



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**ENERJİ PİYASALARINDA SAATLİK
ELEKTRİK TÜKETİM TAHMİNİ İÇİN
VERİYE DAYALI MODEL GELİŞTİRME VE
MALİYET ANALİZİ**

Şenel Aycan ALTUNBAŞ

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Ekim-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Şenel Aycan Altunbaş tarafından hazırlanan “ENERJİ PİYASALARINDA SAATLİK ELEKTRİK TÜKETİM TAHMİNİ İÇİN VERİYE DAYALI MODEL GELİŞTİRME VE MALİYET ANALİZİ” adlı tez çalışması 27/10/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Dr. Öğr. Üyesi Esra BOZ

Danışman

Doç. Dr. Bilal ERVURAL

Üye

Dr. Öğr. Üyesi Halil İbrahim AYAZ

İmza

.....

.....

.....

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.

İmza

Şenel Aycan ALTUNBAŞ

Tarih: 24/11/2025

ÖZET

YÜKSEK LİSANS TEZİ

ENERJİ PİYASALARINDA SAATLİK ELEKTRİK TÜKETİM TAHMİNİ İÇİN VERİYE DAYALI MODEL GELİŞTİRME VE MALİYET ANALİZİ

Şenel Aycan ALTUNBAŞ

NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Doç. Dr. Bilal ERVURAL

2025, 64 Sayfa

Jüri

Doç. Dr. Bilal ERVURAL

Dr. Öğr. Üyesi Esra BOZ

Dr. Öğr. Üyesi Halil İbrahim AYAZ

Şebeke yükünün dengelenmesi ve özellikle depolama kaynaklı maliyetlerin azaltılması açısından saatlik elektrik tüketiminin doğru tahmin edilmesi büyük önem taşımaktadır. Enerji piyasalarının giderek karmaşıklaştığı günümüzde, tahmin doğruluğu yalnızca teknik başarı kriteri değil, aynı zamanda doğrudan ekonomik sonuçlar üzerinde belirleyici ve çoğu zaman daha kritik bir etkidir. Bu kapsamda, İç Anadolu Bölgesi'ndeki Aksaray, Karaman, Kırşehir, Konya, Nevşehir ve Niğde illerine ait saatlik elektrik tüketimi için veri odaklı tahmin modelleri karşılaştırılmıştır. Çalışmada, makine öğrenmesi yaklaşımlarından Aşırı Gradyan Arttırma (XGBoost) ile birlikte, Yapay Sinir Ağı (YSA) tabanlı, İleri Beslemeli Sinir Ağları (FFNN), Geçitli Tekrarlayan Birim (GRU), Uzun Kısa Süreli Bellek (LSTM) ve 1 Boyutlu Evrişimli Sinir Ağları (1D-CNN) gibi farklı derin öğrenme mimarileri karşılaştırılmıştır. Performans yalnızca hata metrikleri (RMSE, MAE, MAPE, R^2) ile değil aynı zamanda Türkiye elektrik piyasası koşullarını esas alan bir dengesizlik maliyeti analizi üzerinden de değerlendirilmiştir. Mayıs 2022–Nisan 2025 dönemini kapsayan 25.752 saatlik veri üzerinde uygulanmış ve veriler kronolojik olarak eğitim, doğrulama ve test kümelerine ayrılmıştır. Bulgular, XGBoost'un en düşük hata değerleriyle en yüksek teknik tahmin doğruluğunu sağladığını göstermektedir. Ancak piyasa temelli analiz, daha yüksek hata oranına rağmen 1D-CNN'in dengesizlik maliyetlerini en fazla azalttığını ve finansal olarak daha verimli bir çözüm sunduğunu ortaya koymuştur. Sonuç olarak, enerji portföy yönetiminde model seçiminde yalnızca teknik doğruluk değil, ekonomik sonuçların da birlikte ele alınması gerektiği vurgulanmıştır.

Anahtar Kelimeler: 1D-CNN, Dengesizlik maliyeti, GRU, LSTM, XGBoost, YSA

ABSTRACT

MS THESIS

DATA-DRIVEN MODEL DEVELOPMENT AND COST ANALYSIS FOR HOURLY ELECTRICITY CONSUMPTION FORECASTING IN ENERGY MARKETS

Şenel Aycan ALTUNBAŞ

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

Advisor: Assoc. Prof. Dr. Bilal ERVURAL

2025, 64 Pages

Jury

Assoc. Prof. Dr. Bilal ERVURAL

Asst. Prof. Dr. Esra BOZ

Asst. Prof. Dr. Halil İbrahim AYAZ

Balancing grid load and reducing the costs arising especially from storage make accurate forecasting of hourly electricity consumption very important. In today's energy markets, forecasting accuracy is not only a technical measure but also an important factor that directly influences economic outcomes, often proving to be even more critical. In this context, data-driven forecasting models are compared for the hourly electricity consumption of six provinces in Central Anatolia: Aksaray, Karaman, Kırşehir, Konya, Nevşehir, and Niğde. In the study, alongside Extreme Gradient Boosting (XGBoost) from machine learning approaches, different deep learning architectures based on Artificial Neural Networks (ANN)—such as Feedforward Neural Networks (FFNN), Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM), and 1D-Convolutional Neural Networks (1D-CNN)—are compared. Performance is evaluated not only with error metrics (RMSE, MAE, MAPE, R^2) but also through an imbalance cost analysis based on the rules of the Turkish electricity market. The models were applied on 25,752 hourly observations covering the period from May 2022 to April 2025, and the data were chronologically split into training, validation, and test sets. The results show that XGBoost provides the highest technical forecasting accuracy with the lowest error values. However, the market-based analysis shows that although 1D-CNN has higher error rates, it achieves the greatest reduction in imbalance costs, offering a more financially efficient solution. In conclusion, the study shows that model selection in energy portfolio management should consider not only technical accuracy but also the economic outcomes that result from the model's performance.

Keywords: 1D-CNN, ANN, GRU, Imbalance Cost, LSTM, XGBoost.

ÖNSÖZ

Bu çalışma sürecinde öncelikle aileme ve danışmanlık yaparak sorduğum soruları cevaplayan, benden bilgi ve desteğini esirgemeyen Sayın Doç. Dr. Bilal ERVURAL'a teşekkür ederim.

Şenel Aycan ALTUNBAŞ
KONYA-2025



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER LİSTESİ	ix
ÇİZELGELER/TABLolar LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM.....	14
3.1. Talep Tahmini.....	14
3.1.1. Talep tahmin yöntemleri	15
3.2. Kullanılan Yöntemler	16
3.2.1. Yapay sinir ağları (YSA)	16
3.2.2. Aşırı gradyan artırma (XGBoost-Extreme gradient boosting)	23
3.3. Veri Seti Hazırlığı ve Ön İşleme.....	27
3.3.1. Veri temizleme ve yapısal düzenleme	28
3.3.2. Veri dönüştürme ve değişken türetimi.....	28
3.3.3. Model değerlendirme ve veri bölme	29
3.3.4. Normalizasyon	29
3.3.5. Aşırı öğrenme (overfitting) tespiti ve erken durdurma (early stopping).....	30
3.4. Model Mimarisi ve Hiperparametrelerin Belirlenmesi.....	31
3.4.1. XGBoost modeli parametreleri	31
3.4.2. Derin öğrenme modelleri mimarisi	32
3.5. Model Performans Kriterleri.....	32
3.5.1. Kök ortalama kare hata (Root mean squared error - RMSE)	33
3.5.2. Ortalama mutlak hata (Mean absolute error - MAE).....	34
3.5.3. Ortalama mutlak yüzdesel hata (MAPE)	34
3.5.4. Belirlilik katsayısı (Coefficient of determination – R^2).....	35
3.5.5. Dengesizlik maliyet analizi.....	35
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	37
4.1. Makine Öğrenmesi ve Derin Öğrenme Modellerinin Sonuçları.....	38
4.1.1. XGBoost modeli sonuçları.....	38
4.1.2. 1D-CNN modeli sonuçları	40
4.1.3. FFNN modeli sonuçları	42
4.1.4. GRU modeli sonuçları	44
4.1.5. LSTM modeli sonuçları	46

4.2 Modellerin Karşılaştırılması	48
4.2.1. RMSE karşılaştırması	48
4.2.2. MAE karşılaştırması	49
4.2.3. MAPE karşılaştırması	50
4.2.4. R^2 karşılaştırması	50
4.2.5. Aşırı öğrenme (overfitting) hesaplanması ve karşılaştırılması	51
4.2.6. Hata dağılımları ve varyans analizi	52
4.3. Dengesizlik Maliyet Analiz Sonuçları	53
4.3.1. Kritik bir vaka analizi	54
4.4. Tartışma	57
5. SONUÇLAR VE ÖNERİLERİ.....	59
6. KAYNAKLAR	61



ŞEKİLLER LİSTESİ

Şekil 3.1. YSA nöron yapısı	17
Şekil 3.2. YSA sınıflandırmaları	18
Şekil 3.3. Tek katmanlı hesaplama düğümlerine sahip ileri beslemeli ağ.....	19
Şekil 3.4. Kendi kendine geri besleme döngüleri ve gizli nöronları olmayan yinelemeli ağ.....	20
Şekil 3.5. Öğrenme Yöntemleri Şeması	21
Şekil 3.6. Karar Ağaçları	24
Şekil 3.7. Bagging(Random Forest)	25
Şekil 3.8. Xgboost(Boosting)	27
Şekil 4.1. Xgboost Regresyon Grafiği.....	39
Şekil 4.2. Xgboost Hata Histogramı	39
Şekil 4.3. Xgboost Artıkların Zaman İçinde Dağılımı	40
Şekil 4.4. 1D-CNN Regresyon Grafiği.....	41
Şekil 4.5. 1D-CNN Hata Histogramı.....	41
Şekil 4.6. 1D-CNN Artıkların Zaman İçinde Dağılımı	42
Şekil 4.7. FFNN Regresyon Grafiği	43
Şekil 4.8. FFNN Hata Histogramı	43
Şekil 4.9. FFNN Artıkların Zaman İçinde Dağılımı.....	44
Şekil 4.10. GRU Regresyon Grafiği.....	45
Şekil 4.11. GRU Hata Histogramı	45
Şekil 4.12. GRU Artıkların Zaman İçinde Dağılımı	46
Şekil 4.13. LSTM Regresyon Grafiği.....	47
Şekil 4.14. LSTM Hata Histogramı.....	47
Şekil 4.15. LSTM Artıkların Zaman İçinde Dağılımı	48
Şekil 4.16. Modellerin RMSE Değerlerinin Karşılaştırılması.....	48
Şekil 4.17. Modellerin MAE Değerlerinin Karşılaştırılması.....	49
Şekil 4.18. Modellerin MAPE Değerlerinin Karşılaştırılması	50
Şekil 4.19. Modellerin R ² Değerlerinin Karşılaştırılması.....	51
Şekil 4.20. Modellerin test seti hata dağılımları	52
Şekil 4.21. Sapma Oranı (%)	54

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 2.1. Kaynak araştırması	11
Çizelge 3.1. Kullanılan derin öğrenme mimarileri	22
Çizelge 3.2. Modellerin hiperparametre yapılandırmaları.....	32
Çizelge 4.1. Modeller	37
Çizelge 4.2. RMSE doğrulama ve test sonuçları	51
Çizelge 4.3. Maliyet sapma oranı	54
Çizelge 4.4. Gerçekleşen değer ve model tahminleri	55
Çizelge 4.5. Modellerin dengesizlik durumları ve maliyet analizi sonuçları	56



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

SİMGELER

mWh	Megawatt/Saat
kWh	Kilowatt/Saat

KISALTMALAR

1D-CNN	Tek Boyutlu Evrişimli Sinir Ağı
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
CNN-LSTM	Evrişimli Sinir Ağı – Uzun Kısa Süreli Bellek
DGP	Dengeleme Güç Piyasası
EPDK	Enerji Piyasası Düzenleme Kurumu
EPİAŞ	Enerji Piyasaları İşletme A.Ş.
FFNN	İleri Beslemeli Sinir Ağları (Feedforward Neural Networks)
GİP	Gün İçi Piyasa
GÖP	Gün Öncesi Piyasası
GRU	Geçitli Tekrarlayan Birim (Gated Recurrent Unit)
LR	Doğrusal Regresyon (Linear Regression)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
MAD	Ortalama Mutlak Hata (Mean Absolute Deviation)
MAE	Ortalama Mutlak Yüzde Hata (Mean Absolute Error)
MAPE	Ortalama Mutlak Yüzdesel Hata (Mean Absolute Percentage Error)
NLR	Doğrusal Olmayan Regresyon (Non-Linear Regression)
PTF	Piyasa Takas Fiyatı
RMSE	Kök Ortalama Kare Hata (Root Mean Squared Error)
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SMF	Sistem Marjinal Fiyatı
YSA(ANN)	Yapay Sinir Ağları

1. GİRİŞ

Modern enerji şebekelerinin temelini oluşturan arz ve talebin anlık denge prensibi, elektrik enerjisinin depolanamaz doğası ve bunun getirdiği yüksek maliyetler nedeniyle kritik bir operasyonel zorunluluktur. Bu dengeyi sağlamanın en önemli aracı olan talep tahmini, bu nedenle yalnızca teknik bir gereklilik değil, aynı zamanda finansal sürdürülebilirliğin de temel taşıdır. Enerji tüketimini etkileyen ekonomik dinamikler, mevsimsel ve günlük döngüler, hava koşulları ve özel sosyal olaylar gibi çok sayıda değişkenin varlığı, bu tahmin sürecini oldukça karmaşık hale getirmektedir. Özellikle enerji piyasalarındaki serbestleşme süreci, en doğru tahmini yapabilme ihtiyacını, teknik bir zorunluk olmanın ötesinde, doğrudan bir finansal optimizasyon problemine dönüştürmüştür. Bu rekabetçi ortam, enerji şirketlerini finansal risklerini minimize etmek ve operasyonel verimliliklerini en üst düzeye çıkarmak için daha kapsamlı tahmin yöntemleri aramaya itmektedir.

Bu finansal optimizasyon problemi, Türkiye enerji piyasalarında Enerji Piyasaları İşletme A.Ş. (EPİAŞ) tarafından yönetilen organize piyasalar özelinde somut bir karşılık bulmaktadır. Piyasa katılımcıları, Gün Öncesi Piyasası'nda (GÖP), bir sonraki günün tüketim öngörülerine dayanarak Piyasa Takas Fiyatı (PTF) üzerinden enerji alım-satım anlaşmaları yaparlar. Ancak, yapılan bu tahmin ile ertesi gün gerçekleşen tüketim arasında oluşan farklar, sistemde "dengesizlik" olarak adlandırılan ve Dengeleme Güç Piyasası'nda (DGP) uzlaştırılan bir duruma yol açar. Temel finansal risk, önceden anlaşılan GÖP fiyatları ile anlık dengeleme işlemleri için kullanılan ve genellikle çok daha değişken olan Sistem Marjinal Fiyatı (SMF) arasındaki makastan kaynaklanır. Bu mekanizma, tahmin hatası yapan katılımcılar için öngörülemeyen ve ciddi boyutlara ulaşabilen maliyet artışlarına yol açabilmektedir. Tahmin edilenden eksik veya fazla alınan enerji, DGP'de telafi edilmek zorunda kalınır ve bu durum şirketler için beklenmedik maliyet artışlarına neden olabilir. Enerjinin depolanamaz bir kaynak olması, arz ve talebin birbirine mümkün olan en yakın düzeyde karşılanmasını, kaynak israfını ve finansal yükleri engellemek adına zorunlu kılmaktadır (Nebati vd., 2021).

Enerji talep tahmini literatürü incelendiğinde, geliştirilen modellerin başarısının genellikle RMSE, MAE veya MAPE gibi simetrik hata metrikleri üzerinden değerlendirildiği görülmektedir. Bu çalışmalarda odak noktası hatayı matematiksel olarak en aza indirmek olup, tahmin başarısının ticari operasyonlara finansal yansıması değerlendirme dışı bırakılmaktadır. Ancak enerji piyasalarının asimetric maliyet yapısı

göz önüne alındığında, istatistiksel doğruluğun finansal verimlilikle her zaman birebir örtüşmeyebileceği düşünülmektedir. Gerçek piyasa koşullarında, hatanın yönü (enerji açığı veya fazlası) ve o anki piyasa fiyatları (PTF ve SMF), maliyet üzerinde belirleyici bir role sahiptir. Bu doğrultuda, bu çalışma sadece teknik doğruluğa odaklanan geleneksel yaklaşımın ötesine geçerek, istatistiksel başarı ile finansal performans arasındaki ilişkiyi ve olası ayrışmaları irdelemeyi hedeflemektedir.

Bu kapsamda model seçimi yapılırken, algoritmaların literatürdeki popülaritesinin ötesinde, elektrik tüketim verisinin yapısal karakteristiğine olan uygunlukları esas alınmıştır. Elektrik tüketim zaman serileri; doğrusal olmayan (non-linear) karmaşık ilişkiler, uzun vadeli mevsimsel döngüler ve anlık yerel dalgalanmalar barındıran hibrit bir yapıya sahiptir. Bu nedenle modeller, verinin bu farklı dinamiklerini çözümleme yeteneklerine göre seçilmiştir: XGBoost ve FFNN doğrusal olmayan genel ilişkileri (Chen ve Guestrin, 2016; Haykin, 2009), LSTM ve GRU zamansal ve mevsimsel bağımlılıkları (Bişkin ve Çifci, 2021), 1D-CNN ise anlık değişkenliği ve yerel kalıpları yakalamak amacıyla kullanılmıştır (Berus ve Benteşen Yakut, 2024).

Araştırmanın amacı

Çalışmanın amacı, modellerin performansını bütünsel bir çerçevede, çift katmanlı bir yaklaşımla değerlendirmektir. Modellerin performansı yalnızca RMSE ve MAE gibi geleneksel hata metrikleri üzerinden değil, aynı zamanda ve daha önemlisi, Türkiye enerji piyasasının gerçekçi dinamiklerini ve uzlaştırma mekanizmasını simüle eden bir dengesizlik maliyeti analiziyle de ölçülmüştür. Bu yaklaşım, çalışmanın en kritik hipotezini test etmektedir: en düşük tahmin hatasını veren modelin, her zaman en ekonomik sonucu üretmediğini göstermektir. Bu kapsamda, en düşük tahmin hatasını veren modelin, piyasa koşullarında en ekonomik sonucu üretilip üretilmediği sorusuna yanıt aranmaktadır.

Araştırmanın önemi

Bu çalışmanın önemi, istatistiksel ve finansal performans arasındaki ayrışmayı somut verilerle ortaya koymasından kaynaklanmaktadır. Pür tahmin performansı açısından XGBoost modelinin en başarılı sonuçları vermesine rağmen, dengesizlik maliyetleri göz önüne alındığında 1D-CNN modelinin finansal olarak daha optimal bir çözüm sunduğu ortaya koymuştur. Bu sonuç, enerji ticareti ve portföy yönetimi stratejilerinde model seçiminin, salt teknik metriklerin ötesinde, finansal sonuçları da

içeren bütüncül bir yaklaşımla ele alınması gerektiği gerçeğinin altını çizmektedir. Dolayısıyla bu çalışma, akademik literatüre teorik model değerlendirmelerinin ötesinde finansal bir perspektif sunarak önemli bir katkı sağlamakta ve enerji piyasası katılımcılarına, operasyonel kararlarında riski minimize eden ve kârlılığını artıran pratik bir rehber sunmaktadır.

Bu hedefler doğrultusunda, tez ilerleyen bölümlerde şu şekilde yapılandırılmıştır: İkinci bölümde, elektrik tüketim tahmini alanında yapılmış olan önceki çalışmalar ve kullanılan yöntemler incelenerek konunun literatürdeki yeri ortaya konulmaktadır. Üçüncü bölümde, çalışmanın materyal ve yöntemi detaylandırılmaktadır; bu kısımda kullanılan veri seti, veri ön işleme adımları, geliştirilen makine öğrenmesi ve derin öğrenme modelleri, teknik performans kriterleri ve çalışmanın özgün yönünü oluşturan dengesizlik maliyeti analizi metodolojisi açıklanmaktadır. Dördüncü bölümde, modellerin karşılaştırmalı analizleri sonucunda elde edilen bulgular hem istatistiksel hem de finansal sonuçları içerecek şekilde sunulmuş ve aralarındaki farklılıklar yorumlanarak bir tartışma yürütülmüştür. Beşinci ve son bölümde ise, çalışmadan elde edilen genel sonuçlar özetlenmekte ve bu alanda gelecekte yapılabilecek çalışmalara yönelik önerilerde bulunmaktadır.

2. KAYNAK ARAŞTIRMASI

Tahminleme yapabilmek için birçok bilimsel çalışma bulunmaktadır. Yapılan tahminleme yöntemleri için kaynak araştırması yapılmıştır. Sadece YSA, XGBoost ya da regresyon üzerinde çalışmalar değil birçok tahmin yöntemiyle ilgili kaynak araştırması yapılmıştır.

Ucal ve Doğan (2005) çalışmasında Türkiye'nin 1985-2000 yılları arasındaki tüketim verilerine dayanarak 2020 yılına kadar olan tüketim miktarının öngörülmesine odaklanılmaktadır. Çalışmada, oluşturulan ekonometrik modelin istatistiksel olarak yanıltıcı (sahte) olup olmadığını test etmek amaçlanmaktadır. Bu çalışmada, bu amaçla eş bütünleşme analizi ve birim kök sınamalarını uygulamaktadır. Yaptıkları analizler, modeldeki değişkenler (nüfus, fiyat, sanayi gibi) arasında istatistiksel olarak anlamlı ve gerçek bir uzun dönem ilişkisine sahip olduğunu doğrulamıştır. Bu modelde yapılan tahminler, Türkiye'nin toplam elektrik tüketiminin 2020 yılına kadar yükseliş eğilimi göstereceğini işaret etmiştir.

Ünüvar vd. (2022) çalışmasında Karaman Organize Sanayi Bölgesi'ne odaklanarak, geçmiş tüketim kayıtlarına (saatlikten yıllığa kadar) bakarak gelecekteki yük davranışlarını ve talep seviyelerini tahmin etme yöntemlerini ele almaktadır. Çalışma, karmaşık yapay zekâ modelleri yerine, daha çok Otomatik Sayaç Okuma Sistemi'nden (OSOS) elde edilen verilerin analizine ve bu analizlere dayalı daha basit, korelasyona dayalı tahmin formüllerinin (MS Excel ortamında, kullanımına ağırlık vermektedir. Özellikle, 2018 Ekim ayı için yapılan tahminlerde, Cumhuriyet Bayramı gibi resmi tatil dönemlerinde, kullanılan formülün bu özel günleri hesaba katmamasından kaynaklanan belirgin tahmin hataları tespit edilmiştir. Makale, sanayi tüketicilerinin gelecekteki enerji ihtiyaçlarını belirlemek için geçmiş verilere dayalı bir yük profili oluşturma örneği sunarken, gelecekteki çalışmalarda daha gelişmiş tekniklerin kullanılabileceğine işaret etmektedir.

Genç Kavas (2022) çalışmasında Türkiye'nin artan enerji talebi ve arz güvenliği bağlamında bu çalışma, 2005-2018 arasındaki aylık verilere dayanarak 2019-2023 periyodu için elektrik tüketimini öngörmeyi hedeflemiştir. Araştırmada derin öğrenme tekniklerinden yararlanılmış, özellikle Çift Yönlü Uzun Kısa Süreli Bellek (Bi-LSTM) ağına odaklanılmıştır.

Bişkin ve Çifci (2021) çalışmasında Türkiye'nin genel elektrik tüketimini kısa vadeli (bir saat ve üç saat sonrası için) tahmin etmek amacıyla LSTM ve GRU modelleri

olan iki derin öğrenme modelini kullanmıştır. Bulgular, GRU modelinin, hem tahmin doğruluğu hem de hesaplama hızı açısından, tüm denenen senaryolarda LSTM modeline göre küçük bir üstünlüğe sahip olduğunu göstermiştir. Tahminlere bakıldığında, bir saatlik öngörülerin üç saatlik olanlara göre daha doğru tahmin edildiği görülmüştür. Ayrıca, genellikle 48 saatlik geçmiş veriyi kullanmanın, 24 saatlik veriye kıyasla tahmin doğruluğunu artırdığı tespit edilmiştir.

Berus ve Benteşen Yakut (2024) çalışmasında Diyarbakır'daki bir alışveriş merkezinin enerji tüketimini tahmin etmeye odaklanan bu çalışma, beş yılı aşkın bir süreye yayılan saatlik aktif tüketim verilerini kullanmıştır. Araştırmacılar, bu tahmin görevini gerçekleştirmek için dört farklı derin öğrenme mimarisi karşılaştırmışlardır: 1D-CNN ve üç farklı tekrarlayan sinir ağı türü (RNN, LSTM, BiLSTM). Modellerin ne kadar başarılı olduğunu ölçmek için RMSE, MAE ve R^2 metrikleri kullanılmış ve her model 10 defa eğitilip test edilmiştir.

Erdoğan ve Özyürek (2012) çalışmasında Türkiye'de İMKB 100 endeksinde işlem gören beyaz eşya sektörü firmalarının günlük hisse senedi kapanış fiyatlarını tahmin etmeyi hedefleyerek Finans sektöründe yeni bir uygulama üzerinde durmuşlardır. Tahmin yöntemi olarak YSA kullanılmıştır. Modelin girdi verileri, literatür taraması sonucu belirlenen dolar kuru, İMKB 100 endeks değeri ve ilgili hisse senedinin önceki işlem günlerine (Pazartesi-Perşembe) ait kapanış fiyatlarından oluşmaktadır.

Eren ve Kaçtıoğlu (2017) çalışmasında Türkiye'nin yıllık doğal gaz tüketimini ve nüfusunu 2030 yılına kadar tahmin etmeyi hedeflemektedir. Tahmin yöntemi olarak, özellikle sınırlı veri setleri veya belirsiz sistemler için uygun olan Gri Model tekniği kullanılmıştır. TÜİK'ten alınan 2004-2016 yılları arasındaki yıllık veriler modele girdi olarak kullanılmıştır.

Haliloğlu ve Tutu (2018) çalışmasında Türkiye'deki kısa vadeli elektrik tüketimini günlük frekansta tahmin eden bir ekonometrik model geliştirmeyi amaçlamıştır. Literatürdeki yıllık tahmin ağırlıklı çalışmalardan farklılaşarak, günlük dinamikleri yakalamayı hedeflemiştir. Çalışmanın amacı piyasa katılımcılarının sonraki gün için elektrik üretim ve tüketim tahminlerini paylaştığı bu piyasada ihtiyaç duyulacak enerjinin doğruya yakın bir şekilde tahmin edilmesi, eksik veya fazla taleplerin ortaya çıkmasını en aza indirmektir. 2012-2017 verileriyle kurulan modelin, 2018 Ocak-Nisan dönemi için yapılan testlerde oldukça başarılı olduğu (%92,8 R^2 değeri ve aylık ortalama %1,3-%1,6 arası hata oranı) ve özellikle eşik sıcaklık değişkeninin mevsimselliği dinamik olarak modellemede etkili olduğu sonucuna varılmıştır.

Arslan ve Ertuğrul (2022) çalışmasında literatürde sıkça kullanılan Çoklu Doğrusal Regresyon, ARIMA ve YSA karşılaştırılarak sonuçlar incelenmiştir. Çoklu regresyon ve YSA modellerinde PTF'yi etkilediği düşünülen üretim miktarları (doğalgaz, hidroelektrik, rüzgar, termik) ve talep miktarı gibi değişkenler girdi olarak kullanılırken, ARIMA modelinde sadece geçmiş PTF verileri kullanılmıştır. Mart-Haziran 2020 dönemi verileriyle yapılan analizler sonucunda, tahmin performansları (MAPE - Ortalama Mutlak Yüzde Hata) karşılaştırıldığında, sırasıyla YSA modelinin Çoklu Doğrusal Regresyon ve ARIMA modellerinin doğruya yakın tahmin yaptığı sonucu çıkmıştır.

Doğru ve Büyükakın (2023) çalışmasında Türkiye'nin sanayi ve nüfus açısından önemli bölgelerinden biri olan TR42 (Kocaeli, Sakarya, Düzce, Bolu, Yalova) özelinde elektrik enerjisi talebini tahmin etmeye odaklanmaktadır. Elektriğin depolanamaz yapısı nedeniyle arz-talep dengesinin önemine vurgu yapılarak, bölge için gerçekçi tahminler üretilmesi hedeflenmiştir. Modelin girdileri olarak elektrik fiyatı, dolar kuru, TÜFE, konut satışları, hava durumu, iş günü sayısı ve kişi sayısı gibi aylık veriler kullanılmış ve her il için ayrı analiz yapılmıştır. Bulgular, Yalova hariç diğer iller (Bolu, Düzce, Kocaeli, Sakarya) için tahmin modelinin başarılı sonuçlar verdiğini göstermiştir. Yalova'daki farklı performansın, ildeki enerji dağıtım şirketinin diğerlerinden farklı olması veya veri setindeki olası farklılıklardan kaynaklanabileceği düşünülmektedir.

Bilgili (2009) çalışmasında ise üç farklı modelleme tekniği kullanılmış ve bu modeller karşılaştırılmıştır: Doğrusal Regresyon (LR), Doğrusal Olmayan Regresyon (NLR) ve YSA. Gelecek tahmini için yüksek ve düşük olmak üzere iki farklı senaryo geliştirilmiştir. Çalışmanın bulguları, YSA yönteminin performansının, diğer(LR ve NLR) yöntemlere kıyasla gerçek değere daha yakın olduğunu göstermiştir.

Hamzaçebi ve Kutay (2004) çalışmasında Türkiye'nin ulusal elektrik enerjisi tüketimini 2010 yılına kadar uzun dönemli olarak tahmin etmek için YSA yönteminin kullanımını araştırmaktadır. YSA (Geri Yayılım ve Radyal Tabanlı Fonksiyon ağları) ile elde edilen sonuçlar, geleneksel Box-Jenkins (ARIMA) modelleri ve Regresyon tekniği ile karşılaştırılmıştır. Sonuçlar, 1991-1998 doğrulama ve 1999-2002 test dönemleri için, YSA tekniklerinin genel olarak Box-Jenkins ve regresyon yöntemlerine göre daha düşük hata oranları verdiğini, dolayısıyla daha başarılı tahminler ürettiğini göstermiştir.

Nebati vd. (2021) çalışmasında ise Türkiye'deki elektrik tüketimini tahmin etmek amacıyla Zaman Serisi Analizi (ARIMA/IMA) ve Çoklu Doğrusal Regresyon Analizi tekniklerini karşılaştırmaktadır. 1970-2019 verilerini kullanarak yapılan analizde,

regresyon modeli için nüfus, konut sayısı, kişi başı gelir, beyaz eşya sayısı ve iş yeri sayısı gibi değişkenler kullanılmıştır. Model performansları Ortalama Mutlak Yüzde Hata (MAPE) metriği ile değerlendirilmiştir. MAPE değerinin regresyonda daha düşük olması sebebiyle regresyon analizinin daha uygulanabilir olduğunu belirtilmiştir. Çalışma, regresyon analizinin, seçilen değişkenlerle birlikte, zaman serisi yöntemine göre daha güvenilir sonuçlar verdiğini ortaya koymuş ve 2035 yılına kadar her iki yöntemle de tahminler vermiştir.

Kocadayı vd. (2017) ise çalışmasında Türkiye'nin TR81 İstatistik Bölgesi (Zonguldak, Karabük, Bartın) için yıllık bazda elektrik enerjisi tüketimini tahmin etmeye odaklanmaktadır. Tahmin sürecinde YSA yöntemi tercih edilmiştir. Modelin girdi değişkenleri olarak bölgenin nüfus, ithalat, ihracat ve bina yüzölçümü verileri kullanılmıştır. Çalışmanın bölgedeki gelecekteki enerji yatırımları için faydalı olabileceği sonucuna varılmıştır.

Ünal (2024) çalışmasında 2005-2023 yılları arasındaki Türkiye toplam elektrik tüketimini, makroekonomik ve enerjiye özgü göstergelerle olan ilişkisini YSA kullanarak analiz etmektedir. Çalışmada üç farklı YSA mimarisi denenmiştir. İleri Beslemeli Geri Yayılımlı Ağ, Elman Sinir Ağı ve NARX (Doğrusal Olmayan Otoregresif Dışsal) Sinir Ağı. Model girdileri; toplam elektrik enerjisi üretimi, ihracat, ithalat, sanayi üretim endeksi ve Dolar/TL döviz kurunu içermektedir.

Özden ve Öztürk (2018) çalışmasında ise Ankara'daki İvedik Organize Sanayi Bölgesi gibi spesifik bir endüstriyel alanın kısa dönemli elektrik enerjisi ihtiyacını, kısıtlı veri kullanarak tahmin etmeye odaklanmaktadır. İki farklı yöntem karşılaştırılmıştır: YSA ve Zaman Serileri (Doğrusal Olmayan Otoregresif - NOR-SA). YSA modelinde geçmiş tüketim verilerine ek olarak sıcaklık verisi de girdi olarak kullanılırken, zaman serisi modelinde yalnızca geçmiş tüketim verileri kullanılmıştır. Karşılaştırma sonucunda, YSA modelinin R değeri zaman serisi modeline göre daha iyi sonuç vermiştir, bu da YSA modelinin, sıcaklık faktörünü de içermesi sayesinde, daha başarılı bir tahmin performansı sergilediğini göstermiştir.

Aydın ve Toros (2018) çalışmasında ise modelin önemli bir girdisi, Türkiye'de en çok tüketime sahip 12 ilin sıcaklık verilerinin, tüketim miktarlarına göre ağırlıklandırılmış ortalamasıdır. Ocak 2012 - Kasım 2016 verileriyle yapılan analizde, modelin makul hata oranları ile tahmin yapabildiği görülmüştür. Yakın geçmişteki verilerin (1 gün veya 1 hafta öncesi) daha eski verilere (1 yıl öncesi) göre tahmin üzerinde

daha etkili olduğu ve modelin yaz dönemi tahminlerinde kışa göre daha başarılı olduğu saptanmıştır.

Işık ve Şeker (2021) ise Türkiye'nin uzun dönemli enerji üretim potansiyelini, farklı birincil enerji kaynakları (petrol, gaz, kömür ve diğer/yenilenebilir) bazında ayrı ayrı tahmin etmeyi amaçlamaktadır.

Güven vd. (2025) Çin'in enerji üretiminde kömürün çevresel etkileri nedeniyle azalan kullanımına rağmen, kömürden elde edilen elektrik miktarını tahmin etmeye odaklanmaktadır. Tahmin için YSA modeli kullanılmış; hidroelektrik, rüzgar gücü, nükleer güç ve toplam elektrik üretimi gibi veriler girdi olarak alınmıştır. Modelin hata payları (MAE, MAPE, MAD, MSE, RMSE) da hesaplanmış ve düşük bulunmuştur.

Kaysal vd. (2022) Türkiye için kısa dönemli (bir saat sonrası) elektrik yük/talep tahmininde farklı makine öğrenmesi yöntemlerinin performansını karşılaştırmayı hedeflemiştir. Çalışmada dört yöntem incelenmiştir: YSA, Ridge Regresyon, Lasso Regresyon ve Destek Vektör Regresyonu (SVR).

Çalık ve Şirin (2017) Türkiye'deki elektrik enerjisi tüketim dinamiklerini modellemek için standart üstel büyüme modellerinden farklı bir yaklaşım sunmaktadır. Bu amaçla, kesirsel matematik (fractional calculus) ve bu alandaki Mittag-Leffler (ML) fonksiyonları kullanılarak bir model geliştirilmiştir. 1975-2015 yılları arasındaki TÜİK verileri kullanılarak oluşturulan kesirsel modelin, özellikle son yıllardaki (enerji tüketiminin arttığı dönemlerdeki) gerçek verilere, standart üstel büyüme modeline kıyasla daha iyi uyum sağladığı gözlemlenmiştir. Bu kesirsel model kullanılarak 2037 yılına kadar elektrik tüketimi tahminleri üretilmiş ve kesirsel türev mertebesinin, standart matematik yöntemlerine göre daha gerçekçi sistem tasvirleri sunabileceği vurgulanmıştır.

Sezer vd. (2024) Türkiye'deki toplam elektrik tüketiminin kısa ve orta dönemli tahminine odaklanmaktadır. Tahmin yöntemi olarak, zaman serisi analizinde kullanılan üstel düzleştirme tekniklerinden Holt-Winters metodu tercih edilmiştir. Hem örneklem içi (modelin eğitildiği veriler) hem de örneklem dışı (modelin görmediği gelecek veriler) tahminler incelenmiştir.

Karaca ve Karacan (2016) Türkiye'deki elektrik tüketim talebini etkileyen faktörleri belirlemeyi ve bu faktörleri kullanarak talep tahmini yapmayı amaçlamaktadır. Bu doğrultuda, Çoklu Doğrusal Regresyon yöntemi kullanılmıştır. Modele girdi olarak Gayri Safi Yurtiçi Milli Hasıla (GSYİH), Ortalama Yaşam Beklentisi ve İnternet Kullanımı gibi faktörler dahil edilmiş ve bunların elektrik tüketimi üzerindeki etkileri incelenmiştir. Çalışmada ayrıca basit regresyon ile çoklu regresyon sonuçları

karşılaştırılmış ve çoklu regresyonun, daha fazla açıklayıcı değişkeni hesaba katması nedeniyle, daha doğru ve güvenilir tahminler sunduğu sonucuna varılmıştır.

Kamber vd. (2021) Kısa dönemli elektrik yükü tahminlemesi için YSA ile LSTM)mimarisinin kullanılmasını ele almaktadır. İspanya'nın 2015-2016 yıllarına ait saatlik elektrik enerjisi üretim ve tüketim verileri kullanılarak yapılan tahminlerin performansı, geleneksel zaman serisi yöntemi olan ARIMA ile karşılaştırılmıştır. Çalışmanın sonuçları, LSTM tabanlı YSA modelinin, ARIMA modeline kıyasla daha düşük hata oranıyla daha başarılı tahminler ürettiğini göstermektedir.

Gökçe (2024) elektrik enerjisi üretim planlamasının temelini oluşturan talep tahminine odaklanmaktadır. Çalışmada, derin öğrenme yöntemleri (RNN, LSTM, GRU) ile çoklu makine öğrenmesi modellerinin performansı karşılaştırılmıştır. Analizler sonucunda, derin öğrenme yöntemlerinin makine öğrenmesi modellerine kıyasla daha başarılı olduğu, bu yöntemler içinde ise LSTM'nin RNN ve GRU'dan daha iyi tahmin performansı sergilediği gözlemlenmiştir. Çalışma, doğru tahminlerin enerji arz ve talebi arasındaki uyumsuzlukları gidermede kritik rol oynadığını vurgulamaktadır.

Ercan vd. (2020) konutlardaki elektrik tüketim düzeylerini (düşük/yüksek) hanehalkı ve konut özelliklerini kullanarak tahmin etmeyi hedeflemiştir. Literatürde bu tip bir sınıflandırma çalışmasının eksikliğine dikkat çekilmiştir. Modelleme için makine öğrenmesi yöntemlerinden YSA kullanılmıştır. Veri kaynağı olarak TÜİK Hanehalkı Bütçe Anketi (2009-2012) kullanılmış, elektrik harcaması olmayan haneler çıkarıldıktan sonra kalan haneler ortalama tüketime göre düşük ve yüksek olarak etiketlenmiştir. Bu modelin, elektrik üretim ve dağıtım planlamasına katkı sağlayabileceği belirtilmiştir.

Çayır vd. (2018) Londra'daki 30 farklı konutun yaklaşık 3 yıllık günlük elektrik güç tüketimi verilerini kullanarak kısa vadeli tahmin modelleri geliştirmeyi ve karşılaştırmayı amaçlamaktadır. Üç farklı makine/derin öğrenme yöntemi kullanılmıştır: Destek Vektör Bağlanım (SVM), Rassal Orman (Random Forest) ve LSTM. Model performansları R-Kare, düzeltilmiş R-Kare ve Ortalama Mutlak Hata (OMH) metrikleri ile değerlendirilmiştir. Sonuçlar, topluluk öğrenme algoritması olan Rassal Orman modelinin, incelenen diğer iki modele (SVM ve LSTM) göre daha iyi tahmin performansı sunduğunu göstermiştir.

Erkinay Özdemir (2021) çalışmasında İskenderun bölgesi özelinde, orta dönemli (2 hafta - 3 yıl arası) elektrik enerjisi tüketimini YSA kullanarak tahmin etmeyi amaçlamaktadır. Çalışmada, 2011-2020 yılları arasındaki aylık ortalama sıcaklık ve enerji tüketim verileri kullanılarak çok katmanlı, ileri beslemeli bir YSA modeli

(Levenberg-Marquardt algoritması ve tanjant sigmoid transfer fonksiyonu ile) geliştirilmiştir. Modelin performansını değerlendirmek için Ortalama Mutlak Yüzde Hata (MAPE) metriği kullanılmıştır. Elde edilen sonuçlar, tüm aylar için MAPE değerlerinin %10'un altında kalarak modelin yüksek bir tahmin performansı sergilediğini göstermiştir.

Özkan vd. (2020) çalışmasında Ocak 2016-Aralık 2018 arasındaki aylık tüketim verileri kullanılarak iki popüler zaman serisi yöntemi karşılaştırılmıştır: "En Küçük Kareler Yöntemi ile Fourier Analizi" ve "Winters Yöntemi". Veri seti boyutu arttıkça her iki modelin de hata oranlarının arttığı gözlemlenmiştir. 2019 yılı verileriyle yapılan model doğrulama adımı, Winters Yöntemi'nin Fourier Analizine göre daha düşük MAPE değeri vererek daha başarılı olduğu tespit edilmiş ve 2020 yılı tahminleri bu yöntemle yapılmıştır.

Baltaş ve Akbay (2021) Akdeniz Elektrik Dağıtım Bölgesi (Antalya, Isparta, Burdur) için on yıllık (geleceğe dönük) elektrik tüketimini tahmin etmeyi amaçlamaktadır. Gayri Safi Yurtiçi Hasıla (GSYH) verileri ile elektrik talebi arasında yüksek korelasyon bulunduğu için, Türkiye'nin yıllık brüt elektrik talebini tahmin etmede GSYH kullanılmıştır. Çoklu Doğrusal Regresyon analizi uygulanmış ve modelin katsayıları belirlenmiştir. Türkiye geneli için tahmin yapıldıktan sonra, Akdeniz bölgesinin tüketiminin Türkiye genelindeki değişime göre daha az değişkenlik gösterdiği kovaryans analizi ile tespit edilmiş ve bu katsayı ($\beta=0,532$) kullanılarak bölge tahmini yapılmıştır. Sonuçlar, bölgedeki elektrik tüketiminin yıllara göre artacağını göstermiş ve bölgenin tarım/turizm potansiyeli nedeniyle yatırım planlamasının önemini vurgulamıştır.

Çağlayan Akay ve Topal (2024) çalışmasında ise bunun için tek ve hibrit elektrik tüketim modellerinin tahmin performansları, SARIMA zaman serisi modeli, ANN'ler ve MLP'ler makine öğrenimi tek modelleri ve SARIMA-ANN'ler ve SARIMA-MLP'ler makine öğreniminin hibrit modelleri karşılaştırılmıştır. Sonuca göre, hibrit modeller Türkiye'nin elektrik tüketiminin tahmininde tek modellere göre daha iyi tahmin performans sağladığını ortaya çıkarmıştır.

Heidarpanah vd. (2023) İran elektrik sektörü için yapay zeka ile tahminleme çalışması yapmıştır. Çalıştığı tüm modeller arasında hibrit CNN-LSTM, İran'ın elektrik piyasasındaki elektrik fiyatını tahmin etmek için daha uygulanabilir olduğunu tespit etmiştir.

Calp (2018) YSA'yı işletmeler için personel yemek talep tahmini yapabilmek adına kullanmıştır. Deney sonuçları, modelin hata oranının düşük, performansının yüksek

olduğunu ve talep tahmini için yapay sinir ağları kullanımının olumlu olduğunu ortaya koymuştur.

Ülkü ve Yalpir (2021) çalışmasında ise enerji talep tahmininde Çoklu regresyon tahmini ve yapay zeka yöntemlerinden YSA modelini karşılaştırmıştır. YSA yöntemi ile yapılan model sonuçlarının bakanlığın elde ettiği sonuçlara daha yakın olduğu gözlenmiştir.

Tightiz vd. (2025) çalışmasında ise özellikle yenilenebilir enerji kaynaklarının entegrasyonu ile artan elektrik piyasalarındaki yüksek fiyat dalgalanmalarını yönetmek amacıyla gelişmiş bir tahmin modeli sunulmaktadır. Çalışma, XGBoost algoritmasını temel alarak bunu hata düzeltme özellikleri, Bayes optimizasyonu ve Açıklanabilir Yapay Zeka (XAI) teknikleri (SHAP ve LIME gibi) ile güçlendirmektedir. ISO New England elektrik piyasası verilerini kullanan model, özellikle tatil günleri gibi anormallikleri ve piyasa şoklarını yönetmede daha sağlam ve yorumlanabilir bir çözüm sunarak standart modellere göre daha üstün bir performans sergilemektedir.

Ecevit vd. (2023) ise e-ticaret sektörü için kısa dönemli ve saatlik satış tahminlemesi üzerine odaklanmışlardır. Bu kapsamda, derin öğrenme tabanlı Uzun-Kısa Süreli Bellek (LSTM) ve Facebook'un Prophet modellerinin performansını, klasik bir istatistiksel yöntem olan mevsimsel otoregresif bütünleşik hareketli ortalama (SARIMA) modeliyle karşılaştırmışlardır. Gerçek bir e-ticaret sitesinden alınan verilerle yapılan analizler sonucunda, LSTM modelinin tahmin doğruluğu açısından hem Prophet hem de SARIMA modelinden daha üstün sonuçlar verdiği tespit edilmiştir.

Kaynak araştırmasına ilişkin özet Çizelge 2.1'de sunulmuştur.

Çizelge 2.1. Kaynak araştırması

Yazar(lar)	Yıl	Tahmin Türü	Tahmin Periyodu	Kullanılan Yöntemi
Ucal, Doğan	2005	Talep Tahmini	Uzun Vadeli	Kointegrasyon konusu içinde yer alan birim kök testi, Regresyon
Ünüvar, Balcı, Kayabaşı	2022	Talep Tahmini	Kısa Vadeli	İstatistiksel tahmin
Kavas	2022	Talep Tahmini	Kısa Vadeli	Deep Learning, Bi-LSTM (ADAM, Rmsprop, SGDM)
Bişkin, Çifci	2021	Talep Tahmini	Kısa Vadeli	Deep Learning Gated Recurrent Unit-GRU, Zaman Serileri LSTM

Çizelge 2.1.(devam) Kaynak araştırması

Yazar(lar)	Yıl	Tahmin Türü	Tahmin Periyodu	Kullanılan Yöntemi
Berus, Yakut	2024	Talep Tahmini	Kısa Vadeli	BiLSTM, Deep Learning, 1D-CNN, RNN, LSTM
Erdoğan, Özyürek	2012	Fiyat Tahmini	Kısa Vadeli	YSA
Eren, Kaçtıoğlu	2017	Talep Tahmini	Uzun Vadeli	Gri Tahmin Yöntemi
Haliloğlu, Tutu	2018	Talep Tahmini	Kısa Vadeli	Ekonometrik Model (EKK)
Arslan, Ertuğrul	2022	Fiyat Tahmini	Kısa Vadeli	Çoklu Regresyon, ARIMA, YSA
Doğru, Büyükkın	2023	Talep Tahmini	Orta Vadeli	Makine Öğrenmesi (Çoklu Doğrusal Regresyon)
Bilgili	2009	Talep Tahmini	Uzun Vadeli	Lineer Regresyon (LR), Lineer Olmayan Regresyon (NLR), Yapay Sinir Ağları (YSA)
Hamzaçebi, Kutay	2004	Talep Tahmini	Uzun Vadeli	YSA, Box-Jenkins, Regresyon
Nebati, Taş, Ertaş	2021	Talep Tahmini	Orta Vadeli	Zaman Serisi, Regresyon
Kocadayı, Erkaymaz, Uzun	2017	Talep Tahmini	Uzun Vadeli	YSA
Ünal	2024	Talep Tahmini	Kısa Vadeli	Yapay Sinir Ağları (İleri Beslemeli Geri Yayımlı Sinir Ağı, Elman Sinir Ağı, NARX Sinir Ağı)
Özden, Öztürk	2018	Talep Tahmini	Kısa Vadeli	YSA, Zaman Serileri
Aydın, Toros	2018	Talep Tahmini	Kısa Vadeli	YSA
Işık, Şeker	2021	Üretim Tahmini	Uzun Vadeli	YSA
Güven, Kılıç, Diri	2024	Üretim Tahmini	Orta Vadeli	YSA
Kaysal, Akarslan, Hocaoglu	2022	Talep Tahmini	Kısa Vadeli	Makine Öğrenmesi (YSA, Ridge Regresyon, Lasso Regresyon, Destek Vektör Regresyonu)
Çalık, Şirin	2017	Talep Tahmini	Uzun Vadeli	Kesirsel Matematiksel Model (Mittag-Leffler Fonksiyonları)
Sezer, Yıldırım, Özdemir	2024	Talep Tahmini	Orta Vadeli	Holt-Winters Üstel Düzleştirme Yöntemi
Karaca, Karacan	2016	Talep Tahmini	Orta Vadeli	YSA, Otoregresif Hareketli Ortalamalar, Basit/Çoklu Regresyon
Kamber, Körpüz, Can, Aydoğmuş, Gümüş	2021	Talep Tahmini	Kısa Vadeli	Yapay Sinir Ağları (LSTM), ARIMA
Gökçe, Duman	2024	Talep Tahmini	Kısa Vadeli	Derin Öğrenme (RNN, LSTM, GRU)
Ercan, Irmak, Çevik, Canbazoglu	2020	Talep Tahmini	Kısa Vadeli	YSA
Çayır, Yenidoğan, Dağ	2018	Talep Tahmini	Kısa Vadeli	Destek Vektör Bağlanım (DVM), Rassal Orman (RO), Uzun-Kısa Vadeli Bellek (UKVB-YSA)

Çizelge 2.1.(devam) Kaynak araştırması

Yazar(lar)	Yıl	Tahmin Türü	Tahmin Periyodu	Kullanılan Yöntemi
Özdemir	2021	Talep Tahmini	Orta Vadeli	YSA
Özkan, Güler, Aladağ	2020	Talep Tahmini	Kısa Vadeli	Fourier Analizi, Winters' Yöntemi
Baltaş, Akbay	2021	Talep Tahmini	Orta Vadeli	Regresyon, Kovaryans Analizi
Çağlayan-Akay, Topal	2024	Talep Tahmini	Orta Vadeli	Zaman Serileri, ARIMA-Hibrit Model
Heidarpanah, Fazeli	2023	Fiyat Tahmini	Kısa Vadeli	CNN-LSTM
Calp	2019	Talep Tahmini	Kısa Vadeli	YSA - İleri Beslemeli Geri Yayılımlı
Ülkü, Yalpır	2021	Talep Tahmini	Uzun Vadeli	YSA, Çoklu Regresyon Analizi
Ecevit, Öztürk, Dağ, Özcan	2023	Talep Tahmini	Kısa Vadeli	LSTM, Prophet, SARIMA
Tightiz, Yoo, Al-Shibli	2025	Fiyat Tahmini	Kısa Vadeli	XGBoost, Hata Düzeltme Özellikleri, Bayes Optimizasyonu, Yapay Zeka

3. MATERYAL VE YÖNTEM

Bu bölümde, çalışmada kullanılan veri seti, veri ön işleme süreci ve tahmin modelleri detaylı olarak açıklanmıştır. İç Anadolu Bölgesi'nde bulunan illere (Konya-Karaman-Niğde-Nevşehir-Aksaray-Kırşehir) ait Mayıs 2022 yılından itibaren Nisan 2025 yılını kapsayacak şekilde saatlik olarak dağıtılan elektrik enerjisinin gerçekleştirmeleri kullanılmıştır. 25.752 adet saatlik(37 aylık) veri bulunmaktadır. Aynı zamanda ilgili saatlere denk gelen haftanın günleri de veri setine eklenmiştir. Veri seti tarih, saat, gün ve gerçekleştirmeler şeklindedir. Saatlik enerji tüketim verileri üzerinde YSA, XGBoost modelleri ile orta vadeli enerji tüketimi tahmini gerçekleştirilmiştir ve son olarak modellerin finansal performansını ölçmek için geliştirilen maliyet analizi metodolojisi detaylı olarak açıklanmıştır.

3.1. Talep Tahmini

Geleceğe yönelik planlama ve karar alma süreçlerinde, karşılaşılmaması muhtemel durumları öngörebilmek büyük bir önem taşır. Bu bağlamda talep tahmini, geçmiş dönemlere ait verilerin ve mevcut koşulların analizi yoluyla, belirli bir ürün, hizmet ya da bu çalışma özelinde olduğu gibi enerjide de bir kaynağa yönelik gelecekteki talebin miktarını kestirme çabası olarak tanımlanabilir. Amaç varolan veriler ile geleceğe yönelik atılacak stratejik adımların yapılan tahminler ile belirsizliği ortadan kaldırmaya ya da en aza indirmeye çalışmaktır.

Özellikle enerji sektörü gibi, arzın taleple anlık ve hassas bir denge içinde tutulmasının zorunlu olduğu alanlarda, talep tahminlerinin rolü önem taşır. Çünkü enerji, gündelik yaşamın ve ekonomik faaliyetlerin devamlılığı için temel bir gereksinimdir. Enerji talebinin doğru bir şekilde öngörülmesi;

- Kaynakların verimli kullanılmasına,
- Üretim ve dağıtım süreçlerinin optimize edilmesine,
- Şebeke güvenliğinin ve sürekliliğinin sağlanmasına,
- Uzun vadeli yatırım kararlarının isabetli bir şekilde alınmasına,
- Nihayetinde hem maliyetlerin düşürülmesine hem de çevresel

sürdürülebilirliğe katkıda bulunulmasına olanak sağlar.

Enerji talebi, tek bir faktöre bağlı olmayan, aksine pek çok değişkenin etkileşiminden doğan karmaşık bir olgudur. Geçmiş tüketim alışkanlıkları, mevsimsel değişimler, günün farklı saatlerindeki ihtiyaçlar, haftanın günleri, resmi tatiller gibi

takvimsel etkiler, sıcaklık ve nem gibi hava koşulları, hatta genel ekonomik durum ve nüfus hareketleri gibi unsurlar enerji tüketiminin seyrini belirleyebilir. Bu çalışmada, bu karmaşıklığı göz önünde bulundurarak enerji tüketimini tahmin etmeye yönelik çeşitli yaklaşımlar ele alınmıştır.

Nebati vd. (2021) çalışmasında talep tahmini hemen hemen tüm sektörlerde ve iş planlamalarında karşılaşılabilecek bir kavramdır şeklinde belirtmiştir.

3.1.1. Talep tahmin yöntemleri

Literatürde birçok talep tahmin yöntemi bulunmaktadır. Bu yöntemler, kullandıkları veri türüne ve matematiksel altyapılarına göre çeşitli şekillerde sınıflandırılabilir. Genel bir çerçevede, talep tahmin yöntemleri nitel (kalitatif) ve nicel (kantitatif) yöntemler olarak iki ana grupta incelenebilir.

- Nitel Yöntemler: Bu yöntemler genellikle sayısal verilerin sınırlı olduğu veya hiç olmadığı durumlarda, uzman görüşlerine, pazar araştırmalarına, anketlere veya Delfi tekniği gibi grup karar verme süreçlerine dayanır. Daha çok öznel yargılar ve deneyimler ön plandadır.
- Nicel Yöntemler: Bu yöntemler ise geçmişe ait sayısal verilerin varlığına dayanır ve bu verilerdeki örüntüleri, ilişkileri ve eğilimleri matematiksel ve istatistiksel modeller aracılığıyla analiz ederek geleceğe yönelik tahminler üretir. Nicel yöntemler, kullanılan tekniklere göre daha alt kategorilere ayrılabilir:

Geleneksel Zaman Serisi Modelleri: Bu yaklaşımda, tahmin edilecek değişkenin (örneğin enerji tüketimi) geçmiş değerlerinin, gelecekteki değerlerini belirlemede en önemli faktör olduğu varsayılır. Değişkenin kendi geçmişindeki örüntüler (trend, mevsimsellik, döngüsellik) analiz edilerek geleceğe yönelik projeksiyonlar yapılır.

Nedensel (İlişkisel) Modeller: Bu yöntemlerde ise tahmin edilecek değişken ile onu etkilediği düşünülen bir veya daha fazla bağımsız değişken (örneğin hava durumu, ekonomik göstergeler) arasındaki ilişki modellenir. Klasik regresyon analizi bu gruptaki en temel örnektir.

Makine Öğrenmesi Tabanlı Yöntemler: Son yıllarda, özellikle büyük veri setlerinin ve karmaşık ilişkilerin modellenmesindeki başarıları nedeniyle makine öğrenmesi algoritmaları talep tahmininde giderek daha fazla kullanılmaktadır. Bu yöntemler, hem zaman serisinin kendi içsel dinamiklerini (gecikmeli değerler aracılığıyla) hem de çok sayıda dışsal faktörü eş zamanlı olarak dikkate alabilme

esnekliğine sahiptir. Karmaşık, doğrusal olmayan örüntüleri öğrenebilme kapasiteleri sayesinde geleneksel yöntemlere kıyasla üstün performanslar sergileyebilirler (Runge ve Zmeureanu, 2019). Bu çalışmada, bu kategori altında iki önemli yöntem incelenmiştir:

Bu tez çalışmasında, enerji tüketim tahmininin karmaşık ve dinamik doğası göz önünde bulundurularak, hem geleneksel istatistiksel zaman serisi modellerinden hem de gelişmiş makine öğrenmesi algoritmalarından faydalanılmıştır. Özellikle, aşağıdaki yöntemlerin enerji tüketim tahmini performansları incelenmiş ve karşılaştırılmıştır:

- YSA: İnsan beyninin öğrenme yapısından esinlenerek geliştirilen, karmaşık ve doğrusal olmayan ilişkileri modelleyebilme yeteneğine sahip güçlü bir makine öğrenmesi tekniğidir (Haykin, 2009).
- XGBoost (Extreme Gradient Boosting): Gradyan artırma (gradient boosting) algoritmalarının optimize edilmiş ve yüksek performanslı bir uygulaması olup, karar ağacı topluluklarına dayanan etkili bir makine öğrenmesi modelidir (Tokmak, 2023).

3.2. Kullanılan Yöntemler

Bu çalışmada enerji tüketim tahmininin doğruya en yakın şekilde tahmin edilmesi için farklı yöntemlere sahip dört yöntem kullanılarak enerji tüketim tahminleri yapılmıştır. Her bir yöntem aşağıda detaylı olarak açıklanmıştır. Bu yöntemler sırasıyla YSA, XGBoost modelleridir.


3.2.1. Yapay sinir ağları (YSA)

Birçok bilim insanı karmaşık problemler ile karşı karşıya gelmiş ve bu problemler karşısında insan beyninde bulunan gerçek sinir ağlarından esinlenerek yapay bir yapı oluşturma fikrini ortaya çıkarmıştır. İnsan beyninde bulunan milyonlarca sinir ağı ve bu sinir ağlarının içerisinde ise nöronlar ve katmanlar bulunmaktadır. Nöronlar ve katmanlar birbirleri ile iletişim halinde olan yapılardır. Şekil 3.1’te gösterildiği gibi bu nöronlar(sinir hücreleri) arasında sürekli bilgi alışverişi olmaktadır. İnsan beyni sinir ağları ve yapay sinir ağları tamamen benzemese de avantajlı yanlarını alarak hareket edilmiştir. İnsan beynini inceleyen sinir bilimcileri yapının nasıl olduğunu araştırmış ve bu yapıdan yola çıkarak YSA, insan beyninde bulunan sinir ağlarını ve sinir ağlarıyla beraber öğrenme süreçlerini taklit ederek geliştirilmiş, karmaşık hesaplamalı modellerdir. Temelde,

birbirine bağı çok sayıda basit işlem birimlerinden (yapay nöronlar/sinir ağı) oluşurlar (Haykin, 2009).

Sinir ağının beyine benzerliği:

1. Bilgi, ağ tarafından bir öğrenme süreci aracılığıyla çevresinden edinilir.
2. Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı güçleri, edinilen bilgiyi depolamak için kullanılır (Lecun vd., 2015).



Şekil 3.1. YSA nöron yapısı (Haykin, 2009)

YSA birçok avantajlı özelliği bulunmaktadır. Bunlar;

- Yapılacak işlemleri aynı anda paralel olarak çalıştırabilirler.
- Birden fazla öğrenme mimarisi bulunmaktadır.
- Sınıflandırabilirler, kategorilerine ayırarak verileri tamamlayabilirler.
- Verileri öğrenerek hafızalarında tutabilirler.
- Yeni bilgiler üretebilirler.
- Sayısal olan verilerde modelleme yapabilirler ve birçok problemde çözüm aracı olarak kullanabilirler.

Bu nöronlar 3 katmandan oluşur.

1) Giriş katmanı;

Dışarıdan gelen verilerin ilk katmanıdır.

2) Bir veya daha fazla gizli katman;


Giriş katmanından çıkan veri seti bu katmana gelir. Karmaşık problemlerin çözülmesi için kolaylık sağlar.

3) Çıkış katmanı;

Gizli katmanlardan, ara katmanlardan gelen veri bu katmanda işlenerek çıktı olarak oluşur (Haykin, 2009).

3.2.1.1. Yapay sinir ağlarının sınıflandırılması

YSA, mimari yapıları, öğrenme biçimleri ve öğrenme süreçlerinin zamanlamasına göre farklı şekillerde sınıflandırılabilir. Bu sınıflandırmalar, YSA kullanım amacına uygun olarak daha etkili bir şekilde yapılandırılmasına ve uygulanmasına olanak tanır. Problemin yapısına göre farklı mimariler uygulanarak çözüm için alternatif sonuçlar üretilir. Bu bölümde, YSA'lar üç temel başlık altında ele alınacaktır: mimari yapılarına göre, öğrenme yöntemlerine göre ve öğrenme zamanlamasına göre sınıflandırma. YSA sınıflandırmalarına göre Şekil 3.2'de verilmiştir (Haykin, 2009).




Şekil 3.2. YSA Sınıflandırmaları (Haykin, 2009)

Öğrenme yöntemlerine göre YSA;


YSA, verilerle etkileşime geçme biçimlerine göre danışmanlı, danışmansız ve destekleyici öğrenme olmak üzere üç temel öğrenme yöntemiyle sınıflandırılabilir:

- İleri Beslemeli Sinir Ağları (Feedforward Neural Networks): Girdiden çıktıya doğru tek yönlü bilgi akışı vardır. Genellikle sınıflandırma ve regresyon problemlerinde tercih edilir. Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Tek katmanlı hesaplama düğümlerine sahip ileri beslemeli ağ (Haykin, 2009)

- Geri Beslemeli Sinir Ağları (Recurrent Neural Networks - RNN): Çıkışlar, ağın önceki durumlarını etkileyerek geri besleme mekanizması oluşturur. Zaman serileri ve ardışık veri analizi için uygundur. Şekil 3.3'te gösterilmiştir.




Şekil 3.4. Kendi kendine geri besleme döngüleri ve gizli nöronları olmayan yinelemeli ağ (Haykin, 2009)

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks - CNN): Özellikle görüntü işlemek için ve uzamsal veri amaçlı yapılardır. Katmanlar, filtreler aracılığıyla yerel özellikleri çıkarır. Evrimsel ağ, çeviri, ölçekleme, eğiklik ve diğer bozulma biçimlerine karşı yüksek derecede değişmezliğe sahip iki boyutlu şekilleri tanımak için özel olarak tasarlanmış çok katmanlı bir algılayıcıdır (Haykin, 2009).

Öğrenme yöntemlerine göre YSA;

YSA, verilerle etkileşime geçme biçimlerine göre danışmanlı, danışmansız ve destekleyici öğrenme olmak üzere üç temel öğrenme yöntemiyle sınıflandırılabilir:

- Danışmanlı Öğrenme (Supervised Learning): Girdi verilerinin çıktıları mevcuttur. Ağ, bu eşleşmeleri öğrenerek tahmin yapar. Geri yayılım (backpropagation) bu yöntemde sıkça kullanılır.
- Danışmansız Öğrenme (Unsupervised Learning): Şekil 3.5'te gösterildiği gibi girdi verilerine ait etiket bulunmaz. Ağ, veri içindeki gizli yapıları veya örüntüleri keşfetmeye çalışır. Özellikle kümeleme ve boyut indirgeme işlemlerinde tercih edilir.
- Destekleyici Öğrenme (Reinforcement Learning): Ağ, bir çevreyle etkileşim içerisinde ve doğru kararlar aldığı anda ödüllendirilir. Bu süreçte ağ, eylemlerini en uygun hale getirmeye çalışır (Jordan ve Mitchell, 2015).



Şekil 3.5. Öğrenme Yöntemleri Şeması (Haykin, 2009)

Bunların yanı sıra, öğrenme algoritmalarına göre de ayrı bir sınıflandırma yapılabilir. Örnek olarak, geri yayılım, Hebbian öğrenme, delta kuralı ve genetik algoritmalar sayılabilir. Bu algoritmalar, ağırlıkların güncelleme biçimlerini belirler (Haykin, 2009).

Öğrenme zamanlamasına göre YSA;

YSA öğrenmenin gerçekleştiği zamanlama da ağırlıkların dinamik özelliklerini belirleyen önemli bir faktördür. Bu bağlamda ağırlıklar, statik ve dinamik olmak üzere iki ana gruba ayrılır:

- Statik Öğrenme (Offline / Batch Learning): Tüm eğitim verisi önceden belirlenir ve öğrenme süreci bu veri kümesi üzerinde bir defada gerçekleştirilir. Öğrenme tamamlandıktan sonra ağırlıklar sabit kalır. Yeni veri geldiğinde model yeniden eğitilmelidir.
- Dinamik Öğrenme (Online / Incremental / Adaptive Learning): Ağ, gelen yeni veriye göre kendini sürekli güncelleyebilir. Bu yöntem, özellikle değişken ve zamana bağlı veri setleriyle çalışırken avantaj sağlar.

Her bir bağlantı, bir ağırlık değeri ile ilişkilidir ve bu ağırlıklar, ağırlık öğrenme sürecinde verilerden örüntüleri çıkarmak üzere ayarlanır. YSA'lar, özellikle doğrusal olmayan ve karmaşık ilişkileri modelleyebilme, büyük miktarda veriyi işleyebilme ve genelleme yapabilme yetenekleri sayesinde birçok tahmin probleminde, enerji tüketimi tahmini de dahil olmak üzere, başarılı sonuçlar vermektedir (Haykin, 2009).

Bu çalışmada, farklı YSA mimarilerinin (Tekrarlayan ve 1 Boyutlu Evrişimli Sinir Ağları) enerji tüketim tahminindeki performansları incelenmiştir. Bu

mimarilerin spesifik uygulama detayları ve eğitim süreçleri, "Bölüm 4: Uygulama" başlığı altında detaylandırılacaktır.

3.2.1.2. Kullanılan Derin Öğrenme Mimarileri(1D-CNN/GRU/FFNN/LSTM)

Elektrik tüketim zaman serileri; doğrusal olmayan (non-linear) karmaşık ilişkiler, uzun vadeli mevsimsel döngüler ve anlık yerel dalgalanmalar barındıran hibrit bir yapıya sahiptir. Bu nedenle çalışmada, zaman serisi problemlerinde kullanılan YSA tabanlı farklı derin öğrenme mimarileri incelenmiştir. Her bir mimari, zaman serisi verisindeki farklı türden bilgiyi yakalamak için özelleşmiş bir yapıya sahiptir. Bu çalışmada kullanılan YSA tabanlı derin öğrenme mimarileri, teknik türleri ile birlikte Çizelge 3.1'de özetlenmektedir.

Çizelge 3.1. Kullanılan derin öğrenme mimarileri

Model Adı	Ana Kategori	Türü
1D-CNN	Derin Öğrenme	Evrişimli Sinir Ağı (Convolutional Neural Network)
GRU	Derin Öğrenme	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
FFNN	Derin Öğrenme	İleri Beslemeli Sinir Ağları (Feedforward Neural Networks)
LSTM	Derin Öğrenme	Tekrarlayan Sinir Ağı (Recurrent Neural Network)

FFNN: Yapay Sinir Ağlarının en temel mimarisi olan İleri Beslemeli Sinir Ağları, bilgiyi katmanlar arasında, girişten çıkışa doğru tek yönlü bir akışla işler. Her bir katmandaki nöronlar bir sonraki katmandaki tüm nöronlara bağlıdır ve bu bağlantılar aracılığıyla verideki doğrusal olmayan ilişkileri modelleme yeteneğine sahiptir. Bu temel yapısı nedeniyle, zaman serisi analizinde karmaşık olmayan örüntüleri yakalamak için etkili bir temel model olarak kullanılmaktadır (Haykin, 2009).

LSTM: LSTM, özellikle zaman serisi verilerinde bulunan uzun vadeli bağımlılıkları öğrenmek üzere tasarlanmış, tekrarlayan sinir ağlarının (RNN) gelişmiş bir türüdür. Standart RNN'lerin uzun serilerde yaşadığı "kaybolan gradyan" problemini, sahip olduğu kapı mekanizmaları (unutma, giriş ve çıkış kapıları) sayesinde aşar. Bu kapılar, ağın hangi bilgiyi ne kadar süreyle hafızasında tutacağına ve ne zaman unutacağına karar vermesini sağlayarak, elektrik tüketimi gibi verilerdeki mevsimsel veya haftalık desenleri etkin bir şekilde modellemesine olanak tanır (Bişkin ve Çifci, 2021).

GRU: Tıpkı LSTM gibi, GRU da zaman serilerindeki bağımlılıkları modellemek için tasarlanmış bir tekrarlayan ağ mimarisidir. LSTM'in daha sadeleştirilmiş bir versiyonu olarak kabul edilen GRU, daha az kapı (güncelleme ve sıfırlama kapıları) kullanarak benzer bir performansı daha düşük hesaplama maliyetiyle sunmayı hedefler. Bu verimliliği, özellikle büyük veri setleriyle çalışılan enerji tahmini gibi uygulamalarda onu cazip bir alternatif haline getirmektedir (Bişkin ve Çifci, 2021).

1D-CNN: 1 Boyutlu Evrişimli Sinir Ağları, zaman serisi verisinden otomatik olarak hiyerarşik öznitelikler çıkarmak için kullanılan bir derin öğrenme modelidir. Bu mimari, zaman serisi üzerinde kayan evrişimli filtreler aracılığıyla, verinin farklı alt pencerelerindeki yerel kalıpları (örneğin, günün belirli saatlerinde tekrarlanan tüketim zirveleri) tespit eder. Bu sayede, modelin ham veriden doğrudan anlamlı desenler öğrenmesini ve bu desenleri tahmin için kullanmasını sağlar; bu da onu enerji tüketimi gibi sıralı verilerin analizi için güçlü bir araç yapar (Berus ve Benteşen Yakut, 2024).

3.2.2. Aşırı gradyan artırma (XGBoost-Extreme gradient boosting)


Enerji tüketimi gibi zaman serisi verilerinin tahmin edilmesinde, geleneksel yöntemlerin yanı sıra topluluk öğrenme (karar ağaçları gibi) tabanlı makine öğrenmesi algoritmaları da başarılı sonuçlar verebilmektedir. XGBoost algoritması, özellikle enerji piyasalarındaki doğrusal olmayan ve karmaşık veri desenlerini modelleyebilme konusunda öne çıkmaktadır (Tightiz vd., 2025). Bu kapsamda, bu çalışmada kullanılan XGBoost algoritması; karar ağaçları yapısına dayanan, ancak onu geliştiren ve performansı artıran bir topluluk (ensemble) yöntemidir. Bu çalışmada kullanılan XGBoost, gradyan artırma algoritmaları üzerine inşa edilmiş, ölçeklenebilir ve yüksek performanslı bir topluluk öğrenmesi yöntemidir. Tianqi Chen ve Carlos Guestrin tarafından sunulan orijinal çalışmada da vurgulandığı gibi, XGBoost'u geleneksel uygulamalardan ayıran en önemli özellikler, paralel işleme yeteneği ve aşırı öğrenmeyi önleyen düzenleme (regularization) mekanizmalarıdır (Chen ve Guestrin, 2016).

3.2.2.1. Karar Ağaçları (Decision Trees)

Karar ağaçları, veriyi belirli özelliklere göre dallara ayırarak sınıflandırma veya regresyon yapan, basitlikleri sayesinde yüksek yorumlanabilirlik sunan güçlü algoritmalar (Kobourov vd., 2025). Bir ağaç yapısında, her iç düğüm (internal node) bir girdi özelliğini test eden bir karar kuralı uygularken, bu kurala göre veri özyinelemeli

olarak alt gruplara ayrılır; bu süreç, verinin artık bölünemediği yaprak düğümlere (leaf nodes) ulaşana kadar devam eder (Kobourov vd., 2025). Bu yaprak düğümler, sınıflandırma problemlerinde bir sınıf etiketini, regresyon problemlerinde ise genellikle o yaprağa düşen veri örneklerinin ortalama hedef değerini temsil eder ve bu değer, o veri örneği için ağacın tahmini olur (Pedregosa vd., 2011).

Ancak tek bir karar ağacı, özellikle derinleştğinde, verideki gürültüyü ezberleyerek yüksek varyans gösterme ve aşırı öğrenme (overfitting) eğilimindedir, bu da modelin karmaşık ilişkileri genelleştirme yeteneğini sınırlar (Kobourov vd., 2025). Bu zayıflıkları azaltmak ve daha sağlam modeller oluşturmak için birden fazla ağacın tahminlerini birleştiren topluluk (ensemble) yöntemleri geliştirilmiştir. Bu yöntemler, tek bir ağacın bireysel hatalarını ve varyansını dengeleyerek daha yüksek doğruluk ve genelleme yeteneği sunar (Tightiz vd., 2025).



Şekil 3.6. Karar Ağaçları (Kobourov vd., 2025)


3.2.2.2. Torbalımalı öğrenme (Bagging)

Karar ağaçlarının bu yüksek varyans sorununu çözmek için geliştirilen ilk ve en temel topluluk yöntemlerinden birisi Torbalımalı öğrenmedir. Bu yöntem iki temel adımdan oluşur. Varolan veriyi alt verilere bölerek ya da ayırır ve alt veri setine dönüştürür. Oluşan veri setlerine karşılık bir model oluşur. Şekil 3.7’de görüldüğü üzere birbirlerine paralel hareket ederler, bu da birbirlerinden bağımsız hareket ettikleri anlamına gelir. Yani bir ağacın aşırı kötü tahmin yapması durumunda diğer ağaçların yapacağı iyi tahmin kötü yapılan tahminin etkisinin daha az olması adına faydalı olabileceği gibi, yine de bu durum tüm modelin varyansını düşürebilmektedir. Buna göre Torbalama yönteminin özelliklerini incelediğimizde;

Her model birbirinden bağımsızdır.

1. Orijinal veri setinden rastgele ve yerine koyma yöntemiyle (bootstrap) çok sayıda alt örneklem oluşturulur.
2. Her örneklem üzerinde birbirileri arasında bağımlı olmadan karar ağacı eğitilir.
3. Tahmin aşamasında, tüm bu paralel ağaçların tahminlerinin ortalaması alınarak nihai sonuç elde edilir (Breiman, 1996).

Bu yaklaşımın en bilinen uygulaması olan Rastgele Orman (Random Forest) algoritması, ek olarak her bir ağacın her bir dalında tüm özellikler yerine özelliklerin rastgele bir alt kümesini kullanarak ağaçlar arasındaki benzerliği daha da azaltır ve modelin genelleme yeteneğini artırır (Breiman, 2001).



Şekil 3.7. Torbalı öğrenme (Random Forest) (Breiman, 1996)

3.2.2.3. XGBoost

Torbalı öğrenmenin ağaçları birbirinden bağımsız olarak paralel şekilde eğittiği yaklaşımdan farklı olarak, Pekiştirmeli Öğrenme (boosting) adı verilen bir diğer topluluk stratejisi, modelleri ardışık bir sıra ile oluşturur. Bu felsefede her bir model, kendisinden önce gelen modellerin yaptığı hataları düzeltmeye odaklanır (Chen ve Guestrin, 2016).

Şekil 3.7’de gösterildiği gibi XGBoost’un temel çalışma prensibi, zayıf bir modelle başlayıp, her adımda modelin tahmin edemediği kalan hataları (residuals) tahmin etmek üzere yeni bir ağaç eklemektir. Bu sayede model, iteratif olarak kendini iyileştirir. Chen ve ark. tarafından sunulan XGBoost’un temel optimizasyonlar şunlardır:


1. Düzenleştirme (Regularization): Standart gradyan artırma algoritmalarından farklı olarak, modelin ezber yapmasını (aşırı öğrenme) engellemek için kayıp

fonksiyonuna L1 (lasso) ve L2 (ridge) düzenleme terimleri ekler. Bu, model karmaşıklığını cezalandırarak daha sade ve genellenebilir modeller oluşturulmasını sağlar.

2. Akıllı Ağaç Budama: Sadece ağaç derinliğini sınırlamakla kalmaz, aynı zamanda bir dalın modele getireceği faydayı (gamma parametresi) da hesaba katarak gereksiz dallanmaların önüne geçer.
3. Eksik Veri Yönetimi: Eksik veriler için önceden bir doldurma işlemi gerektirmez; bunun yerine, eğitim sırasında eksik değerler için en uygun yolu kendi kendine öğrenerek veri ön işleme sürecini kolaylaştırır.
4. Paralel ve Ölçeklenebilir Yapı: Algoritma, hesaplama verimliliğini artırmak için modern işlemcilerin paralel hesaplama gücünden yararlanacak şekilde tasarlanmıştır.
5. Dahili Çapraz Doğrulama: Eğitim sırasında en uygun ağaç sayısını belirlemek için dahili bir çapraz doğrulama mekanizması sunar ve bu da modelin aşırı öğrenmesini engellemeye yardımcı olur (Chen ve Guestrin, 2016).

Enerji tahmini probleminde XGBoost, takvim özellikleri (günün saati, tatil günleri vb.) ve gecikme değerleri gibi özelliklerle beslendiğinde, doğrusal olmayan karmaşık ilişkileri yakalama ve yüksek doğrulukta tahminler üretme potansiyeli nedeniyle bu çalışmanın önemli bir bileşeni olarak seçilmiştir. XGBoost'un güçlü yönlerinin yanı sıra dengesiz veri kümelerinde birçok sınıfın öğrenmeye eğilimli olma gibi durumu da bulunmaktadır. Bu durum, modelin nadir görülen ancak kritik olan azınlık sınıflarını tespit etme performansını düşürebilir (Burez ve Van den Poel, 2009).

Bu durum, modelin nadir görülen ancak kritik olan azınlık sınıflarını tespit etme performansını düşürebilir (Burez ve Van den Poel, 2009).



Şekil 3.8. Xgboost(Boosting) (Chen ve Guestrin, 2016)

3.3. Veri Seti Hazırlığı ve Ön İşleme

Geliştirilen tahmin modellerinin başarısı, kullanılan ham verinin kalitesine ve algoritmaların matematiksel yapısına uygun olarak hazırlanma biçimine bağlıdır. Bu çalışmada, ham verinin modern makine öğrenmesi algoritmaları tarafından etkin bir şekilde kullanılabilmesi için kapsamlı bir ön işleme süreci uygulanmıştır. Bu süreç, zaman serisi problemini bir gözetimli öğrenme (supervised learning) problemine dönüştürmeyi amaçlamaktadır (Hyndman ve Athanasopoulos, 2021).

Veri seti üzerinde gerçekleştirilen yapısal düzenleme, veri temizleme ve normalizasyon adımları aşağıda detaylandırılmıştır:

3.3.1. Veri temizleme ve yapısal düzenleme

Veri hazırlık sürecinin ilk adımında, ham veriler zaman serisi analizine uygun hale getirilmiştir. Veri setinde ayrı sütunlarda bulunan tarih ve saat bilgileri birleştirilmiş ve tüm veriler tarihsel olarak sıraya dizilmiştir. Böylece verinin zaman akışı (kronolojisi) sağlanarak analiz için gerekli yapısal bütünlük oluşturulmuştur.

Veri setindeki eksik (boş) kayıtlar incelendiğinde, bu boşlukları ortalama alma veya benzeri yapay yöntemlerle doldurmanın (imputasyon), verinin orijinalliğini bozabileceği ve modelde istatistiksel yanlılık (bias) yaratabileceği için modelin sadece %100 gerçek piyasa verileriyle eğitilmesi hedeflendiği için, eksik veriye sahip satırlar analiz dışı bırakılmıştır.

Ayrıca, enerji tüketim verilerinde zaman zaman görülen ani yükselişler ve düşüşler (uç değerler) üzerinde herhangi bir düzeltme veya silme işlemi yapılmamıştır. İstatistiksel olarak "aykırı" gibi görünse de bu değerler, enerji piyasasındaki gerçek talep değişimlerini yansıtmaktadır. Modellerin sadece normal günleri değil, bu tür kriz veya yoğunluk anlarını da doğru tahmin edebilmesi amaçlandığı için bu değerler veri setinde olduğu gibi korunmuştur (Nebati vd., 2021).

3.3.2. Veri dönüştürme ve değişken türetimi

Modelin, verinin altında yatan zamansal dinamikleri ve kalıpları öğrenebilmesi amacıyla, her bir saatlik tüketim değerini (y) tahmin etmek için kullanılacak bir girdi özellikleri matrisi (X) oluşturulmuştur. Bu matrisin oluşturulma mantığı ve toplam 42 özelliğin dağılımı aşağıda detaylandırılmıştır:

1. Gecikmeli Tüketim Değerleri (24 Özellik): Serinin kısa vadeli momentumunu ve günlük mevsimselliğini yakalamak için, tahmin yapılacak zamandan önceki 24 saatin tüketim değerleri özellik olarak eklenmiştir (Christ vd., 2018).
2. Gecikmeli Döngüsel Zaman Özellikleri (16 Özellik): İlk olarak, günün saati ve haftanın günü için sinüs ve kosinüs dönüşümleriyle anlık 4 adet döngüsel özellik oluşturulmuştur. Daha sonra, bu 4 özelliğin her birinin geçmiş 1, 2, 3 ve 4 saatlik değerleri alınarak (4 saat x 4 özellik) toplam 16 adet gecikmeli döngüsel özellik türetilmiştir (Hyndman ve Athanasopoulos, 2021).

3. Yuvarlanan Ortalamalar (2 Özellik): Serideki yerel trendleri ve gürültüyü yumuşatmak amacıyla, son 6 ve 24 saatlik tüketim değerlerinin hareketli ortalamaları hesaplanarak özellik setine eklenmiştir (Christ vd., 2018).

Bu üç grubun birleştirilmesiyle ($24 + 16 + 2$), her bir zaman adımı için modelleri besleyecek toplam 42 adet özellik oluşturulmuştur.

3.3.3. Model değerlendirme ve veri bölme

Modellerin güvenilir, tarafsız ve tekrar edilebilir sonuçlar üretebilmesi için bilimsel standartlara uygun, üç aşamalı bir eğitim ve değerlendirme stratejisi izlenmiştir. Makine öğrenmesi literatüründe standart olan bu yaklaşım zaman serisi verilerinin sıralı doğası gereği rastgele karıştırılarak değil, kronolojik bloklar halinde uygulanmıştır (Hastie vd., 2009).

Özellik mühendisliği uygulanmış veri seti, kronolojik olarak üç ana parçaya ayrılmıştır:

1. Eğitim Seti (Train Set - %70): Modelin, verideki temel kalıpları, ilişkileri ve mevsimselliği bu set üzerinden öğrendiği bölümdür.
2. Doğrulama Seti (Validation Set - %15): Bu set, modelin eğitim sırasında genelleme performansını izlemek için kullanılır. Modelin eğitim seti üzerindeki performansı ile doğrulama seti üzerindeki performansı arasındaki fark, aşırı öğrenmenin ilk işaretlerini verir.
3. Test Seti (%15): Bu set, model eğitimi tamamlandıktan sonra, aşırı öğrenip öğrenmediğinin nihai teyidini yapmak ve tamamen görünmeyen verilerdeki tarafsız performansını ölçmek için kullanılır. Doğrulama ve test setleri arasındaki performans farkı, modelin genelleme yeteneğinin en somut göstergesidir.

3.3.4. Normalizasyon

Derin öğrenme modellerinde, ağ ağırlıklarını güncellemek ve hatayı minimize etmek için stokastik gradyan inişi (SGD) ve türevleri (Adam, RMSProp vb.) gibi optimizasyon algoritmalarını kullanır. Girdi değişkenlerinin farklı ölçeklerde olması (örneğin; fiyat verisi 2000 TL civarındayken, sıcaklık verisinin 20°C olması), hata fonksiyonunun yüzeyinde (error surface) eliptik ve dengesiz bir geometriye yol açar. Bu durum, gradyanların optimum noktaya ilerlerken zikzaklar çizmesine (salınım

yapmasına) ve modelin yakınsama hızının ciddi şekilde düşmesine neden olur (Goodfellow vd., 2016).

Bu optimizasyon problemini gidermek ve tüm özniteliklerin model üzerindeki etkisini dengelemek amacıyla, veriler Min-Max Normalizasyonu yöntemiyle aralığına lineer olarak dönüştürülmüştür. Uygulanan dönüşüm 3.1'te gösterilmiştir:

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

Burada X ham veriyi; X_{min} ve X_{max} ise ilgili verinin minimum ve maksimum değerlerini temsil eder. Veri sızıntısını önlemek adına, bu istatistikler X_{min} ve X_{max} sadece eğitim seti üzerinden hesaplanmış; doğrulama ve test setleri bu parametreler kullanılarak dönüştürülmüştür (Haykin, 2009).

Karar ağacı tabanlı bir topluluk öğrenme algoritması olan XGBoost, verilerin mutlak sayısal büyüklüğünden ziyade, veri setindeki sıralama ve kesme noktalarına (split points) odaklanmaktadır. Algoritmanın düğüm bölme mekanizması, öznitelik değerlerini belirli bir eşik değeri ile kıyaslayan eşitsizlik koşullarına dayanır. Veriye uygulanan monotonik bir dönüşüm (ölçekleme), verilerin birbirine göre sıralamasını değiştirmeyeceğinden, ağacın yapısal bütünlüğü ve bölme noktalarının işlevi korunur. Bu nedenle, ağaç tabanlı algoritmalar girdilerin ölçeğinden bağımsız (scale-invariant) bir yapı sergiler (Chen ve Guestrin, 2016).

3.3.5. Aşırı öğrenme (overfitting) tespiti ve erken durdurma (early stopping)

Derin öğrenme ve makine öğrenmesi modellerinin eğitim süreçlerinde karşılaşılan en kritik sorunlardan biri aşırı öğrenme durumudur. Bu senaryoda model, eğitim verisini ezberlemeye başlar ancak yeni gelen verilerde başarısız olur. Bu problemi engellemek ve modelin genelleme yeteneğini korumak amacıyla, çalışmada kullanılan tüm modellerde "Erken Durdurma" mekanizması uygulanmıştır (Goodfellow vd., 2016).

Bu mekanizma, modelin eğitim süresini sabit bir adım sayısında tutmak yerine, modelin performansına göre dinamik olarak belirler. Çalışmada uygulanan strateji, aşağıdaki iki temel kurala dayanır:

Sabır (Patience = 10): Modelin doğrulama setindeki hatasının iyileşmemesine kaç adım boyunca tahammül edileceğini belirleyen eşik değeridir. Tüm modeller için bu değer 10 olarak belirlenmiştir. Yani, 10 adım boyunca performans iyileşmesi sağlanamazsa eğitim durdurulur.

En İyi Ağırlıkları Geri Yükleme: Eğitim durdurulduğunda, modelin en son halini değil, eğitim boyunca elde edilen en düşük hataya sahip en başarılı halini kaydetmesini sağlar.

Mekanizmanın çalışma mantığı ise sistem, her eğitim adımı sonunda doğrulama hatasını izler. Örneğin, bir modelin eğitiminde 104. adımda en iyi skor elde edilmiş, takip eden 10 adım boyunca (114. adıma kadar) daha iyi bir sonuç alınamamıştır. Sabır süresi dolduğunda eğitim otomatik olarak durdurulmuş ve model, aşırı öğrenme riskine karşı en başarılı olduğu 104. adımdaki parametrelerine döndürülerek kaydedilmiştir.

3.4. Model Mimarisi ve Hiperparametrelerin Belirlenmesi

Bu çalışmada model parametrelerinin belirlenmesinde iki temel hedef gözetilmiştir: Birincisi, modelin elektrik tüketim verisindeki karmaşık ve doğrusal olmayan ilişkileri öğrenebilme kapasitesini (learning capacity) artırmak; ikincisi ise bir önceki bölümde değinilen aşırı öğrenme riskini kontrol altında tutarak modelin genelleme yeteneğini korumaktır.

Bu doğrultuda, kullanılan hiper parametreler rastgele seçilmemiş; enerji tahmini literatüründeki benzer çalışmalarda başarılı sonuç verdiği raporlanan değerler ve en iyi uygulama (best practice) örnekleri referans alınmıştır. Belirlenen bu başlangıç parametreleri üzerinde "Deneme-Yanılma" (Trial-and-Error) yöntemi uygulanmış ve doğrulama seti performansına göre modelin en kararlı (stabil) sonuçları ürettiği nihai yapılandırmalar oluşturulmuştur.

3.4.1. XGBoost modeli parametreleri

XGBoost modelinde, tahmin hassasiyetini artırmak ve modelin varyansını düşürmek amacıyla stratejik bir parametre optimizasyonu yapılmıştır. Seçilen değerler ve teknik gerekçeleri şöyledir (Chen ve Guestrin, 2016):

Maksimum Derinlik (Max Depth = 5): Ağaçların karmaşıklığını belirler. Aşırı öğrenme ile eksik öğrenme arasındaki dengeyi gözeterek, gürültüleri ezberlemeyen ancak karmaşık ilişkileri yakalayabilen optimum derinlik tercih edilmiştir.

Öğrenme Oranı (Learning Rate = 0,02): Modelin her iterasyonda ağırlıkları ne kadar güncelleyeceğini belirler. Düşük oran, daha yavaş ama daha kararlı bir öğrenme süreci sağlar.

Ağaç Sayısı ($n_{\text{estimators}} = 1000$): Düşük öğrenme oranı tercih edildiği için yüksek iterasyon sayısı tanımlanmış, ancak bu sayı erken durdurma mekanizması ile dinamik olarak sınırlandırılmıştır.

Alt Örnekleme (Subsample = 0,7): Her ağaç oluşturulurken veri setinin %70'inin rastgele seçilmesi sağlanarak modelin varyansı düşürülmüştür.

3.4.2. Derin öğrenme modelleri mimarisi

FFNN, 1D-CNN ve tekrarlayan mimariler olan LSTM ve GRU modellerinin mimari yapısı, giriş verisinin boyutu (42 öznitelik) dikkate alınarak oluşturulmuştur. Ağ yapısında genellikle katmanlar ilerledikçe nöron sayısının azaldığı "Piramit Yaklaşımı" (Örn: 128 -> 64) izlenmiştir (Haykin, 2009).

Derin öğrenme modellerinin eğitim sürecinde, ağ ağırlıklarının güncellenmesi için Adam (Adaptive Moment Estimation) optimizasyon algoritması tercih edilmiştir. Adam, her bir parametre için öğrenme hızını dinamik olarak ayarlayabilme yeteneğine sahiptir. Gürültülü ve değişken elektrik tüketim verilerinde, gradyanların salınımını sönümleyerek klasik yöntemlere göre daha hızlı ve kararlı bir yakınsama sağlar (Kingma ve Ba, 2017).

Kayıp fonksiyonu olarak ise Ortalama Kare Hata (MSE) kullanılmıştır. MSE, büyük hataları karesini alarak (örneğin ani pikleri ıskalamay) çok daha şiddetli cezalandırır. Bu özellik, enerji piyasasındaki maliyet risklerini minimize etme stratejisiyle tam bir uyum gösterdiği için tercih edilmiştir (Goodfellow vd., 2016).

Modellerin nihai yapılandırılmaları Çizelge 3.2'de özetlenmiştir.

Çizelge 3.2. Modellerin hiperparametre yapılandırılmaları

Model	Katman/Nöron Sayıları	Aktivasyon Fonksiyonu	Optimizasyon / Kayıp Fonk.
XGBoost	Ağaç Sayısı: 1000, Derinlik: 5	Yok(Karar Ağacı Yapısı)	Squared Error
FFNN	2 Gizli Katman (128, 64 Nöron)	ReLU	Adam / MSE
GRU	2 GRU Katmanı (100, 50 Ünite)	Tanh	Adam / MSE
LSTM	2 LSTM Katmanı (100, 50 Ünite)	Tanh	Adam / MSE
1D-CNN	64 Filtre - MaxPool - 50 Nöron	ReLU	Adam / MSE

3.5. Model Performans Kriterleri

Tüm modellerin tahmin başarısı aşağıdaki istatistiksel ölçütler kullanılarak değerlendirilmiştir:

- Kök Ortalama Kare Hata (RMSE)
- Ortalama Mutlak Hata (MAE)
- Ortalama Mutlak Yüzde Hata (MAPE)
- Belirlilik Katsayısı (R^2)
- Dengesizlik Maliyet Analizi

Bu çalışmada bulunan tahmin modellerinin başarısını ve nasıl sonuçlar verdiğini objektif olarak değerlendirmek için istatistiksel ölçütler belirlemiştir. Bir modelin performansını ölçmek için sadece tahminlerin gerçekleşen değerlere ne kadar yakın veya uzak olduğunu belirleyerek hareket etmek doğru bir sonuç vermez. İstatistiksel ölçütler bu noktada sayısal verilerle karşılaştırılarak doğru bir yorumlama kolaylığı sağlamış olur. Enerji tüketimi gibi doğrusal olmayan zaman serilerinin tahmin performansını değerlendirmek için, her biri farklı hata karakteristiklerine odaklanan birden fazla metriğin birlikte kullanılması gerekmektedir. Bu çalışmada modellerin performansını çok yönlü bir şekilde analiz etmek amacıyla, literatürde zaman serisi tahminleme problemleri için birbirini tamamlayıcı nitelikte olan dört temel ölçüt kullanılmıştır. Bu kriterlerin seçimi, modellerin hem ortalama hata miktarını, hem büyük hatalara karşı hassasiyetini, hem de ölçek-bağımsız başarısını bir arada değerlendirmek için yapılmıştır (Hyndman ve Athanasopoulos, 2021).

3.5.1. Kök ortalama kare hata (Root mean squared error - RMSE)

RMSE, tahmin edilen hataların karesinin ortalamasının karekökü alınarak hesaplanmaktadır. RMSE, tahmin hatalarının standart sapmasına karşılık gelir ve büyük hatalara daha fazla ağırlık verdiği için enerji piyasasındaki aşırı sapmaların tespitinde özellikle önemlidir.

Matematiksel olarak aşağıdaki denklem ile formüle edilir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.2)$$

RMSE, hata terimlerinin karesini aldığı için büyük hataları orantısız şekilde cezalandırır. Enerji tahminlerinde arz-talep dengesinin kritik önemi nedeniyle, büyük tahmin hataları küçük hatalardan daha maliyetli ve risklidir. Bu nedenle RMSE, enerji tahmini çalışmalarında önemli bir performans metriğidir.

3.5.2. Ortalama mutlak hata (Mean absolute error - MAE)

MAE, tahmin edilen değerler ile gerçekleşen değerler arasındaki mutlak farkın ortalamasıdır.

Matematiksel olarak aşağıdaki denklem ile formüle edilir:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.3)$$

Burada:

1. n , toplam gözlem (tahmin) sayısıdır.
2. y_i , i 'inci zaman dilimindeki gerçekleşen değerdir.
3. $\hat{y}_i$, i 'inci zamanda model ile tahmin edilen değerdir.

MAE, yapılan tahmin değeri ile gerçekleşen değer aynı birimde olması anlaşılabilirlik açısından kolaylık sağlar. MAE, tahmin hatasının mutlak büyüklüğünü doğrudan ölçer ve yorumlaması kolaydır.

3.5.3. Ortalama mutlak yüzdesel hata (MAPE)

MAPE, hataların gerçekleşen değerlere oranlanmasıyla elde edilen yüzdesel bir ölçüttür. Bu metrik, hatanın büyüklüğünü mutlak bir değer olarak değil, gerçekleşen değere kıyasla göreceli bir büyüklük olarak ifade eder.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3.4)$$

MAPE'nin avantajlarından biri ölçek bağımsız olmasıdır. Sonuç yüzde cinsinden olduğu için, farklı büyüklüklerdeki zaman serilerinin tahmin performanslarını veya farklı modelleri karşılaştırmak için ortak alan yaratmış olur. Bu yüzden de anlaşılabilirliği yüksektir.

Ancak, MAPE'nin avantajı olduğu gibi dezavantajı da vardır. Sıfır veya sıfıra çok yakın gerçekleşen değerler (y_i) olduğunda formülün paydasının tanımsız hale gelmesi gibi bir dezavantajı vardır. Enerji tüketimi gibi verilerde bu durumla karşılaşılmasa da, bu ölçütün dikkatli kullanılması gerekir.

3.5.4. Belirlilik katsayısı (Coefficient of determination – R^2)

R^2 olarak bilinen bu katsayı, bir hata ölçütü değil bir "uyum iyiliği" (goodness-of-fit) ölçüsüdür. Bağımlı değişkendeki (enerji tüketimi) varyansın, model tarafından ne kadarının açıklanabildiğini gösterir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.5)$$

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

R^2 , 0 ile 1 arasında bir değer alır ve 1'e yakın bir değer, modelin verideki değişimin büyük bir kısmını açıkladığını gösterirken, 0'a yakın bir değer modelin basit bir ortalama tahmininden daha iyi performans göstermediğini ifade eder. Bu metrik, modelin sadece hata miktarını değil, aynı zamanda verinin genel eğilim ve yapısını ne kadar başarıyla yakaladığına hakkında bir fikir verir. Bu çalışmada, diğer hata metriklerini destekleyici ve modelin açıklama gücünü özetleyici bir rol oynamaktadır (Hyndman ve Athanasopoulos, 2021).

3.5.5. Dengesizlik maliyet analizi

Bu çalışmada, geliştirilen tahmin modellerinin istatistiksel doğruluğunun ötesinde, pratik ve finansal performanslarını da ölçmek amacıyla, Türkiye enerji piyasasındaki gerçek dengesizlik uzlaştırma mekanizmasını temel alan bir maliyet analizi metodolojisi oluşturulmuştur. Bu analiz, her bir modelin tahmin hatasının, piyasa katılımcıları için ne kadarlık bir dengesizlik maliyeti veya gelir kaybı oluşturduğunu simüle etmeyi amaçlamaktadır. Analizlerde kullanılan saatlik PTF ve SMF verileri, Türkiye enerji piyasasının resmi işletmecisi olan Enerji Piyasaları İşletme A.Ş.'nin (EPIAŞ) halka açık Şeffaflık Platformu'ndan (Enerji Piyasaları İşletme A.Ş., 2025) temin edilmiştir.

Türkiye elektrik piyasasında enerji tedarik süreci, büyük ölçüde Gün Öncesi Piyasası'nda (GÖP) yapılan planlamalara dayanır. Piyasa katılımcıları, bir gün öncesinden, ertesi günün her bir saati için ihtiyaç duyacakları enerji miktarını tahmin ederek GÖP'te Piyasa Takas Fiyatı (PTF) üzerinden alım yaparlar. Ancak, tahmin edilen tüketim ile gerçekleşen tüketim arasındaki sapmalar, sistemde bir dengesizlik yaratır ve

bu dengesizlikler, Dengeleme Güç Piyasası'nın (DGP) dinamiklerine göre finansal olarak uzlaştırılır.

Bu çalışmada, her bir modelin test seti için ürettiği saatlik tahminler, bir piyasa katılımcısının GÖP'ten aldığı enerji miktarı olarak kabul edilmiştir. Gerçekleşen tüketimle karşılaştırılarak ortaya çıkan "enerji açığı" (pozitif dengesizlik) veya "enerji fazlası" (negatif dengesizlik) durumları, EPIAŞ tarafından uygulanan uzlaştırma formüllerine göre maliyetlendirilmiştir. İlgili saatin Sistem Marjinal Fiyatı (SMF) da dikkate alınarak, dengesizlikten kaynaklanan finansal etki aşağıdaki gibi hesaplanmıştır:

Elektrik piyasasında alınması gereken enerji ihtiyacı gün öncesi piyasasından 24 saatlik olarak PTF ile alınmaktadır. Ertesi gün gerçekleşmelerine bakılarak enerji açığı veya fazlası olması durumları tespit edilmektedir. Bu durumda EPDK(Enerji Piyasası Düzenleme Kurumu) tarafından belirlenen yönetmelik gereği oluşan dengesizlikler için sistem aşağıdaki formüle göre işlemektedir (Enerji Piyasası Düzenleme Kurumu, 2025).

Enerji açığı olması durumunda:

$$Maliyet = Maksimum(PTF, SMF) \times 1,03 \times Enerji \text{ Açığı}(mWh) \quad (3.6)$$

Enerji fazlası olması durumunda:

$$Maliyet = Minimum(PTF, SMF) \times 0,97 \times Enerji \text{ Fazlası}(mWh) \quad (3.7)$$

Bu durumda toplam maliyet, gerçekleşen tüketim ve fazla veya eksik alınan farkın toplanıp ya da çıkarılması ile oluşmaktadır. Bu çalışmada yapılan tahminlerin ardından oluşacak sonuçların tamamı için hesaplamalar somutlaştırılarak sayısal sonuçlar bölüm 4.3'te uygulanarak maliyet olarak etkisi hesaplanacaktır.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, enerji tüketim tahmini için kullanılan yöntemlerin uygulama detayları ve performans sonuçları sunulurken hem istatistiksel hem de finansal açıdan en optimum modelin belirlenmesi amaçlanmaktadır.

Çalışmada kullanılan tüketim verileri, 23.05.2022-29.04.2025 tarihleri arasında 24 saatlik periyotlarla ölçülen gerçek tüketim değerlerini içermektedir. Toplam 25.752 adet saatlik tüketim verisi analiz edilmiş olup, zamansal bağımlılıkları modelleyebilmek için haftanın günleri de veri setine eklenmiştir.

Ham verinin doğrusal olmayan bir zaman serisi yapısına sahip olduğu gözlemlenmiştir. Modellerin karşılaştırılması, bu karmaşık yapı içerisinde hangi yaklaşımın daha etkin ve doğru tahminler üretebildiğini ortaya koymak amacıyla gerçekleştirilmiştir. İncelenen modeller Çizelge 4.1'de özetlenmektedir.

Çizelge 4.1. Modeller

Model Adı	Ana Kategori	Türü
1D-CNN	Derin Öğrenme	Evrişimli Sinir Ağı (Convolutional Neural Network)
GRU	Derin Öğrenme	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
FFNN	Derin Öğrenme	İleri Beslemeli Sinir Ağları (Feedforward Neural Networks)
LSTM	Derin Öğrenme	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
Xgboost	Makine Öğrenmesi	Gradyan Artırma / Ağaç Tabanlı Model

Makine öğrenmesi ve derin öğrenme tabanlı modellerin (XGBoost, 1D-CNN, GRU, LSTM, FFNN) eğitimi için, her bir tahmin adımında kullanılmak üzere toplam 42 adet özellik (girdi değişkeni) mühendisliği uygulanmıştır. Bu özelliklerin dağılımı ve mantığı aşağıda detaylandırılmıştır:

- **Gecikmeli Tüketim Değerleri (24 Özellik):** Serinin kısa vadeli momentumunu ve günlük mevsimselliğini yakalamak amacıyla, tahmin yapılacak saatten önceki 24 saate ait tüketim değerleri özellik olarak kullanılmıştır.
- **Gecikmeli Döngüsel Takvim Özellikleri (16 Özellik):** Zamanın döngüsel yapısını (saat/gün) sinüs ve kosinüs dönüşümleriyle temsil eden 4 temel özelliğin, geçmiş 4 saatlik penceredeki değerleri alınarak 16 adet ek özellik türetilmiştir.

- Kayma Penceresi Özellikleri (2 Özellik): Serinin yerel eğilimini yansıtmak ve gürültüyü azaltmak amacıyla, son 6 ve 24 saatlik tüketim değerlerinin hareketli ortalamaları hesaplanmıştır.

4.1. Makine Öğrenmesi ve Derin Öğrenme Modellerinin Sonuçları

Bu bölümde, geliştirilen her bir modelin doğrulama ve test veri kümeleri üzerindeki performans metrikleri ayrı ayrı sunulmakta ve model davranışları detaylandırılmaktadır.

4.1.1. XGBoost modeli sonuçları

Gradyan artırma tekniğine dayanan XGBoost modeli, yüksek tahmin doğruluğu olan modeldir. Modelin, test seti üzerindeki nihai performans metrikleri aşağıda özetlenmiştir:


- RMSE: 29,94
- MAE: 19,18
- MAPE: %1,78
- R^2 Skoru: 0,9851

Bu sonuçlar, modelin son derece yüksek bir tahmin doğruluğuna ulaştığını göstermektedir. 29,94'lük RMSE değeri, modelin tahminlerinin ortalama olarak gerçekleşen değerlerden 27,94 mWh kadar saptığını ifade ederken, %1,78 gibi düşük bir MAPE değeri, oransal hatanın ne kadar küçük olduğunu ortaya koymaktadır. Özellikle 0,9851'lik R^2 Skoru, modelin, test verisindeki toplam değişkenliğin %98,5 gibi çok büyük bir kısmını başarıyla açıkladığının en güçlü kanıtıdır.


Şekil 4.1'de sunulan regresyon grafiği, tahmin edilen değerler ile gerçek değerlerin 45 derecelik referans çizgisi etrafında yoğun bir şekilde kümelenmiş olduğunu göstermektedir. Bu görsel bulgu, modelin tahminlerinin gerçek değerlerle yüksek düzeyde bir korelasyona sahip olduğunu ve tutarlı tahminler ürettiğini doğrulamaktadır.

Şekil 4.2'de yer alan hata histogramı incelendiğinde, artıkların sıfır etrafında simetrik bir şekilde toplandığı ve normal dağılıma yakın bir yapı sergilediği görülmektedir. En yüksek frekansa sahip hata değerlerinin sıfıra yakın bölgede yoğunlaşması ve büyük mutlak hata değerlerinin frekansının giderek azalması, modelin sistematik bir yanlılıktan uzak olduğunu ve genel olarak gerçek değerlere yakın tahminler ürettiğini göstermektedir.


Son olarak Şekil 4.3'te bulunan artıkların zaman içindeki dağılımı grafiği incelendiğinde, artıkların sıfır çizgisi etrafında belirli bir örüntü veya sistematik bir yapı oluşturmaktan rastgele bir şekilde dağıldığı görülmektedir. Hata terimlerinin varyansının zaman içinde sabit kalması ve herhangi bir döngüsel desen içermemesi, modelin verideki temel zaman serisi dinamiklerini ve mevsimselliği başarıyla yakaladığının önemli bir göstergesidir. Bu durum, geriye kalan artıkların büyük ölçüde tahmin edilemeyen rastgele gürültüden oluştuğuna işaret etmektedir.



Şekil 4.1. Xgboost Regresyon Grafiği



Şekil 4.2. Xgboost Hata Histogramı



Şekil 4.3. Xgboost Artıkların Zaman İçinde Dağılımı

4.1.2. 1D-CNN modeli sonuçları

Evrişimli Sinir Ağı mimarisine dayanan 1D-CNN modeli, XGBoost'a oldukça yakın, rekabetçi bir performans sergilemiştir. Modelin test seti üzerindeki nihai performans metrikleri aşağıda özetlenmiştir:

- RMSE: 29,08
- MAE: 21,41
- MAPE: %1,99
- R^2 Skoru: 0,9839


Bu sonuçlar, 1D-CNN modelinin de son derece başarılı olduğunu doğrulamaktadır. 29,08 RMSE değeri, XGBoost'tan marjinal olarak daha yüksek olsa da hala çok düşük bir hata seviyesini temsil etmektedir. %1,99'luk MAPE değeri de oransal hatanın %2'nin altında kalarak modelin yüksek doğruluğunu teyit etmektedir. 0,9839'luk R^2 Skoru ise, modelin test verisindeki değişkenliğin %98,39'unu başarıyla açıkladığını göstermektedir. Bu bulgular, CNN mimarisinin, oluşturulan sıralı özellikler (özellikle gecikme değerleri) arasındaki yerel kalıpları ve kısa vadeli bağımlılıkları yakalamada ne kadar etkili olduğunun bir kanıtıdır.

Şekil 4.4'te sunulan Regresyon Grafiği, tahmin edilen ve gerçek değerler arasındaki ilişkiyi göstermektedir. Grafikteki noktaların $R = 0,9839$ gibi çok yüksek bir korelasyon katsayısıyla, 45 derecelik referans çizgisi etrafında sıkı bir şekilde kümелendiği görülmektedir. Bu, modelin tahminlerinin gerçek değerlerle son derece tutarlı olduğunun güçlü bir görsel kanıtıdır.


Modelin hata dağılımı ise Şekil 4.5'te sunulan Hata Histogramı ile incelenmiştir. Artıkların sıfır etrafında merkezlenmiş ve çan eğrisine benzer bir normal dağılım

sergilediği görülmektedir. En sık rastlanan hata değerlerinin sıfıra yakın olması modelin genel olarak isabetli tahminler yaptığını teyit eder.


Şekil 4.6, Artıkların Zaman İçindeki Dağılımı'nı göstermektedir. Bu grafikte, hataların zaman eksenini boyunca sıfır çizgisi etrafında belirgin bir örüntü veya mevsimsel bir yapı oluşturmadan, rastgele bir şekilde dağıldığı (homoscedasticity) ortaya koyulmuştur. Bu durum, modelin verideki zamansal dinamikleri başarıyla yakaladığını ve geriye sadece tahmin edilemeyen rastgele gürültü bıraktığını göstermektedir.



Şekil 4.4. 1D-CNN Regresyon Grafiği



Şekil 4.5. 1D-CNN Hata Histogramı



Şekil 4.6. 1D-CNN Artıkların Zaman İçinde Dağılımı

4.1.3. FFNN modeli sonuçları

İleri Beslemeli YSA (FFNN) mimarisi, bu çalışmada kullanılan en temel derin öğrenme yaklaşımı olmasına rağmen, son derece başarılı ve stabil sonuçlar üretmiştir. Modelin test seti üzerindeki nihai performans metrikleri aşağıda özetlenmiştir:


- RMSE: 32,48
- MAE: 24,17
- MAPE: %2,26
- R^2 Skoru: 0,9799

Bu sonuçlar, FFNN modelinin yüksek bir tahmin doğruluğuna ulaştığını göstermektedir. 0,9799'luk R^2 Skoru, modelin test verisindeki toplam değişkenliğin %97,99'unu başarıyla açıkladığını ortaya koymaktadır. Modelin hata yapısını ve performans karakteristiğini daha detaylı incelemek için yapılan görsel analizler aşağıda sunulmuştur.


Şekil 4.7'de sunulan Regresyon Grafiği, tahmin edilen ve gerçek değerler arasındaki güçlü ilişkiyi gözler önüne sermektedir. Grafikteki noktaların $R = 0,9799$ gibi çok yüksek bir korelasyon katsayısıyla, 45 derecelik referans çizgisi etrafında sıkı bir şekilde kümелendiği görülmektedir. Bu, modelin tahminlerinin gerçek değerlerle son derece tutarlı olduğunu güçlü bir görsel kanıttır.

Modelin hata dağılımı ise Şekil 4.8'deki Hata Histogramı ile incelenmiştir. Artıkların (hataların) sıfır etrafında merkezlenmiş ve çan eğrisine benzer bir normal dağılım sergilediği görülmektedir. En sık rastlanan hata değerlerinin sıfıra yakın olması ve büyük hataların frekansının düşük olması, modelin sistematik bir yanlılığa (bias) sahip olmadığını ve tahminlerinin genel olarak isabetli olduğunu teyit eder.


Şekil 4.9, Artıkların Zaman İçindeki Dağılımı'nı göstermektedir. Bu grafikte, hataların zaman eksenini boyunca sıfır çizgisi etrafında belirgin bir örüntü veya mevsimsel bir yapı oluşturmada, rastgele bir şekilde dağıldığı (homoscedasticity) ortaya konulmuştur. Bu durum, modelin verideki zamansal dinamikleri başarıyla yakaladığını ve geriye sadece tahmin edilemeyen rastgele gürültü bıraktığını göstermektedir.



Şekil 4.7. FFNN Regresyon Grafiği



Şekil 4.8. FFNN Hata Histogramı



Şekil 4.9. FFNN Artıkların Zaman İçinde Dağılımı

4.1.4. GRU modeli sonuçları

Zaman serisi analizinde sıkça kullanılan GRU ve LSTM modelleri ise kabul edilebilir sonuçlar verse de, diğer modellere kıyasla daha yüksek hata oranları vermektedir.

Tekrarlayan Sinir Ağı (RNN) ailesinin bir üyesi olan GRU (Gated Recurrent Unit) modeli, zamansal bağımlılıkları modelleme yeteneğiyle öne çıkmaktadır. Modelin test seti üzerindeki nihai performans metrikleri aşağıda özetlenmiştir:


- RMSE: 36,04
- MAE: 26,09
- MAPE: %2,41
- R^2 Skoru: 0,9753

Bu sonuçlar, GRU modelinin de %97,5'in üzerinde bir R^2 skoru ile başarılı tahminler ürettiğini göstermektedir. Ancak RMSE değeri, XGBoost ve 1D-CNN gibi modellere kıyasla bir miktar daha yüksektir. Modelin performans karakteristiğini ve hata yapısını daha detaylı incelemek için yapılan görsel analizler aşağıda sunulmuştur.


Şekil 4.10'da sunulan Regresyon Grafiği, tahmin edilen ve gerçek değerler arasındaki güçlü doğrusal ilişkiyi $R = 0,9753$ gibi yüksek bir korelasyon katsayısıyla doğrulamaktadır. Grafikteki noktaların 45 derecelik referans çizgisi etrafında toplanması, modelin genel olarak tutarlı tahminler yaptığını göstermektedir.

Modelin hata dağılımı ise Şekil 4.11'de verilen Hata Histogramı ile incelenmiştir. Artıkların (hataların) sıfır etrafında merkezlenmiş ve çan eğrisine benzer bir normal dağılım sergilediği görülmektedir.


Şekil 4.12, Artıkların Zaman İçindeki Dağılımı'nı göstermektedir. Bu grafikte, hataların zaman eksenini boyunca sıfır çizgisi etrafında belirgin bir örüntü oluşturmadan, rastgele bir şekilde dağıldığı (homoscedasticity) görülmektedir. Bu durum, GRU modelinin de verideki zamansal dinamikleri başarıyla öğrendiğini ve geriye sadece tahmin edilemeyen rastgele gürültü bıraktığını göstermektedir.



Şekil 4.10. GRU Regresyon Grafiği



Şekil 4.11. GRU Hata Histogramı



Şekil 4.12. GRU Artıkların Zaman İçinde Dağılımı

4.1.5. LSTM modeli sonuçları

LSTM modeli, GRU gibi Tekrarlayan Sinir Ağı ailesinin bir üyesidir ve özellikle uzun vadeli zamansal bağımlılıkları yakalamak için tasarlanmıştır. Modelin test seti üzerindeki nihai performans metrikleri aşağıda özetlenmiştir:


- RMSE: 33,45
- MAE: 23,78
- MAPE: %2,19
- R^2 Skoru: 0,9787

LSTM modeli, GRU'ya kıyasla daha düşük bir RMSE değeri elde ederek biraz daha iyi bir performans sergilemiştir. Modelin hata yapısını ve performans karakteristiğini daha detaylı incelemek için yapılan görsel analizler aşağıda sunulmuştur.


Şekil 4.13'te sunulan Regresyon Grafiği, $R = 0,9787$ gibi çok yüksek bir korelasyon katsayısıyla, tahminlerin gerçek değerlerle son derece tutarlı olduğunu göstermektedir.

Modelin hata dağılımı Şekil 4.14'teki Hata Histogramı ile incelenmiştir. Artıkların sıfır etrafında merkezlenmiş normal dağılımı, modelin sistematik bir yanlılığa sahip olmadığını doğrulamaktadır.


Şekil 4.15, Artıkların Zaman İçindeki Dağılımı'nı göstermektedir. Hataların zaman eksenini boyunca rastgele dağılımı, LSTM modelinin de verideki zamansal dinamikleri ve mevsimselliği başarıyla yakaladığını göstermektedir.



Şekil 4.13. LSTM Regresyon Grafiği



Şekil 4.14. LSTM Hata Histogramı




Şekil 4.15. LSTM Artıkların Zaman İçinde Dağılımı

4.2 Modellerin Karşılaştırılması

Önceki bölümlerde her bir modelin performansı bireysel olarak incelenmiştir. Bu bölümde ise, tüm modellerin performansını bütünsel bir çerçevede karşılaştırmak, aralarındaki temel farkları vurgulamak ve en uygun modeli belirlemek amacıyla karşılaştırmalı bir analiz sunulmuştur. Bu analiz, farklı istatistiksel hata metrikleri ve maliyet analizi olarak incelenecektir.

4.2.1. RMSE karşılaştırması

RMSE, büyük hatalara daha fazla ceza vererek modelin genel hata büyüklüğünü ölçen en temel metriklerden biridir. Şekil 4.16, başarılı olan beş modelin test seti üzerindeki RMSE değerlerini karşılaştırmaktadır.




Şekil 4.16. Modellerin RMSE Değerlerinin Karşılaştırılması

Şekil 4.16'da 27,94 MWh'lık RMSE değeri ile XGBoost modeli, en düşük ortalama hatayı üreterek bu metrik açısından en başarılı model olmuştur. Onu 29,08 MWh RMSE değeri ile 1D-CNN modeli yakından takip etmektedir. Bu iki model, diğer derin öğrenme yaklaşımlarından (FFNN, LSTM, GRU) daha düşük hata oranları elde ederek öne çıkmaktadır. GRU modeli ise 36,04 MWh'lık RMSE değeri ile en yüksek hataya sahip modeldir.

4.2.2. MAE karşılaştırması

MAE, RMSE farklı olarak büyük hataların karesini almadığı için, aykırı değerlere karşı daha az hassastır. Bu metrik, modelin ortalama tahmin sapmasını doğrudan ve yorumlanabilir bir şekilde ifade eder. Modellerin MAE performansları Şekil 4.17'de karşılaştırılmıştır.



Şekil 4.17. Modellerin MAE Değerlerinin Karşılaştırılması


MAE metriği açısından yapılan değerlendirmede de performans sıralamasının büyük ölçüde korunduğu görülmektedir. 19,18 MWh'lık MAE değeri ile XGBoost modeli yine en iyi performansı sergilemiştir. Bu değer, modelin tahminlerinin ortalama olarak gerçekleşen değerden mutlak olarak ne kadar saptığını göstermektedir. 1D-CNN

modeli 21,41 MWh ile ikinci sıradaki yerini korurken, diğer modellerin MAE değerleri de RMSE sıralamasıyla yüksek bir tutarlılık sergilemektedir.

4.2.3. MAPE karşılaştırması

Ortalama Mutlak Yüzdesel Hata (MAPE), hatayı ölçekten bağımsız, yüzdesel bir değer olarak sunarak modellerin oransal başarısını karşılaştırma imkânı tanır. Bu, özellikle farklı ölçeklerdeki veriler veya modeller arasında karşılaştırma yaparken önemlidir. Başarılı modellerin MAPE sonuçları Şekil 4.18'de gösterilmiştir.


Şekil 4.18 incelendiğinde, tüm başarılı modellerin MAPE değerlerinin %1,7 ile %2,5 gibi dar ve düşük bir aralıkta yer aldığı görülmektedir. %1,78 ile en düşük oransal hatayı yine XGBoost modeli yapmıştır.



Şekil 4.18. Modellerin MAPE Değerlerinin Karşılaştırılması

4.2.4. R² karşılaştırması

Diğer metrikler hatanın büyüklüğüne odaklanırken, R², modelin bağımlı değişkendeki (enerji tüketimi) toplam değişkenliğin ne kadarını açıklayabildiğini gösteren bir "uyum iyiliği" (goodness-of-fit) ölçüsüdür. Başarılı modellerin R² skorları Şekil 4.19'da karşılaştırılmıştır.



Şekil 4.19. Modellerin R^2 değerlerinin karşılaştırılması

Şekil 4.19 incelendiğinde, tüm başarılı modellerin R^2 skorlarının 0,975'in üzerinde olduğu görülmektedir. 0,9851'lik R^2 skoru ile XGBoost modeli, verideki değişkenliği en iyi açıklayan model olarak bu metrikte de liderliğini korumuştur. Bu yüksek R^2 değerleri, modellerin sadece anlık tahminlerde değil, aynı zamanda serinin genel davranışını ve yapısını anlamada da başarılı olduğunun bir kanıtıdır.

4.2.5. Aşırı öğrenme (overfitting) hesaplanması ve karşılaştırılması

Bu bölümde, modellerin bu genelleme yeteneğini ve aşırı öğrenme (overfitting) eğilimlerini karşılaştırmak amacıyla, materyal ve yöntem bölümünde kurgulanan %70 eğitim, %15 doğrulama ve %15 test veri seti ayrımı temelinde bir analiz yapılmıştır.

Bu analizin temelini, tüm modellerin doğrulama ve test seti performansını bir arada sunan Çizelge 4.2 oluşturmaktadır. Bu tablo, özellikle modellerin aşırı öğrenme eğilimlerini ve veriyle olan uyumlarını sayısal olarak ortaya koymaktadır.

Çizelge 4.2. RMSE Doğrulama ve Test Sonuçları

Model	RMSE Doğrulama	RMSE Test
XGBoost	37,70	27,94
1D-CNN	30,47	29,08
FFNN	32,27	32,48
GRU	38,22	33,45
LSTM	43,90	36,04

Çizelge 4.2'deki verilerden yola çıkarak, modellerin genelleme performansı daha net yorumlanabilmektedir. Aşırı öğrenmenin en belirgin göstergesi, doğrulama hatası ile test hatası arasındaki farkın büyüklüğüdür. Bu bağlamda:

XGBoost modelinde doğrulama ve test RMSE'si arasında yaklaşık 9,76 MWh'lik önemli bir fark bulunmaktadır. Bu durum, modelin eğitim verisi üzerinde çok iyi performans gösterirken, görülmeyen verilerde performansının düştüğünü ve hafif bir aşırı öğrenme eğilimi olabileceğini göstermektedir.


1D-CNN modelinde ise doğrulama ve test RMSE'si arasındaki fark sadece 1,39 MWh'dir. Bu, modelin çok daha iyi bir genelleme yeteneğine sahip olduğunu ve aşırı öğrenmeden kaçındığını göstermektedir.

FFNN modeli neredeyse mükemmele yakın bir denge sergilemektedir (32,27 vs 32,48), bu da modelin çok iyi genelleme yaptığının göstergesidir.

4.2.6. Hata dağılımları ve varyans analizi

Modellerin performansını sadece ortalama hata metrikleri (RMSE, MAE) üzerinden değerlendirmek, tahminlerin kararlılığı (stabilitesi) ve güvenilirliği hakkında eksik bilgi verebilir. Bir modelin ortalama hatası düşük olsa bile, varyansının yüksek olması (tahminlerin çok geniş bir aralıkta dalgalanması) enerji piyasaları gibi riskli alanlarda tercih edilmez.

Bu nedenle, Şekil 4.20'de gösterildiği gibi modellerin test seti üzerindeki hata dağılımlarını, varyanslarını ve aykırı değer (outlier) üretme eğilimlerini karşılaştırmak amacıyla Kutu Grafiği analizi yapılmıştır.



Şekil 4.20. Modellerin test seti hata dağılımları

Varyans ve Kararlılık: İstatistiksel gösterimde kutuların dikey uzunluğu (Çeyrekler Arası Aralık - IQR), verinin yayılımını ve varyansını temsil eder. Grafikte XGBoost modeline ait kutunun diğer modellere (özellikle GRU ve LSTM'e) göre daha dar (kısa) olduğu görülmektedir. Bu durum, XGBoost modelinin hatalarının genellikle "0" noktası etrafında yoğunlaştığını, varyansının düşük olduğunu ve daha kararlı bir tahmin karakteristiği sergilediğini kanıtlamaktadır.

Aykırı Değerler (Outliers): Kutuların alt ve üst bıyıklarının (whiskers) dışında kalan noktalar, modellerin yaptığı ekstrem hataları temsil eder. Grafikte tüm modellerde belirli miktarda aykırı değer gözlemlenmesi, enerji piyasasındaki ani fiyat veya talep şoklarında (yüksek volatilité anlarında) modellerin anlık sapmalar yaşayabildiğini doğrulamaktadır.

Merkezi Eğilim (Yanlılık): Kutuların ortasındaki yatay çizgiler (medyan), hataların merkezini gösterir. Tüm modellerde medyan değerinin "0" çizgisine oldukça yakın olması, modellerin sistematik bir yanlılık (bias) içermediğini, yani sürekli eksik veya sürekli fazla tahmin yapma eğiliminde olmadıklarını göstermektedir.

4.3. Dengesizlik Maliyet Analiz Sonuçları


Modellerin tahmin doğruluğu metrikler üzerinden değerlendirilmiş ve XGBoost modelinin en düşük hata oranlarına sahip olduğu tespit edilmiştir. Ancak bir tahmin modelinin enerji piyasalarındaki gerçek değeri, sadece başarısıyla değil, aynı zamanda yol açtığı finansal sonuçlarla da ölçülür. Bu nedenle, çalışmanın bu nihai analiz aşamasında, her bir modelin tahmin hatalarının, Bölüm 3'te detaylandırılan metodolojiye göre ne kadarlık bir toplam enerji maliyetine yol açtığı simüle edilmiştir.

Başarılı olan beş modelin (XGBoost, 1D-CNN, FFNN, GRU, LSTM) test seti üzerindeki tahminleri kullanılarak, her biri için kümülatif toplam enerji maliyetleri hesaplanmış ve bu sonuçlara göre yüzdesel olarak hesaplanmış ve Çizelge 4.3 ile sunulmuştur. Bir tahmin modelinin enerji piyasalarındaki gerçek değeri, sadece RMSE gibi teknik metriklerle değil, aynı zamanda yol açtığı finansal maliyetle de ölçülür. Bu bölümde, her bir modelin tahmin hatasının yol açtığı dengesizlik maliyetinin, mükemmel tahmin senaryosundaki ideal toplam maliyete oranı incelenmiştir. Bu "Ek Maliyet Yüzdesi (%)" olarak adlandırılan metrik, tahmin hatasının finansal etkisini birimsiz bir yüzde olarak ifade eder ve modellerin finansal verimliliğini karşılaştırmak için kullanılmıştır.

Çizelge 4.3. Maliyet Sapma Oranı

Model	Yüzde (%)
1D-CNN	0,2564%
FFNN	0,2571%
GRU	0,3246%
LSTM	0,3291%
XGBoost	0,3331%

Beş model arasındaki hassas farkları görselleştirmek amacıyla, bu modellerin sonuçları Şekil 4.21'de ayrıca sunulmuştur.

**Şekil 4.21.** Sapma Oranı (%)

Çizelge 4.3 ve Şekil 4.21'de sunulan sonuçlar incelendiğinde, istatistiksel performans sıralaması ile maliyet sıralaması arasında önemli bir farklılık olduğu gözlemlenmektedir. İstatistiksel metrikler açısından en başarılı model olan XGBoost'un (0,2571%), finansal sapma oranı açısından en verimli model olmadığı tespit edilmiştir. İdeal maliyete sadece 0,2563%'lük bir maliyet getiren 1D-CNN modeli, en düşük finansal sapmayı yaratarak bu analizde en iyi performansı gösteren model olmuştur.

4.3.1. Kritik bir vaka analizi

Yapılan bu hesaplama yöntemi, çalışmada kullanılan tüm modeller için aynı zaman diliminde uygulanmıştır. Modellerin tahmin hassasiyetlerinin finansal tabloya

nasıl yansıdığını somutlaştırmak adına, 29.04.2025 tarihi saat 12:00 için tüm modellerin ürettiği tahminler, oluşan enerji açığı miktarları ve buna bağlı dengesizlik maliyetleri için Çizelge 4.4'te 29.04.2025 saat 12:00'da gerçekleşen değer, o saatte PTF ve SMF TL fiyatlarını ve bu saat için tahmin modellerinin tahminleri verilmiştir.

Çizelge 4.4. Gerçekleşen değer ve model tahminleri

Tarih Saat	PTF (TL/MWh)	SMF (TL/MWh)	Gerçekleşen (MWh)	XGBoost	FFNN	GRU	LSTM	1D-CNN
29.04.2025 12:00	200	1.704	1934	1922	1968	1946	1912	1951

Bu örnek, enerji piyasalarındaki yüksek değişkenlikleri yansıtması bakımından kritiktir. İlgili saatte Piyasa Takas Fiyatı (PTF) 200 TL/MWh iken, sistemde oluşan enerji açığı nedeniyle Sistem Marjinal Fiyatı (SMF) 1.704 TL/MWh seviyesine yükselmiştir. Formül 3.6 ve 3.7'ye göre her MWh için dengesizlik birim fiyatları şöyle hesaplanmıştır: Enerji açığı olması durumunda;

$$\begin{aligned} \text{Maksimum}(PTF, SMF) \times 1,03 &= \text{Maksimum}(200, 1.704) \times 1,03 \\ &= 1.755,33 \text{ TL/MWh} \end{aligned}$$

Enerji fazlası olması durumunda;

$$\begin{aligned} \text{Minimum}(PTF, SMF) \times 0,97 &= \text{Minimum}(200, 1.704) \times 0,97 \\ &= 194,01 \text{ TL/MWh} \end{aligned}$$

Bu fiyatlamanın finansal karşılığı şöyledir: İlgili saatte tahminin gerçekleşen tüketimin altında kalması durumunda, sistemden tedarik edilecek her 1 MWh'lik enerji açığı için 1.755,33 TL ödeme yapılması gerekmektedir. Buna karşın, tahminin tüketimden yüksek olması durumunda, artan her 1 MWh'lik enerji fazlası için sisteme satış fiyatı yalnızca 194,01 TL olacaktır. Yani bir birimlik enerji açığının maliyeti, bir birimlik enerji fazlasının getirisinin yaklaşık 9 katıdır. Bu oran, maliyet hesaplamalarında ciddi etkisi olmaktadır.

Hesaplanan bu birim fiyatlar ve sapmaları kullanılarak, her bir modelin (XGBoost, FFNN, GRU, LSTM, 1D-CNN) oluşturduğu dengesizlik maliyeti ve toplam enerji tedarik maliyeti detayları ile birlikte Çizelge 4.5'te sunulmuştur. Sapmalar ve etkileri açıklanmıştır.

Çizelge 4.5. Modellerin dengesizlik durumları ve maliyet analizi sonuçları (29.04.2025 - 12:00)

Model	Tahmin Sapması (MWh)	Dengesizlik Durumu	Dengesizlik Maliyeti (TL)	Toplam Maliyet (TL)
XGBoost	-12,18	Enerji Açığı	+21.378	405.758
FFNN	+34,3	Enerji Fazlası	-6.655	387.021
GRU	+12,25	Enerji Fazlası	-2.377	386.889
LSTM	-22,07	Enerji Açığı	+38.744	421.145
1D-CNN	+16,66	Enerji Fazlası	-3.232	386.915

Çizelge 4.5 incelendiğinde, piyasa fiyatlarındaki asimetrinin (SMF > PTF) finansal sonuçları ne denli değiştirdiği açıkça görülmektedir. Özellikle LSTM ve XGBoost modelleri, gerçekleşen tüketimin altında tahmin yaparak "Enerji Açığı"na düşmüşlerdir. Bu durum, piyasa katılımcısının eksik kalan enerjiyi 1.755,33 TL/MWh gibi çok yüksek bir birim fiyattan tamamlamasına neden olmuş ve LSTM modeli için 38.744 TL gibi yüksek bir ek maliyet doğurmuştur.

Buna karşın FFNN, GRU ve 1D-CNN modelleri, tüketimi olduğundan fazla tahmin ederek "Enerji Fazlası" pozisyonunda kalmışlardır. Bu modeller istatistiksel olarak hata yapsalar da, hatanın yönü "güvenli tarafta" olduğu için ceza ödemiş, aksine sistemden iade alarak toplam maliyetlerini düşürmüşlerdir. Örneğin FFNN modeli, mutlak değerce en yüksek sapmaya (34,30 MWh) sahip olmasına rağmen, bu sapma "fazlalık" yönünde olduğu için finansal açıdan LSTM modeline göre çok daha avantajlı bir sonuç üretmiştir.

Bu örneklem, yüksek değişkenliğe sahip enerji piyasalarında tahmin modellerinin sadece doğruluğunun değil, tahmin hatasının yönünün de kritik bir maliyet parametresi olduğunu kanıtlamaktadır.

Bu analiz, tezin tartışma bölümünde detaylandırılacak olan "tahmin doğruluğu ile finansal başarının her zaman doğru orantılı olmadığı" bulgusunu destekler niteliktedir. Çalışma kapsamındaki istatistiksel değerlendirmelerde (MAE, RMSE metriklerine göre) genellikle en başarılı tahminleri üreten XGBoost modeli, bu örneklemde görüldüğü üzere kritik anlarda 'negatif dengesizlik' tuzağına düşerek finansal açıdan dezavantajlı konuma gelmiştir. Buna karşılık, tezin maliyet analizi bölümünde toplamda en düşük maliyeti sunduğu tespit edilen 1D-CNN modeli, bu örnekte de piyasa dinamiklerine (yüksek SMF riski) karşı daha dirençli bir profil sergilemiştir. Dolayısıyla bu vaka analizi, en iyi tahmin yapan modelin her zaman en iyi finansal sonucu üreten model

olmayabileceğini; XGBoost'un istatistiksel liderliğine rağmen, 1D-CNN'in maliyet yönetiminde (hatanın yönü sayesinde) neden daha başarılı olduğunu somut bir şekilde ortaya koymaktadır.

4.4. Tartışma

Bu çalışmanın en kritik tartışma noktası, hata metriklerinde performansı en iyi olan model XGBoost modelinin, neden finansal performans (dengesizlik maliyeti) açısından 1D-CNN modelinin gerisinde kaldığıdır.

Çizelge 4.3'te görüldüğü üzere, 1D-CNN (0,2563%) ve XGBoost (0,2571%) modellerinin maliyet sapma oranları arasındaki fark yüzdesel olarak küçük görünse de, enerji piyasasının devasa işlem hacimleri dikkate alındığında bu farkın finansal karşılığı oldukça önemlidir. Bu marjinal maliyet farkı, daha uzun operasyonel dönemlerde veya daha büyük enerji portföylerinde milyonlarca TL'lik tasarruf potansiyeline işaret etmektedir.

Bu finansal ayrışmanın temel nedeni, modellerin hata yapma karakteristiğindeki farklılıklar ve enerji piyasasının cezalandırıcı maliyet yapısıdır. RMSE gibi metrikler modelin ortalama performansını ölçerken, Dengeleme Güç Piyasası'nın maliyet formülasyonu özellikle büyük ve ani hataları (outliers) orantısızca cezalandırır. Bu bağlamda, yapılan analiz şu çıkarımları desteklemektedir:

- XGBoost, en düşük ortalama hataya sahip olmasına rağmen, nadiren de olsa maliyeti katlanarak artıran çok büyük tekil hatalar yapma eğilimindedir.
- 1D-CNN ise, ortalama hatası daha yüksek olsa da, daha tutarlı ve daha öngörülebilir bir hata profili sergilemiştir. Büyük ve "cezalandırıcı" hatalar yapmaktan kaçınma yeteneği, toplamda daha düşük bir finansal risk ve maliyet profili oluşturmasını sağlamıştır.

Bu bulgu, enerji piyasaları gibi finansal sonuçların kritik olduğu alanlarda model seçiminin, sadece genel hata metriklerine dayanmaması gerektiğini kanıtlamaktadır. Modelin hata dağılımının uç noktaları ve büyük sapmalara karşı dayanıklılığı, pratik uygulamada ortalama performansından daha önemli olabilir. Bu nedenle, finansal optimizasyon hedefiyle yapılan bu analiz, 1D-CNN modelini bu spesifik problem için en uygun ve pratik çözüm olarak öne çıkarmaktadır.

Dengesizlik maliyeti, sadece hatanın büyüklüğüne değil, aynı zamanda hatanın yapıldığı andaki piyasa koşullarına da bağlıdır. Analiz periyodu boyunca, PTF ve SMF

arasındaki fiyat farkının (spread) oldukça değişken olduğu dönemler gözlemlenmiştir. Örneğin, PTF'nin yüksek, SMF'nin ise düşük olduğu bir senaryoda, enerji fazlası yaratan bir tahmin hatası, GÖP'te pahalıya alınan enerjinin DGP'de düşük fiyattan satılmasına neden olarak finansal kayba yol açabilir.

Bu durumun en somut kanıtı, Bölüm 4.3'te detaylandırılan 29.04.2025 tarihli vaka analizinde açıkça görülmektedir. İlgili saatte sistemde enerji açığı oluşmuş ve SMF (1.704 TL/MWh), PTF'nin (200 TL/MWh) yaklaşık 8,5 katına çıkmıştır. Bu "kritik" anda:

- XGBoost, istatistiksel hatayı minimize etme (ortalamaya yaklaşma) eğilimi nedeniyle tüketimi eksik tahmin etmiş ve piyasa katılımcısını 21.378 TL gibi yüksek bir ceza maliyetiyle karşı karşıya bırakmıştır.
- 1D-CNN ise, zaman serisindeki ani dalgalanmaları yakalama yeteneği sayesinde tüketimi daha yüksek (güvenli tarafta) tahminlemiştir. Bu sayede, "eksik enerji" cezasına yakalanmak yerine, fazla enerjiyi sisteme satarak maliyet avantajı sağlamıştır.

XGBoost, normal saatlerdeki istikrarlı yapısıyla hata oranını düşürse de, 1D-CNN piyasanın can yaktığı (SMF'nin fırladığı) anlarda daha korumacı bir refleks göstermiştir.

Bu bağlamda, 1D-CNN'in finansal başarısının bir diğer nedeni, bu tür yüksek değişkenliğe sahip saatlerde daha dikkatli ve daha az riskli tahminler yapmış olması olabilir. XGBoost ise, ortalama olarak daha başarılı olsa da, tam da bu kritik ve "cezalandırıcı" saatlerde büyük bir hata yaparak toplam maliyetini artırmış olabilir. Bu durum, modellerin sadece ortalama hatasını değil, aynı zamanda riskli piyasa koşullarındaki davranışını da analiz etmenin önemini vurgulamaktadır.

Bu tartışma, model seçiminde "tek doğru" olmadığını, en iyi modelin amaca (pür istatistiksel doğruluk mu, yoksa finansal risk minimizasyonu mu) göre değişebileceğini ortaya koymaktadır.

5. SONUÇLAR VE ÖNERİLERİ

Bu tez çalışmasında, saatlik enerji tüketimi gibi karmaşık ve doğrusal olmayan bir zaman serisinin tahmini için farklı modelleme yaklaşımları karşılaştırılmıştır. Çalışmanın temel amacı, sadece en yüksek istatistiksel doğruluğa sahip modeli belirlemek değil, aynı zamanda bu modelin gerçek piyasa koşullarındaki finansal performansını da analiz ederek pratik uygulanabilirliğinin test edilmesi amaçlanmıştır.

Analizler sonucunda, zaman serisi problemini geçmiş verilerden ve takvim etkilerinden türetilen zengin bir özellik setiyle bir denetimli öğrenme problemine dönüştürme stratejisinin, geleneksel istatistiksel yaklaşımlara kıyasla belirgin bir üstünlük sağladığı görülmüştür. Bu modellerin pür tahmin doğruluğu açısından XGBoost modeli, en düşük hata oranı (RMSE) ve en yüksek R^2 skoru ile istatistiksel olarak en başarılı model olarak öne çıkmıştır. 1D-CNN modeli de XGBoost'a çok yakın bir performans sergilerken, diğer derin öğrenme yaklaşımları da yüksek başarı oranları yakalamıştır.

Tezin en önemli ve özgün bulgusu ise, istatistiksel doğruluk ile finansal optimizasyon arasındaki ayrışmadır. Türkiye enerji piyasasındaki dengesizlik maliyeti mekanizması simüle edildiğinde, istatistiksel olarak en başarılı olan XGBoost modelinin, finansal olarak en optimal çözüm olmadığı görülmüştür. Bunun yerine, daha dengeli ve tutarlı bir hata profiline sahip olan 1D-CNN modeli, en düşük kümülatif dengesizlik maliyetini yaratarak pratik ve finansal uygulama için en uygun model olduğunu kanıtlamıştır. Bu bulgu, en düşük ortalama hataya sahip bir modelin, nadir de olsa yaptığı büyük hatalar nedeniyle, finansal olarak daha riskli olabileceğini göstermektedir.

Son olarak, en başarılı modellerin dahi uzun vadeli özyinelemeli tahminlerde "hata birikimi" olgusu nedeniyle ciddi performans kaybı yaşadığı tespit edilmiş, bu da çok adımlı tahmin probleminin kendine özgü zorluklarını ortaya koymuştur.

Bu tez çalışmasında elde edilen bulgular ve karşılaşılan zorluklar ışığında, gelecekte bu alanda yapılacak çalışmalara yönelik çeşitli stratejik öneriler geliştirilmiştir. Tahmin doğruluğunu daha da artırmak amacıyla, modellere hava durumu verileri (sıcaklık, nem) gibi dışsal faktörlerin dahil edilmesi hedeflenmelidir. Bu tür ek bilgiler, modellerin sadece geçmiş tüketim verilerine olan bağımlılığını azaltarak tahmin performansını, özellikle de uzun vadeli öngörülerini iyileştirme potansiyeline sahiptir. Ayrıca, bu çalışmada gözlemlenen istatistiksel ve finansal performans ayrışmasını

yönetmek amacıyla, en iyi istatistiksel performansı gösteren XGBoost ile en iyi finansal performansı gösteren 1D-CNN'in güçlü yönlerini birleştiren hibrit modelleme yaklaşımları geliştirilebilir.

Ancak, bu çalışmanın en önemli çıkarımlarından biri, dengesizlik maliyetinin sadece tahmin hatasının büyüklüğüne değil, aynı zamanda hatanın yapıldığı andaki piyasa fiyatlarının değişkenliğine de bağlı olduğudur. Bu çalışmada maliyet analizi, gerçekleşmiş piyasa fiyatları kullanılarak geriye dönük bir simülasyonla yapılmıştır. Gelecek çalışmalarda, bu yaklaşım bir adım ileri taşınarak, eş zamanlı bir piyasa fiyat tahmini modelinin sisteme entegre edilmesi önerilmektedir.

Bu entegrasyon, hem Piyasa Takas Fiyatı (PTF) hem de özellikle değişken olan Sistem Marjinal Fiyatı (SMF) için ayrı tahminler üretmeyi içerebilir. Böyle bir yapı, sadece tüketim hatasını değil, aynı zamanda hataların finansal riskini de minimize etmeye yönelik riske duyarlı (risk-aware) tahmin ve alım stratejilerinin geliştirilmesine olanak tanır. Örneğin, SMF'nin çok yüksek olacağının tahmin edildiği saatlerde, modelin bilinçli olarak daha "güvenli" (bir miktar fazla veya eksik) tahminler üreterek potansiyel bir finansal cezadan kaçınması sağlanabilir. Bu, enerji ticareti operasyonları için çok daha proaktif ve dinamik bir karar destek sistemi oluşturacaktır.

Son olarak, uzun vadeli tahminlerde karşılaşılan hata birikimi sorununu çözmek için, özyinelemeli yöntem alternatif olarak, gelecekteki her bir zaman adımını bağımsız olarak tahmin eden veya tüm tahmin ufkunu tek bir adımda üreten alternatif çok adımlı tahmin stratejilerinin incelenmesi önerilmektedir. Bu öneriler, bu tezin üzerine inşa edilecek ve enerji tüketim tahmini alanındaki bilgi birikimine katkı sağlayacak potansiyel araştırma yollarını sunmaktadır.

6. KAYNAKLAR

- Arslan, B., ve Ertuğrul, İ. (2022). Çoklu regresyon, ARIMA ve yapay sinir ağı yöntemleri ile Türkiye elektrik piyasasında fiyat tahmin ve analizi. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 20(1), 331-353. <https://doi.org/10.11611/yead.988146>
- Aydın, D., ve Toros, H. (2018). Prediction of short-term electricity consumption by artificial neural networks using temperature variables. *European Journal of Science and Technology*, 14, 393-398. <https://doi.org/10.31590>
- Baltaş, M., ve Akbay, C. (2021). Akdeniz elektrik dağıtım bölgesi (Antalya - Isparta - Burdur) elektrik tüketim talep tahmini. *Yönetim ve Ekonomi Araştırmaları*, 19(2), 222-238. <https://doi.org/10.11611/yead.730809>
- Berus, Y., ve Benteşen Yakut, Y. (2024). Derin öğrenme (1D-CNN, RNN, LSTM, BiLSTM) ile enerji tüketim tahmini: *Dişarbakır AVM örneđi. DÜMF Mühendislik*, 15(2). <https://doi.org/10.24012/dumf.1415055>
- Bilgili, M. (2009). Estimation of net electricity consumption of Turkey. *J. of Thermal Science and Technology*, 29(2), 89-98.
- Bişkin, O. T., ve Çifci, A. (2021). Forecasting of Turkey's electrical energy consumption using LSTM and GRU networks. *Bilecik Şeyh Edebalı Üniversitesi Fen Bilimleri Dergisi*, 8(2), 656-667. <https://doi.org/10.35193/bseufbd.935824>
- Breiman, L. (1996). *Bagging predictors*. Machine learning, 24, 123-140.
- Breiman, L. (2001). *Random forests*. Machine learning, 45(1), 5-32.
- Burez, J., ve Van den Poel, D. (2009). Handling class imbalance in customer churn prediction. *Expert Systems with Applications*, 36(3), 4626-4636. <https://doi.org/10.1016/j.eswa.2008.05.027>
- Calp, M. H. (2018). İşletmeler için personel yemek talep miktarının yapay sinir ağıları kullanılarak tahmin edilmesi. *Journal of Polytechnic*, 22(3), 675-686. <https://doi.org/10.2339/politeknik.444380>
- Chen, T., ve Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-August-2016, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Christ, M., Braun, N., Neuffer, J., ve Kempa-Liehr, A. W. (2018). Time series feature extraction on basis of scalable hypothesis tests (tsfresh – a python package). *Neurocomputing*, 307, 72-77. <https://doi.org/10.1016/j.neucom.2018.03.067>
- Çağlayan Akay, E., ve Topal, K. H. (2024). Forecasting Turkish electricity consumption: A critical analysis of single and hybrid models. *Energy*, 305, 132115. <https://doi.org/10.1016/j.energy.2024.132115>
- Çalık, A. E., ve Şirin, H. (2017). Türkiye'deki elektrik enerji ihtiyacının matematiksel bir modellenmesi. *SAÜ Fen Bilimleri Enstitüsü*, 21(6), 1475-1482. <https://doi.org/10.16984/saufenbilder.300362>

- Çayır, A., Yenidoğan, I., ve Dağ, H. (2018). Konutların günlük elektrik güç tüketimi tahmini için uygun model seçimi. *Fırat Üniv. Müh. Bil. Dergisi Science and Eng. J of Fırat Univ*, 30(3), 15-21.
- Doğru, B. N., ve Büyükakın, F. (2023). Tr42 bölgesi için elektrik enerjisi talebinin makine öğrenimi tabanlı tahmini. *Uluslararası Ekonomik Araştırmalar*, 9(3), 45-64. <https://dergipark.org.tr/tr/pub/ead/issue/81973/1407729>
- Ecevit, A., Öztürk, İ., Dağ, M., ve Özcan, T. (2023). Short-term sales forecasting using LSTM and prophet based models in e-commerce. *Acta Infologica*, 1(7), 59-70. <https://doi.org/10.26650/acin.1259067>
- Enerji Piyasaları İşletme A.Ş. (2025). PTF SMF listeleme. *Epiaş Şeffaflık Platformu*. <https://seffaflik.epias.com.tr/>
- Enerji Piyasası Düzenleme Kurumu. (2025). Elektrik piyasası dengeleme ve uzlaştırma yönetmeliği.
- Ercan, U., Irmak, S., Çevik, K. K., ve Canbazoğlu, E. (2020). Yapay sinir ağları kullanılarak Konutlarda elektrik tüketimi düzeylerinin tahmin edilmesi. *Sosyoekonomi*, 28(46), 173-186. <https://doi.org/10.17233/sosyoekonomi.2020.04.09>
- Erdoğan, E., ve Özyürek, H. (2012). Yapay sinir ağları ile fiyat tahminlemesi. *Sosyal ve Beşeri Bilimler*, 4(1), 85-92.
- Eren, T., ve Kaçtıoğlu, S. (2017). Türkiye'deki doğal gaz tüketimi ve gri tahmin metoduyla tahmin Edilmesi. *Istanbul Commerce University Journal of Science İstanbul Ticaret Üniversitesi Fen Bilimleri*, 16(31), 23-41. <http://dergipark.gov.tr/ticaretfbid>
- Erkınay Özdemir, M. (2021). Yapay sinir ağları kullanılarak orta dönem elektrik enerjisi tüketim tahmini: İskenderun örneği. *European Journal of Science and Technology*, 28. <https://doi.org/10.31590/ejosat.1007589>
- Genç Kavas, H. (2022). Forecasting Turkey electricity consumption with deep learning Bi-Lstm model. *Journal of Science and Technology*, 1(1), 24-33. <https://orcid.org/0000-0002-6813-529X>
- Goodfellow, I., Bengio, Y., ve Courville, Aaron. (2016). Deep learning. *The MIT Press*. <https://doi.org/10.7551/mitpress/9780262035613.001.0001>
- Gökçe, M. M. (2024). A deep learning-based demand forecasting system for planning electricity generation. *KSU Mühendislik Bilimleri*, 27(2), 511-522.
- Güven, M. H., Kılıç, F., ve Diri, F. Ü. (2025). Kömür Kullanımı ile üretilen enerji miktarının yapay sinir ağı modeliyle tahmini Çin üzerine örnek uygulama. *Savunma Bilimleri*, 21(1), 57-72. <https://doi.org/10.17134/khosbd.1499159>
- Haliloğlu, E. Y., ve Tutu, Y. (2018). Türkiye için kısa vadeli elektrik enerjisi talep tahmini. *Journal of Yasar University*, 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*, 19(3), 227-233.
- Hastie, T., Tibshirani, R., ve Friedman, J. (2009). Springer series in statistics the elements of statistical learning data mining, inference, and prediction (*Springer, Ed.*). <https://doi.org/10.1007/978-0-387-84858-7>
- Haykin, S. (2009). Neural networks and learning machines (Third Edition). *Pearson Prentice Hall*.
- Heidarpanah, M., Hooshyaripor, F., ve Fazeli, M. (2023). Daily electricity price forecasting using artificial intelligence models in the Iranian electricity market. *Energy*, 263, 126011. <https://doi.org/10.1016/j.energy.2022.126011>
- Hyndman, R. J., ve Athanasopoulos, G. (2021). Forecasting: Principles and practice (3. bs). *OTexts*. <https://otexts.com/fpp3/>
- Işık, H., ve Şeker, M. (2021). Yapay sinir ağı (YSA) kullanarak farklı kaynaklardan Türkiye’de elektrik enerjisi üretim potansiyelinin tahmini. *Computer Science, IDAP-2021*. <https://doi.org/10.53070/bbd.991039>
- Jordan, M. I., ve Mitchell, T. M. (2015). Data, privacy, and the greater good. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aac4520>
- Kamber, E., Körpüz, S., Can, M., Aydoğmuş Yumurtacı, H., ve Gümüş, M. (2021). Yapay sinir ağlarına dayalı kısa dönemli elektrik yükü tahmini. *Journal of Industrial Engineering*, 32(2), 364-379. <https://orcid.org/0000-0002-8715-3143>
- Karaca, C., ve Karacan, H. (2016). Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi. *Selcuk University Journal of Engineering ,Science and Technology*, 4(3), 182-182. <https://doi.org/10.15317/scitech.2016320514>
- Kaysal, K., Akarslan, E., ve Hocaoglu, F. O. (2022). Türkiye kısa dönem elektrik yük talep tahmininde makine öğrenmesi yöntemlerinin karşılaştırılması. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri*, 9(2), 693-702. <https://doi.org/10.35193/bseufbd.1004827>
- Kingma, D. P., ve Ba, J. (2017). Adam: A Method for stochastic optimization. <http://arxiv.org/abs/1412.6980>
- Kobourov, S., Löffler, M., Montecchiani, F., Pilipczuk, M., Rutter, I., Seidel, R., Sorge, M., ve Wulms, J. (2025). The influence of dimensions on the complexity of computing decision trees. *Artificial Intelligence*, 343, 104322. <https://doi.org/10.1016/j.artint.2025.104322>
- Kocadayı, Y., ErKaymaz, O., ve Uzun, R. (2017). Yapay sinir ağları ile Tr81 bölgesi yıllık elektrik enerjisi tüketiminin tahmini. *Bilge International Journal of Science and Technology Research*, 1(1), 59-64.
- Lecun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>

- Nebati, E. E., Taş, M., ve Ertaş, G. (2021). Türkiye’de elektrik tüketiminde talep tahmini: zaman serisi ve regresyon analizi ile karşılaştırma. *European Journal of Science and Technology*, 31(1), 348-357. <https://doi.org/10.31590/ejosat.998277>
- 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*, 11(3), 255-261. <https://doi.org/10.17671/gazibtd.404250>
- Özkan, E., Güler, E., ve Aladağ, Z. (2020). Elektrik enerjisi tüketim verileri için uygun tahmin yöntemi seçimi. *Journal of Industrial Engineering*, 31(2), 198-214. <https://orcid.org/0000-0002-2638-3674>
- Pedregosa, F., Michel, V., Grisel Oliviergrisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Vanderplas, J., Cournapeau, D., Pedregosa, F., Varoquaux, G., Gramfort, A., Thirion, B., Grisel, O., Dubourg, V., Passos, A., Brucher, M., Perrot and Édouardand, M., Duchesnay, and Édouard, ve Duchesnay EDOUARD DUCHESNAY, Fré. (2011). Scikit-learn: machine learning in python. *Journal of Machine Learning Research*, 12, 2825-2830. <http://scikit-learn.sourceforge.net>.
- Runge, J., ve Zmeureanu, R. (2019). Forecasting energy use in buildings using artificial neural networks: A review. *Energies*, 12(17). <https://doi.org/10.3390/en12173254>
- Sezer, E., Yildirim, G., ve Özdemir, M. T. (2024). Türkiye’deki toplam elektrik tüketiminin holt-winters üstel düzleştirme yöntemi ile tahmini. *Ankara Science University, Researcher*, 4(2), 2717-9494.
- Tightiz, L., Yoo, J., ve Al-Shibli, W. K. (2025). Strategic enhancements in electricity price forecasting: The role of XGBoost and error correction features. *Results in Engineering*, 26, 105609. <https://doi.org/10.1016/j.rineng.2025.105609>
- Tokmak, M. (2023). XGBoost algoritması ile ikili parçacık sürü optimizasyonu öznetelik seçme tabanlı jar kötü amaçlı yazılımlarının tespiti. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 10(1), 140-152. <https://doi.org/10.35193/bseufbd.1194460>
- Ucal, M., ve Doğan, S. (2005). Türkiye’de elektrik tüketimi: kointegrasyon ve tahmin yolu ile sahte regresyon analizi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi*, 10(2), 75-91.
- Ülkü, H., ve Yalpır, Ş. (2021). Enerji talep tahmini için metodoloji geliştirme: 2030 yılı Türkiye örneği. *Bilim. Derg. / NOHU J. Eng. Sci.*, 10(1), 188-201. <https://doi.org/10.28948/ngmuh.814134>
- Ünal, Ş. N. (2024). Yapay sinir ağları yöntemleri ile elektrik tüketimi analizi. *Karabük üniversitesi iktisadi ve idari bilimler fakültesi*, 2(4), 98-111.
- Ünüvar, Y., Balcı, S., ve Kayabaşı, A. (2022). Endüstriyel bir bölgede geçmiş elektrik enerjisi tüketim verilerine dayalı gelecekteki yük tahminleri: Karaman organize sanayi bölgesi örneği. *Karamanoğlu mehmetbey üniversitesi mühendislik ve doğa bilimleri*, 4(2), 135-160. <https://doi.org/10.55213/kmujens.1210736>