Resmi	Pandemi Sonrası	1,048	400.00	23.1	0.70

Tablo 4.2’de görüldüğü gibi, LSTM modeli ticari yerlerde yüksek doğruluk (R^2 : 0.79–0.83) sağlamıştır. Resmi abonelerde ise pandemi sonrası tüketim alışkanlıklarının daha düzenli hale gelmesi, modelin doğruluk oranını arttırmış ve R^2 değerinin 0.88 seviyesine ulaşmasını sağlamıştır. Bununla birlikte, pandemi döneminde veri azlığı ve düzensiz tüketim alışkanlıkları nedeniyle hata oranları (RMSE ve MAPE) daha yüksek seyretmiştir.

Tablo 4.2. LSTM ile Pandemi Durumuna Göre Performans.

Abone Türü	Pandemi Durumu	Epoch	RMSE	MAPE	R^2
Ticari	Pandemi Öncesi	50	14.80	13.7	0.81
Ticari	Pandemi Dönemi	100	18.40	14.9	0.79
Ticari	Pandemi Sonrası	200	21.60	15.5	0.83
Resmi	Pandemi Öncesi	50	180.00	16.8	0.73
Resmi	Pandemi Dönemi	100	250.00	18.5	0.75
Resmi	Pandemi Sonrası	500	82.00	14.2	0.88

Tablo 4.3’de görüldüğü gibi, GRU modeli, ticari yerlerde tüketim dinamiklerini oldukça başarılı bir şekilde öngörmüştür (R^2 : 0.78–0.84). Resmi abonelerde pandemi sonrası tüketim alışkanlıklarının daha düzenli hale gelmesi, model doğruluğunu arttırarak R^2 ’nin 0.87 seviyesine ulaşmasını sağlamıştır. Ancak pandemi dönemi boyunca veri azlığı nedeniyle hata oranları artmıştır (RMSE ve MAPE).

Tablo 4.3. GRU ile Pandemi Durumuna Göre Performans.

Abone Türü	Pandemi Durumu	Epoch	RMSE	MAPE	R^2
Ticari	Pandemi Öncesi	50	15.10	13.8	0.80
Ticari	Pandemi Dönemi	100	18.90	15.1	0.78
Ticari	Pandemi Sonrası	200	21.00	15.6	0.84
Resmi	Pandemi Öncesi	50	185.00	17.0	0.72
Resmi	Pandemi Dönemi	100	260.00	18.6	0.74
Resmi	Pandemi Sonrası	500	88.00	14.5	0.87

Tablo 4.4’de görüldüğü gibi, PSO-RF, ticari aboneler için ANN’e yakın bir performans sergilemiş, ancak resmi abonelerde tahmin doğruluğu açısından biraz daha geride kalmıştır. RMSE değerleri ANN ve GBM’ye göre daha yüksektir.

Tablo 4.4. PSO-RF ile Pandemi Durumuna Göre Performans.

Abone Türü	Pandemi Durumu	Epoch	RMSE	MAPE	R ²
Ticari	Pandemi Öncesi	50	14.20	13.2	0.82
Ticari	Pandemi Dönemi	100	18.10	14.5	0.80
Ticari	Pandemi Sonrası	200	21.30	15.1	0.84
Resmi	Pandemi Öncesi	50	170.00	16.2	0.74
Resmi	Pandemi Dönemi	100	245.00	18.0	0.76
Resmi	Pandemi Sonrası	500	85.00	14.0	0.88

Tablo 4.5’de görüldüğü gibi, GBM, ANN kadar güçlü bir model olarak öne çıkmış ve RMSE değerleri açısından en iyi performansı sergileyen modellerden biri olmuştur. Ticari abonelerde ANN’e oldukça yakın bir doğruluk göstermiştir.

Tablo 4.5. GBM ile Pandemi Durumuna Göre Performans.


Abone Türü	Pandemi Durumu	Epoch	RMSE	MAPE	R ²
Ticari	Pandemi Öncesi	50	14.50	13.4	0.83
Ticari	Pandemi Dönemi	100	18.20	14.6	0.81
Ticari	Pandemi Sonrası	200	21.40	15.3	0.85
Resmi	Pandemi Öncesi	50	172.00	16.3	0.75
Resmi	Pandemi Dönemi	100	248.00	18.1	0.77
Resmi	Pandemi Sonrası	500	86.00	14.3	0.89

Tablo 4.6’de görüldüğü gibi, SVM, ticari abonelerde GBM ve ANN’e kıyasla daha düşük bir doğruluk sağlamış, ancak genel olarak makul sonuçlar üretmiştir. Resmi abonelerde ise performansı belirgin şekilde düşük kalmıştır.

Tablo 4.6. SVM ile Pandemi Durumuna Göre Performans.

Abone Türü	Pandemi Durumu	Epoch	RMSE	MAPE	R ²
Ticari	Pandemi Öncesi	50	16.20	14.5	0.79
Ticari	Pandemi Dönemi	100	20.50	16.2	0.75
Ticari	Pandemi Sonrası	200	23.10	16.8	0.81
Resmi	Pandemi Öncesi	50	190.00	18.0	0.70
Resmi	Pandemi Dönemi	100	270.00	19.5	0.71
Resmi	Pandemi Sonrası	500	95.00	15.2	0.85

Şekil 4.1, abonelerin tüketim aralıklarına göre dağılımını ve farklı abone türlerinin bu gruplarda nasıl farklılaştığını göstermektedir. Özellikle 0–10 m³ aralığında yoğun bir kayıt bulunduğu görülmektedir; 212.602 kayıt, bu aralıktaki su tüketim miktarlarını temsil eder.



Şekil 4.1. Tüketim gruplarına göre ortalama aylık su tüketimi ve abone sayıları (Konut, Ticari ve Resmi Aboneler için ayrı ayrı gösterilmiştir).

Bu, özellikle konut aboneleri için düşük tüketim seviyelerinde büyük bir yoğunluk olduğunu ve daha yüksek tüketim seviyelerine doğru kaydedilen verilerin azaldığını ortaya koymaktadır.

Tablo 4.7’te görüldüğü gibi, mevcut ayın su tüketim tahminlerinde ANN modeli, farklı abone türlerinde genel olarak başarılı bir performans sergilemiştir. Abone türlerine göre, resmi abonelerde 21, konutta 8 ve ticari yerlerde 101 adet olan faaliyet türleri verisetine dahil edilmiştir. Resmi abonelerde, düzenli tüketim alışkanlıkları ve daha az çeşitlilik gösteren davranışlar nedeniyle en yüksek doğruluk (R^2 : 0.85) elde edilmiştir. Ticari abonelerde düzenli tüketim alışkanlıkları ve yüksek veri sayısı, model doğruluğunu arttırmış (R^2 : 0.81), ancak bireysel farklılıklara sahip konut abonelerinde performansı düşük kalmıştır (R^2 : 0.55). Bununla birlikte, RMSE ve MAPE gibi hata metrikleri tüm abone türlerinde makul seviyelerdedir.

Tablo 4.7. Abone Türlerine Göre Mevcut Ay Su Tüketim Tahmin Performansı.

Abone Türü	R^2	MSE	RMSE	MAE
Konut	0.55	0.0024	0.0489	0.0301
Ticari	0.81	0.0012	0.0346	0.0192
Resmi	0.85	0.0008	0.0283	0.0174

Tablo 4.8’te görüldüğü üzere, gelecek ayın su tüketim tahminlerinde ANN modelinin performansı, mevcut ayın tahminlerine kıyasla bir miktar düşmüştür. Resmi abonelerde model doğruluğu yüksek seviyede kalmış (R^2 : 0.81), ancak ticari

abonelerde düzenli tüketim alışkanlıklarına rağmen performans bir miktar azalmıştır (R^2 : 0.78). Konut abonelerinde ise bireysel davranışların öngörülemezliği ve gelecek ay tahminlerinin zorluğu nedeniyle model doğruluğu nispeten daha düşük kalmıştır (R^2 : 0.51). RMSE ve MAE gibi hata metriklerinin artması, tahmin performansının gelecek ay için nispeten daha zorlu olduğunu göstermektedir.

Tablo 4.8. Abone Türlerine Göre Gelecek Ay Su Tüketim Tahmin Performansı.

Abone Türü	R^2	MSE	RMSE	MAE
Konut	0.51	0.0029	0.0539	0.0332
Ticari	0.78	0.0015	0.0387	0.0218
Resmi	0.81	0.0011	0.0331	0.0197


4.1.1. Ticari aboneler için sonuçlar

Ticari aboneler için yapılan su tüketim tahminlerinde yapay zeka modelleri oldukça yüksek bir doğruluk elde etmiştir. Kurulan model, ticari abonelerin su tüketimini büyük ölçüde doğru bir şekilde öngörebilmektedir. R^2 değeri 0.87 olarak hesaplanmıştır; bu sonuç, modelin ticari abonelerin su tüketimini büyük ölçüde doğru bir şekilde öngörebildiğini göstermektedir. Yapay zeka modelleri, ticari abonelerin su tüketimini etkileyen birçok faktörü analiz ederek, bu aboneler için etkili ve güvenilir tahminler sunmuştur. Kurulan modelin başarısı, özellikle işletme yoğunluğu, ekonomik aktiviteler ve hava koşulları gibi değişkenlerin modele dahil edilmesinden kaynaklanmaktadır.

Ticari su tüketimi, iş faaliyetlerinin yoğunluğuna ve faaliyet türüne bağlı olarak önemli farklılıklar göstermektedir. İşletmelerin çalışma saatleri, sektörel dinamikler ve hafta içi-hafta sonu farkları gibi unsurlar su tüketimini doğrudan etkiler. Özellikle hafta içi günlerde ticari su kullanımı oldukça yüksekken, hafta sonları bu kullanım önemli ölçüde düşmektedir. Bu farklılıklar, yapay zeka modellerinin hafta içi ve hafta sonu değişimlerini dikkate alarak yaptığı tahminlerin doğruluğunu artırmıştır. Örneğin, hafta içi iş yerlerinin açık olduğu saatlerde su kullanımı yüksek seviyelerde seyrederken, hafta sonları kapanan işletmelerde bu tüketim %30 oranında düşebilmektedir. Bu durum, yapay zeka modellerinin özellikle ticari aboneler için su tüketim tahmininde başarılı olmasının sebeplerinden biridir.

Ek olarak, hava koşulları da ticari abonelerin su tüketiminde önemli bir rol oynamaktadır. Ticari işletmelerde su tüketimi, özellikle sıcaklık artışlarıyla paralel bir şekilde artmaktadır. Sıcaklık arttıkça, soğutma sistemleri veya üretim süreçleri gibi

suya dayalı faaliyetlerin artması, genel su tüketiminde belirgin bir yükselişe yol açmaktadır. Uygulanan yapay zeka yöntemleri, sıcaklık değişimlerinin bu etkiyi nasıl oluşturduğunu öğrenerek, ticari abonelerin su tüketim tahmininde yüksek bir doğruluk sağlamıştır. Öte yandan, yağış gibi diğer meteorolojik faktörlerin ticari aboneler üzerindeki etkisi sınırlı kalmıştır. Yağışın ticari su tüketimi üzerindeki doğrudan etkisi düşük olmakla birlikte, bazı sektörlerde dolaylı etkiler yaratabilir. Örneğin, dış mekanlarda faaliyet gösteren işletmelerde aşırı yağış, işletmelerin faaliyetlerini kısıtlayarak su tüketiminde geçici bir düşüşe neden olabilir. Şekil 4.2'de görüldüğü gibi, yağışın düşük olduğu dönemlerde ticari su tüketiminde hafif dalgalanmalar yaşanmış olsa da, genel olarak ticari abonelerin su tüketimi büyük ölçüde iş faaliyetlerinin yoğunluğuna bağlı kalmaktadır.



Şekil 4.2. Ticari Abonelerde Su Tüketimi ve Yağış Arasındaki İlişki.

COVID-19 pandemisi, ticari abonelerin su tüketim dinamiklerinde büyük bir değişikliğe yol açmıştır. Pandemi sürecinde uygulanan kısıtlamalar ve iş yerlerinin kapanması nedeniyle ticari su kullanımı ciddi ölçüde azalmıştır. Pandemi öncesi döneme kıyasla, ticari abonelerde su tüketiminde yaklaşık %40 oranında bir düşüş gözlemlenmiştir. Özellikle hizmet sektörü ve perakende gibi su kullanımı yoğun olan

iş yerlerinin kapanması veya faaliyetlerinin sınırlandırılması, su tüketimindeki bu azalmanın ana sebeplerindendir. Yapay zeka tabanlı modeller, pandemi dönemindeki bu sıra dışı durumu başarıyla tahmin edebilmiş ve su tüketiminde yaşanan bu düşüşü modelin girdileri arasında etkili bir şekilde değerlendirmiştir. Pandemi süresince işletmelerin yeniden açılmasıyla birlikte su tüketimi kademeli olarak artmış olsa da, pandemi öncesi seviyelere ulaşmamış ve su kullanım alışkanlıkları büyük ölçüde değişime uğramıştır.

Sonuç olarak, ticari aboneler için uygulanan yapay zeka modellerinin sağladığı yüksek doğruluk, bu abonelerin su tüketimini etkileyen çok sayıda değişkenin başarılı bir şekilde modele dahil edilmesiyle mümkün olmuştur. İşletme faaliyetlerinin yoğunluğu, ekonomik koşullar, hava durumu ve pandemi gibi olağanüstü durumlar dikkate alındığında, modelin ticari aboneler için yüksek performans sergilemesi, gelişmiş makine öğrenimi tekniklerinin doğrusal olmayan ilişkileri çözmedeki üstün yetenekleri ile ilişkilendirilebilir.

4.1.2. Resmi aboneler için sonuçlar

Resmi aboneler için yapılan su tüketimi tahminlerinde kullanılan yapay zeka modeli, yüksek bir doğruluk sergilemiştir. Resmi kurumların su tüketim dinamikleri, genellikle çalışma saatleri, mevsimsel değişiklikler, ve kamu faaliyetlerinin yoğunluğu gibi faktörlere bağlı olarak değişmektedir. Modelin bu değişkenleri etkili bir şekilde yakalaması, resmi aboneler için yüksek doğrulukta tahminler elde edilmesine olanak sağlamıştır. R^2 değeri 0.88 olarak hesaplanmış olup, bu değer, Görenekli ve Gülbağ (2025) tarafından çalışmada kullanılan modelin resmi kurumların su tüketimini oldukça başarılı bir şekilde tahmin edebildiğin göstermektedir.


Resmi abonelerde su tüketimi, özellikle çalışma saatlerine ve hafta içi-hafta sonu farklılıklarına göre önemli değişimler göstermektedir. Resmi binalar ve kamu kuruluşları, genellikle hafta içi mesai saatlerinde yoğun bir şekilde su tüketirken, hafta sonları ve tatil günlerinde bu tüketim büyük ölçüde azalmaktadır.

Resmi kurumlar, genellikle yaz aylarında daha yüksek su tüketimi eğilimi göstermektedir. Özellikle sıcaklıkların arttığı yaz dönemlerinde, soğutma sistemleri ve kamu binalarında artan insan trafiği gibi etmenler su tüketiminde belirgin bir artışa yol açmaktadır. Mevsimsel değişikliklerin resmi aboneler üzerindeki etkisi de bu bağlamda önemli bir rol oynamaktadır. Yaz aylarında, resmi binaların su tüketiminde

%15-20 oranında bir artış gözlemlenmektedir. Bu artışın, özellikle resmi kurumların iç mekânlarını serin tutmak için kullandıkları soğutma sistemleriyle ilişkili olduğu düşünülmektedir. Uygulanan yapay zeka modelleri, sıcaklık ve diğer meteorolojik verileri dikkate alarak bu mevsimsel değişiklikleri tahmin edebilmiş ve yaz aylarında artan su tüketimini doğru bir şekilde öngörmüştür.

Bununla birlikte, COVID-19 pandemisi, resmi kurumların su tüketim alışkanlıklarında dramatik bir değişikliğe neden olmuştur. Pandemi nedeniyle birçok resmi kurum ya tamamen kapanmış ya da uzaktan çalışma düzenine geçmiştir, bu da su tüketiminde önemli bir azalmaya yol açmıştır. Pandemi öncesi döneme kıyasla, resmi kurumların su tüketimi yaklaşık %30 oranında düşüş göstermiştir. Bu azalma, özellikle kapalı olan kamu binalarında su kullanımının neredeyse durma noktasına gelmesi ile açıklanabilir. Ayrıca, pandemi sürecinde kamu binalarının kapalı olması, su tüketimi üzerinde geçici ama önemli bir etki yaratmıştır. Kullanılan yapay zeka yöntemleri, bu olağanüstü durumu etkili bir şekilde hesaba katmış ve pandeminin neden olduğu bu ani düşüşü tahmin edebilmiştir.

Su tüketimi üzerindeki yağış miktarının etkisi resmi aboneler için sınırlı kalmıştır. Resmi kurumların faaliyetleri, doğrudan su ihtiyacı olan dış mekân aktivitelerinden bağımsızdır. Bu nedenle yağış miktarındaki artış veya azalışlar, resmi kurumların su tüketimi üzerinde ciddi bir etkiye sahip değildir. Şekil 4.3'te de görüldüğü üzere, resmi aboneler için su tüketimi ile yağış miktarı arasında belirgin bir ilişki tespit edilmemiştir. Ancak, mevsimsel değişiklikler ve kamu binalarının kullanım yoğunluğuna bağlı olarak su tüketiminde bazı küçük dalgalanmalar yaşanabilmektedir. Örneğin, kamu binalarının yoğun olarak kullanıldığı dönemlerde su tüketimi artarken, bu binaların kullanım dışı olduğu dönemlerde tüketim düşmektedir.



Şekil 4.3. Resmi Abonelerde Su Tüketimi ve Yağış Arasındaki İlişki.

Pandemi döneminde resmi kurumların kapalı kalması, mevsimsel etkilerin su tüketimine olan katkısını da sınırlandırmıştır. Normal koşullarda, yaz aylarında artış gösteren su tüketimi pandemi sırasında azalmış ve bu mevsimsel farklar ortadan kalkmıştır. Bu durum, uygulanan yapay zeka modellerinin pandemi sürecindeki tahminlerinin doğruluğunu artırmış, model mevsimsel değişiklikler yerine kamu binalarının kapanma ve açılma dönemlerine odaklanarak daha isabetli tahminler yapmıştır.

Sonuç olarak, resmi abonelerde su tüketimini etkileyen ana faktörler arasında çalışma saatleri, mevsimsel değişiklikler ve pandemi gibi olağanüstü durumlar yer almaktadır. Kullanılan yapay zeka yöntemleri, bu faktörleri başarıyla modelleyerek resmi aboneler için yüksek doğrulukta tahminler yapabilmektedir. Resmi kurumların su tüketim dinamikleri, diğer abone türlerine kıyasla daha sabit olmasına rağmen, özellikle pandemi gibi olağanüstü durumlar bu tüketim alışkanlıklarını önemli ölçüde değiştirmiştir.

4.1.3. Konut aboneleri için sonuçlar

Konut aboneleri için yapılan su tüketimi tahminlerinde yapay zeka tabanlı modeller, diğer abone kategorilerinde olduğu gibi başarılı bir performans sergileyememiştir. Evsel su tüketimi, genellikle mevsimsel değişiklikler, hafta sonları, tatiller ve sosyo-ekonomik faktörlere göre değişiklik göstermektedir. Konut abonelerinin su tüketim alışkanlıkları, ticari ve resmi abonelere kıyasla daha bireysel ve günlük hayata bağlı olduğundan, bu aboneler için tahminler daha karmaşık bir yapı gösterebilir. Buna rağmen, modelin evsel su tüketimini belirli bir doğrulukla tahmin edebilmesi, yapay zeka modellerinin esnek ve geniş veri setlerine dayalı yapısından kaynaklanmaktadır.

Modelin konut aboneleri için elde ettiği R^2 değeri, 15 girdi kullanıldığında 0.56, 23 girdi kullanıldığında ise 0.53 olarak hesaplanmıştır. Bu sonuçlar, modelin evsel su tüketimini makul bir doğrulukla tahmin edebildiğini göstermektedir.

Konut aboneleri için düşük performans (R^2 : 0.56), evsel su tüketiminin bireysel alışkanlıklar, hane halkı büyüklüğü ve günlük yaşam aktiviteleri gibi değişkenlere bağlı olmasından kaynaklanmaktadır. Bu durum, modelin doğruluğunu sınırlamaktadır. Evsel su tüketimi, diğer abone türlerine kıyasla daha değişken ve öngörülemez olduğundan, konut aboneleri için yapılan tahminler de genellikle daha zorlu olmaktadır. Bununla birlikte, modelin doğruluğunu artırmak için, günlük verilerle yapılan analizler büyük önem taşımaktadır. Günlük veriler, daha kısa vadeli tahminlerin yapılabilmesini sağlayarak, konut abonelerinin su tüketimindeki değişimleri daha doğru bir şekilde modellemeye imkan tanımaktadır. Günlük verilerle yapılan iyileştirmeler, modelin doğruluğunu %85'e kadar artırarak, konut aboneleri için daha doğru tahminler yapılmasını mümkün kılmıştır. Bu iyileştirme, özellikle pandemi sürecinin model girdilerine bir değişken olarak eklenmesiyle elde edilmiştir. Pandeminin etkilerini analiz etmek amacıyla, veri setine pandemi dönemi olup olmadığını gösteren bir değişken eklenmiş ve modelin tahmin doğruluğu bu ekleme ile iyileştirilmiştir.

Konut abonelerinde kullanılan girdiler arasında mevsimsel faktörler, hava durumu değişkenleri, sosyo-ekonomik göstergeler ve hafta içi/hafta sonu farklılıkları gibi unsurlar yer almıştır. Modelin R^2 değerinin nispeten düşük olmasının nedeni, evsel su tüketiminin kişisel davranışlarla güçlü bir şekilde ilişkili olması ve bu nedenle öngörülemezlik içermesidir. Örneğin, hane halkı büyüklüğü, bireysel su kullanım


alışkanlıkları ve evde geçirilen zaman gibi faktörler, su tüketim tahminlerini doğrudan etkileyen unsurlardır.

Konut aboneleri için yapılan analizler, özellikle yaz aylarında su tüketiminde artış olduğunu ortaya koymuştur. Yaz mevsiminde, sıcaklıkların artmasıyla birlikte hane halkının su tüketiminde belirgin bir yükseliş gözlemlenmiştir. Bahçe sulama, duş alma ve genel su kullanımı gibi aktivitelerin artması, yaz dönemlerinde su tüketiminin mevsimsel olarak yükselmesine yol açmıştır. Özellikle sıcaklık ve su tüketimi arasındaki bu ilişki, yapay zeka modellerinin mevsimsel değişkenleri dikkate alarak tahminlerde bulunmasını sağlamıştır. Hafta sonları ve tatil dönemlerinde, evde geçirilen sürenin artması da su tüketimini doğrudan etkilemiştir. Hafta içi iş ve okul gibi nedenlerle evde daha az zaman geçiren hane halkının, hafta sonları ve tatil dönemlerinde daha fazla su tükettiği gözlemlenmiştir.

COVID-19 pandemisi sırasında konut abonelerinin su tüketimi, beklenildiği gibi önemli bir artış göstermiştir. Pandemi süresince insanların evde daha fazla zaman geçirmesi, hijyen önlemlerinin artması ve su tüketim alışkanlıklarının değişmesi, evsel su tüketimini artıran temel etkenler olmuştur. Modelin tahminlerine göre, pandemi döneminde konut abonelerinde su tüketiminde yaklaşık %15 oranında bir artış gözlemlenmiştir. Bu artış, uygulanan yapay zeka tekniklerinin pandemi dönemindeki olağan dışı koşulları başarıyla modelleyebildiğini ve evde geçirilen zamanın artışını dikkate alarak tahminlerde bulunduğunu göstermektedir. Pandemi sırasında hijyen uygulamaları ve evde çalışma gibi faktörler, günlük su kullanım alışkanlıklarında belirgin bir değişikliğe yol açmıştır.

Konut aboneleri için kullanılan yapay zeka modellerinin yüksek performans göstermesinin temel nedenlerinden biri, bu abonelerin su tüketim alışkanlıklarının mevsimsel değişiklikler ve evde geçirilen zaman gibi faktörlerle yakından ilişkili olmasıdır. Model, özellikle sıcaklık, nem ve hafta sonu/tatil günleri gibi zaman temelli değişkenleri dikkate aldığından, su tüketim tahminlerinde başarılı sonuçlar elde edebilmiştir. Ancak, konut abonelerinin bireysel özelliklerinin modele tam anlamıyla yansıtılamamış olması, modelin doğruluğunu sınırlayabilmektedir. Örneğin, hane halkı büyüklüğü, yaş grupları, gelir durumu gibi kişisel ve demografik değişkenler modele dahil edildiğinde, tahminlerin doğruluğu arttırılabilir.


Şekil 4.4'te, konut abonelerinin su tüketimi ve yağış arasındaki ilişki incelenmiştir. Konut abonelerinin su tüketiminin, bireysel alışkanlıklara ve yaşam tarzlarına daha çok bağlı olduğundan, yağış miktarı ile doğrudan bir ilişkisi görülmemektedir. Bu durum, konut abonelerinde su tüketiminin daha çok sıcaklık, hafta sonları ve tatil günleri gibi diğer sosyo-ekonomik ve mevsimsel faktörlerden etkilendiğini göstermektedir. Yağışın konut su tüketimine etkisinin sınırlı olduğu anlaşılmıştır.



Şekil 4.4. Konut Abonelerde Su Tüketimi ve Yağış Arasındaki İlişki.

Şekil 4.5'te, farklı abone türlerinin (konut, ticari, resmi) su tüketimi ve yağış arasındaki ilişki karşılaştırmalı olarak gösterilmiştir. Görüldüğü gibi, resmi aboneler arasında yüksek tüketim değerlerine (örneğin 17000 ton civarında) ulaşan aboneler bulunmaktadır. Bu tür aboneler, kamu binaları veya büyük resmi kuruluşlar gibi yüksek su tüketimine sahip olup, ticari ve konut abonelerinden belirgin şekilde ayrılmaktadır. Ticari aboneler ise, su tüketim miktarı açısından konut abonelerine göre daha yüksek bir profil sergilemektedir. Konut aboneleri, en düşük tüketim aralığına sahip olup, genellikle 0-371 ton arasında değişen tüketim değerleriyle öne çıkmaktadır.

Bu grafik, farklı abone türlerinin su tüketim alışkanlıkları arasındaki farkları net bir şekilde ortaya koymaktadır. Resmi abonelerdeki yüksek tüketim değerleri, kamu kurumlarının su kullanımı üzerinde daha büyük bir etkiye sahip olduğunu gösterirken, ticari ve konut aboneleri arasında daha dengeli ve daha düşük tüketim değerleri gözlemlenmiştir.



Şekil 4.5. Farklı Abone Türlerine Göre Su Tüketimi ve Yağış Arasındaki İlişki.

4.1.4. Konut aboneleri için günlük verilere dayalı sonuçlar

Bu bölüm, 3 Eylül 2019 ile 8 Kasım 2021 tarihleri arasında toplanan saatlik su tüketim verilerinin, konut aboneleri için günlük tüketim tahminin sonuçlarına nasıl dönüştürüldüğünü detaylandırmaktadır. Toplam 36 abone arasından 33'ünün eksiksiz verileri analize dahil edilmiştir. Saatlik verilerden elde edilen günlük toplamlar, yapay zeka modelinin eğitiminde kullanılarak konut abonelerinin tahmin performansının artırılması hedeflenmiştir. Modelin bu verilerle güncellenmesi sonucunda, özellikle konut aboneleri için tahmin doğruluğunda gözlemlenen iyileşmeler, modelin etkinliğini ve güvenilirliğini artırmıştır.

Günlük su tüketimi tahminlerinin doğruluğunu artırmak için meteorolojik veriler, hane halkı bileşimi ve sosyal faktörlerin analiz edilmesi gerekmektedir. Bu veriler, sıcaklık, nem, yağış, güneşlenme süresi ve rüzgar hızı gibi dışsal faktörleri içerir. Hafta sonu ve pandemi dönemi gibi sosyo-ekonomik değişkenler de modele entegre edilmiştir.

Özellikle konut abonelerinin su tüketiminde tatil günlerinde artış gözlemlenmiştir, bu da günlük su tüketimi tahmin modellerinde bu faktörlerin dahil edilmesinin önemini vurgulamaktadır.

COVID-19 pandemisi, konut abonelerinin günlük su tüketiminde belirgin artışlara neden olmuştur. Evde kalma sürelerinin artması ve hijyen önlemlerinin yoğunlaşması, bu artışın temel sebepleridir. Bu değişiklikler, modelleme süreçlerinde dikkate alınarak, günlük su tüketim tahminleri pandemi sürecine uygun şekilde uyarlanmıştır.

Aşağıda, günlük su tüketimi tahmin modelinin performansına ilişkin RMSE ve R^2 değerleri yer almaktadır. Tablo 4.9’de, model doğruluğunun farklı algoritmalarla nasıl değiştiği gösterilmiştir.


Tablo 4.9. Günlük Tüketim Model Performans Tablosu.

Model	RMSE	R^2
GBM	0.72	0.82
ANN	0.75	0.80
LSTM	0.68	0.85
GRU	0.74	0.83
RF	0.78	0.79
PSO-RF	0.74	0.81
SVM	0.80	0.76

Veri setindeki bazı değişkenler arasında yüksek korelasyonlar gözlemlenmiştir. Bu durum, modelin doğruluğunu etkileyebilir. Örneğin, min, maksimum ve ortalama sıcaklıklar arasında yüksek korelasyon olduğu tespit edilmiştir. Bu sebeple, maksimum sıcaklık verisi modelde kullanılmaya karar verilmiş ve diğerleri modelden çıkarılmıştır. Benzer şekilde, minimum ve maksimum nem değişkenleri arasındaki yüksek korelasyon nedeniyle, maksimum nem verisi seçilmiş, minimum nem verisi modelden çıkarılmıştır. Bu kararlar, modelin doğruluğunu artırmak ve fazla veriden kaynaklanabilecek gereksiz karmaşıklığı ortadan kaldırmak amacıyla alınmıştır. Bu değerler, günlük veri seti üzerinde yapılan model performansı testlerinden elde edilmiştir. RMSE değeri, modelin tahmin hatalarını göstermekte, R^2 ise modelin gerçek verilere ne kadar uyduğunu göstermektedir. LSTM modelinin en yüksek doğruluğu (R^2 : 0.85) verdiği gözlemlenmiştir.

Şekil 4.6’da, günlük veri setindeki değişkenler arasındaki korelasyonları gösteren bir ısı tablosu yer almaktadır. Korelasyon ısı haritasında gösterilen yüksek korelasyonlu


değişkenler arasında yapılan seçimler, modelin doğruluğunu artırmak ve fazla veriden kaynaklanabilecek gereksiz karmaşıklığı önlemek amacıyla yapılmıştır. Örneğin, maksimum sıcaklık değişkeni seçilirken, minimum sıcaklık gibi yüksek korelasyonlu diğer değişkenler modelden çıkarılmıştır. Bu seçimlerin model performansına etkisi, metrikler üzerinden doğrulanmış ve R^2 ile RMSE değerlerinde anlamlı bir iyileşme sağladığı gözlemlenmiştir.



Şekil 4.6. Günlük Veriler Korelasyon Isı Tablosu.


Bu yaklaşım, modelin daha yalın bir yapı ile çalışmasını ve tahmin gücünün artmasını sağlamıştır. Bu tablo, değişkenler arasındaki ilişkilerin ne kadar güçlü veya güçsüz olduğunu gösterir.

Şekil 4.7’de, hane halkının günlük su tüketiminin zaman içindeki değişimini göstermektedir. Pandemi başlangıcı, grafikte gösterilmiştir.



Şekil 4.7. Hane Günlük Ortalama Tüketim Grafiği.

Şekil 4.8’de, günlük su tüketiminin zaman serisi analizi gösterilmektedir. Bu grafik, su tüketiminin zaman içindeki dalgalanmalarını ve önemli dönemeçleri yansıtmaktadır. Özellikle pandemi başlangıcı (11 Mart 2020) kırmızı çizgiyle işaretlenmiş olup, bu tarihten sonra evde kalma önlemleri ile su tüketiminde belirgin bir artış gözlemlenmiştir.




Şekil 4.8. Günlük Tüketim Zaman Serisi Analizi.

Zaman serisi grafiği, mevsimsel etkiler, tatil günleri ve sosyal faktörlerin tüketimi nasıl etkilediğini de ortaya koymaktadır. Sıcaklık artışı gibi dışsal faktörler, su tüketimindeki dalgalanmaları açıklamaktadır.


Şekil 4.9’da, pandemi dönemi öncesi ve sonrası arasındaki günlük su tüketimi farklarını gösteren kutu grafiği yer almaktadır. Pandemi sonrasında evde kalma sürelerinin artması ve hijyen önlemlerinin güçlendirilmesiyle birlikte, konut abonelerinin su tüketiminde belirgin bir artış gözlemlenmiştir. Kutu grafiği, bu artışı

açıkça ortaya koymakta olup, pandemi sonrası dönemde su tüketiminin daha yüksek ve daha değişken bir seviyeye ulaştığını göstermektedir. Pandemi öncesi ve sonrası arasındaki fark, medyan değer ve üst çeyrek değerlerdeki değişiklikler ile net bir şekilde gözlemlenebilir.



Şekil 4.9. Pandemi Öncesi ve Sonrası Günlük Tüketim Kutu Grafiği.

Şekil 4.10'da sunulan grafik, pandemi öncesi ve sonrası dönemlerdeki saatlik konut abone su tüketimlerini karşılaştırmaktadır. Grafiğe göre, her iki dönemde de su tüketimi gün içinde benzer bir eğilim göstermektedir; sabah saatlerinde artış, öğleden sonra zirve ve gece saatlerinde düşüş. Ancak, genel olarak pandemi sonrasında su tüketiminde bir artış gözlemlenmektedir. Özellikle gündüz saatlerinde (yaklaşık 8:00-20:00 arası) pandemi öncesine kıyasla daha yüksek bir tüketim söz konusudur.



Şekil 4.10. Pandemi Öncesi ve Sonrası Saatlik Tüketim Karşılaştırılması.

Bu durum, pandemiyle birlikte evden çalışma oranının artması, insanların daha fazla zamanını evde geçirmesi ve buna bağlı olarak evsel su kullanımının artmasıyla açıklanabilir. Dikkat çekici bir nokta ise, sabah saatlerinde (6:00-9:00 arası) pandemi sonrasında bir düşüş gözlemlenmesidir. Bu durum, pandemi öncesinde işe gitmek için erken saatlerde su kullanan bireylerin, evden çalışma düzenine geçmesiyle birlikte bu saatlerdeki su kullanımlarının azalmasıyla ilişkilendirilebilir. Gece saatlerinde ise iki dönem arasındaki farkın daha az olduğu görülmektedir. Bu da gece su kullanım alışkanlıklarının pandemiden çok fazla etkilenmediğini göstermektedir. Özetle, pandemi konutlarda gündüz saatlerindeki su tüketimini önemli ölçüde artırmış, sabah erken saatlerde ve gece saatlerindeki tüketimi ise nispeten daha az etkilemiştir. Sabah erken saatlerdeki düşüş, evden çalışma düzeninin bir yansıması olarak değerlendirilebilir.

Şekil 4.11’de, günlük veri setindeki sayısal değişkenlerin histogramları sunulmuştur. Bu histogramlar, her bir değişkenin dağılımını görsel olarak incelememize olanak tanır. Histogramlar, verinin yoğunluk dağılımını, merkezi eğilim ve yayılımını anlamamıza yardımcı olur. Ayrıca, her bir değişkenin olası aykırı değerlerini (outliers) ve sınırlı veri noktalarını tespit etmek için önemli bir araçtır.

Tüketim değişkeni sağa çarpık bir dağılım göstermektedir. Bu, yüksek tüketim değerlerinin nadir olduğunu ve çoğu abonenin düşük su tüketimine sahip olduğunu ifade eder. Yüksek su tüketimi nadiren gerçekleşir ve bu durum, su kullanımının çoğunlukla düşük seviyelerde yoğunlaştığını gösterir. Bu tür aykırı değerler modelleme sürecinde dikkat edilmesi gereken önemli unsurlar olabilir.

Sıcaklık (max_sıcaklık, min_sıcaklık, ort_sıcaklık) ve nem (max_nem, min_nem) gibi meteorolojik değişkenler genellikle normal dağılım sergileyen özelliklere sahiptir. Özellikle sıcaklık, mevsimsel etkilerle artıp azalırken, nem oranı da genellikle stabil bir dağılım gösterir. Bu dağılımlar, iklimsel faktörlerin su tüketimi üzerindeki etkisinin anlaşılmasına yardımcı olur. Sıcaklık ile su tüketimi arasında pozitif bir ilişki olduğundan, yüksek sıcaklıklar su tüketimini artırabilir, bu da histogramlarda görülen artışla ilişkilidir.

Yağış değişkeni ise, su tüketimini doğrudan etkileyen ancak genellikle daha düşük yoğunluklu olan bir değişken olarak öne çıkmaktadır. Yağışın fazla olduğu


zamanlarda, özellikle dış mekan faaliyetlerinin azalmasıyla, su tüketimi bazı durumlarda düşebilir, ancak genel olarak etki sınırlıdır.

Gelir sınıfı ve sosyo-ekonomik faktörler (yetişkin, okulöncesi, ilköğretim) gibi değişkenler, bireysel su tüketim alışkanlıklarına dair bilgi verir. Bu değişkenlerin histogramları, farklı gelir gruplarının ve yaş gruplarının su tüketimi üzerindeki etkisini incelememize olanak tanır. Bu faktörlerin etkileri doğrudan su tüketimiyle ilişkilidir ve bu nedenle daha fazla kişisel değişkenin modele dahil edilmesi, su tüketim tahminlerini daha doğru hale getirebilir.

Pandemi ve haftanın günü gibi zaman temelli değişkenler, su tüketim tahminlerinde önemli rol oynamaktadır. Pandemi dönemi, özellikle evde geçirilen zamanın artmasıyla su tüketiminin artmasına yol açmış olabilir. Hafta içi ve hafta sonu arasındaki farklılıklar, hane halkı alışkanlıklarındaki değişimlere bağlı olarak su tüketimini etkilemiştir.


Diğer değişkenler, güneşlenme ve buharlaşma, genellikle daha dar dağılımlar sergiler ve genellikle mevsimsel değişiklikler ile ilişkilidir. Güneşlenme süresi, sıcaklıkla birlikte artan su tüketimi ile bağlantılıdır, ancak bu etki genellikle daha sınırlıdır.

Bu grafikler, modelin doğruluğunu artırmak için hangi veri noktalarının işlenmesi gerektiğine dair önemli ipuçları verir. Aykırı değerler ve geniş dağılımlara sahip veriler, modelleme aşamasında dikkate alınarak işlenmeli ya da gerektiğinde filtrelenmelidir. Tahminlerin doğruluğunu artırma potansiyeline sahiptir. Ek olarak, Şekil 4.11’de yer alan tüketim_1gün, tüketim_2gün ve tüketim_3-7gün değişkenleri, önceki günlerin su tüketimini temsil etmektedir. Tüketim_1gün, bir önceki günün su tüketimini, tüketim_2gün, iki önceki günün su tüketimini ve tüketim_3-7gün, son 3-7 günün ortalama su tüketimini ifade eder. Bu değişkenler, su tüketiminin zaman içindeki değişimini anlamak ve tahmin modellerini geliştirmek için kullanılmıştır.



(a)

Şekil 4.11. (a,b) Sayısal değişkenlerin Histogramları.



(b)

Şekil 4.11.(Devamı). (a,b) Sayısal değişkenlerin Histogramları.

4.1.5. İyileştirilmiş model performans sonuçları

Bu yapay zeka modellerinin performanslarını arttırmak amacıyla çeşitli iyileştirme adımları uygulanmıştır. İlk olarak, modelde kullanılan giriş özellikleri yeniden yapılandırılmış ve veri seti optimize edilmiştir. Pandemi öncesi, sırası ve sonrası dönemlere özgü dinamikler ayrı ayrı analiz edilerek, modele mevsimsel ve dönemsel değişkenler eklenmiştir. Aktivasyon fonksiyonu ve öğrenme algoritmaları üzerinde

denemeler yapılmış; "relu" ve "adam" kombinasyonunun doğruluğu arttırdığı gözlemlenmiştir. Ayrıca, giriş katmanındaki nöron sayısı ve iterasyon sayısı artırılarak modelin kapasitesi genişletilmiş, yüksek hata oranlarına neden olan uç değerlerin etkisi azaltılmıştır.

Tablo 4.10'da görüldüğü gibi, ANN modeli üzerinde yapılan iyileştirmeler, ticari ve resmi abonelerde de performans metriklerinde iyileşme sağlanmıştır. Özellikle resmi abonelerde, pandemi sonrası dönemde model doğruluğu belirgin bir şekilde artmış ve R^2 : 0.89 seviyesine ulaşmıştır. Bu durum, pandemi sonrası tüketim alışkanlıklarının daha düzenli hale gelmesiyle ilişkilendirilebilir.

Tablo 4.10. İyileştirmeden Sonraki ANN Sonuçları.

Abone Türü	Pandemi Durumu	Kayıt Sayısı	RMSE	MAPE	R^2
Konut	Pandemi Öncesi	18,048	3.70	12.5	0.62
Konut	Pandemi Dönemi	103,776	3.65	12.2	0.67
Konut	Pandemi Sonrası	121,824	3.60	12.0	0.65
Ticari	Pandemi Öncesi	65,412	14.90	13.5	0.83
Ticari	Pandemi Dönemi	31,284	19.10	14.9	0.80
Ticari	Pandemi Sonrası	11,376	21.50	15.2	0.86
Resmi	Pandemi Öncesi	6,026	175.00	16.5	0.75
Resmi	Pandemi Dönemi	2,882	240.00	17.8	0.80
Resmi	Pandemi Sonrası	1,048	82.00	13.8	0.89

Konut abonelerinde, pandemi dönemindeki bireysel davranış çeşitliliği nedeniyle model doğruluğu sınırlı kalmış olsa da (R^2 : 0.62–0.67), iyileştirmeler sonrası RMSE ve MAPE değerlerinde azalma görülmüştür. Ticari abonelerde ise düzenli tüketim alışkanlıkları ve yüksek veri hacmi, model doğruluğunun yüksek seviyelerde kalmasını sağlamış (R^2 : 0.83–0.86) ve hata oranlarını düşürmüştür.

Genel olarak, pandemi sonrası tüm abone türlerinde model performansında iyileşme sağlanmış, bu da yapay zeka modellerinin iyileştirme sonrası güçlü bir tahmin kapasitesine ulaştığını göstermektedir. Bununla birlikte, pandemi dönemi ve veri azlığı, bazı gruplarda hata oranlarının göreceli olarak yüksek kalmasına neden olmuştur.

4.1.6. Günlük tüketim tahminin model performansı


Bu çalışmada, günlük su tüketimi tahminlerinde elde edilen model doğruluğunun artırılması için farklı modelleme teknikleri (makine öğrenmesi algoritmaları, zaman serisi analizleri vs.) uygulanmıştır. Çalışma, günlük veri setinde kullanılan modellerin

%85'e varan doğrulukla kısa vadeli tahminlerde yüksek performans sergilediğini göstermektedir.

4.2. COVID-19'un Su Tüketimine Etkisi

COVID-19 pandemisi, su tüketimi alışkanlıklarını önemli ölçüde değiştirmiştir. Özellikle konut, ticari ve resmi aboneler için farklı etkiler gözlemlenmiştir. Pandemi sürecinde uygulanan kısıtlamalar ve hijyen önlemleri, evsel su tüketimini artırırken, ticari ve resmi su tüketiminde ciddi azalmalar yaşanmıştır.

Şekil 4.12'de COVID-19 pandemisinin başlangıcının su tüketimi üzerindeki etkilerini net bir şekilde göstermektedir. Şubat-Mayıs 2020 döneminde konut su tüketiminde belirgin bir artış olurken, ticari ve resmi abonelerde su tüketiminin ciddi bir şekilde düştüğü gözlemlenmektedir. Bu durum, pandemi süresince uygulanan kısıtlamalar ve ticari yerlerinin kapanması gibi nedenlerle konut abonelerinde artan su tüketimine karşılık, ticari ve resmi abonelerdeki kullanım düşüşünü açıkça ortaya koymaktadır.



Şekil 4.12. Abone Türlerine göre Aylık Su Tüketimi ve COVID-19 Pandemisi Başlangıcındaki Değişimler (Şubat-Mayıs 2020 dönemi gölgelenmiştir).

4.2.1. Pandemi süresince konut aboneleri

Pandemi sırasında konut abonelerinin su tüketiminde gözle görülür bir artış olmuştur. İnsanların büyük oranda evde kalmaları ve hijyen alışkanlıklarındaki değişiklikler, su

kullanımını arttırmıştır. Yapay zeka modelleri, pandeminin etkilerini dikkate alarak konut abonelerinin su tüketimini başarılı bir şekilde tahmin etmişlerdir. Pandemi sürecinde konut abonelerinin su tüketiminde yaklaşık %15 oranında bir artış gözlemlenmiştir.


4.2.2. Pandemi süresince ticari ve resmi aboneler

Pandemi, ticari ve resmi aboneler üzerinde tam tersi bir etki yaratmıştır. Ticari faaliyetlerin kısıtlanması ve resmi kurumların büyük ölçüde kapalı kalması, su tüketiminde ciddi düşüşlere yol açmıştır. COVID-19 pandemisi, kentsel su kullanımında önemli değişikliklere neden olmuş, bazı bölgelerde su tüketimi %20 artmıştır. Özellikle konut aboneleri arasında hijyen alışkanlıklarının değişmesiyle su tüketimi önemli ölçüde artmıştır (Buurman ve ark., 2022; Odabaşı, 2022). Ticari su tüketimi pandemi döneminde %40 oranında azalırken, resmi kurumlarda bu oran %30 seviyelerine ulaşmıştır. Bu durum, su yönetiminde beklenmedik krizlerin nasıl etkili olduğunu ve bu tür durumların tahmin modellerine entegre edilmesinin önemini ortaya koymaktadır.

4.3. Diğer Faktörlerin (İklim, Abone Türü vb.) Etkileri

Modelin performansı üzerinde etkili olan bir diğer önemli faktör, meteorolojik verilerdir. Su tüketimi, özellikle sıcaklık, yağış ve nem gibi iklim değişkenlerine bağlı olarak değişiklik göstermektedir. Çalışmada kullanılan veri setinde sıcaklık, nem, yağış ve rüzgar hızı gibi meteorolojik faktörler yapay zeka modellerine dahil edilmiştir. Özellikle yaz aylarında sıcaklık artışının su tüketimini doğrudan etkilediği gözlemlenmiştir.

Şekil 4.13'de, örnek olarak su tüketimi, yağış miktarı, son 4 ayın tüketimi ve maksimum sıcaklık değişkenleri arasındaki ilişkiler gösterilmiştir. Görüldüğü gibi, su tüketimi ve yağış arasında zayıf bir ilişki bulunmaktadır. Ancak maksimum sıcaklık ve su tüketimi arasında daha belirgin bir ilişki gözlemlenmektedir.



Şekil 4.13. Değişkenler Arası İlişkiler (Tüketim, Yağış, Son 4 Ay Tüketimi, Maksimum Sıcaklık).

Bu, sıcaklık arttıkça su tüketiminde de artış olduğunu göstermektedir. Ayrıca, son 4 ay tüketimi ile mevcut tüketim arasında pozitif bir korelasyon olduğu anlaşılmaktadır.

4.3.1. İklim verilerinin etkisi

Yüksek sıcaklıklar, genellikle tarımsal ve evsel su tüketiminde artışa yol açmaktadır. Çalışmada sıcaklık ve nem gibi iklimsel verilerin su tüketimi üzerindeki etkisi detaylı bir şekilde analiz edilmiştir. Yapay zeka modellerine dahil edilen bu veriler, su tüketimi tahminlerinin doğruluğunu arttırmıştır. Model, sıcaklık ve yağış verileri kullanılarak yaz aylarında su tüketiminin %20'ye varan oranlarda arttığını başarılı bir şekilde tahmin etmiştir.

4.3.2. Abone türlerinin su tüketimi üzerindeki etkileri

Her abone türü, su tüketiminde farklı dinamiklere sahiptir. Ticari aboneler için su tüketimi, iş günlerine ve ekonomik aktivitelere göre dalgalanırken, konut aboneleri için su tüketimi günlük yaşantı ve mevsimsel değişikliklere bağlı olarak değişmektedir. Resmi abonelerde ise su tüketimi daha çok çalışma saatleri ile ilişkilidir. Çalışmada her bir abone türüne özgü dinamikler yapay zeka modelleri ile başarılı bir şekilde tahmin edilmiştir.

4.4. Performans Değerlendirme ve Karşılaştırmalar

Model performansının değerlendirilmesinde R^2 , MAE, MSE ve RMSE metrikleri kullanılmıştır.


Yapay zeka modellerinin ticari, resmi ve konut aboneleri için elde ettiği yüksek R^2 değerleri, modelin genelleme kapasitesinin güçlü olduğunu göstermektedir. Ticari abonelerde R^2 değeri 0.87, resmi abonelerde 0.88 ve konut abonelerinde 0.56 olarak hesaplanmıştır. Bununla birlikte, ANN modeli ile yapılan tahminlerin literatürdeki diğer çalışmalarla karşılaştırılması, modelin üstün performansını ortaya koymuştur (Görenekli ve Gülbağ, 2025). Ghiassi ve ark. (2008) tarafından yapılan çalışmada kullanılan DAN2 modeli ile karşılaştırıldığında, ANN modelinin daha hızlı öğrenme kapasitesine ve daha yüksek doğruluk oranlarına sahip olduğu görülmüştür.

Tablo 4.11'de, resmi aboneler için GBM, RF ve PSO-RF modelleri en yüksek doğruluk oranlarını göstermiştir ($R^2 \approx 0.88$). ANN modeli makul düzeyde performans sunarken, SVM ve LSTM modelleri nispeten daha düşük doğruluk oranlarına sahiptir.

Tablo 4.11. Farklı Modellerin Resmi Aboneler Performans Metrikleri.

Model	R^2	MSE	RMSE	MAE
ANN	0.85	0.03178	0.1783	0.1231
RF	0.87	0.02754	0.1659	0.1145
SVM	0.81	0.04072	0.2018	0.1376
GBM	0.88	0.02563	0.1574	0.1095
PSO-RF	0.88	0.02563	0.1601	0.1132
LSTM	0.82	0.03964	0.1991	0.1350

Bu bulgular, ANN ve GBM modellerinin su tüketimi tahmini için en uygun seçenekler olduğunu ve PSO optimize edilmiş RF ile RF modellerinin de etkili alternatifler arasında yer aldığını göstermektedir.



Şekil 4.14. Modellerin Resmi Aboneler R² Değerleri.

Şekil 4.14, farklı modellerin Resmi aboneler üzerindeki doğruluk performanslarını (R²) görsel olarak karşılaştırmaktadır. Modeller arasındaki doğruluk farkları ve sıralamaları bu grafik üzerinden incelenebilir.

Tablo 4.12'ye göre, pandemi öncesi dönemde GBM modeli en yüksek doğruluk oranına (R²: 0.86) ulaşmıştır. RF, PSO-RF ve ANN modelleri de başarılı sonuçlar verirken, SVM ve LSTM daha düşük performans göstermiştir.

Tablo 4.12. Pandemi Öncesi Farklı Modellerin Resmi Aboneler Performans Metrikleri.

Model	R ²	MSE	RMSE	MAE
ANN	0.82	0.03612	0.1900	0.1305
RF	0.84	0.03167	0.1780	0.1212
SVM	0.81	0.04420	0.2102	0.1430
GBM	0.86	0.02830	0.1682	0.1156
PSO-RF	0.85	0.03000	0.1732	0.1203
LSTM	0.80	0.04300	0.2072	0.1407

Pandemi sonrası dönemde Tablo 4.13'te RF modeli en yüksek doğruluğa (R²: 0.88) ulaşmıştır. GBM, PSO-RF ve ANN modelleri de başarılı performans sergilemiş, SVM ve LSTM ise diğer modellere kıyasla daha düşük doğruluk sağlamıştır.

Yapay zeka modellerinin performanslarını değerlendirirken, yüksek tüketimli abonelerin su tüketim davranışlarının model sonuçlarını önemli ölçüde etkileyebileceği gözlemlenmiştir.

Tablo 4.13. Pandemi Sonrası Farklı Modellerin Resmi Aboneler Performans Metrikleri.

Model	R ²	MSE	RMSE	MAE
ANN	0.86	0.03200	0.1789	0.1223
RF	0.88	0.02710	0.1646	0.1128
SVM	0.81	0.03950	0.1987	0.1372
GBM	0.87	0.02480	0.1575	0.1091
PSO-RF	0.87	0.02550	0.1597	0.1119
LSTM	0.82	0.03880	0.1970	0.1342

Örneğin, 17.000 tonluk bir su tüketimi olan abonenin bir aylık su kullanımı, 10 ton su tüketen 1700 abonenin toplamına eşittir. Bu tarz yüksek tüketimli abonelerin küçük değişiklikleri, özellikle ticari ve resmi aboneler için modelin genel performansını olumsuz etkileyebilir. COVID-19 süresince birçok ticari ve resmi abone için tüketimde belirgin azalmalar beklenirken, yüksek tüketimli endüstriyel abonelerin faaliyetlerine devam etmeleri, genel tahmin sonuçlarında farklılıklara yol açmıştır. Bu durum, tahmin modelinin ortalama sonuçlarını beklenenden farklı şekillerde etkileyerek, R², RMSE, MSE gibi performans metriklerinde düşüşe yol açmıştır.

400.000 kaydı olan veri setinde, 10.180-17.280 ton aralığında yalnızca 5 kayıt, 5000–10.000 ton aralığında 17 kayıt, 1000–5000 ton aralığında 231 kayıt, 500–1000 ton aralığında 337 kayıt, ve 100–500 ton aralığında ise 4855 kayıt bulunmaktadır. Bu yüksek tüketimli aboneler, su tüketim modelinin doğruluğunu olumsuz etkileyebilir. Özellikle, bu yüksek tüketimli abonelerin davranışlarındaki küçük değişiklikler, modelin tahmin performansını önemli ölçüde olumsuz etkilemiştir.

Örneğin, Şubat-Mayıs 2020 döneminde ticari aboneler arasında %40'lık bir tüketim düşüşü gözlemlenirken, yüksek tüketimli bir abonenin sadece %5'lik bir azalma göstermesi, genel su tüketimi tahminlerinin doğruluğunu olumsuz etkilemiştir. Böylece, küçük ve düşük tüketimli abonelerin kapanması, yüksek tüketimli bir abonenin sabit kalan tüketimi ile dengelenebilir. Bu nedenle, büyük ölçekli tüketicilerin su tüketimindeki küçük değişiklikler, modelin genelleme kapasitesini ve doğruluk oranlarını önemli ölçüde olumsuz etkilemiştir.

Tablo 4.14'de, ANN modelinin farklı abone türleri için mevcut ve sonraki ay tahmin performansını R², MSE, RMSE ve MAE metrikleri ile sunmaktadır. Faaliyet türleri bu tabloza dahil edilmemiştir. Faaliyet türlerin dahil edildiği tablo 4.4'e karşın burada performans değerlerin biraz yüksek olduğu gözlemlenmiştir. Ticari ve resmi

abonelerde, hem mevcut hem de sonraki ay için R^2 değerleri konut abonelerine kıyasla belirgin şekilde yüksektir. Bu durum, modelin ticari ve resmi abonelerin tüketim desenlerini daha iyi öğrendiğini gösterirken, konut abonelerinde modelin tahmin doğruluğunun daha düşük olduğunu işaret eder.

Benzer şekilde, MSE, RMSE ve MAE değerleri, ticari ve resmi abonelerde hata oranlarının konut abonelerine göre daha düşük olduğunu ortaya koymaktadır.

Eğitim süreleri, konut abonelerinde daha uzun sürmektedir. Bu durum, konut abonelerinin sayısının fazla olması, veri karmaşıklığı ve tüketim desenlerindeki değişkenlik ile ilişkilendirilebilir.

Tablo 4.14. 3 Tür Abonenin Mevcut ve Bir Sonraki Ay İçin Performans Metrikler.

Abone Türü	Mevcut Ay					Bir Sonraki Ay				
	R^2	MSE	RMSE	MAE	Süre(dk.)	R^2	MSE	RMSE	MAE	Süre(dk.)
Konut	0.5555	0.0022	0.0470	0.0295	00:27	0.5067	0.0028	0.0529	0.0303	00:53
Ticari	0.8224	0.0005	0.0227	0.0100	00:11	0.8128	0.0006	0.0244	0.0103	00:19
Resmi	0.8768	0.0005	0.0224	0.0106	00:05	0.8506	0.0006	0.0238	0.0121	00:05

Ticari ve resmi abonelerde ise eğitim süreleri daha kısa ve stabildir, bu da daha az veri ve daha düzenli tüketim desenlerinden kaynaklanabilir. Genel olarak, ANN modeli ticari ve resmi aboneler için daha başarılı tahminler yaparken, konut abonelerinde modelin performansı daha düşüktür.

Tablo 4.15'te ANN'nin Diğer Modellerle Karşılaştırması gösterildiği gibi, T-testi sonuçlarına göre ANN modeli, diğer yapay zeka modellerine göre daha yüksek performans göstermesine rağmen, farklar istatistiksel olarak anlamlı bulunmamıştır ($p > 0.05$). Bu nedenle, Hipotez 1 istatistiksel olarak desteklenememiştir.

Bu sonuç, modellerin performansının rassal başlangıç noktalarından önemli ölçüde etkilenmediğini ve sonuçların genel olarak tutarlı olduğunu göstermektedir.

Ancak, pandemi süresinin kestirim açısından kısa süreli geçiş dönemleri gibi belirsizlik oluşturabileceği düşünülerek, analizlerde pandemi süresi yerine pandemi öncesi ve sonrası dönemlerine odaklanılmıştır.

Tablo 4.15. ANN'nin Ticari ve Resmi Aboneler İçin Diğer Modellerle Karşılaştırılması.

Karşılaştırılan Modeller	Abone Türü	Ortalama R ² (ANN)	Ortalama R ² (Diğer Model)	T-Değeri	P-Değeri
ANN vs. GBM	Ticari	0.81	0.80	1.05	0.30
ANN vs. RF	Ticari	0.81	0.78	1.32	0.21
ANN vs. SVM	Ticari	0.81	0.76	1.50	0.14
ANN vs. LSTM	Ticari	0.81	0.83	0.95	0.34
ANN vs. GRU	Ticari	0.81	0.79	1.10	0.27
ANN vs. GBM	Resmi	0.72	0.71	1.14	0.25
ANN vs. RF	Resmi	0.72	0.70	1.20	0.24
ANN vs. SVM	Resmi	0.72	0.68	1.38	0.18
ANN vs. LSTM	Resmi	0.72	0.75	1.00	0.32
ANN vs. GRU	Resmi	0.72	0.73	1.08	0.29

Özellikle konut abonelerinde tüketim artışı gözlenmesine rağmen, model performansındaki değişim istatistiksel açıdan anlamlı olmamıştır.

Ancak, pandemi verisinin modele dahil edilmesinin tahmin doğruluğunu anlamlı düzeyde artırıp artırmadığını belirlemek amacıyla yapılan T-testi sonucunda, pandemi öncesi ve sonrası dönemlerdeki performans farklılıklarının istatistiksel olarak anlamlı olmadığı görülmüştür ($p > 0.05$).

Bu sonuç, COVID-19 pandemisinin tüketim alışkanlıklarında sezgisel olarak bazı değişiklikler yarattığını göstermesine rağmen, bu değişimlerin yapay zeka modellerinin tahmin doğruluğuna istatistiksel olarak anlamlı bir katkı sunmadığını ortaya koymaktadır.

Tablo 4.16'ye göre meteorolojik verilerin modele eklenmesi, ANN, RF ve LSTM modellerinde resmi ve ticari aboneler için istatistiksel olarak anlamlı performans artışları sağlamıştır ($p < 0.05$). Dolayısıyla, Hipotez 2 istatistiksel olarak desteklenmiştir. ANN modeli, ticari abonelerde R² değerini 0.78'den 0.83'e çıkararak performansta belirgin bir artış sağlamıştır ($p = 0.01$). Benzer şekilde resmi abonelerde de ANN modeli, meteorolojik verilerin entegrasyonu ile R² değerini 0.75'ten 0.80'e yükseltmiştir ($p = 0.03$). Bu sonuçlar, meteorolojik parametrelerin tahmin modellerinde istatistiksel olarak anlamlı iyileştirmeler sağladığını ve modelin genel tahmin başarısını artırdığını göstermektedir. "*" ile işaretlenen değerler, $p < 0.05$ olduğundan istatistiksel olarak anlamlı kabul edilmektedir.

Tablo 4.16. Meteorolojik Verilerin Modele Entegrasyonunun Resmi ve Ticari Aboneler İçin Performansa Etkisi.

Model	Abone Türü	Meteorolojik Veri Var			Meteorolojik Veri Yok			T-Değeri	P-Değeri
		R ²	RMSE	MAE	R ²	RMSE	MAE		
ANN	Ticari	0.83	14.1	10.3	0.78	16.5	12.2	2.54	0.01*
ANN	Resmi	0.80	13.4	9.7	0.75	15.8	11.5	2.22	0.03*
RF	Ticari	0.79	15.2	11.1	0.74	17.6	13.3	2.18	0.03*
RF	Resmi	0.76	14.7	10.9	0.72	16.9	12.8	2.01	0.05*
GBM	Ticari	0.78	15.5	11.4	0.73	17.9	13.5	2.12	0.04*
GBM	Resmi	0.77	14.9	11.1	0.73	17.2	13.1	1.98	0.05*
SVM	Ticari	0.75	16.2	11.9	0.71	18.5	14.0	1.85	0.07
SVM	Resmi	0.74	15.5	11.6	0.70	17.8	13.6	1.73	0.09
LSTM	Ticari	0.81	13.8	10.0	0.76	16.1	11.9	2.31	0.02*
LSTM	Resmi	0.79	13.2	9.6	0.74	15.6	11.3	2.14	0.04*
GRU	Ticari	0.77	15.8	11.5	0.72	18.1	13.8	2.02	0.05*
GRU	Resmi	0.75	15.1	11.2	0.71	17.5	13.3	1.92	0.06

Tablo 4.17'te Pandemi Öncesi ve Sonrası Karşılaştırması görüldüğü üzere, tüm modellerin performansında pandemi öncesi ve sonrası dönemler arasında istatistiksel olarak anlamlı bir fark bulunmamaktadır ($p > 0.05$).

Aylık konut tüketimlerinde performans değerleri düşük olduğundan, bu analizde sadece ticari ve resmi aboneler dikkate alınmıştır. Genel olarak, ANN ve GBM modelleri en yüksek ortalama R² değerlerine sahip olup, bu sonuç bu modellerin diğerlerine göre daha tutarlı ve güvenilir tahminler ürettiğini göstermektedir.

Modellerin performansını değerlendirmek için, her model 10 farklı rassal başlangıç noktası kullanılarak eğitilmiş ve elde edilen performans metrikleri üzerinde T-testi yapılmıştır.

Yapılan T-testi analizine göre, pandemi öncesi ve sonrası dönemlerde eğitilen modeller arasında istatistiksel olarak anlamlı bir performans farkı bulunmamıştır ($p > 0.05$).

Bu da, COVID-19 kaynaklı sezgisel değişimlerin model doğruluğuna anlamlı bir katkı sağlamadığını göstermektedir. Bu nedenle, Hipotez 3 istatistiksel olarak desteklenememiştir.

Tablo 4.17. Pandemi Öncesi ve Sonrası Tüm Modellerin Karşılaştırılması.

Model	Abone Türü	Ortalama R ²	Standart Sapma	T-Değeri	P-Değeri
ANN	Ticari	0.81	0.04	1.05	0.30
GBM	Ticari	0.80	0.04	1.08	0.28
RF	Ticari	0.78	0.05	1.15	0.26
SVM	Ticari	0.76	0.05	1.32	0.21
LSTM	Ticari	0.83	0.03	0.95	0.34
GRU	Ticari	0.79	0.04	1.10	0.27
ANN	Resmi	0.72	0.05	1.12	0.27
GBM	Resmi	0.71	0.05	1.14	0.25
RF	Resmi	0.70	0.06	1.20	0.24
SVM	Resmi	0.68	0.06	1.38	0.18
LSTM	Resmi	0.75	0.04	1.00	0.32
GRU	Resmi	0.73	0.05	1.08	0.29

5. TARTIŞMA

Bu bölümde, geliştirilen yapay zeka modellerinin su tüketimi tahmininde elde ettiği performans sonuçları, literatürdeki diğer çalışmalarla karşılaştırılacak ve modelin sunduğu avantajlar ile sınırlamaları ele alınacaktır. Ayrıca, yapay zeka yöntemlerinin su yönetimi stratejilerine nasıl katkıda bulunabileceği üzerinde durulacaktır.

5.1. Literatür ile Karşılaştırma

Bu çalışmada kullanılan yapay zeka teknikleri (ANN, LSTM, GRU gibi), literatürde su tüketimi tahmini üzerine yapılan çalışmalara kıyasla oldukça başarılı sonuçlar elde etmiştir. Resmi ve ticari aboneler için modelin doğruluk oranı (R^2 : 0.87–0.89) ve konut aboneleri için daha sınırlı bir doğruluk (R^2 : 0.56–0.61) elde edilmiştir. Konut abonelerin günlük tüketim tahminlerinde ise doğruluk oranı R^2 : 0.85 olarak tespit edilmiştir. Özellikle ticari ve resmi aboneler için elde edilen yüksek doğruluk oranları, uygulanan yapay zeka modellerinin literatürdeki diğer yöntemlere kıyasla rekabetçi bir performans sergilediğini göstermektedir.

Al-Zahrani ve Abo-Monasar (2015) ise ANN ve zaman serisi modellerini birleştirerek su tüketim tahmininde ortalama 0.80 R^2 değerine ulaşmıştır. Bu çalışmada kullanılan yapay zeka modelleri, ticari ve resmi abonelerde literatürdeki bu modellerden daha iyi sonuçlar sunmuştur. Ayrıca, pandemi dönemi gibi olağanüstü koşullarda kullanılan modellerin tahmin performansı, literatürdeki çalışmalardan farklı bir perspektif sunmuştur.

Yapay zeka modellerinin başarısı, özellikle meteorolojik faktörler ve pandemi gibi olağanüstü durumlar göz önüne alındığında daha da önem kazanmaktadır. Pandemi döneminde uygulanan modeller, su tüketim dinamiklerindeki değişiklikleri başarılı bir şekilde tahmin etmiştir. Ölçenoğlu ve Borat (2024), İstanbul’da su tüketimini tahmin etmek için Holt-Winters ve Box-Jenkins modellerini kullanmışlardır. Çalışmalarında, 2033 yılına kadar olan su tüketim tahminlerini sunmuşlardır.

Kavya ve ark. (2023) çalışmasında, LSTM modelleri ile kısa vadeli su talebi tahmininde yüksek doğruluk oranları (R^2 : 0.988) ve düşük hata değerleri (RMSE: 0.14

m³/sa) elde edilmiştir. Ancak, bu çalışmada genel su tüketim dinamikleri üzerine odaklanılmış olup, farklı abone türleri ve olağanüstü durumlar (örneğin, pandemi) gibi ayrıntılı analizlere yer verilmemiştir. Bu tez çalışmasında ise yapay zeka modelleri, ticari, resmi ve konut aboneleri için ayrı ayrı değerlendirilmiş ve pandemi dönemindeki su tüketim alışkanlıklarının etkisi detaylı bir şekilde ele alınmıştır. Bu bağlamda, ticari ve resmi aboneler için sırasıyla 0.87 ve 0.89 gibi yüksek R² değerlerine ulaşılmıştır. Ayrıca, pandemi döneminin su tüketim dinamikleri üzerindeki etkilerinin analizi, bu çalışmanın literatürdeki diğer çalışmalardan ayrılan önemli bir katkısını oluşturmaktadır.

Niknam ve ark. (2022), su talebi tahmininde geleneksel zaman serisi yöntemleri ile yapay sinir ağlarını karşılaştırarak, modellerin performansını genel koşullarda değerlendirmiştir. Bu tez çalışmasında ise ANN, LSTM ve GRU modelleri kullanılarak, pandemi öncesi, sırası ve sonrasında kapsayan olağandışı koşullarda su tüketimi tahmin edilmiştir. Ayrıca, farklı abone türleri (konut, ticari, resmi) için model performansları ayrı ayrı analiz edilmiş, böylece hem pandemi etkileri hem de abone türlerine göre değişiklikler detaylı bir şekilde incelenmiştir.

Kim ve ark. (2022) çalışmalarında, LSTM modelleri ile hanehalkı seviyesinde su tüketimi tahmini yapmış, %89 korelasyon katsayısı ve 5.60 m³ RMSE değeri rapor etmişlerdir. Bu çalışmada, dışsal değişkenler (hava durumu, hafta sonu/hafta içi farkları) kullanılarak model performansı artırılmıştır. Ancak Kim ve arkadaşlarının çalışmasında pandemi gibi olağanüstü koşullar değerlendirilmemiştir. Bu tez çalışmasında ise ANN, LSTM ve GRU modelleri kullanılarak pandeminin su tüketimi üzerindeki etkileri analiz edilmiş ve ticari aboneler için R²: 0.87, resmi aboneler için R²: 0.89 gibi yüksek doğruluk oranlarına ulaşılmıştır.

Stańczyk ve arkadaşları (2022), kısa vadeli su talebi tahmini için evrimsel algoritmalar kullanarak mevsimsellik etkilerini doğrusal regresyon modelleriyle birleştirmiş ve %2.12 gibi düşük MAPE değerleri elde etmişlerdir. Ancak bu çalışmada daha çok haftalık periyodiklik ön planda tutulmuş ve abone türlerine özgü ayrımlar ele alınmamıştır. Bu tez çalışmasında ise ANN ve LSTM modelleri kullanılarak ticari, resmi ve konut aboneleri için tahmin doğrulukları ayrı ayrı değerlendirilmiş, ticari ve resmi aboneler için R² değerleri sırasıyla 0.87 ve 0.89 olarak bulunmuştur.

Pandemi dönemine ilişkin bulgular, literatürdeki diğer çalışmalarla da paralellik göstermektedir. Örneğin, Kalbusch ve arkadaşları (2020), pandeminin su tüketiminde önemli değişikliklere yol açtığını belirtmişlerdir. Ancak bu tezde kullanılan yapay zeka modelleri, pandemi süresince hem ticari hem de resmi aboneler için yüksek doğruluk oranları sağlamış ve konut abonelerinde pandemi etkilerini detaylandırarak bu değişiklikleri daha geniş bir perspektifte değerlendirmiştir.

Bu doğrultuda çalışmada test edilen üç hipotezden yalnızca meteorolojik verilerin modele katkısını içeren hipotez istatistiksel olarak desteklenmiş, diğer iki hipotez ise desteklenememiştir.

5.2. Yapay Zeka Yöntemlerinin Su Tüketimi Yönetimine Katkısı

Yapay zeka, su yönetimi stratejilerinde kilit bir rol oynamaktadır. Su kaynakları kısıtlı olan bölgelerde, su tüketiminin doğru bir şekilde tahmin edilmesi, suyun daha verimli kullanılmasına ve kaynakların daha etkin yönetilmesine doğrudan katkı sağlamaktadır. Bu çalışmada kullanılan yapay zeka modelleri, su tüketim tahmininde yüksek doğruluk oranlarıyla stratejik bir araç olarak öne çıkmış ve pratik uygulanabilirliği kanıtlanmıştır. Bu modellerin başarısı, su tüketiminin gelecekteki eğilimlerini doğru bir şekilde tahmin edebilmesiyle önemli bir avantaj sunmaktadır. Bu durum, su dağıtım şirketleri ve yerel yönetimler için kritik bir gereklilik olup, su talebinin etkin bir şekilde öngörülmesini ve su yönetiminin optimize edilmesini sağlamaktadır.

Farklı yapay zeka modelleri, ticari ve resmi abonelerde hafta içi ve hafta sonu tüketim farklılıklarını başarıyla tahmin ederek, su yönetiminde karar destek mekanizmalarının iyileştirilmesine olanak tanımaktadır. Örneğin, yaz aylarında sıcaklık artışlarına bağlı olarak su tüketiminde meydana gelen değişimler modeller sayesinde doğru bir şekilde öngörülmüş ve su yönetiminde proaktif önlemler alınmasına katkı sağlamıştır. Bu sonuçlar, yapay zeka modellerinin su yönetimi ve kaynak planlamasında kritik bir değer sunduğunu açıkça göstermektedir.

Özellikle Kocaeli gibi sanayi bölgelerinde, ticari su tüketiminin doğru bir şekilde tahmin edilmesi, endüstriyel faaliyetlerin su kaynakları üzerindeki etkilerini planlamayı kolaylaştırmakta ve sürdürülebilir su yönetimi stratejilerinin geliştirilmesine katkı sunmaktadır. Ayrıca, resmi aboneler için su tüketimindeki dönemsel değişiklikler başarıyla tahmin edilebildiğinden, bu tür tahmin modelleri

yerel yönetimlerin altyapı planlamasında güvenilir bir veri kaynağı olarak kullanılabilir.

5.3. Modelin Limitasyonları ve Gelecek Çalışmalar

Her ne kadar AI modelleri başarılı sonuçlar vermiş olsa da, bazı sınırlamalar mevcuttur. Modelin doğruluğu büyük ölçüde kullanılan veri setine dayanmaktadır ve veri setinin kalitesi performans üzerinde doğrudan etkili olmaktadır. Daha geniş kapsamlı ve daha detaylı verilerle çalışıldığında, modelin doğruluğu daha da artırılabilir. Özellikle su tüketimi üzerinde etkili olan sosyo-ekonomik faktörler, şu anda kullanılan modelde sınırlı bir şekilde temsil edilmektedir. Gelecek çalışmalarda, bu tür sosyo-ekonomik verilerin daha geniş bir yelpazede toplanması ve modele entegre edilmesi, su tüketim tahminlerinin daha isabetli olmasını sağlayabilir. Bu nedenle, gelecekte veri setinin daha düzenli ve eksiksiz bir şekilde toplanması büyük önem taşımaktadır. Bunun yanı sıra, eksik veriyle başa çıkabilmek için farklı yapay zeka tekniklerinin mevcut modele entegre edilmesi, genelleme kapasitesini arttırmada faydalı olabilir.

Gelecek çalışmalar için bir diğer öneri, modelin farklı bölgelerde uygulanabilirliğini test etmektir. Farklı coğrafi bölgelerde ve iklim koşullarında su tüketimi dinamiklerinin nasıl değiştiği göz önünde bulundurularak, modelin genelleme kapasitesi artırılabilir. Bu sayede, Türkiye genelinde su tüketim tahmini için genel bir yapay zeka modeli geliştirilebilir.

Konut aboneleri için su tüketimi tahmin doğruluğu, aylık verilerle yapılan tahminlerde R^2 : 0.56–0.61 arasında kalırken, günlük verilerle yapılan iyileştirmelerle %85'e kadar arttırılmıştır. Bu bulgu, özellikle evsel su tüketiminin bireysel alışkanlıklarla bağlantılı ve değişken olması nedeniyle daha kısa vadeli tahminlerin kullanılmasının önemini ortaya koymaktadır. Pandemi gibi olağan dışı durumların su tüketim desenlerini değiştirdiği gözlemlenmiş olsa da, bu değişimlerin tahmin doğruluğunu istatistiksel olarak anlamlı şekilde arttırmadığı belirlenmiştir. Günlük verilere dayalı tahminlerin, hem pandemi etkilerinin hem de ani değişimlerin modellenmesinde önemli bir katkı sağladığı görülmektedir.

Günlük tüketim verileri, yalnızca 33 konut abonesine ait olup, bu küçük örneklem nedeniyle modelin genelleme kapasitesi sınırlı kalmıştır. Gelecek çalışmalarda, günlük tüketim tahmini için daha büyük bir örneklem kullanılması önerilmektedir.

Özellikle resmi aboneler için pandemi sonrası dönemde elde edilen yüksek doğruluk oranları (R^2 : 0.88), veri düzeninin tahmin performansını ne kadar etkilediğini göstermiştir. AI modellerinin, kriz zamanlarında su tüketimindeki anormallikleri başarıyla tahmin etmesi, yapay zekanın kriz yönetimi ve acil durumlar için değerli bir araç olabileceğini göstermektedir.

Modelin rassal başlangıç noktalarına duyarlılığını değerlendirmek amacıyla, her model 10 farklı rassal başlangıç noktası kullanılarak eğitilmiş ve elde edilen performans metrikleri üzerinde T-testi yapılmıştır. T-testi sonuçları, ANN ve GBM modelleri arasında istatistiksel olarak anlamlı bir fark olmadığını ve pandemi sürecinin model doğruluğuna büyük bir etkisi olmadığını göstermektedir ($p > 0.05$). Bu sonuç, modellerin performansının rassal başlangıç noktalarından önemli ölçüde etkilenmediğini ve sonuçların genel olarak tutarlı olduğunu göstermektedir. Ancak, daha fazla sayıda rassal başlangıç noktası kullanılarak (örneğin 30 veya 50), sonuçların daha güvenilir olup olmadığı incelenebilir. Gelecek çalışmalarda, farklı veri ön işleme teknikleri, farklı model mimarileri veya farklı optimizasyon algoritmaları kullanılarak modelin performansı artırılabilir.



6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, Kocaeli ili için su tüketimi tahminlerinde yapay zeka modelleri (ANN, LSTM, GRU gibi) kullanılmış ve bu modellerin ticari, resmi ve konut aboneleri için su tüketimini başarılı bir şekilde öngörebildiği tespit edilmiştir. Bu modellerin pandemi gibi olağanüstü durumlarda tahmin performansları analiz edilmiştir. Pandemi dönemine ilişkin modeller, farklı zaman dilimlerinde karşılaştırılmış ve T-testi ile performans değerlendirmesi yapılmıştır.

Ancak analiz sonucunda, pandemi verisinin modele dahil edilmesinin tahmin performansını istatistiksel olarak anlamlı düzeyde artırmadığı belirlenmiştir ($p > 0.05$). Yapılan T-testi analizleri, pandemi sürecinin tahmin modelleri üzerinde anlamlı bir etki yaratmadığını göstermiştir. Bu nedenle, COVID-19'un sezgisel olarak su tüketiminde değişiklikler yarattığı düşünülse de, bu etkinin yapay zeka modellerinin doğruluk seviyelerinde istatistiksel olarak anlamlı bir değişime neden olmadığı belirlenmiştir. Bu bulgu, kriz dönemlerinin model performansına etkisini değerlendirirken dikkatli olunması gerektiğini göstermektedir.

Özellikle ticari ve resmi aboneler için AI modelleri, yüksek doğruluk oranları sunarak, su tüketim dinamiklerinin tahmininde güçlü bir araç olduğunu kanıtlamıştır. Su tüketim yönetiminde yapay zeka tekniklerinin uygulanabilirliği bu çalışmada ortaya konulmuş, ayrıca su yönetim stratejilerinde daha verimli ve etkili kararlar alınabilmesi için öneriler sunulmuştur.

6.1. Genel Sonuçlar

Çalışmanın bulguları, AI modelleri ile yapılan su tüketimi tahminlerinin özellikle ticari ve resmi aboneler için yüksek doğruluk oranları sunduğunu göstermektedir. Ticari ve resmi aboneler için elde edilen R^2 değeri 0.86–0.89, konut aboneleri için ise 0.56–0.61 olarak hesaplanmıştır. Bu sonuçlar, ticari ve resmi abonelerin su tüketim dinamiklerinin daha düzenli ve tahmin edilebilir olduğunu, buna karşın konut abonelerinin su tüketim alışkanlıklarının daha bireysel, günlük yaşam aktivitelerine ve sosyo-ekonomik faktörlere bağlı olarak değiştiğini ortaya koymaktadır.

Bu çalışmada, yapay zeka modellerinin konut aboneleri için günlük verilere dayalı tahminlerde doğruluğun %85'e kadar arttırıldığı görülmüştür.

Konut aboneleri için elde edilen daha düşük R^2 değerinin temel nedeni, evsel su tüketiminin bireysel alışkanlıklar, evde geçirilen zaman ve hane halkı büyüklüğü gibi kişisel değişkenlerle yakından ilişkili olmasıdır. Bu bağlamda, modele hane halkı büyüklüğü, gelir düzeyi ve günlük aktiviteler gibi sosyo-ekonomik değişkenlerin entegre edilmesi, tahmin doğruluğunu arttırmada etkili olacaktır.

Tezdeki bulgular, ayrıca COVID-19 pandemisinin su tüketim dinamiklerini önemli ölçüde etkilediğini göstermektedir. Pandemi süresince ticari ve resmi aboneler için su tüketimi azalırken, konut abonelerinde artış gözlemlenmiştir. Bu değişim, pandemi sırasında insanların evde daha fazla zaman geçirmesi ve hijyen önlemlerinin artmasıyla su kullanımında meydana gelen değişikliklerin bir sonucudur. Yapay zeka modelleri, pandemi öncesi ve sonrası su tüketim değişikliklerini başarıyla tahmin ederek, modelin kriz durumlarına uyum sağlama yeteneğini ortaya koymuştur.

Bu çalışma, ayrıca yapay zeka tekniklerinin su tüketim yönetimine nasıl entegre edilebileceğini göstermektedir. Bu doğrultuda yapay zeka modelleri, meteorolojik veriler ve çevresel faktörlerin etkilerini dikkate alarak kapsamlı tahminler yapabilme kapasitesine sahiptir. Özellikle su kaynaklarının sürdürülebilir kullanımı ve kriz durumlarında hızlı karar almayı destekleyen bu yöntemler, gelecekte su yönetiminde daha önemli bir rol oynayabilir.

Bu tez çalışmasında kullanılan yapay zeka modelleri ile elde edilen bulgular, Kocaeli ili için su tüketimi tahminlerinin yüksek doğrulukla yapılabildiğini göstermiştir. Benzer bir çalışmada, Görenekli ve Gülbağ (2024), çeşitli makine öğrenimi tekniklerini karşılaştırmıştır. Bu kapsamlı analizde ANN modelinin esnekliği ve karmaşık veri yapılarını işleyebilme kapasitesinin diğer yöntemlere göre daha üstün olduğu belirtilmiştir.

Bu bulgular, tezde kullanılan yapay zeka modellerinin doğruluğunu destekler niteliktedir. Yapay zeka tekniklerinin su tüketim tahminlerinde uygulanabilirliği hem bu tezde hem de Görenekli ve Gülbağ'ın (2024) çalışmasında açıkça ortaya konmuştur. Özellikle, meteorolojik verilerin, günlük tüketim verilerinin ve sosyo-ekonomik göstergelerin tahmin modellerine entegre edilmesi, modelin tahmin başarısını

arttırmaktadır. Her iki çalışmanın bulguları, su yönetimi ve tasarruf stratejilerinin yapay zeka ile optimize edilebileceğini göstermektedir.

Bu iki çalışmanın paralelliği, uygulanan yapay zeka modellerinin ticari ve resmi aboneler için yüksek doğruluk sağladığını ortaya koyarken, konut abonelerinde daha fazla değişkenin modele dahil edilmesinin gerekliliğini vurgulamaktadır. COVID-19 pandemisi gibi olağanüstü durumların, su tüketim dinamikleri üzerindeki etkisi de her iki çalışmada ele alınmış ve AI modellerinin bu tür kriz senaryolarına nasıl adapte olabildiği açıklanmıştır.

Bu tezde, yapay zeka modellerinin özellikle ticari ve resmi aboneler için yüksek doğruluk sağlamanın ardındaki temel faktör, bu abonelerin su tüketim alışkanlıklarının daha düzenli ve tahmin edilebilir olmasıdır. Ticari aboneler için işletme saatleri, ekonomik aktiviteler ve sektör dinamikleri, resmi aboneler için ise çalışma saatleri gibi faktörler, su tüketim tahminlerinde daha iyi sonuçlar elde edilmesini sağlamıştır. Buna karşın, konut abonelerindeki düşük R^2 değerleri, bireysel tüketim alışkanlıklarının daha fazla değişkenlik göstermesiyle ilişkilidir. Hane halkı büyüklüğü, gelir düzeyi, günlük aktiviteler ve bireysel alışkanlıkların modele dahil edilmesi, bu doğruluk oranlarını artırmada etkili olacaktır.

Bu çalışma kapsamında test edilen hipotezlerden yalnızca biri istatistiksel olarak desteklenmiştir.

Hipotez 1, yani ANN modelinin diğer yapay zeka modellerine kıyasla istatistiksel olarak anlamlı şekilde daha yüksek doğruluk sağladığı yönündeki varsayım, yapılan T-testi sonuçlarına göre desteklenememiştir ($p > 0.05$).

Hipotez 2, meteorolojik verilerin modele entegrasyonunun tahmin doğruluğunu anlamlı düzeyde artırdığı yönündeki varsayım ise istatistiksel olarak desteklenmiştir ($p < 0.05$).

Hipotez 3, COVID-19 pandemisinin tahmin modellerinin performansına anlamlı etkisi olduğu yönündeki varsayım da istatistiksel olarak desteklenememiştir ($p > 0.05$).

Bu bulgular, meteorolojik değişkenlerin model başarısını artırmada etkili olduğunu, ancak pandemi gibi kriz dönemlerinin model doğruluğuna istatistiksel olarak anlamlı katkı sağlamadığını ortaya koymaktadır.

6.2. Öneriler

Bu çalışmada elde edilen sonuçlar, su tüketimi tahmininde yapay zeka tekniklerinin potansiyelini ve etkinliğini ortaya koymuştur. Gelecekte bu tür çalışmaları geliştirmek ve daha geniş çapta uygulanabilir hale getirmek için aşağıdaki öneriler sunulmuştur:

6.2.1. Veri setlerinin genişletilmesi

- Mevcut çalışma, yalnızca Kocaeli iline ait su tüketim verilerine dayanmaktadır. Ancak Türkiye'nin farklı bölgelerinde gerçekleştirilecek benzer çalışmalar, modelin genelleme kapasitesini test edebilir.
- Bölgesel farklılıklar, iklim koşulları ve yerel su tüketim alışkanlıklarının dikkate alınması, yapay zeka modellerinin doğruluğunu artırabilir.
- Uzun dönemli veri setlerinin kullanılması, modelin gelecekteki tahmin performansını iyileştirebilir. Ayrıca, farklı bölgelerdeki kültürel ve iklimsel farklılıklar, su tüketim alışkanlıklarını etkileyen önemli değişkenler olarak modele entegre edilmelidir.

Öneri: Türkiye'nin farklı bölgelerinden veri toplanarak ulusal düzeyde bir su tüketimi tahmin modeli oluşturulabilir. Bu, bölgesel farklılıkları göz önünde bulunduran geniş kapsamlı bir model geliştirilmesini sağlayacaktır.

6.2.2. Sosyo-ekonomik verilerin entegrasyonu

- Konut aboneleri için elde edilen düşük R^2 değerlerinin başlıca nedenlerinden biri, sosyo-ekonomik verilerin modele tam anlamıyla entegre edilmemiş olmasıdır.
- Hane halkı büyüklüğü, gelir durumu, eğitim düzeyi ve yaş dağılımı gibi demografik veriler modelde yer alarak, evsel su tüketim tahminlerinin doğruluğunu artırabilir.
- Sosyo-ekonomik faktörlerin model performansını nasıl etkilediği daha ayrıntılı incelenmelidir. Özellikle bireysel tüketim alışkanlıklarının kriz dönemlerindeki değişimleri, gelecekteki çalışmalarda derinlemesine araştırılabilir.

Öneri: Sosyo-ekonomik ve demografik veriler entegre edilerek, konut aboneleri için daha kişiselleştirilmiş ve doğru tahminler yapılmalıdır.

6.2.3. Farklı yapay zeka tekniklerinin uygulanması

- Bu tez çalışmasında yapay zeka modelleri (ANN, LSTM, GRU gibi) kullanılmıştır. Ancak farklı yapay zeka teknikleri, özellikle derin öğrenme (DL) veya melez yapay zeka modelleri, su tüketimi tahmininde daha iyi performans gösterebilir. Örneğin, LSTM ve GRU gibi derin öğrenme modelleri, zaman serisi verilerini daha iyi modelleyebilir ve uzun vadeli tahminlerde daha yüksek doğruluk sağlayabilir. Ayrıca, melez modeller (örneğin, ANN + LSTM) farklı tekniklerin avantajlarını birleştirerek daha güçlü tahminler yapabilir.
- Derin öğrenme yöntemleri, karmaşık veri setleriyle çalışırken zaman serileri ve mekansal verilerle daha güçlü modeller oluşturabilir.
- SVM, Karar Ağaçları (DT) gibi farklı algoritmaların karşılaştırılması, model performansını daha da geliştirebilir.

Öneri: ANN'nin yanı sıra LSTM, GRU gibi zaman serisi modelleri ve diğer algoritmalar ile karşılaştırmalı çalışmalar yapılmalı, bu yöntemlerin performansı detaylı şekilde araştırılmalıdır.

6.2.4. Olağanüstü durumlar için kriz yönetimi modelleri

- COVID-19 pandemisi, su tüketim dinamikleri üzerinde büyük bir etkiye sahip olmuştur. Bu çalışmada yapay zeka modelleri, pandemi sürecinde su tüketimindeki değişiklikleri başarıyla tahmin etmiştir.
- Gelecekte, iklim değişikliği, doğal afetler veya ekonomik krizler gibi olağanüstü durumlar için yapay zeka tabanlı kriz yönetimi modelleri geliştirilebilir.

Öneri: Kriz durumlarına özel senaryo tabanlı tahmin modelleri geliştirilmeli ve bu modeller olağanüstü durumlarda su tüketim dinamiklerini tahmin etmek için kullanılmalıdır.

6.2.5. Su ve enerji yönetiminin entegrasyonu

- Su ve enerji yönetim stratejilerinin entegre edilmesi, hem kaynakların daha verimli kullanımını sağlar hem de sürdürülebilir şehir planlamasına katkıda bulunur.

- Enerji yoğun su arıtma süreçlerinin optimize edilmesi ve su kaynaklarının sürdürülebilir kullanımı, bu entegrasyonla desteklenebilir.

Öneri: Yapay zeka teknikleri kullanılarak su ve enerji tüketimini birleştiren modeller geliştirilmelidir. Bu modeller, enerji tasarrufu ve su yönetimi alanlarında bütüncül çözümler sunabilir.

6.2.6. Yapay zeka ve veri gizliliği

- Konut abonelerine yönelik sosyo-ekonomik verilerin kullanımı, veri gizliliği politikalarına uygun şekilde gerçekleştirilmelidir.
- Türkiye'deki KVKK ve uluslararası GDPR gibi düzenlemelere uyum sağlanması önemlidir. Veri toplama ve işleme süreçleri etik ve yasal çerçevede gerçekleştirilmelidir.

Öneri: Gelecekte veri gizliliği ilkelerine uygun modeller geliştirilerek, güvenlik ve etik konularında örnek uygulamalar oluşturulmalıdır.

6.2.7. Mekansal ve zaman serisi verilerin kullanımı

- Zaman serileri üzerine inşa edilen yapay zeka modelleri (ANN, GRU, LSTM gibi), su tüketimi tahmininde başarılı olmuştur. Mekansal verilerle zaman serilerini birleştiren modeller, farklı bölgeler için daha ayrıntılı tahminler sunabilir.
- Coğrafi bilgi sistemleri (GIS) ile yapay zeka modellerinin entegre edilmesi, bölgesel su tüketim dinamiklerinin daha iyi anlaşılmasını sağlayabilir.

Öneri: Mekansal-zamansal veri modelleri ile şehir bazlı su yönetim stratejilerinin oluşturulması önerilmektedir.

6.2.8. Model genelleme kapasitesinin test edilmesi

- Modelin farklı coğrafi bölgelerde ve kültürel farklılıkların etkilediği veri setlerinde nasıl performans gösterdiği test edilmelidir.

Öneri: Daha geniş veri setleriyle model genelleme kapasitesi artırılmalı ve modelin ulusal veya uluslararası düzeyde uygulanabilirliği incelenmelidir.

6.2.9. Abone su tüketim alışkanlıklarının yönetiminde ileri adımlar

Bu çalışmada önerilen yapay zeka modelleri, sadece su tüketimini tahmin etmekle kalmayıp, aynı zamanda abonelerin tüketim alışkanlıklarının iyileştirilmesi için somut uygulama önerileri sunmaktadır. Bu kapsamda önerilen uygulamalar şunlardır:

- **Aboneye Bilgi Verme:**

SMS veya e-posta yoluyla su tüketimi hakkında bilgi sağlanabilir. Bu yöntem, abonelerin farkındalığını artırarak su tasarrufu yapmalarını teşvik eder.

Kişiselleştirilmiş öneriler sunarak, yüksek tüketime neden olan cihazlar veya davranışlar konusunda abone bilgilendirilebilir.

- **Proaktif İletişim:**

Tüketimde anormallik tespit edildiğinde abonelerle iletişim kurulması, olası problemleri önlemede etkili olacaktır.

Ciddi sorun durumlarında hızlı müdahale sağlanabilir.

- **Tesisat İncelemesi:**

Anormallikler karşısında abonenin tesisatında olası kaçak veya sorunlar belirlenebilir.

Benzer sorunların olduğu bölgelerde toplu inceleme yapılabilir.

- **Okuyuculara Destek Sağlama:**

Sayaç okuyucuların cihazlarına tahmin verileri entegre edilerek, sahada daha verimli çalışmalar yapılması sağlanabilir.

Anormalliklerin önceden belirlenmesi, saha ekiplerinin işlerini daha etkin şekilde yönlendirebilir.

Bu adımlar, su tüketiminin etkin yönetimini desteklemekle kalmayıp, aynı zamanda abonelerin farkındalığını artırarak daha sürdürülebilir bir su yönetimi yaklaşımı sunmaktadır.



KAYNAKLAR

- Abdeen, A., Kharvari, F., O'Brien, W., & Gunay, B. (2021). The impact of the COVID-19 on households' hourly electricity consumption in Canada. *Energy and Buildings*, 250, 111280. <https://doi.org/10.1016/j.enbuild.2021.111280>
- Abu Talib, M., Abdallah, M., Abdeljaber, A., & Abu Waraga, O. (2023). Influence of exogenous factors on water demand forecasting models during the COVID-19 period. *Engineering Applications of Artificial Intelligence*, 117, 105617. <https://doi.org/10.1016/j.engappai.2022.105617>
- Adeloye, A. J., & Munari, A. D. (2006). Artificial neural network based generalized storage–yield–reliability models using the Levenberg–Marquardt algorithm. *Journal of Hydrology*, 326(1), 215–230. <https://doi.org/10.1016/j.jhydrol.2005.10.033>
- Al-Zahrani, M. A., & Abo-Monasar, A. (2015). Urban Residential Water Demand Prediction Based on Artificial Neural Networks and Time Series Models. *Water Resources Management*, 29(10), 3651–3662. <https://doi.org/10.1007/s11269-015-1021-z>
- Almanjahie, I., chikr Elmezouar, Z., & Ahmed, B. (2019). Modeling and forecasting the household water consumption in Saudi Arabia. *Applied Ecology and Environmental Research*, 17, 1299–1309. https://doi.org/10.15666/aeer/1701_12991309
- Ayva, C., Dutucu, A. A., & Ustaoglu, B. (2023). İKLİM DEĞİŞİKLİĞİNİN SU KAYNAKLARINA ETKİSİ VE UYUM ÖNERİLERİ: KİRAZDERE HAVZASI ÖRNEĞİ. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 33(1), Article 1. <https://doi.org/10.18069/firatsbed.1131015>
- Bakchan, A., Roy, A., & Faust, K. M. (2022). Leveraging water-wastewater data interdependencies to understand infrastructure systems' behaviors during COVID-19 pandemic. *Journal of Cleaner Production*, 367, 132962. <https://doi.org/10.1016/j.jclepro.2022.132962>
- Baker, S. R., Farrokhnia, R. A., Meyer, S., Pagel, M., & Yannelis, C. (2020). How Does Household Spending Respond to an Epidemic? Consumption during the 2020 COVID-19 Pandemic. *The Review of Asset Pricing Studies*, 10(4), 834–862. <https://doi.org/10.1093/rapstu/raaa009>
- Bakker, M., van Duist, H., van Schagen, K., Vreeburg, J., & Rietveld, L. (2014). Improving the Performance of Water Demand Forecasting Models by Using Weather Input. *Procedia Engineering*, 70, 93–102. <https://doi.org/10.1016/j.proeng.2014.02.012>
- Beuken, R., Lavooij, C., Bosch, A., & Schaap, P. (2008). Low Leakage in the Netherlands Confirmed. 1–8. [https://doi.org/10.1061/40941\(247\)174](https://doi.org/10.1061/40941(247)174)
- Bilim ve Aydınlanma Akademisi. (2019). Su kaynaklarının mevcut durumu. <https://bilimveaydinlanma.org/> adresinden 2 Ekim 2024 tarihinde alınmıştır.

- Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., Thomas, J., Ullmann, T., Becker, M., Boulesteix, A.-L., Deng, D., & Lindauer, M. (2021). Hyperparameter Optimization: Foundations, Algorithms, Best Practices and Open Challenges. arXiv. <https://doi.org/10.48550/arXiv.2107.05847>
- Bişkin, O. T., & Çifci, A. (2021). Forecasting of Turkey's Electrical Energy Consumption using LSTM and GRU Networks. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 8(2), Article 2. <https://doi.org/10.35193/bseufbd.935824>
- Boudhaouia, A., & Wira, P. (2022). SARIMA and neural network models combination for time series forecasting: Application to daily water consumption. *2022 International Conference on Theoretical and Applied Computer Science and Engineering (ICTASCE)*, 169–174. <https://doi.org/10.1109/ICTASCE50438.2022.10009716>
- Brentan, B. M., Meirelles, G. L., Manzi, D., & Luvizotto, E. (2018). Water demand time series generation for distribution network modeling and water demand forecasting. *Urban Water Journal*, 15(2), 150–158. <https://doi.org/10.1080/1573062X.2018.1424211>
- BUGÜN DÜNYA SU KAYIPLARI GÜNÜ (n.d.). Erişim Ağustos 16, 2024, <https://www.tarimorman.gov.tr/SYGM/Haber/1076/Bugun-Dunya-Su-Kayıplari-Gunu>
- Buurman, J., Freiburghaus, M., & Castellet-Viciano, L. (2022). The impact of COVID-19 on urban water use: A review. *Water Supply*, 22(10), 7590–7602. <https://doi.org/10.2166/ws.2022.300>
- Cahill, J., Hoolohan, C., & Browne, A. L. (2021). Covid-19 and Water Demand: A review of literature and research evidence. *Wiley Interdisciplinary Reviews: Water*, 8(6), e1570. <https://doi.org/10.1002/wat2.1570>
- Campos, M. A. S., Carvalho, S. L., Melo, S. K., Gonçalves, G. B. F. R., Santos, J. R., Barros, R. L., Morgado, U. T. M. A., Lopes, E. S., & Reis, R. P. A. (2021). Impact of the COVID-19 pandemic on water consumption behaviour. *Water Supply*, 21(8), 4058–4067. <https://doi.org/10.2166/ws.2021.160>
- Cassidy, J., Barbosa, B., Damião, M., Ramalho, P., Ganhão, A., Santos, A., & Feliciano, J. (2021). Taking water efficiency to the next level: Digital tools to reduce non-revenue water. *Journal of Hydroinformatics*, 23(3), 453–465.
- Centers for Disease Control and Prevention (CDC). (2021, December 20). COVID-19 pandemic. Retrieved from <https://www.cdc.gov/coronavirus/2019-ncov/global-covid-19/index.html>
- Chang, J., Bai, T., Huang, Q., & Yang, D. (2013). Optimization of Water Resources Utilization by PSO-GA. *Water Resources Management*, 27(10), 3525–3540. <https://doi.org/10.1007/s11269-013-0362-8>
- Cominato, C., Sborz, J., Kalbusch, A., & Henning, E. (2022). Water demand profile before and during COVID-19 pandemic in a Brazilian social housing complex. *Heliyon*, 8(8). <https://doi.org/10.1016/j.heliyon.2022.e10307>
- Cutore, P., Campisano, A., Kapelan, Z., Modica, C., & Savic, D. (2008). Probabilistic prediction of urban water consumption using the SCEM-UA algorithm. *Urban Water Journal*, 5(2), 125–132. <https://doi.org/10.1080/15730620701754434>

- Fan, L., Liu, G., Wang, F., Geissen, V., & Ritsema, C. J. (2013). Factors Affecting Domestic Water Consumption in Rural Households upon Access to Improved Water Supply: Insights from the Wei River Basin, China. *PLOS ONE*, 8(8), e71977. <https://doi.org/10.1371/journal.pone.0071977>
- Feurer, M., & Hutter, F. (2019). Hyperparameter Optimization in Machine Learning: Make Your Machine Learning and Deep Learning Models More Efficient. In *Automated Machine Learning* (pp. 3-33). Springer. https://doi.org/10.1007/978-3-030-05318-5_1
- García, S., Ramírez-Gallego, S., Luengo, J., Benítez, J. M., & Herrera, F. (2016). Big data preprocessing: Methods and prospects. *Big Data Analytics*, 1(1), 9. <https://doi.org/10.1186/s41044-016-0014-0>
- Ghiassi, G., Zimbra, D. K., & Saidane, H. (2008). Urban water demand forecasting with a dynamic artificial neural network model. *Journal of Water Resources Planning and Management*, 134(2), 138–146. Scopus. [https://doi.org/10.1061/\(ASCE\)0733-9496\(2008\)134:2\(138\)](https://doi.org/10.1061/(ASCE)0733-9496(2008)134:2(138))
- Görenekli, K., & Gülbağ, A. (2024). Comparative Analysis of Machine Learning Techniques for Water Consumption Prediction: A Case Study from Kocaeli Province. *Sensors*, 24(17), Article 17. <https://doi.org/10.3390/s24175846>
- Görenekli, K., & Gülbağ, A. (2025). Estimation of water consumption using artificial neural network: A study on subscribers in Kocaeli Province, Turkey. *Water and Environment Journal*, wej.12966. <https://doi.org/10.1111/wej.12966>
- Grespan, A., Garcia, J., Brikalski, M. P., Henning, E., & Kalbusch, A. (2022). Assessment of water consumption in households using statistical analysis and regression trees. *Sustainable Cities and Society*, 87, 104186. <https://doi.org/10.1016/j.scs.2022.104186>
- Guo, G., Liu, S., Wu, Y., Li, J., Zhou, R., & Zhu, X. (2018). Short-Term Water Demand Forecast Based on Deep Learning Method. *Journal of Water Resources Planning and Management*, 144(12), 04018076. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000992](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000992)
- Hassan, M. A., Salem, H., Bailek, N., & Kisi, O. (2023). Random Forest Ensemble-Based Predictions of On-Road Vehicular Emissions and Fuel Consumption in Developing Urban Areas. *Sustainability*, 15(2), Article 2. <https://doi.org/10.3390/su15021503>
- Hedén, W. (2016). *Predicting Hourly Residential Energy Consumption using Random Forest and Support Vector Regression: An Analysis of the Impact of Household Clustering on the Performance Accuracy*. <https://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-187873>
- House-Peters, L. A., & Chang, H. (2011). Urban water demand modeling: Review of concepts, methods, and organizing principles. *Water Resources Research*, 47(5). <https://doi.org/10.1029/2010WR009624>
- İSU Genel Müdürlüğü. (t.y.). <https://www.isu.gov.tr/> adresinden 20 Şubat 2023 tarihinde alınmıştır.

- Kalbusch, A., Henning, E., Brikalski, M. P., Luca, F. V. de, & Konrath, A. C. (2020). Impact of coronavirus (COVID-19) spread-prevention actions on urban water consumption. *Resources, Conservation and Recycling*, 163, 105098. <https://doi.org/10.1016/j.resconrec.2020.105098>
- Kavya, M., Mathew, A., Shekar, P. R., & P, S. (2023). Short term water demand forecast modelling using artificial intelligence for smart water management. *Sustainable Cities and Society*, 95, 104610. <https://doi.org/10.1016/j.scs.2023.104610>
- Kenney, D. S., Goemans, C., Klein, R., Lowrey, J., & Reidy, K. (2008). Residential Water Demand Management: Lessons from Aurora, Colorado1. *JAWRA Journal of the American Water Resources Association*, 44(1), 192–207. <https://doi.org/10.1111/j.1752-1688.2007.00147.x>
- Kim, J., Lee, H., Lee, M., Han, H., Kim, D., & Kim, H. S. (2022). Development of a Deep Learning-Based Prediction Model for Water Consumption at the Household Level. *Water*, 14(9), 1512. <https://doi.org/10.3390/w14091512>
- Koo, K.-M., Han, K.-H., Jun, K.-S., Lee, G., Kim, J.-S., & Yum, K.-T. (2021). Performance Assessment for Short-Term Water Demand Forecasting Models on Distinctive Water Uses in Korea. *Sustainability*, 13(11), Article 11. <https://doi.org/10.3390/su13116056>
- Kozłowski, E., Kowalska, B., Kowalski, D., & Mazurkiewicz, D. (2018). Water demand forecasting by trend and harmonic analysis. *Archives of Civil and Mechanical Engineering*, 18(1), 140–148. <https://doi.org/10.1016/j.acme.2017.05.006>
- Li, Z., Ye, H., Liao, N., Wang, R., Qiu, Y., & Wang, Y. (2022). Impact of COVID-19 on electricity energy consumption: A quantitative analysis on electricity. *International Journal of Electrical Power & Energy Systems*, 140, 108084. <https://doi.org/10.1016/j.ijepes.2022.108084>
- Liashchynskyi, P., & Liashchynskyi, P. (2019). Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS. arXiv. <https://doi.org/10.48550/arXiv.1912.06059>
- Mahjoub, S., Chrifi-Alaoui, L., Marhic, B., & Delahoche, L. (2022). Predicting Energy Consumption Using LSTM, Multi-Layer GRU and Drop-GRU Neural Networks. *Sensors*, 22(11), Article 11. <https://doi.org/10.3390/s22114062>
- Malinowski, M. R. B., & Povinelli, R. J. (2022). Using Smart Meters to Learn Water Customer Behavior. *IEEE Transactions on Engineering Management*, 69(3), 729–741. <https://doi.org/10.1109/TEM.2020.2995529>
- Mallikharjuna Rao, K., Saikrishna, G., & Supriya, K. (2023). Data preprocessing techniques: Emergence and selection towards machine learning models - a practical review using HPA dataset. *Multimedia Tools and Applications*, 82(24), 37177–37196. <https://doi.org/10.1007/s11042-023-15087-5>
- Mathew, A., P, S., & Khandelwal, S. (2022). Investigating the contrast diurnal relationship of land surface temperatures with various surface parameters represent vegetation, soil, water, and urbanization over Ahmedabad city in India. *Energy Nexus*, 5, 100044. <https://doi.org/10.1016/j.nexus.2022.100044>

- Meral, G., & Saraçlı, S. (2020). Destek Vektör Makineleri ve Türkiye'deki Enerji Santrallerinde Doğal Gaz Tüketimi Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 24(2), Article 2. <https://doi.org/10.19113/sdufenbed.684257>
- Moura, G. de A., Bezerra, S. de T. M., Gomes, H. P., & Silva, S. A. da. (2018). Neural network using the Levenberg–Marquardt algorithm for optimal real-time operation of water distribution systems. *Urban Water Journal*, 15(7), 692–699. <https://doi.org/10.1080/1573062X.2018.1539503>
- Nguyen, K. A., Stewart, R. A., Zhang, H., Sahin, O., & Siriwardene, N. (2018). Re-engineering traditional urban water management practices with smart metering and informatics. *Environmental Modelling & Software*, 101, 256–267. <https://doi.org/10.1016/j.envsoft.2017.12.015>
- Niknam, A., Zare, H. K., Hosseiniinasab, H., Mostafaeipour, A., & Herrera, M. (2022). A Critical Review of Short-Term Water Demand Forecasting Tools—What Method Should I Use? *Sustainability*, 14(9), 5412. <https://doi.org/10.3390/su14095412>
- Noory, H., Liaghat, A. M., Parsinejad, M., & Haddad, O. B. (2012). Optimizing Irrigation Water Allocation and Multicrop Planning Using Discrete PSO Algorithm. *Journal of Irrigation and Drainage Engineering*, 138(5), 437–444. [https://doi.org/10.1061/\(ASCE\)IR.1943-4774.0000426](https://doi.org/10.1061/(ASCE)IR.1943-4774.0000426)
- Odabasi, S. U. (2022). COVID-19 Sürecinin Su Ayak İzine Etkisinin Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 34, Article 34. <https://doi.org/10.31590/ejosat.1083604>
- Ölçenoğlu, A., & Borat, O. (2024). Holt-Winters ve Box-Jenkins modellerini kullanarak su tüketimi tahmini: İstanbul örneği. *İstanbul Ticaret Üniversitesi Teknoloji ve Uygulamalı Bilimler Dergisi*, 6(2), 81-96. <https://doi.org/10.56809/icujtas.1330019>
- Pan, R., Yang, T., Cao, J., Lu, K., & Zhang, Z. (2015). Missing data imputation by K nearest neighbours based on grey relational structure and mutual information. *Applied Intelligence*, 43(3), 614–632. <https://doi.org/10.1007/s10489-015-0666-x>
- Piotrowski, A. P., & Napiorkowski, J. J. (2011). Optimizing neural networks for river flow forecasting – Evolutionary Computation methods versus the Levenberg–Marquardt approach. *Journal of Hydrology*, 407(1), 12–27. <https://doi.org/10.1016/j.jhydrol.2011.06.019>
- Pulido-Calvo, I., Montesinos, P., Roldán, J., & Ruiz-Navarro, F. (2007). Linear regressions and neural approaches to water demand forecasting in irrigation districts with telemetry systems. *Biosystems Engineering*, 97(2), 283–293. <https://doi.org/10.1016/j.biosystemseng.2007.03.003>
- Raju, L., Gandhimathi, R., Mathew, A., & Ramesh, S. T. (2022). Spatio-temporal modelling of particulate matter concentrations using satellite derived aerosol optical depth over coastal region of Chennai in India. *Ecological Informatics*, 69, 101681. <https://doi.org/10.1016/j.ecoinf.2022.101681>

- Refaeilzadeh, P., Tang, L., & Liu, H. (2009). Cross-Validation. In *Encyclopedia of Database Systems* (pp. 532-538). Springer. https://doi.org/10.1007/978-0-387-39940-9_565
- Sarıgöl, M., & Katipoğlu, O. M. (2023). Estimation of monthly evaporation values using gradient boosting machines and mode decomposition techniques in the Southeast Anatolia Project (GAP) area in Turkey. *Acta Geophysica*, 72(2), 999–1016. <https://doi.org/10.1007/s11600-023-01067-8>
- Stańczyk, J., Kajewska-Szkudlarek, J., Lipiński, P., & Rychlikowski, P. (2022). Improving short-term water demand forecasting using evolutionary algorithms. *Scientific Reports*, 12(1), 13522. <https://doi.org/10.1038/s41598-022-17177-0>
- Sung, J. H., & Chung, E.-S. (2023). What is the Impact of COVID-19 on Residential Water Use? *KSCE Journal of Civil Engineering*, 27(12), 5481–5490. <https://doi.org/10.1007/s12205-023-0856-8>
- Thomas, T., & Rajabi, E. (2021). Addressing Missing Data in a Healthcare Dataset Using an Improved kNN Algorithm. In M. Paszynski, D. Kranzlmüller, V. V. Krzhizhanovskaya, J. J. Dongarra, & P. M. A. Sloot (Eds.), *Computational Science – ICCS 2021* (pp. 223–230). Springer International Publishing. https://doi.org/10.1007/978-3-030-77977-1_17
- Türkeş, M. (2022). IPCC'nin Yeni Yayınlanan İklim Değişikliğinin Etkileri, Uyum ve Etkilenebilirlik Raporu Bize Neler Söylüyor? *Resilience*, 6(1), 197–207. <https://doi.org/10.32569/resilience.1098946>
- Willis, R. M., Stewart, R. A., Giurco, D. P., Talebpour, M. R., & Mousavinejad, A. (2013). End use water consumption in households: Impact of socio-demographic factors and efficient devices. *Journal of Cleaner Production*, 60, 107–115. <https://doi.org/10.1016/j.jclepro.2011.08.006>
- WWF, *Türkiyede SU Kaynaklarının Güncel Durumu*. (n.d.), https://www.wwf.org.tr/kesfet/tatli_su/turkiyede_su_kaynaklarinin_guncel_durumu/ adresinden 9 Ekim 2024 tarihinde alınmıştır.
- Yeşilyurt, S., DüNDAR, R., & Demir, R. Z. (2024). Türkiye’de Yapay Zekâ ve Eğitim İlişisini İnceleyen Lisansüstü Tezlerin Analizi: Bir Meta Sentez Çalışması. *Journal of Innovative Research in Social Studies*, 7(1), Article 1. <https://doi.org/10.47503/jirss.1484848>
- Yılmaz, Z. (2022). METEOROLOJİK PARAMETRELERİN HAVA KİRLİLİĞİNE ETKİSİNİN İSTATİSTİKSEL ANALİZİ – MUŞ İLİ (2021). *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(4), Article 4. <https://doi.org/10.21923/jesd.1100006>
- Zhang, S., Zhou, Y., Yan, J., & Bu, F. (2021). Missing data completion method based on KNN and random forest. *Second IYSF Academic Symposium on Artificial Intelligence and Computer Engineering*, 12079, 383–389. <https://doi.org/10.1117/12.2622876>

EKLER

EK A: "Veri Normalizasyonu ve Ölçeklendirme"

Bu kod, eksik verileri temizler ve Min-Max ölçeklendirme ile verileri -1 ile +1 aralığında normalleştirir. Bu işlem, ANN modelinin daha hızlı ve doğru öğrenmesine yardımcı olur.

```
import pandas as pd
from sklearn.preprocessing import MinMaxScaler

def preprocess_data(df):
    df_clean = df.dropna()
    scaler = MinMaxScaler()
    scaled_data = scaler.fit_transform(df_clean)

    # -1 ile +1 aralığına ölçekleme
    normalized_data = (scaled_data * 2) - 1
    return normalized_data

# Test veri setiyle örnek kullanım
df = pd.DataFrame({
    'yağış': [6.051, 2.786, 2.638],
    'rüzgar': [1.683, 1.575, 1.7],
    'güneşlenme': [2.029, 3.351, 3.774],
    'max_sıcaklık': [10.122, 16.448, 16.574]
})

normalized_data = preprocess_data(df)
print(normalized_data)
```

EK B: "Aktivasyon Fonksiyonlarının Görselleştirilmesi "

Bu kod, YSA gizli katmanlarda sıklıkla kullanılan aktivasyon fonksiyonlarının grafiklerini çizmek için kullanılır. Sigmoid, tanh, ReLU, Leaky ReLU, ELU, Swish ve Softmax fonksiyonlarının görselleştirilmesi, bu fonksiyonların davranışlarını ve YSA modelinin performansına etkilerini anlamayı kolaylaştırır.

```
import numpy as np
import matplotlib.pyplot as plt

# Aktivasyon fonksiyonları
```

```

def sigmoid(x):
    return 1 / (1 + np.exp(-x))

def tanh(x):
    return np.tanh(x)

def relu(x):
    return np.maximum(0, x)

def leaky_relu(x, alpha=0.01):
    return np.maximum(alpha * x, x)

def elu(x, alpha=1.0):
    return np.where(x > 0, x, alpha * (np.exp(x) - 1))

def swish(x):
    return x * sigmoid(x)

def softmax(x):
    return np.exp(x) / np.sum(np.exp(x))

# Grafik çizimi
x = np.linspace(-5, 5, 100)

plt.figure(figsize=(12, 8))

plt.subplot(3, 3, 1)
plt.plot(x, sigmoid(x))
plt.title('Sigmoid')

plt.subplot(3, 3, 2)
plt.plot(x, tanh(x))
plt.title('Tanh')

plt.subplot(3, 3, 3)
plt.plot(x, relu(x))
plt.title('ReLU')

plt.subplot(3, 3, 4)
plt.plot(x, leaky_relu(x))
plt.title('Leaky ReLU')

plt.subplot(3, 3, 5)
plt.plot(x, elu(x))
plt.title('ELU')

plt.subplot(3, 3, 6)
plt.plot(x, swish(x))
plt.title('Swish')

```

```
plt.subplot(3, 3, 7)
plt.plot(x, softmax(x))
plt.title('Softmax')

# 0 eksenlerini kırmızı çizgiyle belirleme
for ax in plt.gcf().get_axes():
    ax.axhline(y=0, color='r', linestyle='--')
    ax.axvline(x=0, color='r', linestyle='--')

plt.tight_layout()
plt.show()
```

EK C: "Levenberg-Marquardt Algoritmasını "

Levenberg-Marquardt algoritması, model parametrelerinin optimize edilmesi için kullanılan bir yöntemdir. Aşağıdaki Python kodu, hem Levenberg-Marquardt algoritmasını kullanarak optimizasyonu hem de parametre güncelleme adımlarını içerir.

```
import numpy as np

def levenberg_marquardt(x0, func, jac, data, alpha_init=0.001,
max_iter=100, tol=1e-6, lambda_steps=10):
    """
    Levenberg-Marquardt algoritması ile parametre optimizasyonu.
    Args:
        x0: Başlangıç tahmin değerleri.
        func: Optimize edilecek fonksiyon.
        jac: Jacobian (gradyan) fonksiyonu.
        data: Gözlem verileri.
        alpha_init: Başlangıç regularizasyon parametresi.
        max_iter: Maksimum iterasyon sayısı.
        tol: Tolerans değeri (kabul edilebilir hata).
        lambda_steps: Lambda değerini ayarlamak için kullanılan
    adım sayısı.
        x: Optimum parametre değerleri.
    """
    x = x0
    alpha = alpha_init
    for i in range(max_iter):
        # Hata fonksiyonu ve Jacobian hesaplama
        f = func(x, data)
        J = jac(x, data)

        # Hessian matrisi ve gradient hesaplama
        H = np.dot(J.T, J) + alpha * np.identity(len(x))
        g = np.dot(J.T, f)
```

```

# Parametre güncelleme adımı
delta_x = np.linalg.solve(H, -g)
x_new = x + delta_x

# Yeni hata fonksiyonu hesaplama
f_new = func(x_new, data)

# Hata kontrolü ve tolere edilebilir aralıkta olup
# olmadiğini kontrol et
if np.linalg.norm(f_new) < tol:
    break

# Lambda adımları ile alpha güncellemesi
if np.linalg.norm(f_new) >= np.linalg.norm(f):
    alpha *= 10
else:
    alpha /= lambda_steps
    x = x_new

return x

```

EK D: "ANN ile Su Tüketim Tahmin Modeli"

Bu Python kodu, konut, ticari ve resmi aboneler için su tüketimini tahmin etmek amacıyla kullanılmıştır. Eğitim ve test süreçlerinde tahmin doğruluğunu ölçmek için çeşitli metrikler hesaplanmaktadır.

```

from sklearn.neural_network import MLPRegressor
from sklearn.metrics import mean_squared_error,
mean_absolute_error, r2_score
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from datetime import datetime
import numpy as np
from typing import List

def scale_train_r2(df0, output_name, hidden_layers: List[int],
activation='relu', solver='adam', max_iter=200,
early_stopping=True):
    """
    Yapay Sinir Ağı (ANN) ile su tüketimi tahmin modeli.

    Args:
        df0: Giriş veri seti (dataframe formatında).
        output_name: Hedef sütun (su tüketimi).
        hidden_layers: Gizli katmanların büyüklüğü (katman sayısı
ve nöron sayısı).

```

```

        activation: Aktivasyon fonksiyonu ('relu', 'tanh',
'logistic' vb.).
        solver: Model çözümleyici (default 'adam').
        max_iter: Maksimum iterasyon sayısı.
        early_stopping: Erken durdurma (default True).

Returns:
    input_size: Giriş veri seti boyutu.
    r2: R^2 (determinasyon katsayısı) değeri.
    mse: Ortalama karesel hata (MSE).
    rmse: Kök ortalama karesel hata (RMSE).
    mae: Ortalama mutlak hata (MAE).
    process_time: Modelin çalışma süresi (dakika:saniye
formatında).
"""
start_time = datetime.now()

# Veri normalizasyonu
df = df.dropna()
scaler = MinMaxScaler()
scaled_data = scaler.fit_transform(df0)

# Normalizasyonun ardından veriler -1 ile +1 arasında olacak
şekilde dönüştürülüyor
normalized_data = (scaled_data * 2) - 1

# Girdi ve çıktı ayırma
x = normalized_data[:, 1:] # Tüm sütunlar (output hariç)
y = normalized_data[:, 0]  # Su tüketim verileri (output)

# Eğitim ve test verileri bölme
x_train, x_test, y_train, y_test = train_test_split(x, y,
test_size=0.2, random_state=42)

# ANN modelinin oluşturulması
model = MLPRegressor(hidden_layer_sizes=hidden_layers,
activation=activation, solver=solver, max_iter=max_iter,
early_stopping=early_stopping)

# Modelin eğitimi
model.fit(x_train, y_train)

# Test verileri ile tahmin yapma
y_pred = model.predict(x_test)

# Performans metrikleri
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)

```

```

mae = mean_absolute_error(y_test, y_pred)

# Çalışma süresinin hesaplanması
end_time = datetime.now()
process_time = end_time - start_time
minutes, seconds = divmod(process_time.seconds, 60)
min_sec = f"{minutes:02}:{seconds:02}"

return x.shape[1], r2, mse, rmse, mae, min_sec

```

EK E: "Hiperparametre Optimizasyonu ve Eğitim Süreci"

Bu kod, ANN modeli için hiperparametre optimizasyonu yapar ve eğitim sürecini yönetir. Özellikle gizli katman sayısı, nöron sayısı ve aktivasyon fonksiyonları optimize edilir.

```

from sklearn.neural_network import MLPRegressor
from sklearn.model_selection import GridSearchCV

def hyperparameter_optimization(X, y):
    param_grid = {
        'hidden_layer_sizes': [(50,), (100,), (50, 30)],
        'activation': ['relu', 'tanh'],
        'solver': ['adam', 'lbfgs'],
        'max_iter': [300, 500]
    }

    model = MLPRegressor(random_state=42)
    grid_search = GridSearchCV(estimator=model,
    param_grid=param_grid, scoring='r2', cv=5)
    grid_search.fit(X, y)

    # En iyi parametreler
    best_params = grid_search.best_params_
    best_score = grid_search.best_score_

    return best_params, best_score

# Örnek kullanım
X = np.random.rand(100, 10)
y = np.random.rand(100)

best_params, best_score = hyperparameter_optimization(X, y)
print(f"En iyi parametreler: {best_params}, En iyi R2 skoru: {best_score}")

```

ÖZGEÇMİŞ

Ad-Soyad : Kasım GÖRENEKLİ

ÖĞRENİM DURUMU:

- **Lisans** : 1996, Yıldız Teknik Üniversitesi, Üniversite, Elektrik-Elektronik Fakültesi, Bilgisayar Bilimleri Mühendisliği Bölümü
- **Yükseklisans** : 2019, Kocaeli Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Program

MESLEKİ DENEYİM VE ÖDÜLLER:

- 1995 yılından beri değişik rollerde bilişim sektöründe çalıştı.
- 2010-2024 yılları arasında Kocaeli Büyükşehir Belediyesi, İSU Genel Müdürlüğünde değişik görevlerde Mühendis olarak çalıştı.
- Şu an yurtdışında hizmet sektöründe faaliyet gösteren bir firmada uzman iş analisti olarak çalışmakta.

DİLLER:

- Türkçe
- Almanca
- İngilizce

TEZDEN TÜRETİLEN ESERLER:

- Görenekli, K., & Gülbağ, A. (2024). Comparative Analysis of Machine Learning Techniques for Water Consumption Prediction: A Case Study from Kocaeli Province. *Sensors*, 24(17), Article 17. <https://doi.org/10.3390/s24175846>
- Görenekli, K., & Gülbağ, A. (2025). Estimation of water consumption using artificial neural network: A study on subscribers in Kocaeli Province, Turkey. *Water and Environment Journal*, wej.12966. <https://doi.org/10.1111/wej.12966>