



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YAPAY ZEKA UYGULAMALARI İLE TALEP
TAHMİNİ ELEKTRİK PERAKENDE
SEKTÖRÜNDE BİR UYGULAMA

Burak AYÇİÇEK

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Nisan-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Burak Ayçiçek tarafından hazırlanan “Yapay Zeka Uygulamaları ile Talep Tahmini Elektrik Perakende Sektöründe Bir Uygulama” adlı tez çalışması 30/07/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Prof. Dr. Mehmet AKTAN

.....

Üye

Doç. Dr. Beyzanur ÇAYIR ERVURAL

.....

Üye

Dr. Öğr. Üyesi Esra BOZ

.....

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

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

Burak AYÇİÇEK

Tarih: 03.07.2025

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY ZEKA UYGULAMALARI İLE TALEP TAHMİNİ ELEKTRİK PERAKENDE SEKTÖRÜNDE BİR UYGULAMA

Burak AYÇİÇEK

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Mehmet Aktan

2025, 57 Sayfa

Jüri

**Doç. Dr. Beyzanur ÇAYIR ERVURAL
Dr. Öğr. Üyesi Esra BOZ**

Türkiye’de elektrik enerjisinin üretim, iletim, dağıtım ve perakende ağının önemi, yaşanan teknolojik gelişmeler ve tüketim anlayışının değişmesi ile birlikte son yıllarda üzerinde en çok durulan konulardan birisi haline gelmiştir. Bu çalışmanın temel amacı, Türkiye'nin saatlik elektrik enerjisi tüketim miktarını tahmin etmek için farklı yapay zeka (YZ) modellerinin performansını karşılaştırmaktır. Enerji talebinin doğru bir şekilde öngörülmesi, enerji arz güvenliği, şebeke yönetimi ve kaynak planlaması açısından kritik öneme sahiptir. Çalışmada, EPIAŞ (Enerji Piyasaları İşletme A.Ş.) tarafından sağlanan Nisan 2024 ve Nisan 2025 arasındaki saatlik tüketim verileri kullanılmıştır. Tüketim tahmini için Çoklu Doğrusal Regresyon (MLR), Karar Ağaçları (DT), Rassal Orman (RF), Gradyan Artırma Makineleri (GBM), Extreme Gradient Boosting (XGBoost) ve Yapay Sinir Ağları (YSA) gibi yaygın kullanılan algoritmalar uygulanmıştır. Modellerin performansları, Ortalama Mutlak Hata (MAE) ve Kök Ortalama Karese Hata (RMSE) metrikleri kullanılarak değerlendirilmiştir. Elde edilen sonuçlara göre, sonuçlar birbirine yakın olsa da, en iyi tahmini Keras kütüphanesinden kullanılan Yapay Sinir Ağları Çok Katmanlı Algılayıcı (MLP) modeli sağlarken en düşük performanslı tahmini Scikit Learn kütüphanesinden kullanılan Yapay Sinir Ağları MLP modeli sağlamıştır.

Anahtar Kelimeler: Çoklu Doğrusal Regresyon, Elektrik Tüketimi, Gradyan Artırma Makineleri, Karar Ağaçları, Rassal Orman, XGBoost, Yapay Sinir Ağları, Yapay Zeka

ABSTRACT

MS THESIS

DEMAND FORECASTING WITH ARTIFICIAL INTELLIGENCE APPLICATIONS: A CASE STUDY IN THE ELECTRICITY RETAIL SECTOR

Burak AYÇİÇEK

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN INDUSTRIAL ENGINEERING**

Advisor: Prof. Dr. Mehmet AKTAN

2015, 57 Pages

Jury

Assoc. Prof. Dr. Beyzanur ÇAYIR ERVURAL

Asst. Prof. Dr. Esra BOZ

The importance of Türkiye's electricity generation, transmission, distribution, and retail network has become one of the most emphasized topics in recent years, driven by technological advancements and changes in consumption behavior. The primary aim of this study is to compare the performance of different artificial intelligence (AI) models in forecasting Türkiye's hourly electricity consumption. Accurate prediction of energy demand is critically important for energy supply security, grid management, and resource planning. The study utilizes hourly consumption data provided by EPIAŞ (Energy Markets Operation Corporation) for the period between April 2024 and April 2025. Commonly used algorithms such as Multiple Linear Regression (MLR), Decision Trees (DT), Random Forest (RF), Gradient Boosting Machines (GBM), XGBoost, and Artificial Neural Networks (ANN) were applied for consumption forecasting. The performance of the models was evaluated using the Mean Absolute Error (MAE) and Root Mean Square Error (RMSE) metrics. According to the results, although the models yielded similar outcomes, the Random Forest model provided the best prediction, while the Artificial Neural Networks showed the lowest performance.

Keywords: Artificial Intelligence, Artificial Neural Networks, Decision Trees, Electricity Consumption, Multiple Linear Regression, Random Forest, XGBoost

ÖNSÖZ

Elektrik üretim, dağıtım ve perakende sektörlerinin özel şirketler tarafından üstlenilmesiyle birlikte, elektrik yalnızca hayatımızı idame ettirmek için kullandığımız bir araç değil aynı zamanda özel şirketler için de kar-zarar noktasında dikkat edilmesi gereken ve bu konuda yatırım yapılması gereken bir olguya dönüşmüştür. Bu çalışmada saatlik üretim tahmini için literatürde en çok kullanılan modeller karşılaştırılarak doğru model seçimi için fikir vermesi amaçlanmıştır.

Eğitim ve çalışma hayatım boyunca desteklerini ve inançlarını yitirmeden bana destek olan aileme, bilgi ve tecrübelerinden yararlandığım danışmanım Prof. Dr. Mehmet AKTAN'a, bilimi ve ilerlemeyi bizlere sağlayan Mustafa Kemal ATATÜRK'e teşekkürlerimi borç bilirim.

Burak AYÇİÇEK
KONYA-2025

İÇİNDEKİLER

| | |
|---|-------------|
| ÖZET | iv |
| ABSTRACT..... | v |
| ÖNSÖZ | vi |
| İÇİNDEKİLER..... | vii |
| SİMGELER VE KISALTMALAR..... | viii |
| 1. GİRİŞ..... | 1 |
| 2. LİTERATÜR ARAŞTIRMASI..... | 3 |
| 3. MATERYAL VE YÖNTEM..... | 12 |
| 3.1. Çoklu Doğrusal Regresyon (MLR)..... | 13 |
| 3.2. Gradyan Arttırma Makineleri (GBM)..... | 14 |
| 3.3. Karar Ağaçları Algoritması (DT) | 16 |
| 3.4. Rassal Orman Algoritması (RF) | 17 |
| 3.5. Yapay Sinir Ağları (YSA) | 19 |
| 4. UYGULAMA VE TARTIŞMA | 22 |
| 4.1. Uygulama..... | 22 |
| 4.1.1. Rassal orman modeli uygulaması | 25 |
| 4.1.2. Gradyan arttırma modeli uygulaması | 28 |
| 4.1.3. XGBoost modeli uygulaması..... | 31 |
| 4.1.4. Karar ağaçları modeli uygulaması | 34 |
| 4.1.5. Çoklu doğrusal regresyon uygulaması..... | 37 |
| 4.1.6. Yapay sinir ağları uygulaması | 40 |
| 4.2. Tartışma | 46 |
| 5. SONUÇLAR VE ÖNERİLER..... | 52 |
| 5.1 Sonuçlar | 52 |
| 5.2 Öneriler | 52 |
| 6. KAYNAKLAR..... | 54 |

SİMGELER VE KISALTMALAR

Simgeler

ε : Çoklu Doğrusal Regresyon Modeli Hata Terimi
 β_p : Çoklu Doğrusal Regresyon Modeli Sabit Terim
Y: Çoklu Doğrusal Regresyon Bağımlı Değişken
 X_p : Çoklu Doğrusal Bağımsız Değişkeler

Kısaltmalar

ANFIS: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
ANN: Yapay Sinir Ağları
ARIMA: Otoregresif Bütünleşik Hareketli Ortalama
CCP: Maliyet-Karmaşıklık Budaması
CNN: Evrişimli Sinir Ağları
DNN: Derin Sinir Ağları
D-PNN: Diferansiyel Polinom Sinir Ağları
DT: Karar Ağaçları
EKK: En Küçük Kareler
GBM: Gradyan Arttırma Makineleri
GPR: Gauss Süreci Regresyonu
GRU: Kapılı Yinelenebilir Birim
GSYİH: Gayri Safi Yurtiçi Hasıla
HDD: Isıtma Derece Gün
KDS: Karar Destek Sistemi
K-NN: K-En Yakın Komşu
LSTM: Uzun Kısa Süreli Bellek
MAE: Ortalama Mutlak Hata
MAPE: Ortalama Mutlak Yüzde Hata
MWh: Megavat-saat
MLR: Çoklu Doğrusal Regresyon
MLP: Çok Katmanlı Algılayıcı
MSE: Ortalama Kare Hata
MTRY: Öznitelik Alt Kümesi
NAR-NN: Doğrusal Olmayan Otoregresif Sinir Ağı
RF: Rassal Orman
RMSE: Kök Ortalama Kare Hata
RNN: Yinelenebilir Sinir Ağı
S-LSTM: Yığılmış Uzun Kısa Süreli Bellek
SMO: Sıralı Minimum İyileştirme
SMOReg: Sıralı Minimal Optimizasyon Regresyonu
SVM: Destek Vektör Makineleri
SVR: Destek Vektör Regresyonu
XGBoost: Ekstrem Gradyan Arttırma
YZ: Yapay Zeka

1. GİRİŞ

Elektrik enerjisi, günümüz toplumların ekonomik ve sosyal gelişiminde rol alan en temel yapı taşıdır. Sanayiden ulaşıma, iletişimden günlük yaşantımıza kadar hayatın her alanında vazgeçilmez bir role sahip olan elektrik enerjisine duyulan talep, teknolojik gelişmeler, nüfus artışı ve yaşam standartlarının yükselmesiyle birlikte sürekli artış göstermektedir. Bu artan talebin güvenilir, sürdürülebilir ve ekonomik bir şekilde eksiksiz olarak karşılanması, enerji sektörünün son zamanlarda üzerinde en çok yoğunlaştığı alanlardan birisidir. Enerji arzında talebin karşılanabilmesi için üretim, iletim ve dağıtım altyapılarına yönelik büyük ölçekli ve uzun vadeli yatırımlar yapılması gerekmektedir. Gerekli yatırımların doğru zamanda ve doğru ölçekte planlanabilmesi ise ancak gelecekteki enerji tüketiminin doğru bir şekilde tahmin edilmesiyle mümkündür (Özer ve Erkilet, 2012).

Elektrik enerjisi tüketiminin doğru tahmin edilmesi, sadece arz güvenliğini sağlamakla kalmaz, aynı zamanda enerji kaynaklarının verimli kullanılmasını, şebeke operasyonlarının optimize edilmesini ve enerji politikalarının etkin bir şekilde oluşturulmasını da sağlar. Hatalı tahminler, ya gereğinden fazla yatırım yapılarak kaynak israfına ya da yetersiz arz nedeniyle enerji kesintilerine ve ekonomik kayıplara yol açabilir. Elektrik tüketimi; hava durumu, ekonomik aktivite düzeyi, günün saati, mevsimsel etkiler, bina tipleri, kullanıcı davranışları gibi çok sayıda karmaşık ve dinamik faktörden etkilenebilmesiyle beraber (Nishimwe ve Reiter, 2021), (Liu ve ark., 2025) bu durum, geleneksel tahmin yöntemlerinin doğruluğunu sınırlayabilmekte ve daha gelişmiş, hızlı ve etkin yaklaşımlara olan ihtiyacı artırmaktadır. Özellikle hastaneler gibi kritik kurumlar için talep analizi ve öngörüsü, operasyonel faaliyetlerin sürdürülebilmesi ve kaynak planlaması açısından hayati önem taşımaktadır (Özer ve Erkilet, 2012). Benzer şekilde, bölgesel veya şehir ölçeğinde yapılacak doğru tahminler, kentsel enerji verimliliği politikaları için temel oluşturmaktadır (Liu ve ark., 2025).

Son yıllarda, yapay zeka (YZ) teknolojileri, karmaşık problemlerin çözümünde ve büyük veri setlerinin analizinde gösterdikleri başarıyla birçok alanda devrim yaratmıştır. Günlük yaşantımızda bile eğlence amaçlı kullanılan YZ teknolojilerinden Enerji sektörü de faydalanabilmektedir. YZ algoritmaları, elektrik tüketimini etkileyen çok sayıda değişken arasındaki doğrusal olmayan ve karmaşık ilişkileri öğrenebilme, büyük veri setlerini etkin bir şekilde işleyebilme ve geçmiş verilere dayanarak yüksek doğrulukta tahminler üretebilme yetenekleriyle öne çıkmaktadır (Liu ve ark., 2025). Bu algoritmalar,

geleneksel istatistiksel yöntemlerin zorlandığı örüntüleri tespit ederek daha güvenilir ve esnek tahmin modelleri oluşturulmasına olanak tanır. Enerji tüketim etkenlerinin bina hacmi, kullanım yoğunluğu, çevresel faktörler gibi değişkenlerle ilişkilendirilerek modellenmesinde makine öğrenmesi yöntemleri başarıyla kullanılmaktadır (Nishimwe ve Reiter, 2021), (Liu ve ark., 2025). YZ'nin bu alandaki potansiyeli, sadece teknik bir ilerleme değil, aynı zamanda enerji planlaması ve yönetimi paradigmasında bir dönüşüm anlamına da gelmektedir (Erten ve Göktepeliler, 2022).

Bu tez çalışması kapsamında, elektrik enerjisi tüketiminin tahmin edilmesinde Yapay Sinir Ağları (YSA), Gradyan Artırma Makineleri (GBM), Extreme Gradient Boosting (XGBoost), Çoklu Doğrusal Regresyon (MLR), Rassal Orman (RF) ve Karar Ağaçları (DT) kullanılmıştır. Çalışmanın temel amacı, farklı yapay zeka modellerini kullanarak elektrik tüketim tahminlerinin doğruluğunu karşılaştırmak ve veri setine dayalı olarak en uygun algoritmanın önerilmesi amaçlanmıştır. Çalışmada aynı zamanda farklı kütüphaneler (Keras ve Scikit Learn) tercih edilerek, çalışmalarda kullanılan teknolojilerde ortaya çıkan farklılıkların karşılaştırılması amaçlanmıştır. Çalışmada kullanılan veri seti Enerji Piyasaları İşletme A.Ş. (EPIAŞ) şeffaflık platformundan temin edilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Literatür içerisinde araştırma yapıldığı zaman, YZ algoritmalarının farklı sektörlerde ki ileriye yönelik tahmin çalışmalarında kullanıldığı gözlemlenmiştir. Doğalgaz, üretim ve sağlık alanında yapılan çalışmaların yanı sıra elektrik üretim ve tüketim alanında yapılan çalışmalarda da yer aldığı incelenmektedir.

Türkiye'nin ulusal düzeydeki kısa dönem (24 saatlik) elektrik talebini tahmin etmeye odaklanılan çalışmadaki (Başoğlu ve Bulut, 2017) temel amaç, Türkiye'nin piyasa ve mevsimsel koşullarına özgü, yüksek doğruluklu yeni bir hibrit sistem (EPSİM-NN) geliştirmektir. Yöntem olarak YSA ve uzman sistemlerin özgün bir birleşimi kullanılmıştır. Özellikle, günlük ortalama talep miktarını tahmin eden bir YSA (YSA-M) ve talep şeklini (profilini) tahmin eden ayrı bir YSA (YSA-Ş) kullanıldığı görülmektedir. Bu iki ağın çıktıları, tahmin hatalarını en aza indirmek için yakın geçmişteki talep eğilimlerini ve düzeltme faktörlerini kullanan yarı otomatik bir uzman sistem modülü ile iyileştirilmiştir. Modele girdi olarak geçmiş talep verileri, gün tipi (hafta içi, hafta sonu, bayram, ramazan), ekonomik göstergeler (Gayri Safi Milli Hasıla, sanayi üretim endeksi) ve 12 bölgeden hesaplanan ulusal ortalama sıcaklık değerleri verilmiştir. Sonuçlar incelendiği zaman, EPSİM-NN sisteminin Türkiye koşulları için yüksek doğruluk sağladığını göstermiştir. Özellikle uzman sistem modülünün, tahmin hatalarını önemli ölçüde azaltarak sıklıkla %2 bandının altına (%1-2 civarı) çektiği ve sunulan vaka analizlerinde referans tahminlerden (EPİAŞ) daha iyi performans gösterdiği belirtilmiştir.

Özden ve Öztürk (2018), Türkiye'de endüstriyel bir bölge olan Ankara'daki İvedik Organize Sanayi Bölgesi (OSB) özelinde elektrik enerjisi talep tahminine odaklanmaktadır. Çalışmanın ana hedefi, özellikle kısıtlı geçmiş veriye (iki yıllık) sahip olduğunda karşılaşılan zorlukları ele alarak, kısa vadeli tahmin için uygun modeller geliştirmek ve karşılaştırmaktır. YSA ve zaman serisi analizlerinden birisi olan Doğrusal Olmayan Otoregresif Sinir Ağı (NAR-NN) olmak üzere iki farklı yöntem kullanılmış ve değerlendirilmiştir. YSA modelinde girdi olarak geçmiş tüketim verileri ve sıcaklık (endüstriyel alandaki iş yerlerinin ısıtma ihtiyacı için kritik olduğu belirtilmiştir) kullanılırken, zaman serisi modeli yalnızca geçmiş tüketim verilerine dayanmıştır. Bulgular, YSA modelinin (R-kare: 0,9859) bu endüstriyel bölge için zaman serisi modeline (R-kare: 0,93901) kıyasla önemli ölçüde daha iyi performans gösterdiğini ortaya koymuştur. Çalışmada, zaman serisi yönteminin performansının veri azlığından olumsuz etkilendiğini öne sürmektedir.

Nacar ve Erdebilli (2021), perakende sektöründe satış tahminine odaklanmakta ve bir ofis malzemeleri satıcısından alınan ve 25 farklı parametreye sahip verileri kullanarak çalışmalarını yürütmüşlerdir. Çalışmanın amacı, uçtan uca bir makine öğrenmesi proje sürecini göstermek ve çeşitli algoritmaları karşılaştırarak doğru bir satış tahmin modeli geliştirmek olmuştur. Metodoloji, keşifsel veri analizi (EDA), eksik veri ve aykırı değerlerin ele alınması, öznitelik mühendisliği, veri bölme ve model eğitimi gibi temel makine öğrenmesi adımlarını kapsamaktadır. Doğrusal Regresyon, Ridge Regresyon, Lasso Ridge Regresyon, ElasticNet Ridge Regresyon, K-En Yakın Komşu (K-NN) ve RF gibi çeşitli denetimli öğrenme regresyon algoritmaları uygulanmış ve karşılaştırılmıştır. Değerlendirme sonuçlarına göre (öncelikle R-kare değerine dayalı olarak), Rastgele Orman algoritması bu veri seti için test edilen modeller arasında en düşük hatayı vererek en doğru tahminleri sağlamıştır.

Demir ve Sağlam (2023), Türkiye'nin yıllık elektrik tüketiminin tahmin edilmesi üzerine yoğunlaşmışlardır. Çalışmanın temel amacı, standart YSA performansını, Diferansiyel Polinom Sinir Ağları (D-PNN) olarak adlandırılan daha yeni bir tür ile karşılaştırmaktır. Modeller, yıllık elektrik tüketimini tahmin etmek için ihracat, ithalat, nüfus, kurulu güç kapasitesi ve Gayri Safi Yurtiçi Hasıla (GSYİH) gibi temel ulusal göstergeleri girdi olarak kullanmıştır. Çalışmada 1965-2016 arası geçmiş veriler kullanılarak yürütülmüştür. Sonuçlar, D-PNN yaklaşımının bu görev için standart YSA'ya göre test veri setinde açıkça daha üstün olduğunu göstermiştir. D-PNN, RMSE metriğine göre %52,5 ve MAPE metriğine göre %58,8 oranında YSA'dan daha iyi performans sergileyerek, yıllık enerji tahmini için güçlü bir potansiyele sahip olduğunu ortaya koymuştur.

Sönmez (2015), Türkiye'de İç Anadolu bölgesinde yer alan Seydişehir için orta vadeli (2016 yılına kadar) elektrik enerjisi talebi tahminine odaklanmaktadır. Çalışma, bu bölgesel tahmin görevi için farklı YZ ve istatistiksel tekniklerin etkinliğini karşılaştırmayı amaçlamıştır. Üç farklı modelleme yaklaşımı uygulanmıştır: Klasik Regresyon Analizi, YSA ve Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS). Modellerde girdi olarak bölgesel nüfus verileri, meteorolojik değişkenler (sıcaklık, nem, rüzgâr) ve geçmiş elektrik tüketim rakamları kullanılmıştır. Hata kriterlerine dayalı değerlendirme sonucunda, ANFIS modelinin Seydişehir bölgesi için orta vadeli enerji talebi tahmininde regresyon analizi ve YSA'ya kıyasla en başarılı ve en uygun model olduğu tespit edilmiştir.

Pehlivanoglu (2023), plastik sektöründe faaliyet gösteren kurumsal bir firmanın talep tahminine odaklanılmıştır. Çalışmanın temel amacı, YSA ve regresyon analizi yöntemlerini kullanarak firmanın gelecekteki satış miktarını tahmin etmek ve bu iki yöntemin performansını karşılaştırmaktır. Modelleme için firmanın 2021 yılına ait günlük verileri kullanılmış; bağımsız değişkenler olarak üretim miktarı, dolar kuru, hammadde fiyatı, sipariş miktarı ve sevk kapasitesi, bağımlı değişken olarak ise satılan plastik profil miktarı ele alınmıştır. Çalışmanın sonuçları, regresyon analizi yönteminin bu spesifik veri seti ve problem için YSA'ya kıyasla daha başarılı tahminler ürettiğini göstermiştir.

Türkiye'nin saatlik elektrik talebinin kısa vadeli tahminine odaklanılan çalışmada (Dede, 2023), özellikle Derin Sinir Ağları (DNN) ve Yığılmış Uzun Kısa Süreli Bellek (S-LSTM) gibi iki gelişmiş yapay zeka algoritmasının performansını karşılaştırmayı amaçlamıştır. Modellemede, iklim koşulları, takvim etkileri (tatiller, haftanın günü vb.), demografik ve ekonomik veriler gibi faktörlerin yanı sıra, Türkiye'nin farklı bölgelerindeki nüfus yoğunluğunu dikkate alan ağırlıklandırılmış meteorolojik veriler girdi olarak kullanılmıştır. Modellerin tahmin performansları Ortalama Kare Hata (MSE), Ortalama Mutlak Hata (MAE) ve Ortalama Mutlak Yüzde Hata (MAPE) metrikleri kullanılarak değerlendirilmiştir. Sonuçlar, Derin Sinir Ağı (DNN) modelinin, incelenen veri seti ve koşullar altında Yığılmış LSTM modeline göre daha doğru tahminler yaptığını göstermiştir.

Gökçe ve Duman (2024), elektrik üretiminin planlanması için derin öğrenme tabanlı bir talep tahmin sistemi geliştirmeyi amaçlamaktadır. Çalışma, Türkiye'nin 2018-2021 yılları arasındaki saatlik elektrik tüketim verilerini ve ilgili meteorolojik verileri kullanmıştır. Bu verilere resmî tatil günleri gibi özellikler de eklenmiştir. Modelleme sürecinde hem klasik makine öğrenmesi yöntemleri Doğrusal Regresyon, RF, XGBoost hem de derin öğrenme tabanlı zaman serisi modelleri Yinelenebilir Sinir Ağı (RNN), Uzun Kısa Süreli Bellek (LSTM), Kapılı Yinelenebilir Birim (GRU) karşılaştırılmıştır. Performans değerlendirmesi için RMSE metriği kullanılmıştır. Bulgular, derin öğrenme modellerinin, özellikle LSTM'nin (RMSE: 232,36), klasik makine öğrenmesi modellerine göre daha başarılı sonuçlar verdiğini ve elektrik yükü tahmininde daha etkin olduğunu göstermiştir. Çalışma ayrıca, enerji arz ve talep dengesizliğinin giderilmesi potansiyeline de değinmektedir.

Kayış (2023), otomotiv sektöründe faaliyet gösteren bir şirketin yüksek satış yaptığı ürünler için haftalık ürün talebini tahmin etmeye odaklanmıştır. Çalışmanın temel

amacı, literatürde sıkça kullanılan istatistiksel yöntemler Üstel Düzeltme, Mevsimsel Ayırıştırma, Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) ve makine öğrenmesi RF, YSA, Destek Vektör Regresyonu (SVR), Sıralı Minimal Optimizasyon Regresyonu (SMOReg) yöntemlerinin zaman serisi tahmin performanslarını karşılaştırmaktır. Dört yıllık (208 hafta) eğitim verisi ve 9 haftalık test verisi kullanılarak yapılan analizlerde, MAE ve RMSE metrikleri ile değerlendirme yapılmıştır. Sonuçlar, makine öğrenmesi yöntemleri arasında RF modelinin genel olarak en iyi tahmin performansını sergilediğini göstermiştir. İstatistiksel yöntemlerde ise eğitim verisinde Mevsimsel Ayırıştırma, test verisinde ise ARIMA (2,1,1) modeli daha başarılı bulunmuştur.

Aykaş (2023), Düzce ilinin aylık elektrik enerjisi talebinin tahmin edilmesine odaklanmaktadır. Çalışmada, Enerji Piyasası Düzenleme Kurumu (EPDK) verileri kullanılarak 2017-2021 yılları arasındaki 5 yıllık (60 ay) veri seti oluşturulmuş, ilk 4 yıl eğitim, son 1 yıl ise test için ayrılmıştır. Tezin amacı, Düzce için talep tahmini yapmak ve bu amaçla kullanılan üç farklı zaman serisi modeli olan ARIMA, TBATS ve Prophet performanslarını karşılaştırmaktır. Modellerin başarısı MAPE, MAE ve RMSE metrikleri ile değerlendirilmiştir. Çalışmanın sonucunda, genel olarak ARIMA yönteminin daha başarılı tahminler ürettiği görülmekle birlikte, bazı spesifik aylarda TBATS ve Prophet yöntemlerinin daha iyi sonuçlar verebildiği tespit edilmiştir. Bu durum, gelecekteki tahminler için hibrit model yaklaşımlarının potansiyelini ortaya koymaktadır.

Bakkal (2023), tamamladığı yüksek lisans tezinde, iki ana konuya odaklanmaktadır: Türkiye'deki doğal gaz tedarik zincirinin yapısal ve operasyonel süreçlerinin incelenmesi ve Türkiye'nin aylık ulusal doğal gaz talebinin tahmin edilmesi. Talep tahmini amacıyla, 2010-2022 yılları arasındaki aylık veriler kullanılmış ve Isıtma Derece Gün (HDD), 12 aylık gecikmeli tüketim değerleri ve nem oranı bağımsız değişken olarak alınmıştır. Çalışmada üç popüler makine öğrenmesi algoritması olan MLR, SVR ve RF Regresyonu kullanılarak tahminler yapılmış ve performansları karşılaştırılmıştır. Sonuçlar, modellerin birbirine yakın performans sergilediğini ancak en yüksek R-kare değerine Çoklu Doğrusal Regresyon (MLR) ile ulaşıldığını göstermiştir. Çalışma, daha az değişken içeren ve görece basit modellerde geleneksel yöntemlerin de başarılı olabileceğini öne sürmektedir.

Çalmaşur ve Tuna (2020), enerji talebi bağlamında farklı bir konuya değinilmektedir. Çalışma, elektrik yerine doğal gaz talebine odaklanmakta ve gelecek tüketimi tahmin etmekten ziyade, Erzurum ilinde ikamet eden insanların doğal gaz kullanma tercihini etkileyen faktörleri belirlemeye çalışmaktadır. Bu amaçla, 738 hane

halkından yüz yüze anket yöntemiyle toplanan veriler, Logit regresyon modeli kullanılarak analiz edilmiştir. Analiz sonuçlarına göre, hanedeki birey sayısı, yıllık ısınma giderleri ve konutun dış cephesinin yalıtımsız olması gibi faktörler doğal gaz talebini (kullanma eğilimini) negatif yönde etkilerken; konutun yüzölçümü (metrekare) ve hane halkı geliri pozitif yönde etkilemektedir. Bu çalışma, tüketim miktar tahmini sunmak yerine, talep davranışını etkileyen faktörlerin analizi açısından literatüre önemli bir katkı sağlamaktadır.

Kocadayi ve ark. (2017), yaptıkları çalışmada TR81 Bölgesi (Zonguldak, Karabük, Bartın) için yıllık bazda bölgesel elektrik enerjisi tüketimini tahmin etmeyi amaçlamıştır. Araştırmacılar, bu tahmini gerçekleştirmek için YSA yöntemini kullanmışlardır. Modelin girdilerinde bölgenin nüfusu, ithalat ve ihracat değerleri ile bina yüzölçümü verileri (TÜİK 2002-2014 dönemi) kullanılmıştır. Çok katmanlı ileri beslemeli YSA modeli, farklı parametrelerle (gizli katman nöron sayısı, eğitim/test veri oranı) denenerek en iyi performansı veren yapı belirlenmiştir. Modelin başarısı MSE, MAE ve Korelasyon Katsayısı (R-kare) ile ölçülmüştür. Sonuçlar, YSA modelinin bölgenin elektrik tüketimini yüksek bir doğrulukla (%99,75 R-kare) tahmin edebildiğini ortaya koymuş ve bu model kullanılarak 2016-2020 yılları için tüketim öngörülleri üretilmiştir. Çalışma, bölgesel enerji planlaması ve yatırım kararlarına destek olmayı hedeflemiştir.

Köse (2023), gıda ve içecek sektöründe faaliyet gösteren bir şirketin ürünleri için günlük talebi tahmin eden bir Karar Destek Sistemi (KDS) geliştirmeye odaklanmaktadır. Tezin ayırt edici yönü, farklı veri setlerine uyarlanabilirliği sağlamak amacıyla hiper parametre optimizasyonunu merkezi bir bileşen olarak kullanmasıdır. Çalışmada, makine öğrenmesi RF, XGBoost ve derin öğrenme YSA, LSTM modelleri kullanılmıştır. Yürütülen çalışma, İstanbul'daki bir firmanın 5 farklı ürününe ait 4,5 yıllık günlük satış verileri üzerinden gerçekleştirilmiştir. Modellerin performansı MAPE, MAE, MSE ve RMSE metrikleriyle değerlendirilmiş ve ek olarak istatistiksel bir model olan ARIMA ile de karşılaştırılmıştır. Sonuçlar, geliştirilen KDS'nin ve içerdiği modellerin (özellikle RF ve XGBoost) başarılı tahminler yaptığını göstermiştir. Derin öğrenme modellerinin performansı bu veri setinde biraz daha düşük kalsa da potansiyelleri ortaya konmuştur. İlginç bir bulgu olarak, ARIMA modelinin bu spesifik veri seti için en iyi performansı sergilediği görülmüştür. Ayrıca, hiperparametre optimizasyonunun uygulanmasıyla birlikte performansın arttığı ve modellerde aşırı öğrenme sorunuyla karşılaşmadığı tespit edilmiştir.

Dođru ve B y kakin (2023), T rkiye'nin b lgelerinden biri olan TR42 (Kocaeli, Sakarya, D zce, Bolu, Yalova) b lgesinin aylık elektrik enerjisi talebini tahmin etmeye odaklanmaktadır. Bu dođrultuda, 2016-2022 d nemi verileri kullanılarak makine  đrenmesi y ntemlerinden MLR analizi yapılmıřtır. Modelde girdi olarak elektrik fiyatı (TL ve Dolar), dolar kuru, T FE, konut satıřları, hava durumu (meteorolojik veriler), iř g n  sayısı ve kiři sayısı gibi deđiřkenler kullanılmıřtır. Analiz, b lgedeki her il (Bolu, D zce, Kocaeli, Sakarya, Yalova) i in ayrı ayrı ger ekleřtirilmiřtir. Sonu lar, Yalova dıřındaki iller i in yapılan tahminlerin iyi sonu lar verdiđini g stermiřtir.

Hamza ebi ve Kutay (2004), T rkiye'nin ulusal d zeydeki uzun d nemli (2010 yılına kadar) elektrik enerjisi t ketimini tahmin etmeyi ama lamıřtır.  alıřmanın temel hedefi, YSA tekniklerinin bu t r bir tahmindeki etkinliđini arařtırmak ve performansını ARIMA ve Regresyon Tekniđi ile karřılařtırmaktır.  alıřmada, 1970-1990 verileri eđitim/model belirleme, 1991-1998 verileri dođrulama (YSA i in) ve 1999-2002 verileri test i in kullanılmıřtır. YSA modelleri ve diđer y ntemler uygulanmıřtır. Sonu lar, YSA tekniklerinin test periyodu i in ARIMA ve Regresyon Tekniđine g re daha iyi tahmin performansı sergilediđini g stermiřtir. Bu bulgu, YSA'nın elektrik enerjisi t ketim tahmininde g  l  bir ara  olabileceđini ortaya koymaktadır.

Halilođlu ve Tutu (2018), T rkiye'nin g nl k elektrik enerjisi talebini tahmin etmek i in ekonometrik bir model geliřtirmeyi ama lamaktadır. Literat rdeki yıllık tahminlerin aksine g nl k frekansa odaklanan  alıřmada, modele dinamik bir mevsimsellik etkisi katmak amacıyla eřik sıcaklık farkı adında yeni bir deđiřken tanımlanmıřtır. 2012-2017 arası g nl k veriler model kurulumu, Ocak-Nisan 2018 verileri ise model testi i in kullanılmıřtır. En K  k Kareler (EKK) y ntemi ile kurulan modelde, bađımsız deđiřken olarak eřik sıcaklık farkı, zaman kuklaları (haftanın g n , tatiller) ve bir g n  nceki elektrik t ketime yer almıřtır. Sonu lar, modelin elektrik talebini %92,8 oranında a ıkladıđını ve test d nemindeki tahminlerin ger ekleřen deđerlerden aylık ortalama sapmasının d ř k (%1,3-%1,6 aralıđında) olduđunu g stermiřtir. Bu da modelin kısa vadeli tahminler i in g venilir olduđunu ortaya koymaktadır.

Yavuzdemir (2014), T rkiye'nin kısa d nem yıllık br t elektrik enerjisi talebini tahmin edilmesi hedeflenmiřtir.  alıřmanın temel girdisi olarak satın alma g c  paritesine g re hesaplanmış GSYİH verileri kullanılmıřtır. Tezin amacı, bu tek parametreye dayalı olarak Bulanık Mantık, Trend Analizi ve Dođrusal Regresyon olmak  zere    farklı matematiksel y ntemin tahmin performanslarını karřılařtırmaktır.

Performans değerlendirmesi MAPE metriği üzerinden yapılmıştır. Sonuçlar, kullanılan verilerle trend analizi modelinin %2,75 MAPE ile en iyi performansı gösterdiğini, bunu %4,81 MAPE ile bulanık mantık ve %7,64 MAPE ile doğrusal regresyon modelinin takip ettiğini ortaya koymuştur.

Durğun (2018), Türkiye'nin uzun dönem elektrik enerjisi tüketimini tahmin etmeyi amaçlamaktadır. Çalışmada, 1980-2017 yılları arasındaki GSYİH, nüfus ve meteorolojik veriler (nem, sıcaklık, rüzgâr, yağış) girdi olarak kullanılarak Regresyon Analizi (MATLAB programı aracılığıyla) ve yapay zeka teknikleri, WEKA programı aracılığıyla Makine Öğrenmesi algoritmaları: Doğrusal Regresyon, MLR, Sıralı Minimum İyileştirme (SMO), Gauss Süreci Regresyonu (GPR) uygulanmıştır. Veri seti 1980-2012 (model oluşturma/eğitim) ve 2013-2017 (test) olarak ikiye ayrılmıştır. Modellerin performansı MAPE değerleri ile karşılaştırılmış ve ardından 2018-2023 yılları için tahminler üretilmiştir. Sonuçların karşılaştırıldığı zaman, MATLAB ile yapılan regresyon analizinin test verisi üzerinde genel olarak WEKA'daki bireysel makine öğrenmesi algoritmalarından daha iyi performans (daha düşük ortalama MAPE) gösterdiğini ortaya koymuştur.

Elektrik tüketimi ile ilgili yapılan belirli çalışmalarını aşağıdaki tabloda kısaca özetleyebiliriz;

Çizelge 2.1. Elektrik enerjisi tahmin çalışmaları özet tablo

| Çalışmanın Adı | Kullanılan Yöntemler | Kısa Sonuç |
|--|--|---|
| Düzce İli Elektrik Enerjisi Talep Tahmini | ARIMA, TBATS, Prophet (Zaman Serisi Modelleri) | Genel olarak ARIMA daha başarılı bulundu, ancak bazı aylarda TBATS ve Prophet daha iyi sonuç verdi. Hibrit model potansiyeli vurgulandı. |
| Yapay Sinir Ağları ile Tr81 Bölgesi Yıllık Elektrik Enerjisi Tüketiminin Tahmini | Yapay Sinir Ağları (YSA-Çok katmanlı ileri beslemeli) | YSA modelinin %99,75 R ² ile yüksek doğruluk sağladığı ve 2016-2020 için tahminler üretildiği belirtildi. |
| TR42 Bölgesi İçin Elektrik Enerjisi Talebinin Makine Öğrenimi Tabanlı Tahmini | Çoklu Doğrusal Regresyon (Makine Öğrenmesi yaklaşımı olarak) | Yalova dışındaki iller için (Bolu, Düzce, Kocaeli, Sakarya) iyi tahmin sonuçları elde edildiği ifade edildi. Performans metrikleri il bazında değişkenlik gösterdi. |
| Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini | Ekonometrik Model (EKK) | Modelin yüksek açıklayıcılığa (%92,8 R ²) sahip olduğu ve test döneminde tahminlerin gerçekleşen değerlere yakın (aylık ortalama %1,3-%1,6 sapma) olduğu bulundu. |

| Çalışmanın Adı | Kullanılan Yöntemler | Kısa Sonuç |
|---|---|--|
| Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini | Zaman Serisi (Trend Analizi), Bulanık Mantık, Doğrusal Regresyon | Ortalama Mutlak Bağlı Hata (MAPE) karşılaştırmasında Zaman Serisi (%2,75) en iyi performansı gösterdi, bunu Bulanık Mantık (%4,81) ve Doğrusal Regresyon (%7,64) izledi. |
| Türkiye'nin Enerji Talebinin Yapay Zeka Teknikleriyle Uzun Dönem Tahmini | Regresyon Analizi, LR, MLP, SMO, GPR. | Performans metrikleri karşılaştırıldığında, test verileri üzerinde regresyon analizinin genellikle makine öğrenmesi algoritmalarından daha düşük MAPE değerleri verdiği görüldü. |
| Kısa Dönem Elektrik Talep Tahminleri için Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrit Sistem Geliştirilmesi | Yapay Sinir Ağları, Uzman Sistemler | Oluşturulan modelin farklı zaman aralıklarında MAPE'nin %1-2 aralığında seyrettiği gözlemlenmiştir. |
| Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini | Yapay Sinir Ağları, Zaman Serileri | Yapay Sinir Ağlarının %98 doğruluk oranıyla sonuç veriyorken, Zaman Serilerinde bu oran %93 olarak belirlenmiştir. |
| Electricity Consumption Estimation With Differential Polynomial and Artificial Neural Networks: Case of Türkiye | Yapay Sinir Ağları, Diferansiyel Polinom Sinir Ağları | D-PNN, RMSE metriğine göre %52,5 ve MAPE metriğine göre %58,8 oranında YSA'dan daha iyi performans sergilemiştir. |
| Seydişehir Bölgesinin Orta Vadedeki Elektrik Enerjisi Talebinin Yapay Zeka ile Tahmini | Yapay Sinir Ağları, Regresyon Analizi Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi | Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Regresyon Analizi ve Yapay Sinir Ağlarına göre daha başarılı bir sonuç ortaya koymuştur. |
| Short-Term Forecast For Turkey'S Electricity Demand DNN vs LSTM | Derin Sinir Ağları, Yığılmış Uzun Kısa Süreli Bellek | Derin Sinir Ağları, Yığılmış Uzun Kısa Süreli Bellek yöntemine göre daha iyi bir sonuç göstermiştir. |

Literatürde yapılmış diğer çalışmalara göz attığımızda klasik istatistiksel yöntemler tatmin edici sonuçlar verse de son zamanlarda yapılan çalışmalarda Yapay Sinir Ağları mimarileri ve çeşitli Makine Öğrenmesi algoritmalarının öne çıktığı görülmektedir. Bu çalışmamızda, özellikle diğer sektörlerde tahmin çalışmalarında kullanılan ve başarılı sonuçlar verdiği gözlemlenen modellerin ilk defa elektrik tüketim problemlerinde kullanılarak karşılaştırılması aynı zamanda farklı teknolojiler kullanılmasının elde edilen sonuçlar üzerindeki etkilerinin incelenmesinin amaçlanması sağlanmıştır.

Çizelge 2.2 Elektrik enerjisi tahmini çalışmaları model karşılaştırılması

| Çalışmanın Adı | YSA | Regresyon | DT | RF | GBM | XGB | Klasik İstatistiksel Yöntemler |
|----------------|-----|-----------|----|----|-----|-----|--------------------------------|
| Mevcut Çalışma | ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | ✗ |

| Çalışmanın Adı | YSA | Regresyon | DT | RF | GBM | XGB | Klasik İstatistiksel Yöntemler |
|---|-----|-----------|----|----|-----|-----|--------------------------------|
| Düzce İli Elektrik Enerjisi Talep Tahmini | x | x | x | x | x | x | ✓ |
| Yapay Sinir Ağları ile Tr81 Bölgesi Yıllık Elektrik Enerjisi Tüketiminin Tahmini | ✓ | x | x | x | x | x | x |
| TR42 Bölgesi İçin Elektrik Enerjisi Talebinin Makine Öğrenimi Tabanlı Tahmini | x | ✓ | x | x | x | x | x |
| Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini | x | x | x | x | x | x | ✓ |
| Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini | x | ✓ | x | x | x | x | ✓ |
| Türkiye'nin Enerji Talebinin Yapay Zeka Teknikleriyle Uzun Dönem Tahmini | ✓ | x | x | x | x | x | ✓ |
| Kısa Dönem Elektrik Talep Tahminleri için Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrit Sistem Geliştirilmesi | ✓ | x | x | x | x | x | x |
| Yapay Sinir Ağları ve Zaman Serileri Yöntemi ile Bir Endüstri Alanının (İvedik OSB) Elektrik Enerjisi İhtiyaç Tahmini | ✓ | x | x | x | x | x | ✓ |
| Electricity Consumption Estimation With Differential Polynomial and Artificial Neural Networks: Case of Türkiye | ✓ | x | x | x | x | x | x |
| Seydişehir bölgesinin orta vadedeki elektrik enerjisi talebinin Yapay Zeka ile tahmini | ✓ | ✓ | x | x | x | x | x |
| Short-Term Forecast For Turkey'S Electricity Demand DNN vs LSTM | ✓ | x | x | x | x | x | x |

3. MATERYAL VE YÖNTEM

Bu çalışmada Tüm Türkiye özelinde toplanan bir yıllık saatlik tüketim verilerinin Çoklu Doğrusal Regresyon, Rassal Orman Regresyonu, Karar Ağaçları Algoritması, Gradyan Arttırma Algoritması, XGBoost Algoritması ve Yapay Sinir Ağları kullanılarak elektrik tüketimini etkileyen faktörler üzerinde uygulanarak yöntemlerin Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) değerlerinin karşılaştırılması amaçlanmıştır.

Çalışmada kullanılan veri seti EPIAŞ (Enerji Piyasaları İşletme A.Ş.) tarafından temin edilmiştir. Kullanılan veriler 2024 yılının Nisan ayından, 2025 yılının Nisan ayını kapsayacak şekilde saatlik olarak temin edilmiştir. İlgili tarihte, saatlik tüketim değerleri MWh (Megavat-saat) cinsinden belirtilmiştir.

Çizelge 3.1. Veri setine ait ilk 20 satır

| Tarih | Saat | Tüketim (MWh) |
|------------|-------|---------------|
| 26.04.2024 | 00:00 | 35.791,46 |
| 26.04.2024 | 01:00 | 33.172,22 |
| 26.04.2024 | 02:00 | 32.484,44 |
| 26.04.2024 | 03:00 | 31.388,00 |
| 26.04.2024 | 04:00 | 30.496,44 |
| 26.04.2024 | 05:00 | 30.983,03 |
| 26.04.2024 | 06:00 | 30.694,68 |
| 26.04.2024 | 07:00 | 32.758,50 |
| 26.04.2024 | 08:00 | 38.406,07 |
| 26.04.2024 | 09:00 | 40.874,86 |
| 26.04.2024 | 10:00 | 41.646,18 |
| 26.04.2024 | 11:00 | 42.205,72 |
| 26.04.2024 | 12:00 | 39.830,73 |
| 26.04.2024 | 13:00 | 39.363,05 |
| 26.04.2024 | 14:00 | 41.480,39 |
| 26.04.2024 | 15:00 | 41.329,95 |
| 26.04.2024 | 16:00 | 41.297,82 |
| 26.04.2024 | 17:00 | 41.010,80 |
| 26.04.2024 | 18:00 | 39.973,18 |
| 26.04.2024 | 19:00 | 40.496,36 |
| 26.04.2024 | 20:00 | 41.701,66 |
| 26.04.2024 | 21:00 | 40.555,10 |
| 26.04.2024 | 22:00 | 39.262,45 |
| 26.04.2024 | 23:00 | 37.524,82 |

Çizelge 3.2. Veri setine ait ilk 20 Satır

| Tarih | Saat | Tüketim (MWh) |
|------------|-------|---------------|
| 27.04.2024 | 00:00 | 35.938,24 |
| 27.04.2024 | 01:00 | 34.526,06 |
| 27.04.2024 | 02:00 | 32.890,49 |
| 27.04.2024 | 03:00 | 31.846,49 |
| 27.04.2024 | 04:00 | 31.352,90 |
| 27.04.2024 | 05:00 | 31.081,14 |
| 27.04.2024 | 06:00 | 30.406,29 |
| 27.04.2024 | 07:00 | 31.363,30 |
| 27.04.2024 | 08:00 | 35.169,90 |
| 27.04.2024 | 09:00 | 37.865,85 |
| 27.04.2024 | 10:00 | 39.516,32 |
| 27.04.2024 | 11:00 | 40.322,43 |
| 27.04.2024 | 12:00 | 39.200,85 |
| 27.04.2024 | 13:00 | 39.786,82 |
| 27.04.2024 | 14:00 | 39.809,92 |
| 27.04.2024 | 15:00 | 39.109,34 |
| 27.04.2024 | 16:00 | 38.552,03 |
| 27.04.2024 | 17:00 | 38.530,70 |
| 27.04.2024 | 18:00 | 38.335,91 |
| 27.04.2024 | 19:00 | 39.053,48 |
| 27.04.2024 | 20:00 | 40.106,92 |
| 27.04.2024 | 21:00 | 39.304,24 |
| 27.04.2024 | 22:00 | 37.997,81 |
| 27.04.2024 | 23:00 | 36.317,26 |

3.1. Çoklu Doğrusal Regresyon (MLR)

MLR, istatistiksel modelleme ve makine öğrenmesi alanlarında, bir bağımlı değişken ile bu değişkeni etkilediği düşünülen birden fazla bağımsız değişken arasındaki ilişkiyi analiz etmek ve modellemek için yaygın olarak kullanılan temel yöntemlerden birisidir (Polo-Mendoza ve ark., 2024), (Kanıt ve Baykan, 2004). Basit doğrusal regresyon tek bir etkene odaklanırken, MLR tek bir faktör yerine birden çok etkenin bir sonuç üzerindeki kümülatif etkisinin incelenmesini sağlar. Bu özelliği, onu elektrik enerjisi talebi tahmini (Doğru ve Büyükakın, 2023), (Karaca ve Karacan, 2016), bina yaklaşık maliyetlerinin belirlenmesi (Kanıt ve Baykan, 2004), meteorolojik verilerle bulutluluk tahmini (Zateroglu, 2023), hava kirliliği modellemesi (Şenel ve ark., 2014) veya zeminlerin geoteknik özelliklerinin tahmini (Polo-Mendoza ve ark., 2024) gibi çok çeşitli alanlarda değerli bir araç haline getirir. MLR'nin amacı, bağımsız değişkenlerdeki

değişimlerin bağımlı değişkeni nasıl etkilediğini niceliksel anlamda ortaya koyarak geleceğe yönelik tahminlerde bu ilişkiyi geleceğe yönelik tahminlerde kullanmaktadır.

MLR'nin temelinde, bağımlı değişken (Y) ile bağımsız değişkenler (X_1, X_2, \dots, X_p) arasında doğrusal bir fonksiyonel ilişki olduğu varsayımı yatar (Şenel ve ark., 2014). Bu ilişki genellikle şu matematiksel denklemle ifade edilir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (3.1)$$

MLR'nin katsayıların kolayca yorumlanabilmesi sayesinde değişkenler arasındaki ilişkilerin yönünü ve büyüklüğünü anlamak açısından oldukça avantajlı olduğu görülmektedir. Matematiksel temelleri nispeten basit ve anlaşılırdır. Uygulamasının kolay ve sonuçlarının değerlendirilmesinin kola diğer yöntemlere göre öne çıkmasını sağlamaktadır. Ayrıca daha karmaşık makine öğrenmesi veya derin öğrenme modelleri geliştirmeden önce, veriyi anlamak ve bir başlangıç performans seviyesi belirlemek için iyi bir referans noktası sağlar (Polo-Mendoza ve ark., 2024). Öte yandan MLR'nin en temel kısıtlılıklarından bir tanesi doğrusallık kısıtıdır. Gerçek dünyadaki ilişkiler genellikle doğrusal olmadığından, MLR bu karmaşık yapıları yakalamada yetersiz kalabilir. Kullanılan veri setindeki aykırı gözlemler, regresyon doğrusunun eğimini ve kesme noktasını ciddi şekilde etkileyebilir.

MLR'nin basitliği ve yorumlana bilirliliği sayesinde elektrik tüketimi tahmini çalışmalarında kullanılmaktadır. Farklı ekonomik (GSYH, elektrik fiyatı, dolar kuru), demografik (nüfus, tüketici sayısı) ve meteorolojik (sıcaklık, nem, iş günü sayısı) faktörlerin tüketim üzerindeki doğrusal etkilerini belirlemek ve karşılaştırmak için kullanılabilir gibi (Doğru ve Büyükkın, 2023), kısa vadeli veya daha az karmaşık talep yapıları için temel tahminler üretmede ve daha sofistike modellerin performansını değerlendirmek için bir başlangıç noktası olarak kullanılabilir.

3.2. Gradyan Arttırma Makineleri (GBM)

GBM, denetimli öğrenme problemlerinde (hem sınıflandırma hem de regresyon) oldukça başarılı sonuçlar üreten, ağaç tabanlı güçlü bir topluluk (ensemble) öğrenme tekniğidir (Ouadi ve ark., 2024), (Hoang, 2024). Temel fikri, modeli aşamalı olarak inşa etmektir; her yeni eklenen model (genellikle bir karar ağacı), önceki modellerin yaptığı hataları (kalıntıları veya gradyanları) düzeltmeye odaklanır (Badirli ve ark., 2020). Bu ardışık öğrenme süreci, zayıf öğrencileri (weak learners – tek başına tahmin gücü sınırlı

modeller) bir araya getirerek oldukça doğru ve sağlam tahminler yapabilen güçlü bir topluluk modeli oluşturmayı sağlar. Özellikle yapısal (tabular) veriler üzerinde genellikle en son teknoloji performansı sergilemesiyle bilinir ve finansal risk tahmini (Ji ve Li, 2025), mühendislik problemlerinde malzeme özelliklerinin tahmini (Hoang, 2024), verim tahmini (Sánchez ve ark., 2025), veya operasyonel tahminler (Lui ve ark., 2025) gibi çok çeşitli alanlarda başarıyla uygulanmıştır.

XGBoost ise standart GBM algoritmasının üzerine önemli iyileştirmeler getirerek hem hızı hem de performansı artıran popüler bir kütüphane ve algoritmadır (Lui ve ark., 2025). XGBoost'un temel özellikleri şunlardır:

- Düzenleştirme (Regularization): Aşırı öğrenmeyi önlemek için hem L1 (Lasso) hem de L2 (Ridge) düzenleştirme terimlerini kayıp fonksiyonuna ekler. Bu, modelin karmaşıklığını kontrol altında tutar ve daha genellenebilir modeller üretir (Hoang, 2024).
- Ağaç Budama (Tree Pruning): Ağaçları büyüttükten sonra geriye doğru budama (post-pruning) yerine, maksimum derinliğe göre veya negatif kayıp azalmasına göre dallanmayı durdurarak (pre-pruning) daha verimli bir budama yapar.
- Eksik Değer Yönetimi: Eksik verileri otomatik olarak ele almak için yerleşik mekanizmalara sahiptir.
- Paralel İşleme: Ağaç oluşturma sürecinin belirli adımlarını paralelleştirerek hesaplama süresini önemli ölçüde azaltır.
- Önbellek Farkındalığı ve Blok Yapısı: Donanım optimizasyonları sayesinde veri erişimini hızlandırır.
- Çapraz Doğrulama: Model eğitimi sırasında çapraz doğrulama yapma imkanı sunar.
- İkinci Derece Gradyan Bilgisi: Kayıp fonksiyonunu optimize etmek için sadece birinci derece gradyanları değil, ikinci derece gradyanları (Hessian) da kullanarak daha hızlı ve doğru yakınsama sağlayabilir (Badirli ve ark., 2020).

XGBoost, Genellikle sınıflandırma ve regresyon görevlerinde, özellikle yapısal veriler üzerinde, en iyi performansı gösteren algoritmalardan biridir (Ouadi ve ark., 2024), (Hoang, 2024). Aşırı öğrenmeye karşı yerleşik mekanizmalara sahip olduğu gibi eksik verileri de dahili olarak yönetebilmektedir.

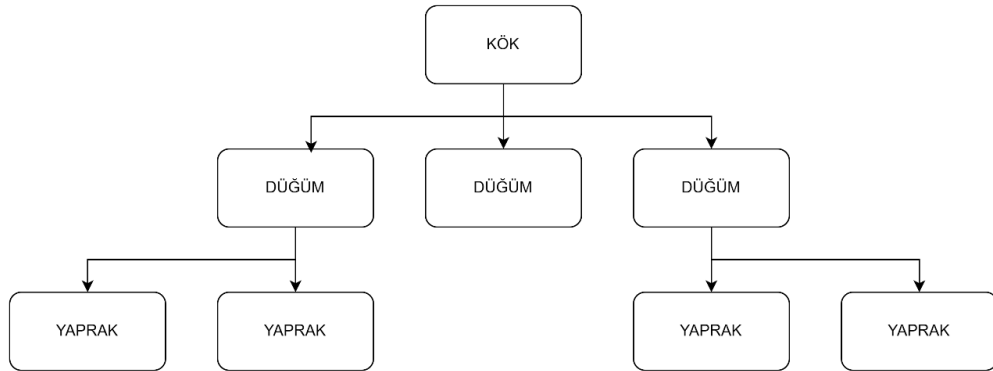
Gradyan artırma yöntemleri, özellikle XGBoost, elektrik tüketimi tahmini gibi zaman serisi problemlerinde güçlü bir adaydır çünkü; elektrik tüketimini etkileyen çok sayıda faktör (hava durumu, takvim etkileri, ekonomik aktivite, önceki tüketim değerleri

vb.) arasındaki doğrusal olmayan ve karmaşık etkileşimleri başarılı bir şekilde modelleyebilme yeteneğine sahiptir. Zaman serisi verilerinden türetilen özelliklerle (gecikmeli değerler, hareketli ortalamalar, mevsimsel kukla değişkenler vb.) etkin bir şekilde çalışabilir, ayrıca yüksek doğruluk potansiyeli sayesinde diğer birçok modelleme tekniğinden daha doğru tahminler üretebilir.

3.3. Karar Ağaçları Algoritması (DT)

DT, hem sınıflandırma hem de regresyon problemleri için kullanılan, denetimli öğrenme (supervised learning) algoritmalarının temel ve popüler bir sınıfıdır (Charbuty ve Abdulazeez, 2021). Temel fikir, veri setini özelliklerine göre hiyerarşik bir yapıda, tekrar tekrar bölerek karar kuralları oluşturmaktır. Oluşturulan yapı, bir ağacın dallarına benzediği için bu şekilde isimlendirilebilmektedir. Kök düğümünden başlayarak, her bir iç düğümde (internal node) veriyi belirli bir özelliğe göre ayırarak alt kümelere böler ve bu süreç, yaprak düğümlere (leaf nodes) ulaşılan kadar devam eder. Yaprak düğümler, nihai tahmini (sınıf etiketi veya regresyon değeri) temsil eder (Charbuty ve Abdulazeez, 2021), (Gao ve ark., 2025). Karar Ağaçları, basit ve kolay yorumlanabilmesi sayesinde tercih edilebilmektedir (Bounia ve Setitra, 2025).

Karar Ağaçlarının çalışma mekanizmasını aşağıdaki gibi görselleştirebiliriz;



Şekil 3.1. Karar ağaçları algoritması örnek şema gösterimi

Eğitilmiş bir karar ağacı ile yeni bir veri örneği için tahmin yapmak oldukça basittir. Örnek, ağacın kök düğümünden başlar ve her bir iç düğümde, o düğümün test kriterine (belirli bir özellik ve eşik değeri) göre ilgili dala (sola veya sağa) yönlendirilir. Bu süreç, örnek bir yaprak düğüme ulaşılan kadar devam eder. Yaprak düğüme

ulaşıldığında, o yaprak düğüme atanmış olan sınıf etiketi veya regresyon değeri, yeni örnek için tahmin olarak verilir (Charbuty ve Abdulazeez, 2021).

DT, aşırı uyum sağlama (overfitting) eğilimi gösterebilmektedir (Alizade-Harakiyan ve ark., 2025). Bu, ağacın eğitim verisindeki gürültüyü veya spesifik desenleri öğrenmesi ancak yeni, görünmeyen verilere iyi genelleme yapamaması anlamına gelir. Aşırı öğrenmeyi engellemek için budama (pruning) teknikleri kullanılır. Budama, ağacın karmaşıklığını azaltmak için bazı dalların veya düğümlerin kaldırılması işlemidir. Ağaç inşa edilirken, belirli kriterler (örn. minimum örnek sayısı, maksimum derinlik) karşılanmazsa dallanma durdurulur, bu işleme Ön Budama adı verilir. Sonradan Budama işlemi ise, önce tam bir ağaç büyütülür, ardından genelleme performansını artırmayan dallar (genellikle bir doğrulama seti üzerinde test edilerek) kaldırılır. Maliyet-Karmaşıklık Budaması (Cost-Complexity Pruning - CCP) yaygın bir sonradan budama tekniğidir (Demirezen ve Çetin, 2021).

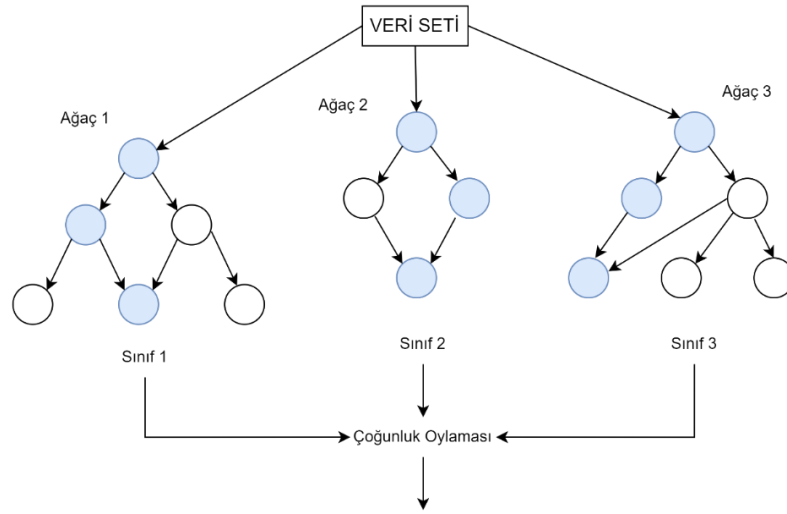
Karar Ağaçları algoritması yorumlana bilirliliği, doğrusal olmayan ilişkileri modellemeyebilme ve çoğu algoritmaya göre basit olması avantajlarına sahipken, Aşırı Öğrenme Eğilimine sahip olması en önemli dezavantajı olarak değerlendirilebilir.

Karar Ağaçları algoritmasının sahip olduğu özellikler incelendiğinde elektrik tüketiminin tahmin edilmesinde bazı avantajlar sağlayabilir. Gün, ay, mevsim gibi kategorik verileri doğrudan işleyebilir, sıcaklık gibi değişkenlerin tüketim üzerindeki etkisinin belirli eşik değerlerinde değiştiği durumları modelleyebilir.

3.4. Rassal Orman Algoritması (RF)

RF, Leo Breiman (2001) tarafından önerilen ve hem sınıflandırma hem de regresyon görevlerinde yüksek doğruluk sağlayan, ağaç tabanlı bir topluluk öğrenmesi (ensemble learning) algoritmasıdır (Mayer ve ark., 2022). Temel amacı, tek bir Karar Ağacı'nın (Decision Tree) varyansının yüksek olması ve ezberlemeye (aşırı öğrenme - overfitting) yatkın olması gibi dezavantajlarını, çok sayıda ağacı bir araya getirerek ve tahminlerini birleştirerek gidermektir (Özen, 2024), (Hassan ve ark., 2023). Çok sayıda "zayıf" veya "orta kuvvette" öğreniciyi birleştirerek "güçlü" bir öğrenici oluşturma fikrine dayanır. Bu kolektif yapı, modelin daha sağlam, gürültüye karşı daha dayanıklı ve genelleme yeteneği daha yüksek olmasını sağlar (Sevgen ve Aliefendioğlu, 2020), (Akay ve ark., 2019). Enerji (Sevgen ve Aliefendioğlu, 2020), finans (Collin ve ark., 2024), tıp (Hassan ve ark., 2023), gayrimenkul değerlendirme (Akay ve ark., 2019), tarım (Erdoğan ve

Özyürek, 2012), ekoloji (Özen, 2024) gibi çok çeşitli alanlarda karmaşık ilişkileri modellemek ve doğru tahminler yapmak için başarıyla kullanılmaktadır.



Şekil 3.2 Rassal orman algoritması örnek şema gösterimi

RF temelinde 2 farklı prensiple hareket etmektedir. Bunlar; Bagging (Bootstrap Aggregating) ve Rastgele Öznitelik Alt Kümesidir. Bagging prensibinde Algoritma, orijinal eğitim veri setinden yerine koyma yöntemiyle (sampling with replacement) rastgele n adet alt örneklem (bootstrap sample) oluşturur. Bu, her bir alt örneklemin orijinal veri setiyle aynı boyutta olabileceği ancak bazı veri noktalarının birden fazla kez, bazılarının ise hiç seçilmeyebileceği anlamına gelir. Ormandaki her bir Karar Ağacı, bu farklı bootstrap örneklemi üzerinde bağımsız olarak eğitilir (Özen, 2024), (Hassan ve ark., 2023), (Erdoğan ve Özyürek, 2012). Rastgele Öznitelik Alt Kümesinde ise RF'nin her bir düğümünde (bölünme noktasında), veriyi en iyi şekilde ayıracak özneliği ve eşik değerini belirlemek için tüm öznelikler dikkate alınmaz. Bunun yerine, toplam öznelik havuzundan rastgele seçilmiş daha küçük bir öznelik alt kümesi değerlendirilir. Bu, ormandaki ağaçların birbirine çok benzemesini engeller, ağaçlar arasındaki korelasyonu düşürür ve topluluğun çeşitliliğini artırarak modelin genelleme performansını yükseltir (Mayer ve ark., 2022), (Özen, 2024). Regresyon problemlerinde öznelik alt kümesi değeri genellikle toplam öznelik sayısının üçte biri ($p/3$) olarak tavsiye edilir (Mayer ve ark., 2022). Tahmin aşamasında, yeni bir veri noktası ormandaki tüm ağaçlara sunulur. Her ağaç kendi regresyon tahminini yapar. Rassal Orman modelinin nihai regresyon tahmini, tüm bu bireysel ağaç tahminlerinin aritmetik ortalaması alınarak elde edilir (Akay ve ark., 2019).

RF, genellikle çok çeşitli veri kümeleri üzerinde yüksek tahmin doğruluğu ve sağlam (robust) performans sergiler. Özellikle karşılaştırmalı çalışmalarda, diğer makine öğrenmesi yöntemlerine (YSA, SVM gibi) göre daha iyi veya benzer sonuçlar verdiği sıklıkla raporlanmıştır (Özen, 2024), (Hassan ve ark., 2023) , (Akay ve ark., 2019). Yapısındaki rassallık mekanizmaları sayesinde, tekil karar ağaçlarına kıyasla aşırı öğrenmeye karşı oldukça dirençlidir (Özen, 2024), fakat sağlamış olduğu bu avantajlar algoritmanın eğitim ve tahmin aşamaları tekil modellere göre daha fazla hesaplama kaynağı (zaman ve bellek) gerektirebilir. Aynı zamanda Modelin içsel çalışma mekanizması, özellikle çok sayıda ağaç içerdiğinde, tek bir karar ağacı kadar şeffaf ve kolay yorumlanabilir değildir. Modelin neden belirli bir tahminde bulunduğunu tam olarak anlamak zor olabilir (Özen, 2024).

3.5. Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (YSA), insan beyninin temel çalışma prensiplerinden, özellikle nöronların birbirleriyle etkileşim kurarak bilgi işleme ve öğrenme yeteneğinden esinlenerek geliştirilmiş güçlü matematiksel ve hesaplamalı modellerdir (Krenker ve ark., 2011), (Bailer-Jones ve ark., 2001), (Aydın ve Yazıcıoğlu, 2019). Birçok alanda geleneksel yöntemlerin yerini alan YSA, özellikle karmaşık, doğrusal olmayan ilişkileri modelleme ve büyük veri setlerinden örüntüler öğrenme konusunda üstün yeteneklere sahiptir (Aydın ve Yazıcıoğlu, 2019). Finansal piyasa tahminleri (Krenker ve ark., 2011), görüntü işleme, doğal dil işleme ve bu tezin odak noktası olan enerji tüketimi tahmini gibi çok çeşitli problemlere başarıyla uygulanmaktadır. Elektrik tüketimi gibi dinamik, çok değişkenli ve genellikle doğrusal olmayan davranışlar sergileyen sistemlerin modellenmesinde güçlü bir alternatif sunarlar (Krenker ve ark., 2011).

Çalışma mekanizmasını incelemek gerekirse ilk olarak Yapay Nöronlardan bahsedebiliriz. Yapay Nöron, YSA'nın temel yapı taşı, biyolojik nöronu basitleştirilmiş şekilde taklit eden yapay nöronudur. Her nöron, kendisine bağlı diğer nöronlardan veya dışarıdan girdiler alır. Bu girdiler, bağlantıların gücünü temsil eden "ağırlıklar" ile çarpılır. Ağırlıklandırılmış girdiler, bir "bias" terimi ile birlikte bir toplama fonksiyonunda birleştirilir. Elde edilen net girdi değeri, genellikle doğrusal olmayan bir aktivasyon fonksiyonundan (transfer fonksiyonu) geçirilerek nöronun çıktısı üretilir (Krenker ve ark., 2011), (Bailer-Jones ve ark., 2001), (Aydın ve Yazıcıoğlu, 2019). Yapay nöronlar, genellikle katmanlar (layers) halinde düzenlenir. En temel ileri beslemeli (feedforward) mimaride üç tür katman bulunur:

- Girdi Katmanı (Input Layer): Modelde kullanılmak üzere verinin aldığı katmandır. Her bir nöron, bir bağımsız değişkene (öznitelik) karşılık gelir.
- Gizli Katman(lar) (Hidden Layer(s)): Girdi ve çıktı katmanları arasında yer alan bir veya daha fazla katmandır. Verideki karmaşık örüntüleri ve öznitelikler arası etkileşimleri öğrenmekten sorumludur. Katman sayısı ve her katmandaki nöron sayısı, modelin kapasitesini belirleyen önemli tasarım parametreleridir
- Çıktı Katmanı (Output Layer): Modelin tahminini veya sınıflandırma sonucunu üreten katmandır. Nöron sayısı, tahmin edilmek istenen değişken sayısına bağlıdır.

Katman yapısıyla beraber, Yapay Sinir Ağlarının ağ mimarisinden de bahsetmemiz gerekir. Çalışmalarda en yaygın kullanılan mimari, bilginin sadece ileri yönde (girdiden çıktıya doğru) aktığı İleri Beslemeli Ağlar (Feedforward Networks), özellikle Çok Katmanlı Algılayıcı'dır (Multilayer Perceptron - MLP) (Aydın ve Yazıcıoğlu, 2019). Zaman serisi gibi sıralı verilerin modellenmesinde ise, geçmiş bilgiyi işleyebilen geri besleme bağlantılarına sahip Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN) ve bunların gelişmiş versiyonları olan Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) ve Kapılı Tekrarlayan Birim (Gated Recurrent Unit - GRU) ağları sıklıkla kullanılır (Bailer-Jones ve ark., 2001), (Kumar ve ark., 2025). Görüntü verileri için Evrimsel Sinir Ağları (Convolutional Neural Networks - CNN) standart haline gelmiştir (Kumar ve ark., 2025). Bu çalışmada odaklanılan ileri ve geri beslemeli mimariler, birçok regresyon problemi için güçlü bir temel model sunmaktadır. Yapay Sinir Ağlarındaki Aktivasyon Fonksiyonları ise, ağlara doğrusal olmayan öğrenme yeteneği kazandıran kritik bileşenlerdir. Gizli katmanlarda yaygın olarak Sigmoid, Hiperbolik Tanjant ve özellikle Düzeltilmiş Doğrusal Birim (Rectified Linear Unit - ReLU) ve varyantları kullanılır. ReLU, hesaplama verimliliği ve gradyan yok olması sorununu hafifletmesi nedeniyle modern derin öğrenme modellerinde sıklıkla tercih edilir (Kumar ve ark., 2025), (Aydın ve Yazıcıoğlu, 2019). Çıktı katmanında ise regresyon problemleri için genellikle doğrusal aktivasyon fonksiyonu kullanılır.

YSA'lar genellikle denetimli öğrenme (supervised learning) paradigması ile eğitilir. Bu süreç şu adımları içerir:

- Veri Besleme: Eğitim setindeki girdi verileri ağa sunulur ve ağın mevcut ağırlıklarla bir tahmin üretmesi beklenir.

- Hata Hesaplama: Ağın tahmini ile gerçek hedef değer arasındaki fark, bir kayıp fonksiyonu (loss function) kullanılarak hesaplanır. Regresyon problemleri için yaygın olarak Ortalama Karesel Hata (Mean Squared Error - MSE) kullanılır.
- Geri Yayılım (Backpropagation): Hesaplanan hata, ağ üzerinden çıktı katmanından girdi katmanına doğru geriye yayılır. Bu süreçte, her bir ağırlığın ve biasın hataya olan katkısı (gradyanı) zincir kuralı kullanılarak hesaplanır.
- Ağırlık Güncelleme: Hesaplanan gradyanlar, bir optimizasyon algoritması (örn. Stokastik Gradyan İniş - SGD, Adam, RMSprop, Levenberg-Marquardt, tarafından kullanılarak ağın ağırlıkları ve biasları güncellenir. Amaç, kayıp fonksiyonunu minimize etmektir.
- Tekrarlama (Epochs): Bu ileri ve geri yayılım adımları, tüm eğitim verisi üzerinden defalarca (epoch sayısı kadar) tekrarlanır veya hata belirli bir seviyeye düşüncüye ya da başka bir durdurma kriteri karşılanıncaya kadar devam eder

Yapay Sinir Ağlarının en önemli avantajı doğrusal olmayan ve karmaşık veri örüntülerini öğrenebilme yeteneğidir. Çok sayıda girdi değişkeniyle başa çıkabilir ve değişkenler arasındaki karmaşık etkileşimleri otomatik olarak yakalayabilmektedir. Dezavantajlarına baktığımızda ise genellikle modelin belirli bir tahmine nasıl ulaştığını anlamak ve yorumlamak zordur. İçsel çalışma mekanizması kolayca anlaşılır değildir. Çoğunlukla iyi performans için büyük miktarda etiketli veriye ihtiyaç duyarlar. Veri az olduğunda performansları düşebilir veya aşırı öğrenmeye yatkın olabilirler. Hesaplama maliyetleri yüksek olabilir, Derin ve karmaşık ağların eğitimi, önemli hesaplama kaynakları (GPU gibi) ve zaman gerektirebilir.

YSA'lar, elektrik tüketiminin altında yatan karmaşık, dinamik ve doğrusal olmayan ilişkileri (hava durumu etkileri, mevsimsel döngüler, gün içi örüntüler, tatil etkileri, ekonomik faktörler vb.) yakalayabilme potansiyelleri nedeniyle bu alanda yaygın olarak kullanılmaktadır. Özellikle yeterli tarihsel veri mevcut olduğunda, geleneksel istatistiksel modellere kıyasla daha doğru tahminler üretebilirler.

Zaman serisi tahminleri için LSTM gibi özel mimariler, geçmiş tüketim örüntülerinin uzun vadeli bağımlılıklarını modellemede özellikle etkilidir. Ancak, model karmaşıklığı, veri gereksinimleri ve yorumlanabilirlik gibi zorluklar göz önünde bulundurulmalıdır. Karşılaştırmalı çalışmalarda, YSA'ların performansı Rassal Orman veya Gradyan Artırma gibi diğer yöntemlerle rekabet edebilir veya bazı durumlarda daha iyi/kötü olabilir; bu durum probleme ve verilere bağlıdır.

4. UYGULAMA VE TARTIŞMA

Çalışmanın sonucunu değerlendirmek üzere Yapay Sinir Ağları, Karar Ağaçları Algoritması, Rassal Orman Algoritması, Gradyan Arttırma Makineleri, XGBoost Algoritması ve Çoklu Doğrusal Regresyon Algoritması kullanılmıştır. Yöntemler, Spyder (Python 3.10) terminali kullanılarak uygulanmış ve görselleştirilmiştir. Modellerin içeri aktarılması için Keras ve Scikit Learn kütüphaneleri kullanılmıştır. Keras, Derin Öğrenme modelleri oluşturmak için tasarlanmış, yüksek seviyeli bir YSA kütüphanesidir. Scikit Learn ise klasik makine öğrenmesi algoritmalarını içeren, açık kaynaklı ve kullanımı kolay bir kütüphanedir.

4.1. Uygulama

Yöntemlerin uygulanabilmesi ve ortaya çıkan sonuçların performansının ölçülebilmesi için ilk olarak gerekli kütüphanelerin içeri aktarılması gerekmektedir. Keras ve Scikit Learn algoritmaları farklı kütüphaneler içerdikleri için uygulama esnasında bilgisayar üzerinde 2 farklı ortam kurulmuş ve kütüphaneler ilgili ortamlara yüklenmiştir.

Çalışma için EPIAŞ Şeffaflık Platformundan temin edilen veriler Excel dosyası yardımıyla .csv formatında içeri aktarılmıştır. Aktarılan veriler rastgele değil kronolojik olarak %70 eğitim ve %30 test oranında belirli bir noktadan ayrılarak ölçeklendirme işlemi gerçekleştirilmiştir.

Algoritmaların uygulanabilmesi için ön işlemeden geçirilen veriler, algoritmalar üzerinde uygulandıktan sonra Hataların Mutlak Değerlerinin Algoritması (MAE) ve Hataların Karesinin Ortalamasının Karekökü (RMSE) yöntemleriyle performans sonuçları ölçülmüştür. Çalışma sonunda ortaya çıkan sonuçları görsel olarak incelemek amacıyla matplotlib kütüphanesinden yararlanılarak uygulamalara ait grafiklerin çizilmesi sağlanmıştır. Çalışmaya ait ön veri işleme, modellerin uygulanması, performans ölçümü ve grafiklerin nasıl oluşturulduğundan bahsedilmiştir. Her bir modele ait sonuçlar ayrı başlıklar altında incelenecektir.

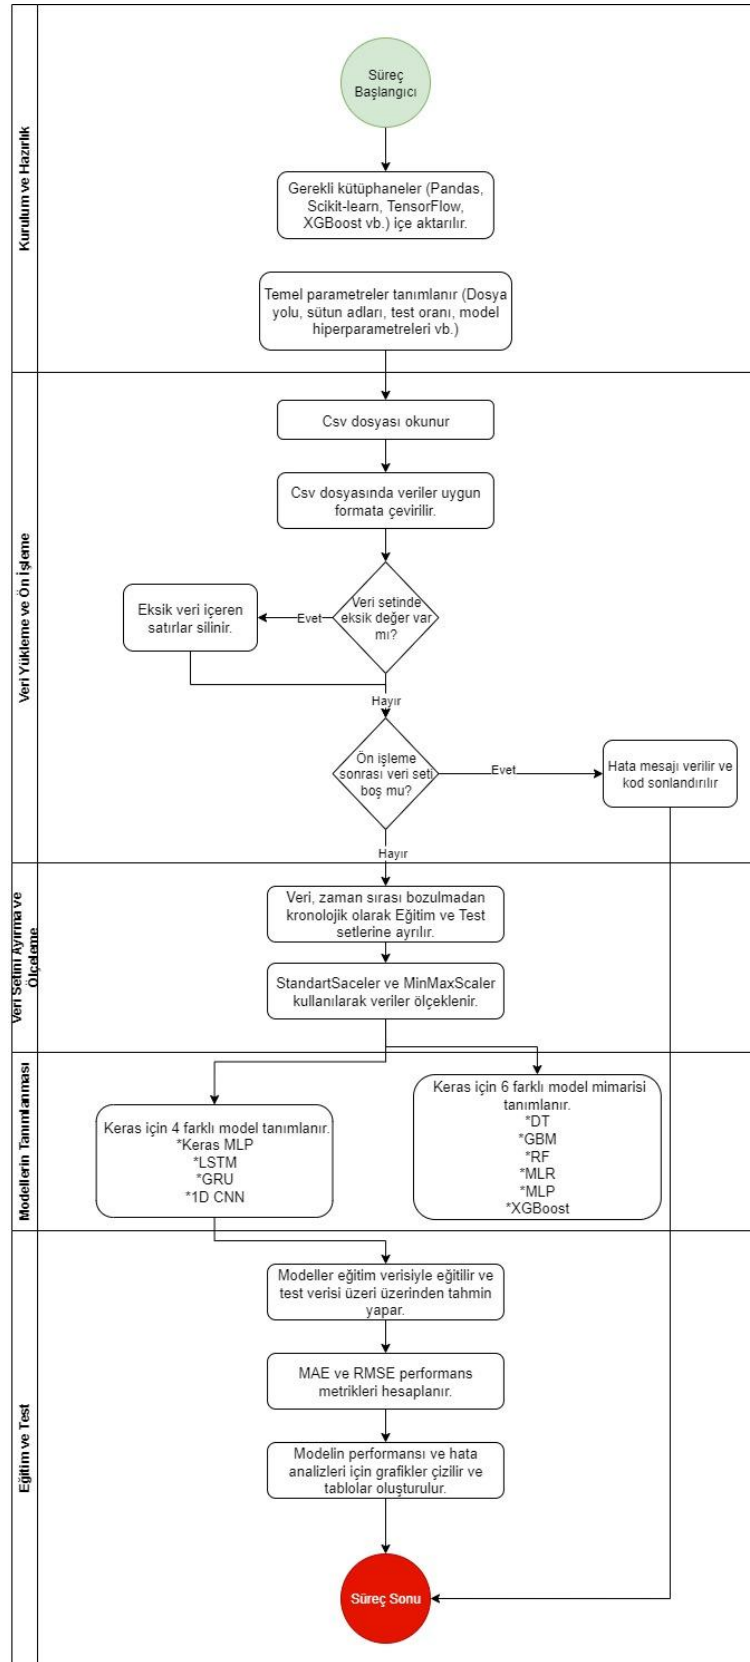
Çalışmada kullanılan algoritmalara ait özet tablo ise aşağıdaki gibidir;

Çizelge 4.1.Çalışmada kullanılan algoritmalar

| Algoritma/Mimari | Model Ailesi | Öğrenme Tipi | Kütüphane |
|--------------------------------|------------------|--------------|---------------|
| MLR (Çoklu Doğrusal Regresyon) | Makine Öğrenmesi | Tekil | Sci-Kit Learn |
| DT (Karar Ağacı) | Makine Öğrenmesi | Tekil | Sci-Kit Learn |

| Algoritma/Mimari | Model Ailesi | Öğrenme Tipi | Kütüphane |
|--|---------------------|---------------------|------------------|
| RF (Rastgele Orman) | Makine Öğrenmesi | Topluluk | Sci-Kit Learn |
| GBM (Gradyan Artırma) | Makine Öğrenmesi | Topluluk | Sci-Kit Learn |
| XGBoost | Makine Öğrenmesi | Topluluk | Sci-Kit Learn |
| MLP (Çok Katmanlı Algılayıcı) | Derin Öğrenme (YSA) | Tekil | Sci-Kit Learn |
| MLP (Çok Katmanlı Algılayıcı) | Derin Öğrenme (YSA) | Tekil | Keras |
| 1D CNN (1 Boyutlu Evrişimli Sinir Ağı) | Derin Öğrenme (YSA) | Tekil | Keras |
| LSTM (Uzun Kısa Süreli Bellek) | Derin Öğrenme (YSA) | Tekil | Keras |
| GRU (Kapılı Tekrarlayan Birim) | Derin Öğrenme (YSA) | Tekil | Keras |

Uygulamaya ait ana iş akış şeması ise aşağıdaki gibidir;



(Şekil 4.1.Uygulamaya ait iş akış şeması)

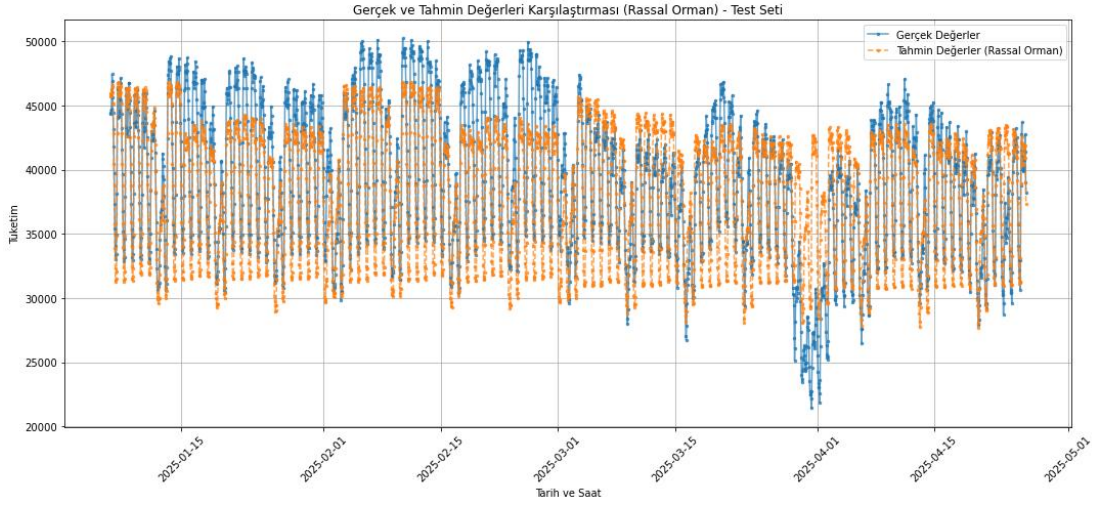
4.1.1. Rassal orman modeli uygulaması

Veri seti Rassal Orman modeli üzerinden çalıştırıldığında %93,91 doğruluk oranı ile MAE değeri 2.379.12 olmuştur. RMSE üzerinden değerlendirildiğinde ise %92,20 doğruluk oranı ile 3.048,13 değerini almıştır.

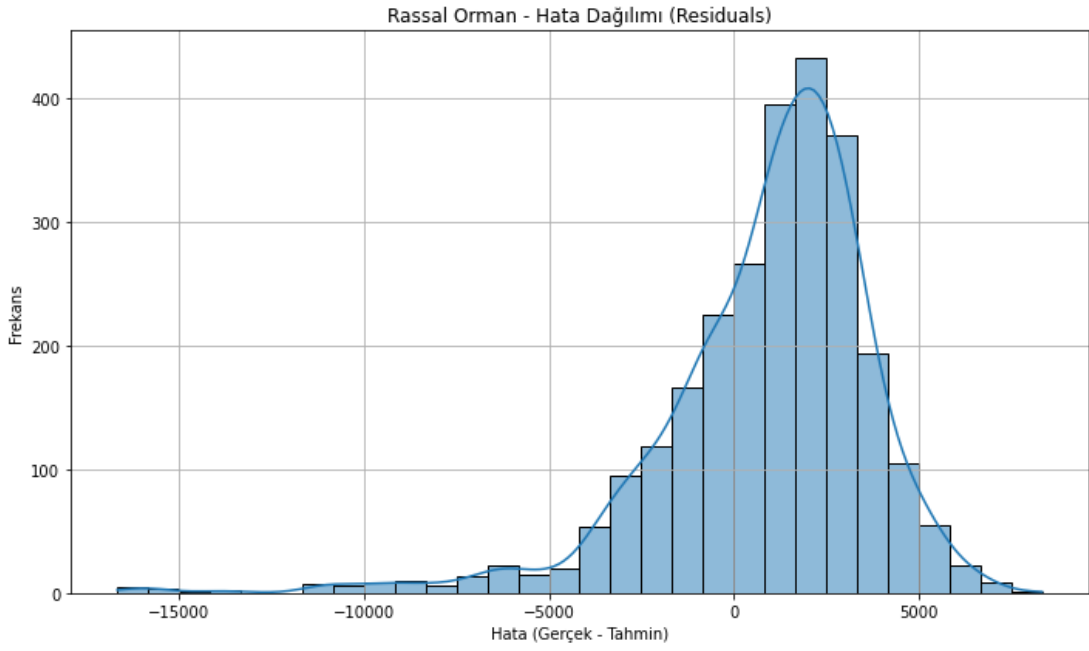
Elde edilen sonuçlara ait gerçek değer, tahmin değer, fark ve mesafeye ait karşılaştırma tablosu ile grafiği aşağıda gösterilmiştir;

Çizelge 4.2 Rassal orman modeli tahmin sonuçları ilk 24 veri


| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|-----------|----------|
| 6.01.2025 | 12:00:00 | 44.379,86 | 45.968,28 | -1.588,42 | 1.588,42 |
| 6.01.2025 | 13:00:00 | 44.438,04 | 45.678,77 | -1.240,73 | 1.240,73 |
| 6.01.2025 | 14:00:00 | 44.697,17 | 45.937,71 | -1.240,54 | 1.240,54 |
| 6.01.2025 | 15:00:00 | 44.678,40 | 45.908,10 | -1.229,70 | 1.229,70 |
| 6.01.2025 | 16:00:00 | 45.716,47 | 46.274,35 | -557,88 | 557,88 |
| 6.01.2025 | 17:00:00 | 47.430,58 | 46.605,46 | 825,12 | 825,12 |
| 6.01.2025 | 18:00:00 | 46.898,08 | 46.392,59 | 505,49 | 505,49 |
| 6.01.2025 | 19:00:00 | 45.620,63 | 46.000,86 | -380,23 | 380,23 |
| 6.01.2025 | 20:00:00 | 44.440,92 | 45.164,66 | -723,74 | 723,74 |
| 6.01.2025 | 21:00:00 | 43.191,54 | 42.845,41 | 346,13 | 346,13 |
| 6.01.2025 | 22:00:00 | 41.803,28 | 40.442,40 | 1.360,88 | 1360,88 |
| 6.01.2025 | 23:00:00 | 39.728,59 | 38.774,33 | 954,26 | 954,26 |
| 7.01.2025 | 00:00:00 | 37.369,33 | 35.793,86 | 1.575,47 | 1.575,47 |
| 7.01.2025 | 01:00:00 | 35.416,09 | 33.940,23 | 1.475,86 | 1.475,86 |
| 7.01.2025 | 02:00:00 | 34.025,14 | 32.344,33 | 1.680,81 | 1.680,81 |
| 7.01.2025 | 03:00:00 | 33.324,74 | 31.448,63 | 1.876,11 | 1.876,11 |
| 7.01.2025 | 04:00:00 | 33.056,53 | 31.287,69 | 1.768,84 | 1.768,84 |
| 7.01.2025 | 05:00:00 | 33.394,42 | 31.478,30 | 1.916,12 | 1.916,12 |
| 7.01.2025 | 06:00:00 | 34.907,00 | 32.073,83 | 2.833,17 | 2.833,17 |
| 7.01.2025 | 07:00:00 | 38.146,34 | 34.860,07 | 3.286,27 | 3.286,27 |
| 7.01.2025 | 08:00:00 | 44.006,50 | 42.861,08 | 1.145,42 | 1.145,42 |
| 7.01.2025 | 09:00:00 | 46.233,56 | 46.418,37 | -184,81 | 184,81 |
| 7.01.2025 | 10:00:00 | 46.469,96 | 46.783,50 | -313,54 | 313,54 |
| 7.01.2025 | 11:00:00 | 46.354,10 | 46.811,82 | -457,72 | 457,72 |




Şekil 4.2 Rassal orman modeli tahmin sonuçlarının grafik üzerinde gösterimi)



Şekil 4.3. Rassal orman modeli hata dağılım grafiği



Şekil 4.4. Rassal orman modeli hataların zaman göre değişim grafiği



Şekil 4.5. Rassal orman modeli tahmin gerçek değer dağılım grafiği

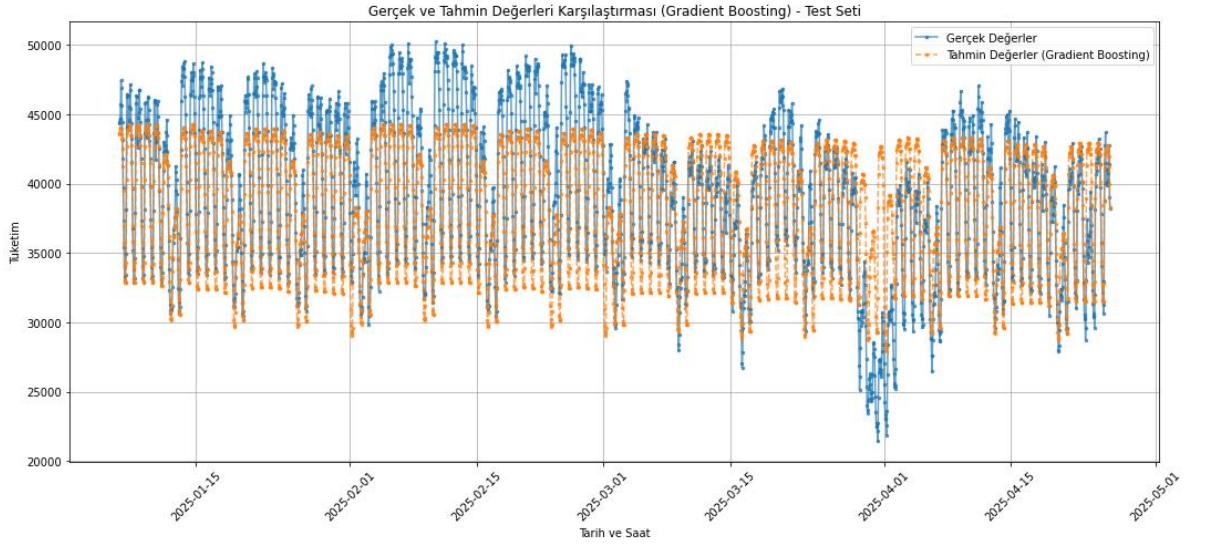
4.1.2. Gradyan arttırma modeli uygulaması

Gradyan Arttırma modelinde ise 2.309,87 MAE değeri ile %94,09 oranında doğruluk sağlarken, RMSE değeri göz önüne alındığında 3.059,19 ile %92,17 oranında bir doğruluk oranı göstermiştir.

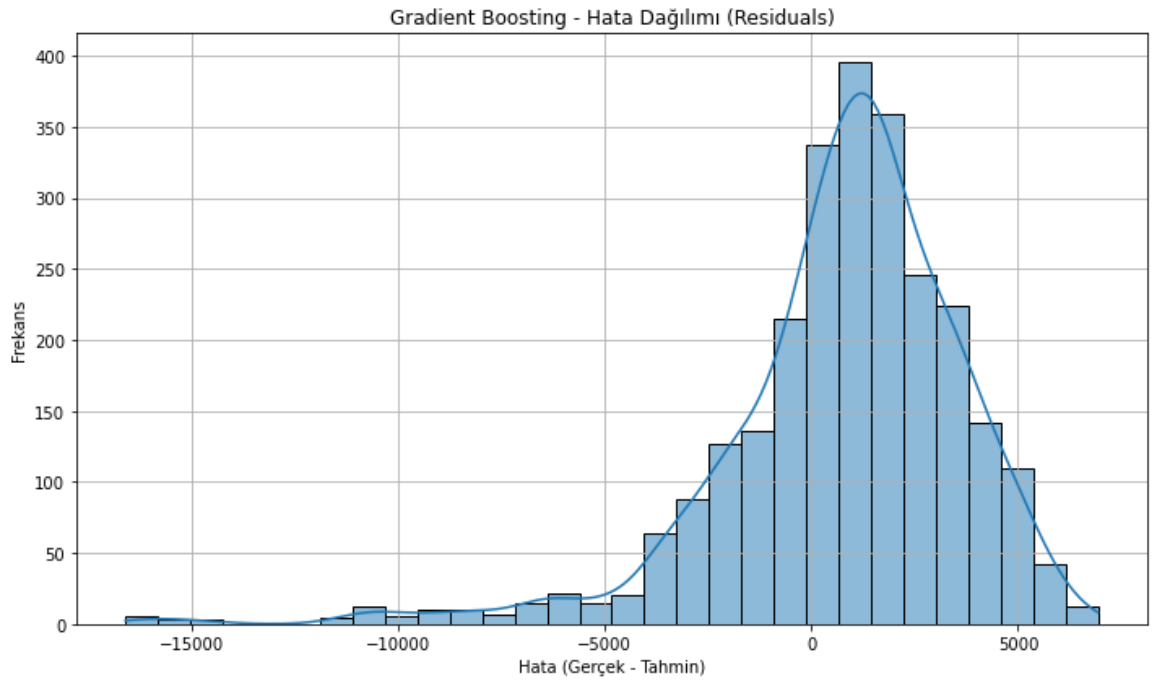
Elde edilen sonuçlara ait gerçek değer, tahmin değer, fark ve mesafeye ait karşılaştırma tablosu ile grafiği aşağıda gösterilmiştir;

Çizelge 4.3 Gradyan arttırma modeli tahmin sonuçları ilk 24 veri


| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|----------|----------|
| 6.01.2025 | 12:00:00 | 44.379,86 | 43.567,30 | 812,56 | 812,56 |
| 6.01.2025 | 13:00:00 | 44.438,04 | 43.658,84 | 779,20 | 779,20 |
| 6.01.2025 | 14:00:00 | 44.697,17 | 44.040,76 | 656,41 | 656,41 |
| 6.01.2025 | 15:00:00 | 44.678,40 | 44.040,76 | 637,64 | 637,64 |
| 6.01.2025 | 16:00:00 | 45.716,47 | 44.040,76 | 1.675,71 | 1.675,71 |
| 6.01.2025 | 17:00:00 | 47.430,58 | 43.961,85 | 3.468,73 | 3.468,73 |
| 6.01.2025 | 18:00:00 | 46.898,08 | 43.587,91 | 3.310,17 | 3.310,17 |
| 6.01.2025 | 19:00:00 | 45.620,63 | 43.201,29 | 2.419,34 | 2.419,34 |
| 6.01.2025 | 20:00:00 | 44.440,92 | 43.201,29 | 1.239,63 | 1.239,63 |
| 6.01.2025 | 21:00:00 | 43.191,54 | 42.497,79 | 693,75 | 693,75 |
| 6.01.2025 | 22:00:00 | 41.803,28 | 41.232,84 | 570,44 | 570,44 |
| 6.01.2025 | 23:00:00 | 39.728,59 | 39.494,32 | 234,27 | 234,27 |
| 7.01.2025 | 00:00:00 | 37.369,33 | 36.922,41 | 446,92 | 446,92 |
| 7.01.2025 | 01:00:00 | 35.416,09 | 35.755,42 | -339,33 | 339,33 |
| 7.01.2025 | 02:00:00 | 34.025,14 | 34.028,09 | -2,95 | 2,95 |
| 7.01.2025 | 03:00:00 | 33.324,74 | 33.124,81 | 199,93 | 199,93 |
| 7.01.2025 | 04:00:00 | 33.056,53 | 32.892,82 | 163,71 | 163,71 |
| 7.01.2025 | 05:00:00 | 33.394,42 | 32.860,02 | 534,40 | 534,40 |
| 7.01.2025 | 06:00:00 | 34.907,00 | 32.860,02 | 2.046,98 | 2046,98 |
| 7.01.2025 | 07:00:00 | 38.146,34 | 34.311,59 | 3.834,75 | 3834,75 |
| 7.01.2025 | 08:00:00 | 44.006,50 | 40.286,83 | 3.719,67 | 3719,67 |
| 7.01.2025 | 09:00:00 | 46.233,56 | 42.699,16 | 3.534,40 | 3534,40 |
| 7.01.2025 | 10:00:00 | 46.469,96 | 43.663,37 | 2.806,59 | 2806,59 |
| 7.01.2025 | 11:00:00 | 46.354,10 | 43.840,01 | 2.514,09 | 2514,09 |



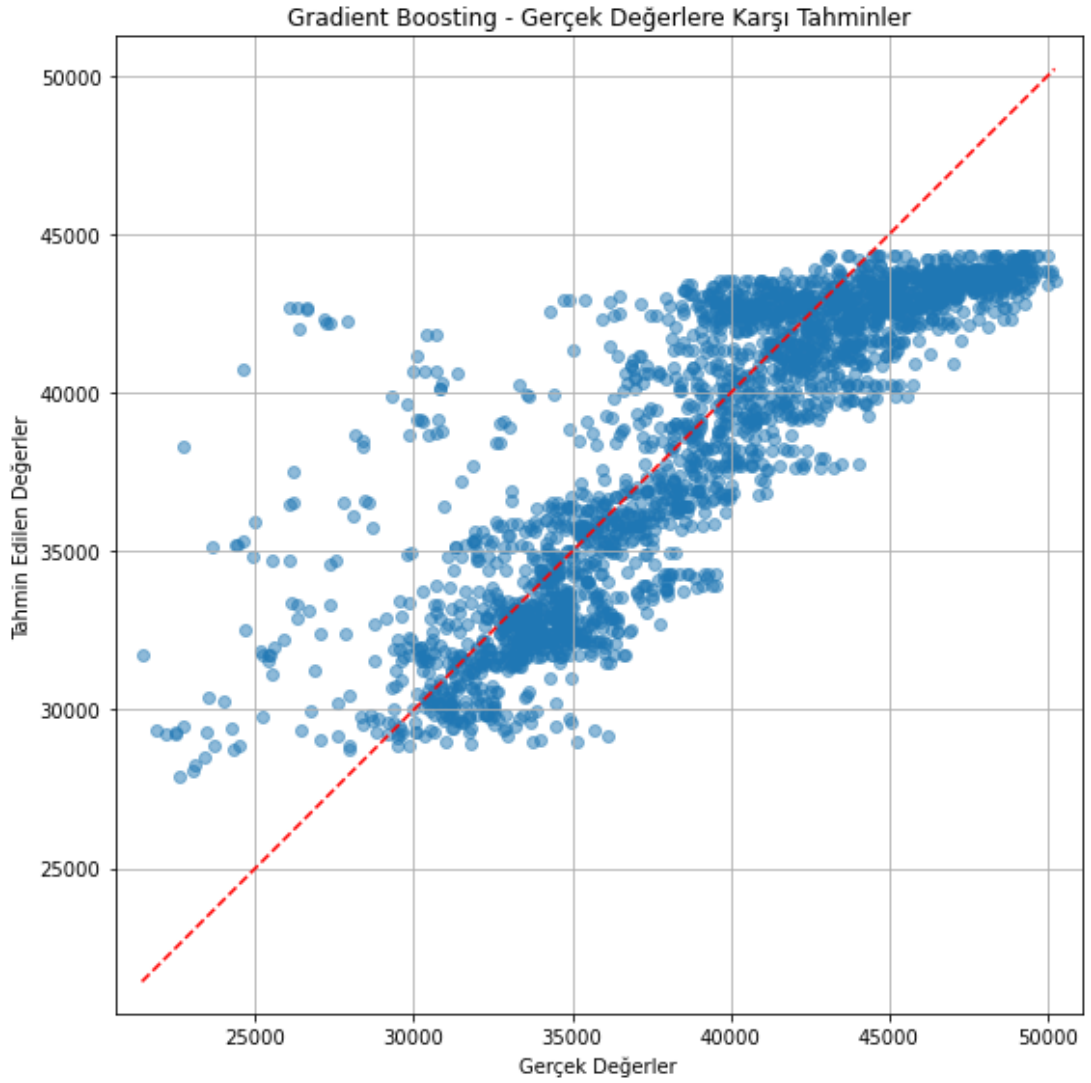
Şekil 4.6. Gradyan artırma modeli tahmin sonuçlarının grafik üzerinde gösterimi



Şekil 4.7. Gradyan artırma modeli hata dağılım grafiği



Şekil 4.8. Gradient boosting modeli hataların zaman göre değişim grafiği



Şekil 4.9. Gradient boosting modeli tahmin gerçek değer dağılım grafiği


4.1.3. XGBoost modeli uygulaması

XGBoost Modeline ait sonuçları incelediğimizde ise MAE değerinin 2.499,0 ile %93,60 oranında doğruluk performansı verdiği gözlenirken RMSE değerinde 3.368,92 değeriyle %91,38 oranında doğruluk performansı verildiği incelenmiştir.

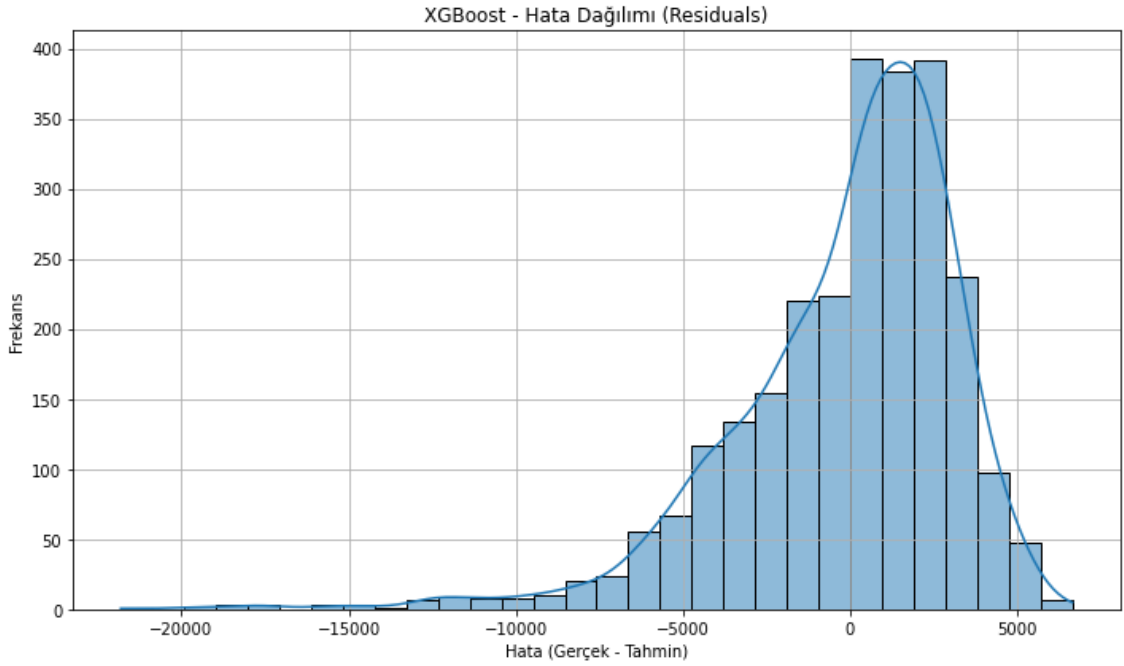
Elde edilen sonuçlara ait gerçek değer, tahmin değer, fark ve mesafeye ait karşılaştırma tablosu ile grafiği aşağıda gösterilmiştir;

Çizelge 4.4. XGBoost modeli tahmin sonuçları ilk 24 veri


| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|----------|----------|
| 6.01.2025 | 12:00:00 | 44.379,86 | 43.994,46 | 385,40 | 385,40 |
| 6.01.2025 | 13:00:00 | 44.438,04 | 44.202,83 | 235,20 | 235,20 |
| 6.01.2025 | 14:00:00 | 44.697,17 | 44.921,51 | -224,36 | 224,36 |
| 6.01.2025 | 15:00:00 | 44.678,40 | 44.621,46 | 56,94 | 56,94 |
| 6.01.2025 | 16:00:00 | 45.716,47 | 44.939,35 | 777,12 | 777,12 |
| 6.01.2025 | 17:00:00 | 47.430,58 | 45.959,46 | 1.471,12 | 1471,12 |
| 6.01.2025 | 18:00:00 | 46.898,08 | 45.888,66 | 1.009,42 | 1009,42 |
| 6.01.2025 | 19:00:00 | 45.620,63 | 46.004,60 | -383,97 | 383,97 |
| 6.01.2025 | 20:00:00 | 44.440,92 | 44.402,26 | 38,65 | 38,65 |
| 6.01.2025 | 21:00:00 | 43.191,54 | 43.236,32 | -44,78 | 44,78 |
| 6.01.2025 | 22:00:00 | 41.803,28 | 41.923,05 | -119,77 | 119,77 |
| 6.01.2025 | 23:00:00 | 39.728,59 | 40.106,92 | -378,34 | 378,34 |
| 7.01.2025 | 00:00:00 | 37.369,33 | 35.568,64 | 1.800,69 | 1.800,69 |
| 7.01.2025 | 01:00:00 | 35.416,09 | 33.618,19 | 1.797,89 | 1.797,89 |
| 7.01.2025 | 02:00:00 | 34.025,14 | 32.536,94 | 1.488,19 | 1.488,19 |
| 7.01.2025 | 03:00:00 | 33.324,74 | 31.305,90 | 2.018,84 | 2.018,84 |
| 7.01.2025 | 04:00:00 | 33.056,53 | 31.109,60 | 1.946,92 | 1.946,92 |
| 7.01.2025 | 05:00:00 | 33.394,42 | 31.377,91 | 2.016,51 | 2.016,51 |
| 7.01.2025 | 06:00:00 | 34.907,00 | 31.918,83 | 2.988,17 | 2.988,17 |
| 7.01.2025 | 07:00:00 | 38.146,34 | 35.062,46 | 3.083,88 | 3.083,88 |
| 7.01.2025 | 08:00:00 | 44.006,50 | 41.168,60 | 2.837,91 | 2.837,91 |
| 7.01.2025 | 09:00:00 | 46.233,56 | 43.637,46 | 2.596,10 | 2.596,10 |
| 7.01.2025 | 10:00:00 | 46.469,96 | 44.171,21 | 2.298,74 | 2.298,74 |
| 7.01.2025 | 11:00:00 | 46.354,10 | 45.188,23 | 1.165,87 | 1.165,87 |




Şekil 4.10 XGBoost modeli tahmin sonuçlarının grafik üzerinde gösterimi



Şekil 4.11. XGBoost modeli hata dağılım grafiği



Şekil 4.12. XGBoost modeli hataların zaman göre değişim grafiği




Şekil 4.13. XGBoost modeli tahmin gerçek değer dağılım grafiği

4.1.4. Karar ağaçları modeli uygulaması

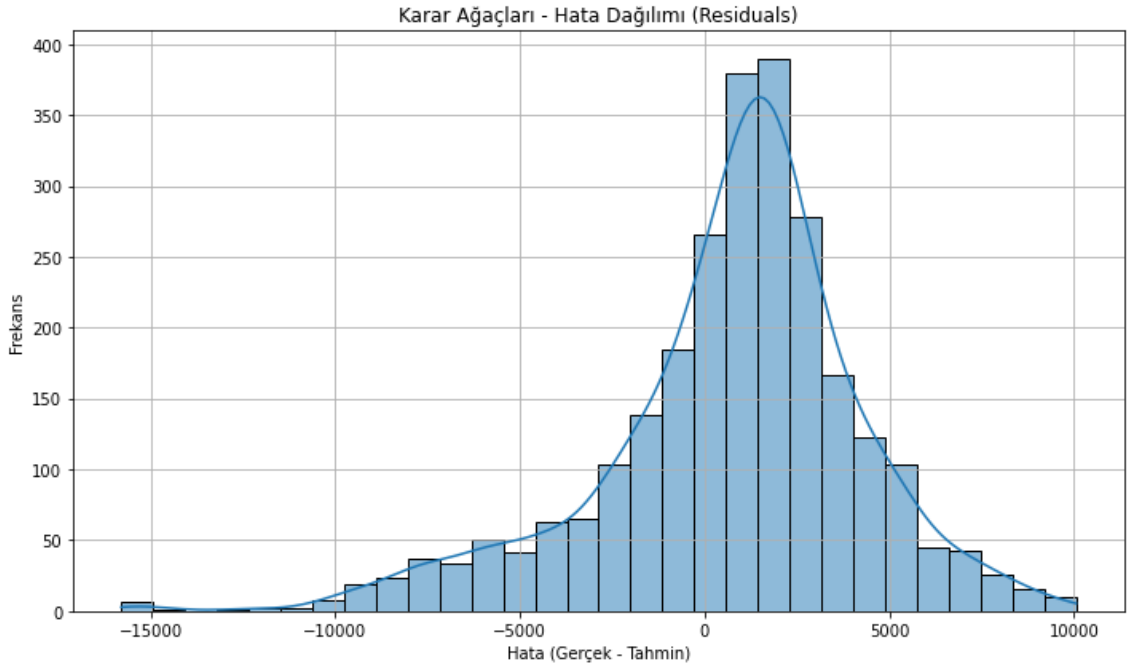
Karar Ağaçlarında ise MAE 2.799,39 değeri ile %92,83 oranında doğruluk performansı göstermiştir. RMSE değeri ise 3.643,43 değeri ile %90,67 oranında doğruluk göstermiştir.

Çizelge 4.5. Karar ağaçları modeli tahmin sonuçları ilk 24 veri


| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|-----------|----------|
| 6.01.2025 | 12:00:00 | 44.379,86 | 46.988,56 | -2.608,70 | 2.608,70 |
| 6.01.2025 | 13:00:00 | 44.438,04 | 46.988,56 | -2.550,52 | 2.550,52 |
| 6.01.2025 | 14:00:00 | 44.697,17 | 46.988,56 | -2.291,39 | 2.291,39 |
| 6.01.2025 | 15:00:00 | 44.678,40 | 46.988,56 | -2.310,16 | 2.310,16 |
| 6.01.2025 | 16:00:00 | 45.716,47 | 46.988,56 | -1.272,09 | 1.272,09 |
| 6.01.2025 | 17:00:00 | 47.430,58 | 46.988,56 | 442,02 | 442,02 |
| 6.01.2025 | 18:00:00 | 46.898,08 | 46.988,56 | -90,48 | 90,48 |
| 6.01.2025 | 19:00:00 | 45.620,63 | 46.988,56 | -1.367,93 | 1.367,93 |
| 6.01.2025 | 20:00:00 | 44.440,92 | 46.988,56 | -2.547,64 | 2.547,64 |
| 6.01.2025 | 21:00:00 | 43.191,54 | 41.309,15 | 1.882,39 | 1.882,39 |
| 6.01.2025 | 22:00:00 | 41.803,28 | 40.011,77 | 1.791,51 | 1.791,51 |
| 6.01.2025 | 23:00:00 | 39.728,59 | 38.145,06 | 1.583,53 | 1.583,53 |
| 7.01.2025 | 00:00:00 | 37.369,33 | 36.411,39 | 957,94 | 957,94 |
| 7.01.2025 | 01:00:00 | 35.416,09 | 34.478,68 | 937,41 | 937,41 |
| 7.01.2025 | 02:00:00 | 34.025,14 | 33.100,50 | 924,64 | 924,64 |
| 7.01.2025 | 03:00:00 | 33.324,74 | 32.336,74 | 988,00 | 988,00 |
| 7.01.2025 | 04:00:00 | 33.056,53 | 32.027,50 | 1.029,03 | 1.029,03 |
| 7.01.2025 | 05:00:00 | 33.394,42 | 32.177,70 | 1.216,72 | 1.216,72 |
| 7.01.2025 | 06:00:00 | 34.907,00 | 32.675,00 | 2.232,00 | 2.232,00 |
| 7.01.2025 | 07:00:00 | 38.146,34 | 33.978,66 | 4.167,68 | 4.167,68 |
| 7.01.2025 | 08:00:00 | 44.006,50 | 43.000,08 | 1.006,42 | 1.006,42 |
| 7.01.2025 | 09:00:00 | 46.233,56 | 46.582,00 | -348,44 | 348,44 |
| 7.01.2025 | 10:00:00 | 46.469,96 | 46.966,44 | -496,48 | 496,48 |
| 7.01.2025 | 11:00:00 | 46.354,10 | 46.988,56 | -634,46 | 634,46 |




Şekil 4.14. Karar ağaçları modeli tahmin sonuçlarının grafik üzerinde gösterimi



Şekil 4.15. Karar ağaçları modeli hata dağılım grafiği



Şekil 4.16. Karar ağaçları modeli hataların zaman göre değişim grafiği



Şekil 4.17. Karar ağaçları modeli tahmin gerçek değer dağılım grafiği

4.1.5. Çoklu doğrusal regresyon uygulaması

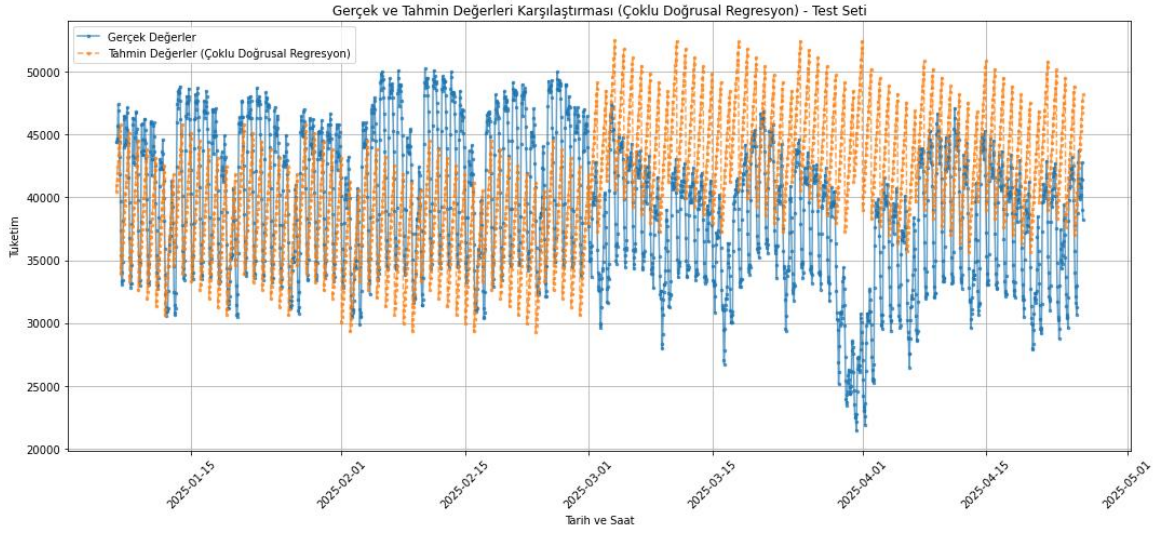
Elimizdeki veriler Çoklu Doğrusal Regresyon modeli üzerinde uygulandığında, bu zamana kadar incelemiş olduğumuz modellere nispeten daha düşük sonuçlar verdiğiniz incelenmektedir.

5.792,69 MAE değeri ile %85,17 oranında doğruluk oranı sağlarken, bu oran RMSE ölçümünde ise 7.053,56 ile %81,94 olarak ölçülmüştür.


Elde edilen sonuçlara ait gerçek değer, tahmin değer, fark ve mesafeye ait karşılaştırma tablosu ile grafiği aşağıda gösterilmiştir;

Çizelge 4.6. Çoklu doğrusal regresyon modeli tahmin sonuçları ilk 24 veri


| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|-----------|----------|
| 6.01.2025 | 12:00:00 | 44.379,86 | 40.457,51 | 3.922,35 | 3.922,35 |
| 6.01.2025 | 13:00:00 | 44.438,04 | 40.943,55 | 3.494,49 | 3.494,49 |
| 6.01.2025 | 14:00:00 | 44.697,17 | 41.429,59 | 3.267,58 | 3.267,58 |
| 6.01.2025 | 15:00:00 | 44.678,40 | 41.915,62 | 2.762,78 | 2.762,78 |
| 6.01.2025 | 16:00:00 | 45.716,47 | 42.401,66 | 3.314,81 | 3.314,81 |
| 6.01.2025 | 17:00:00 | 47.430,58 | 42.887,70 | 4.542,88 | 4.542,88 |
| 6.01.2025 | 18:00:00 | 46.898,08 | 43.373,74 | 3.524,34 | 3.524,34 |
| 6.01.2025 | 19:00:00 | 45.620,63 | 43.859,78 | 1.760,85 | 1.760,85 |
| 6.01.2025 | 20:00:00 | 44.440,92 | 44.345,82 | 95,10 | 95,10 |
| 6.01.2025 | 21:00:00 | 43.191,54 | 44.831,85 | -1.640,31 | 1.640,31 |
| 6.01.2025 | 22:00:00 | 41.803,28 | 45.317,89 | -3.514,61 | 3.514,61 |
| 6.01.2025 | 23:00:00 | 39.728,59 | 45.803,93 | -6.075,34 | 6.075,34 |
| 7.01.2025 | 00:00:00 | 37.369,33 | 33.961,62 | 3.407,71 | 3.407,71 |
| 7.01.2025 | 01:00:00 | 35.416,09 | 34.447,66 | 968,43 | 968,43 |
| 7.01.2025 | 02:00:00 | 34.025,14 | 34.933,70 | -908,56 | 908,56 |
| 7.01.2025 | 03:00:00 | 33.324,74 | 35.419,74 | -2.095,00 | 2.095,00 |
| 7.01.2025 | 04:00:00 | 33.056,53 | 35.905,78 | -2.849,25 | 2.849,25 |
| 7.01.2025 | 05:00:00 | 33.394,42 | 36.391,82 | -2.997,40 | 2.997,40 |
| 7.01.2025 | 06:00:00 | 34.907,00 | 36.877,86 | -1.970,86 | 1.970,86 |
| 7.01.2025 | 07:00:00 | 38.146,34 | 37.363,89 | 782,45 | 782,45 |
| 7.01.2025 | 08:00:00 | 44.006,50 | 37.849,93 | 6.156,57 | 6.156,57 |
| 7.01.2025 | 09:00:00 | 46.233,56 | 38.335,97 | 7.897,59 | 7.897,59 |
| 7.01.2025 | 10:00:00 | 46.469,96 | 38.822,01 | 7.647,95 | 7.647,95 |
| 7.01.2025 | 11:00:00 | 46.354,10 | 39.308,05 | 7.046,05 | 7.046,05 |




Şekil 4.18. Çoklu doğrusal regresyon modeli tahmin sonuçlarının grafik üzerinde gösterimi



Şekil 4.18. Çoklu doğrusal regresyon modeli hata dağılım grafiği



Şekil 4.19. Çoklu doğrusal regresyon modeli hataların zaman göre değişim grafiği



Şekil 4.20. Çoklu doğrusal regresyon modeli tahmin gerçek değer dağılım grafiği


4.1.6. Yapay sinir ağı uygulaması

Yapılan çalışmada Yapay Sinir Ağlarının Scikit Learn MLP mimarisinin en düşük doğruluk oranına sahip olduğu incelenmektedir. MAE 6.739,59 değeri ile %83,83 ve RMSE ise 7.973,13 değeri ile %80,74 oranlarında performans değerlerine ulaşmıştır.


Elde edilen sonuçlara ait gerçek değer, tahmin değer, fark ve mesafeye ait karşılaştırma tablosu ile grafiği aşağıda gösterilmiştir;

Çizelge 4.7. MLP modeli tahmin sonuçları ilk 24 veri)


| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|-----------|-----------|
| 6.01.2025 | 12:00:00 | 44.379,86 | 37.065,17 | 7.314,69 | 7.314,69 |
| 6.01.2025 | 13:00:00 | 44.438,04 | 37.337,10 | 7.100,94 | 7.100,94 |
| 6.01.2025 | 14:00:00 | 44.697,17 | 37.609,03 | 7.088,14 | 7.088,14 |
| 6.01.2025 | 15:00:00 | 44.678,40 | 37.880,97 | 6.797,43 | 6.797,43 |
| 6.01.2025 | 16:00:00 | 45.716,47 | 38.152,90 | 7.563,57 | 7.563,57 |
| 6.01.2025 | 17:00:00 | 47.430,58 | 38.424,84 | 9.005,74 | 9.005,74 |
| 6.01.2025 | 18:00:00 | 46.898,08 | 38.696,77 | 8.201,31 | 8.201,31 |
| 6.01.2025 | 19:00:00 | 45.620,63 | 38.968,70 | 6.651,93 | 6.651,93 |
| 6.01.2025 | 20:00:00 | 44.440,92 | 39.240,64 | 5.200,28 | 5.200,28 |
| 6.01.2025 | 21:00:00 | 43.191,54 | 39.512,57 | 3.678,97 | 3.678,97 |
| 6.01.2025 | 22:00:00 | 41.803,28 | 39.784,51 | 2.018,77 | 2.018,77 |
| 6.01.2025 | 23:00:00 | 39.728,59 | 40.056,44 | -327,85 | 327,85 |
| 7.01.2025 | 00:00:00 | 37.369,33 | 33.613,73 | 3.755,60 | 3.755,60 |
| 7.01.2025 | 01:00:00 | 35.416,09 | 33.885,66 | 1.530,43 | 1.530,43 |
| 7.01.2025 | 02:00:00 | 34.025,14 | 34.157,59 | -132,45 | 132,45 |
| 7.01.2025 | 03:00:00 | 33.324,74 | 34.429,53 | -1.104,79 | 1.104,79 |
| 7.01.2025 | 04:00:00 | 33.056,53 | 34.701,46 | -1.644,93 | 1.644,93 |
| 7.01.2025 | 05:00:00 | 33.394,42 | 34.973,40 | -1.578,98 | 1.578,98 |
| 7.01.2025 | 06:00:00 | 34.907,00 | 35.245,33 | -338,33 | 338,33 |
| 7.01.2025 | 07:00:00 | 38.146,34 | 35.517,27 | 2.629,07 | 2.629,07 |
| 7.01.2025 | 08:00:00 | 44.006,50 | 35.789,20 | 8.217,30 | 8.217,30 |
| 7.01.2025 | 09:00:00 | 46.233,56 | 36.061,13 | 10.172,43 | 10.172,43 |
| 7.01.2025 | 10:00:00 | 46.469,96 | 36.333,07 | 10.136,89 | 10.136,89 |
| 7.01.2025 | 11:00:00 | 46.354,10 | 36.605,00 | 9.749,10 | 9.749,10 |




Şekil 4.21. MLP modeli tahmin sonuçlarının grafik üzerinde gösterimi



Şekil 4.22. MLP modeli hata dağılım grafiği



Şekil 4.23. MLP modeli hataların zaman göre değişim grafiği

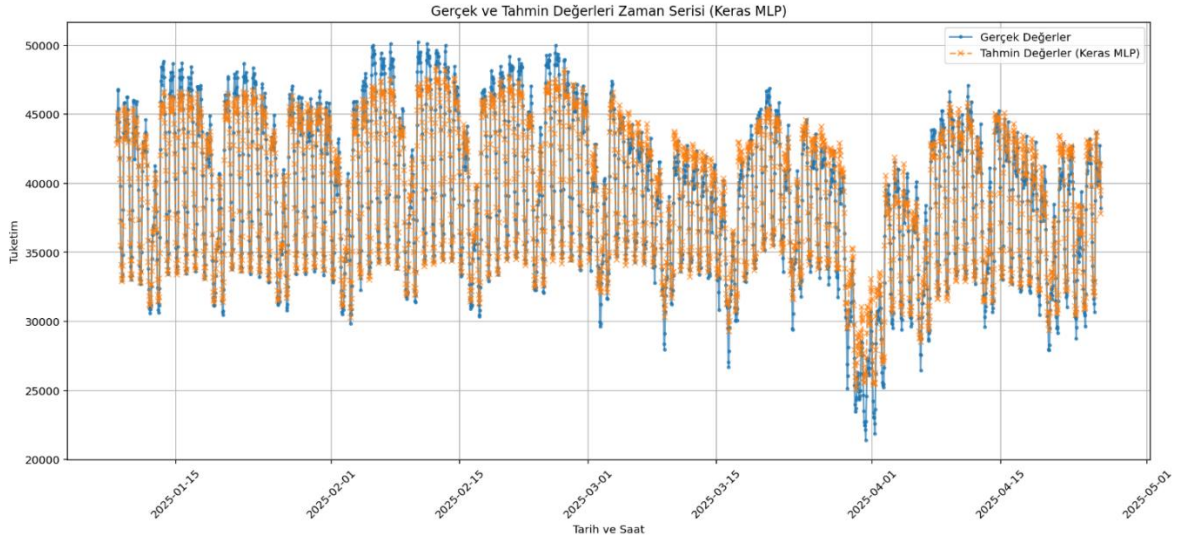


Şekil 4.24. MLP modeli tahmin gerçek değer dağılım grafiği

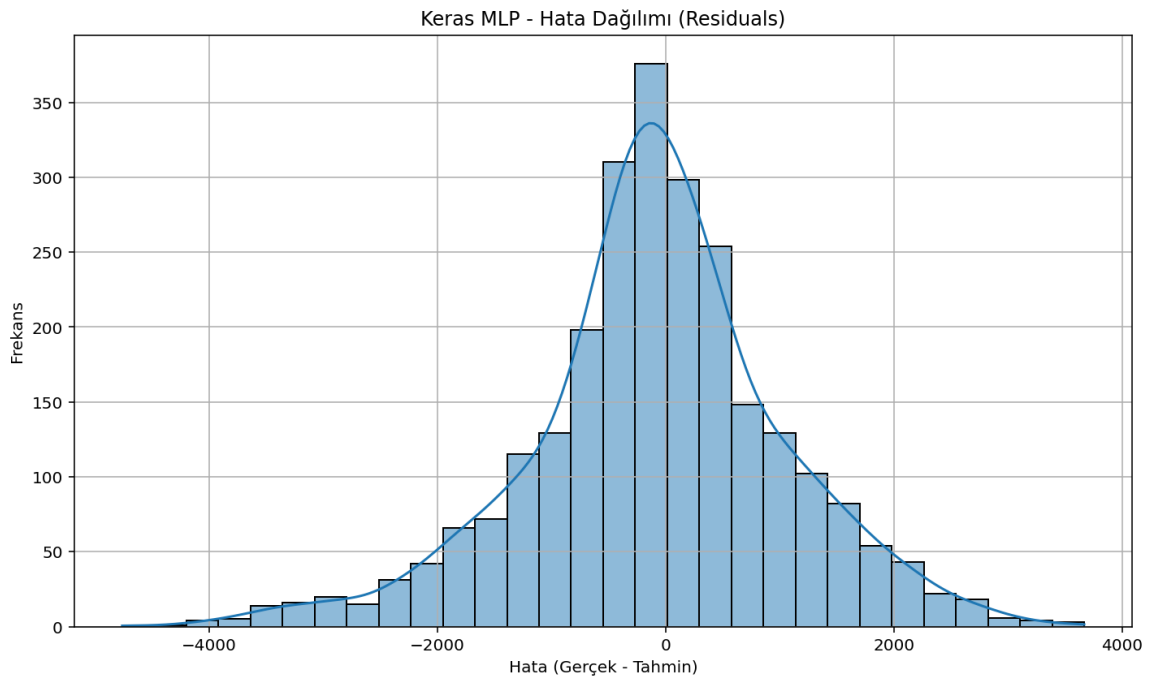
MLP modelinin en düşük doğruluk modeline sahip olmasında Scikit Learn kütüphanesinden kaynaklı olduğunu söyleyebiliriz. Aynı modeli Keras kütüphanesi yardımı ile kullandığımızda çok daha yüksek sonuçlar (MAE değeri 778,34 ile %98,01 doğruluk performansı sağlarken, RMSE değerinde bu oran %97,35 ile 1.139,64 değerini almıştır) elde edildiğini görülmektedir. Scikit Learn kütüphanesi kullanmak, özellikle hesaplama zamanı göz önüne alındığında, daha az maliyetli olsa da doğruluk performansı açısından oldukça geride kalmıştır.

Çizelge 4.8. Keras MLP modeli tahmin sonuçları ilk 24 veri

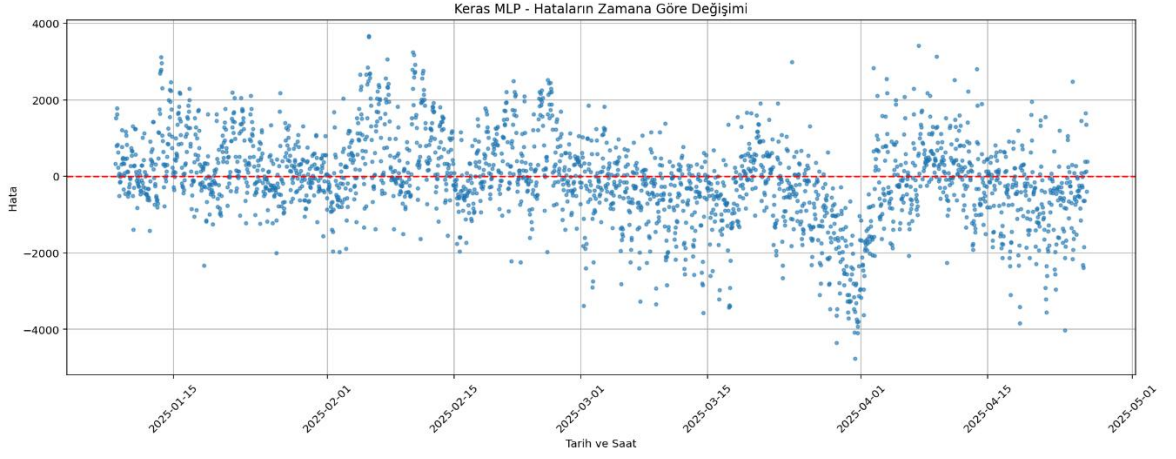
| Tarih | Saat | Gerçek Değerler | Tahmin Değerler | Fark | Mesafe |
|-----------|----------|-----------------|-----------------|----------|----------|
| 8.01.2025 | 14:00:00 | 43.118,28 | 42.782,82 | 335,46 | 335.46 |
| 8.01.2025 | 15:00:00 | 44.724,04 | 43.196,42 | 1.527,63 | 1.527.63 |
| 8.01.2025 | 16:00:00 | 45.157,68 | 44.358,48 | 799,19 | 799.19 |
| 8.01.2025 | 17:00:00 | 46.785,63 | 45.008,19 | 1.777,43 | 1.777.43 |
| 8.01.2025 | 18:00:00 | 46.739,43 | 45.111,83 | 1.627,59 | 1.627.59 |
| 8.01.2025 | 19:00:00 | 45.423,67 | 44.590,19 | 833,47 | 833.47 |
| 8.01.2025 | 20:00:00 | 44.464,54 | 43.837,39 | 627,13 | 627.13 |
| 8.01.2025 | 21:00:00 | 43.333,67 | 43.101,05 | 232,61 | 232.61 |
| 8.01.2025 | 22:00:00 | 41.805,99 | 41.788,48 | 17,51 | 17.51 |
| 8.01.2025 | 23:00:00 | 39.792,68 | 40.303,76 | -511,09 | -511.09 |
| 9.01.2025 | 00:00:00 | 37.332,10 | 37.259,28 | 72,81 | 72.81 |
| 9.01.2025 | 01:00:00 | 35.347,76 | 35.499,01 | -151,26 | 151.26 |
| 9.01.2025 | 02:00:00 | 34.096,30 | 34.112,16 | -15,86 | 15.86 |
| 9.01.2025 | 03:00:00 | 33.212,95 | 33.346,91 | -133,96 | 133.96 |
| 9.01.2025 | 04:00:00 | 32.942,79 | 32.890,42 | 52,36 | 52.36 |
| 9.01.2025 | 05:00:00 | 33.387,87 | 33.067,73 | 320,13 | 320.13 |
| 9.01.2025 | 06:00:00 | 34.799,86 | 34.030,48 | 769,38 | 769.38 |
| 9.01.2025 | 07:00:00 | 38.096,48 | 36.890,23 | 1.206,25 | 1.206.25 |
| 9.01.2025 | 08:00:00 | 43.658,39 | 43.200,28 | 458,12 | 458.12 |
| 9.01.2025 | 09:00:00 | 45.792,21 | 45.312,44 | 479,76 | 479.76 |
| 9.01.2025 | 10:00:00 | 45.853,09 | 45.503,42 | 349,67 | 349.67 |
| 9.01.2025 | 11:00:00 | 44.618,47 | 44.957,32 | -338,85 | 338.85 |
| 9.01.2025 | 12:00:00 | 43.413,12 | 43.084,87 | 328,25 | 328.25 |
| 9.01.2025 | 13:00:00 | 43.352,25 | 43.341,17 | 11,08 | 11.08 |




Şekil 4.25. Keras MLP modeli tahmin gerçek değer dağılım grafiği



Şekil 4.26. Keras MLP modeli hata dağılım grafiği



Şekil 4.27. Keras MLP modeli hataların zaman göre değişim grafiği



Şekil 4.28. MLP Modeli tahmin gerçek değer dağılım grafiği

Çalışmada ayrıca Keras kütüphanesi yardımıyla GRU, LSTM ve bir boyutlu CNN algoritmaları ile de sonuçlar hesaplanmıştır. Ortaya çıkan sonuçlarda MLP kadar olmasa da diğer modeller de tatmin edici sonuçlar sağlamıştır.

Çizelge 4.9. Keras modelleri performans sonuçları

| Model Adı | MAE Değeri | MAE Doğruluk Performansı (%) | RMSE Değeri | RMSE Doğruluk Performansı (%) |
|-----------|------------|------------------------------|-------------|-------------------------------|
| Keras MLP | 778,34 | (%98,01) | 1.032,28 | (%97,35) |
| GRU | 1.371,53 | (%96,48) | 1.788,86 | (%95,41) |
| 1D CNN | 1.613,20 | (%95,86) | 2.071,57 | (%94,69) |
| LSTM | 1.591,80 | (%95,92) | 2.253,60 | (%94,22) |

4.2. Tartışma

Bu çalışmada, Türkiye'nin saatlik elektrik tüketimini tahmin etmek amacıyla altı farklı yapay zeka modeli karşılaştırmalı olarak incelenmiştir. Elde edilen bulgular, model seçimi ve performans değerlendirmesi açısından önemli çıkarımlar sunmaktadır.

Analizleri değerlendirdiğimizde, tek bir modelin tek başına çalışması yerine, birden fazla modelin bir takım gibi birlikte çalıştığı topluluk öğrenmesi yöntemlerin (örneğin, Rassal Orman, Gradient Boosting, XGBoost) genellikle daha iyi sonuçlar verdiğini inceleyebiliriz. Tek başına çalışan modeller (örneğin, Karar Ağacı veya Çoklu Doğrusal Regresyon modeli) bazen sadece öğrendikleri veriye çok fazla odaklanıp yeni verilerde hata yapabilirken, topluluk öğrenmesi bu riski azaltabilmekte ve farklı modellerin tahminlerini birleştirerek daha güvenilir ve genel olarak daha başarılı tahminler yapabilmektedirler. Çalışmamızda özellikle en iyi performans gösteren modeller olan Rassal Orman ve Gradyan Artırma Makineleri, en düşük hata oranlarını (MAE ve RMSE değerleri) vererek en başarılı yöntemler olmuşlardır. Bu bulgumuz, elektrik tüketimi gibi zaman serisi tahminlerinde, topluluk halinde çalışan bu tür modern yapay zeka yöntemlerinin genellikle tekil yöntemlere göre daha başarılı olduğunu gösteren diğer bilimsel çalışmalarla da uyumlu olmaktadır.


Çoklu Doğrusal Regresyon modeli, beklendiği gibi, en basit yaklaşım ve elimizdeki veri setinin doğrusallıktan uzak olması nedeniyle yüksek hata oranları vermiştir. Bu, elektrik tüketimi gibi karmaşık ve doğrusal olmayan örüntüler içeren bir zaman serisini modellemede doğrusal varsayımların yetersiz kaldığını göstermektedir. Çoklu Doğrusal Regresyon modeli, elektrik tüketiminin doğrusal artış gösterdiği (örneğin yıllık) veri setlerinde daha yüksek performans göstermesi beklenebilir. Karar Ağaçları

modeli, Çoklu Doğrusal Regresyon modelinden daha iyi performans gösterse de aşırı öğrenmeye yatkınlığı ve yüksek varyansı nedeniyle topluluk modellerinin gerisinde kalmıştır

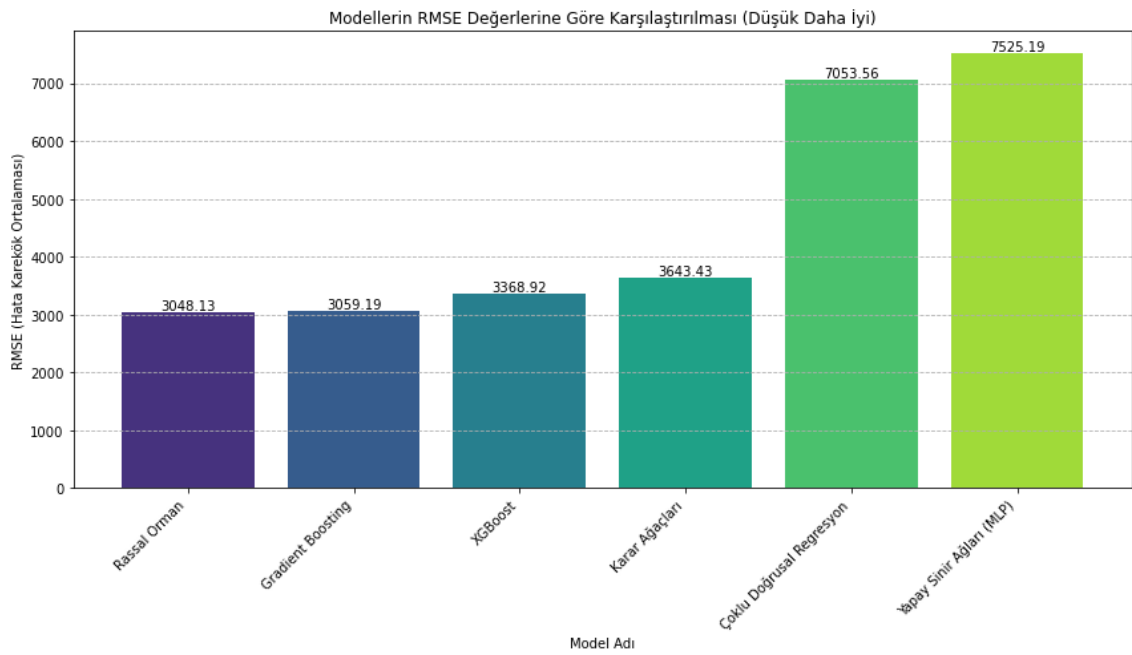
Yapay Sinir Ağları modeli ise bu çalışmada, Scikit Learn kütüphanesinden faydalanılarak uygulanan MLP modeli diğer modellere, özellikle de topluluk öğrenmesi yöntemlerine kıyasla en düşük tahmin doğruluğunu sergilemiştir. Yapay Sinir Ağlarının başarısının, ağ mimarisi (katman ve nöron sayısı gibi) ve öğrenme sürecini yöneten hiper parametrelere (öğrenme oranı, aktivasyon fonksiyonu vb.) oldukça duyarlı olduğu bilinmektedir. Bu çalışmada kullanılan spesifik MLP konfigürasyonu (Tek katmanlı, 100 nöronlu) ile elde edilen sonuçlar, diğer algoritmaların gerisinde kalmıştır. Her ne kadar daha kapsamlı bir hiper parametre optimizasyonu veya farklı ağ mimarileri ile MLP modelinin performansını iyileştirmek teorik olarak mümkün olsa da bu veri seti ve mevcut ayarlarla topluluk yöntemlerinin (Rassal Orman, XGBoost gibi) bariz üstünlüğü gözlemlenmiştir. Bu durum, Yapay Sinir Ağlarının potansiyel olarak güçlü bir model olmasına rağmen, optimum yapılandırmayı bulmanın zorlu olabileceğini ve her probleme en uygun çözüm olmayabileceğini göstermektedir. Diğer yandan Keras kütüphanesi kullanılarak uygulanan MLP ve diğer modellerin (GRU, LSTM, 1D CNN) oldukça iyi sonuçlar verdiği gözlemlenmiştir. Bunun temel sebebi Keras kütüphanesinin Yapay Sinir Ağları özelinde daha gelişmiş ve esnek bir yapısının olmasından kaynaklanmıştır. Bu durum göz önüne alındığında kullanılan veri setine bağlı olarak kütüphane seçiminin de önemli olabileceğini göstermektedir.

Çizelge 4.10. Modellerin performans sonuçları

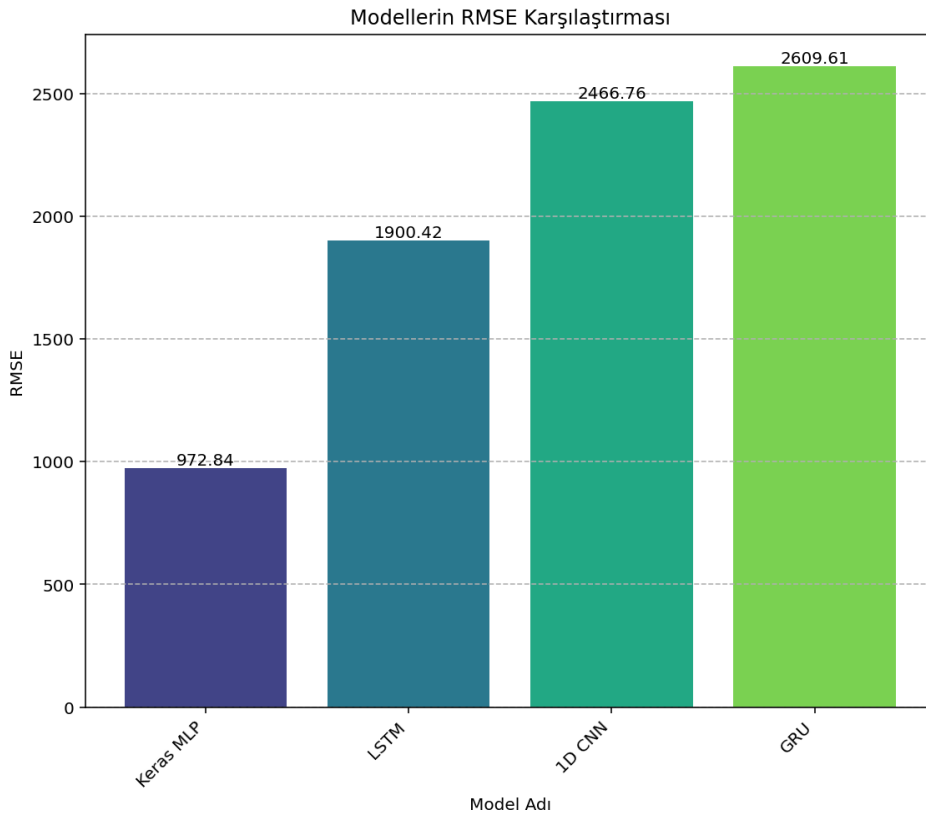
| Kullanılan Kütüphane | Model Adı | MAE Değeri | MAE Doğruluk Performansı (%) | RMSE Değeri | RMSE Doğruluk Performansı (%) |
|----------------------|-----------|------------|------------------------------|-------------|-------------------------------|
| Keras | MLP | 778,34 | %98,01 | 10.032,28 | %97,35 |
| Keras | GRU | 13.371,53 | %96,48 | 17.788,86 | %95,41 |
| Keras | LSTM | 15.591,80 | %95,92 | 22.253,60 | %94,22 |
| Keras | 1D CNN | 16.613,20 | %95,86 | 20.071,57 | %94,69 |
| Scikit Learn | GBM | 23.309,87 | %94,09 | 30.059,19 | %92,17 |
| Scikit Learn | RF | 23.379,12 | %93,91 | 30.48,3 | %92,20 |
| Scikit Learn | XGBoost | 24.99,0 | %93,60 | 33.368,92 | %91,38 |
| Scikit Learn | DT | 27.799,39 | %92,83 | 36.643,43 | %90,67 |
| Scikit Learn | MLR | 57.792,69 | %85,17 | 70.053,56 | %81,94 |
| Scikit Learn | MLP | 67.739,59 | %83,83 | 79.973,13 | %80,74 |



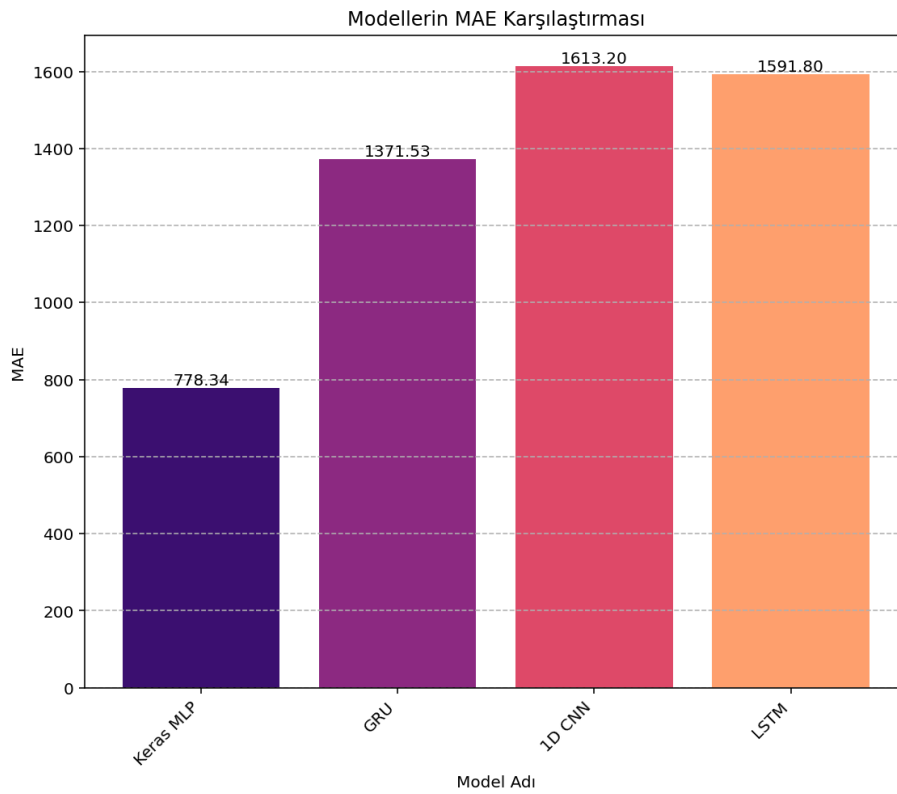
Şekil 4.29. Modellerin MAE değerlerine göre karşılaştırılması



Şekil 4.30. Modellerin RMSE değerlerine göre karşılaştırılması



Şekil 4.31. YSA keras modellerin RMSE değerlerine göre karşılaştırılması



Şekil 4.32. YSA keras modellerin MAE değerlerine göre karşılaştırılması

Çizelge 4.11 Modellerin gerçek ve tahmin değerlerinin karşılaştırılması

| Tarih Zaman | Gerçek Değerler | DT | GBM | RF | MLR | MLP | XGBoost |
|------------------------|-----------------|-----------|-----------|-----------|-----------|-----------|-----------|
| 09.01.2025 15:00:00 | 43.710,87 | 46.988,56 | 44.313,48 | 45.284,02 | 39.925,36 | 37.564,66 | 44.249,85 |
| 09.01.2025 16:00:00 | 44.629,83 | 46.988,56 | 44.313,48 | 45.879,07 | 40.041,04 | 37.786,03 | 44.633,05 |
| 09.01.2025 17:00:00 | 46.231,07 | 46.988,56 | 44.234,57 | 46.451,02 | 40.897,44 | 38.169,93 | 45.834,87 |
| 09.01.2025 18:00:00 | 46.237,47 | 46.988,56 | 43.860,63 | 46.621,07 | 41.383,48 | 38.472,57 | 45.530,94 |
| 09.01.2025 19:00:00 | 45.325,02 | 46.988,56 | 43.474,01 | 45.622,43 | 41.869,51 | 38.877,02 | 45.596,32 |
| 09.01.2025 20:00:00 | 44.308,24 | 46.988,56 | 43.474,01 | 44.633,11 | 42.355,55 | 39.077,83 | 44.049,19 |
| 09.01.2025 21:00:00 | 43.119,98 | 41.309,15 | 42.770,51 | 42.529,29 | 42.841,59 | 39.380,47 | 42.986,46 |
| 09.01.2025 22:00:00 | 41.844,02 | 40.011,77 | 41.505,55 | 40.525,51 | 43.327,63 | 39.968,01 | 41.673,19 |
| 09.01.2025 23:00:00 | 39.834,87 | 38.145,06 | 39.722,73 | 38.804,31 | 43.813,67 | 39.985,74 | 39.966,03 |
| 09.01.2025 00:00:00 | 37.423,96 | 36.411,39 | 36.922,41 | 36.107,99 | 31.971,36 | 32.913,59 | 35.869,64 |
| 09.01.2025 01:00:00 | 35.541,05 | 34.478,68 | 35.801,59 | 34.165,94 | 32.245,04 | 33.216,22 | 33.919,19 |
| 09.01.2025 02:00:00 | 33.995,02 | 33.310,05 | 34.074,27 | 32.745,91 | 32.943,44 | 33.518,86 | 32.753,78 |
| 09.01.2025 03:00:00 | 33.216,23 | 32.336,74 | 33.170,98 | 31.984,96 | 33.429,48 | 33.821,49 | 31.586,27 |
| 09.01.2025 04:00:00 | 33.032,39 | 32.202,05 | 32.329,39 | 31.803,39 | 33.915,51 | 34.124,13 | 31.141,06 |
| 09.01.2025 05:00:00 | 33.333,02 | 32.217,07 | 32.290,02 | 32.017,81 | 34.401,55 | 34.426,76 | 31.771,64 |
| 09.01.2025 06:00:00 | 34.676,13 | 32.326,75 | 32.290,02 | 32.586,01 | 34.887,59 | 34.729,39 | 32.358,43 |
| 09.01.2025 07:00:00 | 38.056,36 | 33.978,66 | 34.196,54 | 35.032,27 | 35.373,63 | 35.032,03 | 35.593,03 |
| 09.01.2025 08:00:00 | 43.661,94 | 43.000,08 | 40.171,78 | 42.290,88 | 35.859,67 | 35.334,66 | 42.041,53 |
| 09.01.2025 09:00:00 | 45.886,08 | 46.465,82 | 42.584,12 | 45.677,93 | 36.345,71 | 35.563,03 | 44.544,01 |
| 09.01.2025 10:00:00 | 46.602,06 | 46.966,44 | 43.548,32 | 46.180,75 | 36.831,75 | 35.939,93 | 45.022,64 |
| 09.01.2025 11:00:00 | 45.960,22 | 46.988,56 | 43.724,97 | 46.628,04 | 37.317,78 | 36.242,56 | 45.905,14 |
| 09.01.2025 12:00:00 | 43.351,31 | 46.988,56 | 43.724,97 | 45.170,17 | 37.803,82 | 36.654,02 | 42.992,01 |
| 09.01.2025 13:00:00 | 41.727,06 | 46.988,56 | 43.816,51 | 44.772,58 | 38.289,86 | 36.847,83 | 42.684,05 |
| 09.01.2025 14:00:00 | 43.303,02 | 46.988,56 | 44.198,43 | 45.222,31 | 38.877,09 | 37.150,46 | 44.132,85 |
| 09.01.2025 15:00:00 | 43.044,04 | 46.988,56 | 44.198,43 | 45.250,35 | 39.261,94 | 37.7450,1 | 43.887,87 |

Çizelge 4.12 Keras modellerin gerçek ve tahmin değerlerinin karşılaştırılması

| Tarih Zaman | Gerçek Değerler | Keras MLP | LSTM | GRU | 1D CNN |
|------------------------|-----------------|-----------|-----------|-----------|-----------|
| 09.01.2025 15:00:00 | 43.710,87 | 44.682,39 | 45.009,37 | 43.878,00 | 43.198,10 |
| 09.01.2025 16:00:00 | 44.629,83 | 44.444,86 | 45.009,37 | 44.175,30 | 44.451,30 |
| 09.01.2025 17:00:00 | 46.231,07 | 45.453,94 | 45.387,51 | 44.468,94 | 44.558,03 |
| 09.01.2025 18:00:00 | 46.237,47 | 45.697,54 | 45.560,62 | 44.748,62 | 44.236,10 |
| 09.01.2025 19:00:00 | 45.325,02 | 45.301,78 | 45.568,21 | 44.777,78 | 43.786,87 |
| 09.01.2025 20:00:00 | 44.308,24 | 44.831,92 | 45.251,71 | 43.874,67 | 42.568,71 |
| 09.01.2025 21:00:00 | 43.119,98 | 43.330,01 | 44.406,03 | 42.137,94 | 41.667,92 |
| 09.01.2025 22:00:00 | 41.844,02 | 41.346,08 | 42.902,10 | 40.535,42 | 40.020,71 |
| 09.01.2025 23:00:00 | 39.834,87 | 39.369,23 | 41.393,28 | 38.747,28 | 38.727,07 |
| 10.01.2025 00:00:00 | 37.423,96 | 37.293,74 | 39.862,28 | 36.801,37 | 35.932,28 |
| 10.01.2025 01:00:00 | 35.541,05 | 35.659,61 | 37.920,26 | 35.261,37 | 34.302,03 |
| 10.01.2025 02:00:00 | 33.995,02 | 34.116,51 | 35.966,07 | 34.151,53 | 32.988,10 |
| 10.01.2025 03:00:00 | 33.216,23 | 33.311,07 | 34.645,01 | 33.341,12 | 32.010,81 |
| 10.01.2025 04:00:00 | 33.032,39 | 32.779,14 | 33.830,48 | 32.761,51 | 32.009,16 |
| 10.01.2025 05:00:00 | 33.333,02 | 33.315,03 | 33.398,80 | 32.592,88 | 32.394,67 |
| 10.01.2025 06:00:00 | 34.676,13 | 34.342,88 | 33.388,37 | 33.228,73 | 33.914,62 |
| 10.01.2025 07:00:00 | 38.056,36 | 37.094,16 | 34.039,73 | 35.627,62 | 38.111,01 |
| 10.01.2025 08:00:00 | 43.661,94 | 42.370,88 | 36.385,19 | 41.012,78 | 41.953,55 |
| 10.01.2025 09:00:00 | 45.886,08 | 44.907,25 | 40.548,78 | 43.825,07 | 43.070,01 |
| 10.01.2025 10:00:00 | 46.602,06 | 45.746,28 | 43.642,07 | 44.281,82 | 43.469,64 |
| 10.01.2025 11:00:00 | 45.960,22 | 45.589,51 | 44.793,87 | 43.927,89 | 42.770,71 |
| 10.01.2025 12:00:00 | 43.351,31 | 45.519,04 | 44.845,39 | 43.668,51 | 41.591,05 |
| 10.01.2025 13:00:00 | 41.727,06 | 43.825,76 | 44.626,89 | 43.588,51 | 41.830,55 |
| 10.01.2025 14:00:00 | 43.303,02 | 43.036,08 | 44.701,89 | 43.611,83 | 42.414,30 |
| 10.01.2025 15:00:00 | 43.044,04 | 43.574,38 | 44.947,35 | 43.795,87 | 43.073,98 |

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu tez çalışması kapsamında, Türkiye'nin saatlik elektrik enerjisi tüketim miktarını tahmin etmek amacıyla Çoklu Doğrusal Regresyon, Karar Ağaçları, Rassal Orman, Gradient Boosting, XGBoost ve Yapay Sinir Ağları olmak üzere altı farklı yapay zeka ve makine öğrenmesi modeli uygulanmış ve performansları karşılaştırılmıştır. Çalışmanın temel sonuçları şu şekilde özetlenebilir;

- İncelenen modeller arasında, topluluk öğrenmesi tabanlı algoritmalar olan Rassal Orman ve Gradyan Artırma Makineleri MAE ve RMSE hata metrikleri açısından en düşük değerleri vererek en yüksek tahmin doğruluğunu gösteren 2 model olmuştur. Bu iki modelin performans sonuçları birbirine çok yakın değerler göstermektedir.
- Elde edilen sonuçlar, elektrik tüketimi gibi karmaşık ve doğrusal olmayan dinamiklere sahip zaman serilerinin tahmininde, özellikle Rassal Orman ve Gradyan Artırma türevleri gibi topluluk öğrenmesi algoritmalarının üstünlüğünü doğrulamaktadır.
- Keras MLP modeli 778,34 MAE ve 1032,28 RMSE değeri ile en iyi performans gösteren model olmuştur.
- Çoklu Doğrusal Regresyon düşük performansı gösterirken, tekil Karar Ağacı modeli Yapay Sinir Ağlarından daha iyi ancak topluluk modellerinden daha düşük bir başarı sergilemiştir.
- Scikit Learn MLP hiperparametre veya farklı ağ mimarisisiyle doğruluk oranının yükseltilmesi mümkün olsa da topluluk yöntemlerinin ve Keras MLP'nin gerisinde kalmıştır.
- Yapılacak çalışmalarda seçilen mimari ile beraber kullanılacak teknolojinin de önemi vurgulanmıştır.

5.2 Öneriler

Bu çalışmada Türkiye genelindeki saatlik tüketim verilerine odaklanılmıştır fakat elektrik perakende şirketleri belirli bölgelere ayrıldığı için belirli bir bölgedeki tüketim verilerine odaklanması daha yüksek doğruluklu bir sonuç sağlayacaktır. Bu yaklaşım sayesinde bölgesel coğrafi etkiler (sıcaklık, yağış, güneşlenme ve nem gibi) göz önüne alınarak modellerin doğruluğu artırılabilir.

Zaman serisi analizinde oldukça başarılı olan MLP, LSTM, GRU modelleri, Transformer gibi daha gelişmiş derin öğrenme modelleri ve hibrit yaklaşımlar denenerek performans karşılaştırması genişletilebilir.

Kullanılan tüm modeller için (özellikle YSA ve GBM/XGBoost) daha sistematik ve kapsamlı hiperparametre optimizasyon teknikleri (Grid Search, Randomized Search, Bayesian Optimization) uygulanarak modellerin potansiyel olarak daha iyi konfigürasyonları bulunabilir.

En iyi performansı gösteren ancak "kara kutu" olarak nitelendirilen modellerin (RF, GBM, XGBoost, YSA) karar verme süreçlerini anlamak için SHAP gibi modelden bağımsız yorumlanabilirlik teknikleri uygulanabilir.

Saatlik tüketimlerde sıcaklık, yağış ve bulutlanma gibi meteorolojik veriler etkili olabileceği için, meteorolojik verilerin modele eklenmesi daha doğru ve etkili sonuçlar ortaya koyabilir.

Uzun Dönem tahmin çalışmalarında kullanılabilen LSTM ile veri setindeki örüntüleri (mevsimsellik, kullanım alışkanlığı vb.) yakalamada başarılı olan 1D CNN modelleri hibrit bir şekilde kullanılarak 2 modelin avantajlı oldukları yönleriyle beraber daha tutarlı veriler elde edilebilir.

6. KAYNAKLAR

- Özer, Ö., ve Erkilet, M., 2012, Talep analizi ve talep öngörüsü: bir özel hastanede, *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14(3), 127-142.
- Akay, E. Ç., Topal, K. H., Kizilarıslan, S., ve Bulbul, H., 2019, Forecasting of Turkish housing price index: ARIMA, random forest, ARIMA-random forest, *Pressacademia*, 10(10), 7-11.
- Alizade-Harakiyan, M., Khodaei, A., Yousefi, A., Zamani, H., ve Mesbahi, A., 2025, Decision tree-based machine learning algorithm for prediction of acute radiation esophagitis, *Biochemistry and Biophysics Reports*, 42, 101991.
- Aydın, R., ve Yazıcıoğlu, O., 2019, Yapay sinir ağları ile talep tahmini: perakende sektöründe bir uygulama, *Fen Bilimleri Dergisi*, 18(35), 43-55.
- Aykaş, H., 2023, Düzce ili elektrik enerjisi talep tahmini, Yüksek Lisans Tezi, *Düzce Üniversitesi Lisansüstü Eğitim Enstitüsü*, Düzce, 1-37.
- Badirli, S., Liu, X., Xing, Z., Bhowmik, A., Doan, K., ve Keerthi, S. S., 2020, Gradient boosting neural networks: Grownnet, *arXiv preprint arXiv:2002.07971*.
- Bailer-Jones, C. A., Gupta, R., ve Singh, H. P., 2001, An introduction to artificial neural networks, *arXiv preprint astro-ph/0102224*.
- Bakkal, S., 2023, Türkiye için doğalgaz talep tahmini, Yüksek Lisans Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, 1-146.
- Başıoğlu, B., ve Bulut, M., 2017, Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 575-583.
- Bounia, L., ve Setitra, I., 2025, Enhancing the intelligibility of decision trees with concise and reliable probabilistic explanations, *Data & Knowledge Engineering*, 156, 102394.
- Charbuty, B., ve Abdulazeez, A., 2021, Classification based on decision tree algorithm for machine learning, *Journal of applied science and technology trends*, 2(01), 20-28.
- Collin, B. R. R., Xavier, D. d. L. A., Amaral, T. M., Silva, A. C. G. C., dos Santos Costa, D., Amaral, F. M., ve Oliva, J. T., 2024, Random forest regressor applied in prediction of percentages of calibers in mango production, *Information Processing in Agriculture*.
- Çalmaşur, G., ve Tuna, Ç., 2020, Doğal gaz talep tahmini: Erzurum ili için bir uygulama, *Ekonomik ve Sosyal Araştırmalar Dergisi*, 16(1), 257-273.

- Dede, B., 2023, Short-Term Forecast for Turkey's Electricity Demand DNN vs LSTM, Yüksek Lisans Tezi, *Kadir Has Üniversitesi Lisansüstü Eğitim Fakültesi*, Kayseri, 1-52.
- Demir, A. S., ve Sağlam, E. B., 2023, Electricity consumption estimation with differential polynomial and artificial neural networks: Case of Türkiye, *Journal of engineering research*, 11(3), 176-181.
- Demirezen, S., ve Çetin, M., 2021, Rassal orman regresyonu ve destek vektör regresyonu ile piyasa takas fiyatının tahmini, *Nicel Bilimler Dergisi*, 3(1), 1-15.
- Doğru, B. N., ve Büyükakın, F., 2023, Tr42 bölgesi için elektrik enerjisi talebinin makine öğrenimi tabanlı tahmini, *Uluslararası Ekonomik Araştırmalar Dergisi*, 9(3), 45-64.
- Durğun, S., 2018, Türkiye'nin enerji talebinin yapay zeka teknikleriyle uzun dönem tahmini, Yüksek Lisans Tezi, *Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 1-52.
- Erdoğan, E., ve Özyürek, H., 2012, Yapay Sinir Ağları İle Fiyat Tahminlemesi, *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), 85-92.
- Erten, O., ve Göktepeliler, Ö., 2022, Yapay zekâ, makine ve sanat, *Ankara Üniversitesi Sosyal Bilimler Dergisi*, 13(2), 145-152.
- Gao, Y., Wang, Y., Tian, L., Hong, X., Xue, C., ve Li, D., 2025, Evolving adaptive and interpretable decision trees for cooperative submarine search, *Defence Technology*.
- Gökçe, M. M., ve Duman, E., 2024, A deep learning-based demand forecasting system for planning electricity generation elektrik üretiminin planlanması için derin öğrenme tabanlı talep tahmin sistemi, *KSÜ Mühendislik Bilimleri Dergisi*, 27(2), 10.
- Haliloğlu, E. Y., ve Tutu, B. E., 2018, Türkiye için kısa vadeli elektrik enerjisi talep tahmini, *Yaşar Üniversitesi E-Dergisi*, 13(51), 243-255.
- Hamzaçebi, C., ve Kutay, F., 2004, Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3).
- Hoang, N.-D., 2024, Metaheuristic optimization of extreme gradient boosting machine for enhanced prediction of lateral strength of reinforced concrete columns under cyclic loadings, *Results in Engineering*, 24, 103125.
- Ji, L., ve Li, S., 2025, A dynamic financial risk prediction system for enterprises based on gradient boosting decision tree algorithm, *Systems and Soft Computing*, 7, 200189.

- Kanıt, R., ve Baykan, U. N., 2004, Bina yaklaşık maliyetinin çoklu doğrusal regresyon ile belirlenmesi, *Politeknik dergisi*, 7(4), 359-369.
- Karaca, C., ve Karacan, H., 2016, Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi, *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 4(3), 182-195.
- Kayış, E. A., 2023, Demand Forecasting Using Statistical and Machine Learning Methods—a Case Study in Automotive Industry, Yüksek Lisans Tezi, *İzmir Ekonomi Üniversitesi Lisansüstü Eğitim Enstitüsü*, İzmir, 1-43.
- Kocadayı, Y., ErKaymaz, O., ve Uzun, R., 2017, Yapay sinir ağları ile Tr81 bölgesi yıllık elektrik enerjisi tüketiminin tahmini, *Bildiri Özetleri Kitabı*, 239.
- Köse, E., 2023, Developing a decision-support system using machine learning and deep learning models for daily demand forecasting: a case study, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü*, İstanbul, 1-127.
- Krenker, A., Bešter, J., ve Kos, A., 2011, Introduction to the artificial neural networks, *Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech*, 1-18.
- Kumar, P., Almeida, F., ve Al-Mdallal, Q., 2025, Artificial neural network algorithm for time dependent radiative Casson fluid flow with couple stresses through a microchannel, *Alexandria Engineering Journal*, 125, 167-184.
- Liu, G., Ou, J., Zheng, Y., Cai, Y., Liu, X., ve Zhang, H., 2025, Large-scale building-level electricity consumption estimation for multiple building types: A case study from Dongguan, China, *Sustainable Cities and Society*, 121, 106224.
- Lui, G. N., Nguyen, C. H., Hui, K. Y., Hon, K. K., ve Liem, R. P., 2025, Enhancing aircraft arrival transit time prediction: A two-stage gradient boosting approach with weather and trajectory features, *Journal of the Air Transport Research Society*, 4, 100062.
- Mayer, S., van Herwijnen, A., Techel, F., ve Schweizer, J., 2022, A random forest model to assess snow instability from simulated snow stratigraphy, *The Cryosphere*, 16(11), 4593-4615.
- Nacar, E. N., ve Erdebilli, B., 2021, Makine Öğrenmesi Algoritmaları İle Satış Tahmini, *Endüstri Mühendisliği*, 32(2), 307-320.
- Nishimwe, A. M. R., ve Reiter, S., 2021, Estimation, analysis and mapping of electricity consumption of a regional building stock in a temperate climate in Europe, *Energy and Buildings*, 253, 111535.
- Ouadi, B., Khatir, A., Magagnini, E., Mokadem, M., Abualigah, L., ve Smerat, A., 2024, Optimizing silt density index prediction in water treatment systems using pressure-based gradient boosting hybridized with Salp Swarm Algorithm, *Journal of Water Process Engineering*, 68, 106479.

- Özden, S., ve Öztürk, A., 2018, Yapay sinir ağları ve zaman serileri yöntemi ile bir endüstri alanının (ivedik OSB) elektrik enerjisi ihtiyaç tahmini, *Bilişim Teknolojileri Dergisi*, 11(3), 255-261.
- Özen, F., 2024, Random forest regression for prediction of Covid-19 daily cases and deaths in Turkey, *Heliyon*, 10(4).
- Özer, Ö., ve Erkilet, M., 2012, Talep analizi ve talep öngörüsü: bir özel hastanede, *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14(3), 127-142.
- Pehlivanoglu, H. E., 2023, Plastik sektöründe yapay sinir ağları ve regresyon analizi ile talep tahmini, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Fen Bilimleri Enstitüsü*, Kocaeli, 1-67.
- Polo-Mendoza, R., Duque, J., ve Maşín, D., 2024, Prediction of California bearing ratio and modified proctor parameters using deep neural networks and multiple linear regression: A case study of granular soils, *Case Studies in Construction Materials*, 20, e02800.
- Sánchez, J. C. M., Mesa, H. G. A., Espinosa, A. T., Castilla, S. R., ve Lamont, F. G., 2025, Improving Wheat Yield Prediction through Variable Selection Using Support Vector Regression, Random Forest, and Extreme Gradient Boosting, *Smart Agricultural Technology*, 100791.
- Sönmez, İ., 2015, Seydişehir bölgesinin orta vadedeki elektrik enerjisi talebinin yapay zeka ile tahmini, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 1-165.
- Şenel, T., Cengiz, M., Savaş, N., ve Terzi, Y., 2014, Çoklu doğrusal regresyonda model seçiminde genelleştirilmiş toplamsal modellerin kullanımı, *Erzincan University Journal of Science and Technology*, 2(2), 217-227.
- Yavuzdemir, M., 2014, Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini, Yüksek Lisans Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Ankara, 1-92
- Zateroglu, M. T., 2023, Estimation of Cloudiness Data Based on Multiple Linear Regression Model, *Karadeniz Fen Bilimleri Dergisi*, 13(1), 33-41.
- 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* 2023, 15, 1503.
- Sevgen, S. C., & Aliefendioğlu, Y. (2020). Mass appraisal with a machine learning algorithm: random forest regression. *Bilişim Teknolojileri Dergisi*, 13(3), 301-311.