

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DALGA DÖNÜŞÜMÜ ENTEGRELİ DERİN
ÖĞRENME KULLANILARAK
ÖNGÖRÜLEMİYEN OLAYLARI İÇEREN
ELEKTRİK TÜKETİMİ TAHMİNİ

Hisham Alnour Adam HAMZA

YÜKSEK LİSANS TEZİ
Elektrik Mühendisliği Anabilim Dalı
Elektrik Makinaları ve Güç Elektroniği Programı

Danışman
Doç. Dr. Ali AJDER

Eş-Danışman
Dr. Öğr. Üyesi Ramazan AYAZ

Haziran, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**DALGA DÖNÜŞÜMÜ ENTEGRELİ DERİN ÖĞRENME
KULLANILARAK ÖNGÖRÜLEMİYEN OLAYLARI
İÇEREN ELEKTRİK TÜKETİMİ TAHMİNİ**

Hisham Alnour Adam HAMZA tarafından hazırlanan tez çalışması 25.06.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı Elektrik Makinaları ve Güç Elektroniği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Ali AJDER
Yıldız Teknik Üniversitesi
Danışman

Dr. Öğr. Üyesi Ramazan AYAZ
Yıldız Teknik Üniversitesi
Eş-Danışman

Jüri Üyeleri

Doç. Dr. Ali AJDER, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. İsmail NAKİR, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Hakan AKÇA, Üye
Ege Üniversitesi

Danışmanım Doç. Dr. Ali AJDER sorumluluğunda tarafımca hazırlanan DALGA DÖNÜŞÜMÜ ENTEGRELİ DERİN ÖĞRENME KULLANILARAK ÖNGÖRÜLEMEYEN OLAYLARI İÇEREN ELEKTRİK TÜKETİMİ TAHMİNİ başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Hisham Alnour Adam HAMZA

İmza

*Aileme, arkadaşlarıma, Danışmanıma ve ülkeye, **Sudan**'a*



TEŞEKKÜR

Her şeyden önce, yüksek lisans yolculuğum boyunca bana rehberlik eden, sarsılmaz destekleri ve akademik mentorluklarıyla yanımda olan danışmanım Doç. Dr. Ali Ajder'e ve eş danışmanım Dr. Öğr. Üyesi Ramazan Ayaz'a en derin şükranlarımı sunmak isterim. Ailem savaşın etkilediği bir bölgede yaşarken, onların gösterdiği anlayış ve teşvik, bu son derece zorlu süreçte bana güç ve moral kaynağı olmuş; süreci atlatmamda hayati bir rol oynamıştır. Verdikleri değerli geri bildirimler, bu tezin şekillenmesine ve akademik gelişimime önemli katkılar sağlamıştır.

Sonsuz sevgileri, duaları ve bana olan sarsılmaz inançlarıyla her zaman güç ve motivasyon kaynağım olan anne ve babama derin bir minnettarlık duyuyorum. Kardeşlerime de, sürekli teşvikleri ve potansiyelime duydukları sarsılmaz güven için gönülden teşekkür ederim.

Son olarak, bana ikinci bir yuva gibi kucak açan ve kişisel ile akademik gelişimim için destekleyici bir ortam sunan Türkiye'ye içten şükranlarımı sunmak isterim. Bu yolculukta tanıma fırsatı bulduğum harika arkadaşlara da, gösterdikleri nezaket ve dostluklarıyla bu süreci unutulmaz kıldıkları için derin bir teşekkür borçluyum.

Hisham Alnour Adam HAMZA

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	4
1.3 Hipotez	4
2 METODOLOJİ	5
2.1 Veri Toplama ve Ön İşleme	5
2.1.1 Eksik Değerler ve Aykırı Değerlerin İşlenmesi	6
2.2 Yöntem ve Modelleme	6
2.2.1 Zaman Serisi Analizinde Dalgacık Dönüşümleri	6
2.2.2 Ayırık Dalgacık Dönüşüm Teorisi	6
2.3 Zaman serisi tahmin teknikleri	7
2.3.1 Geleneksel istatistiksel yöntemler (ARIMA, SARIMA)	7
2.3.2 Destek Vektör Makineleri	9
2.3.3 Rastgele Ormanlar	10
2.3.4 Uzun Kısa Süreli Bellek Ağları	11
2.3.5 XGBoost	13
2.3.6 Tekrarlayan Sinir Ağları	14
2.3.7 Kapılı Tekrarlayan Birimler	15
2.3.8 LSTM-XGBoost Hibrit Modeline Genel Bakış	17
2.3.9 Öznitelik Çıkarımı için Ayırık Dalgacık Dönüşümü	17
2.3.10 Dizi Tahmini için LSTM	17

2.3.11	XGBoost ile Artık Hata Düzeltmesi	18
2.3.12	Hibrit LSTM-XGBoost Tahmini	19
2.3.13	Model Değerlendirmesi	19
3	ANALİZ SONUÇLARI	22
3.1	Standart Derin Öğrenme Mimarileri ile Karşılaştırma	22
3.2	Genel Model Performansı	25
3.3	Temel Modellerle Karşılaştırmalı Analiz	32
3.4	Tahmin Edilemeyen Olayları Ele Alma: COVID-19 Pandemisi Sırasındaki Performans	33
3.5	Sınırlamalar ve Gelecek Yönelimler	34
4	SONUÇ	35
	KAYNAKÇA	37
	TEZDEN ÜRETİLMİŞ YAYINLAR	42

SİMGE LİSTESİ

$x(t)$	Original time series data (Orijinal zaman serisi verisi)
$\psi_{j,k}(t)$	Wavelet basis functions (Dalgaçık temel fonksiyonları)
$A_{j,k}$	Approximation coefficients (Yaklaşım katsayıları)
D_j	Detail coefficients at level j (j . seviyedeki ayrıntı katsayıları)
A_j	Approximation component at level j (j . seviyedeki yaklaşım bileşeni)
f_t	Forget gate of LSTM at time t (LSTM unutma geçidi)
i_t	Input gate of LSTM at time t (LSTM giriş geçidi)
$\tilde{C}_t$	Candidate cell state at time t (Aday hücre durumu)
C_t	Cell state at time t (Hücre durumu)
o_t	Output gate of LSTM at time t (LSTM çıkış geçidi)
h_t	Hidden state at time t (Gizli durum)
W_f, W_i, W_o	Weight matrices for forget, input, and output gates (Unutma, giriş ve çıkış geçitleri ağırlık matrisleri)
b_f, b_i, b_o	Bias vectors for forget, input, and output gates (Unutma, giriş ve çıkış geçitleri yanlılık vektörleri)
σ	Sigmoid activation function (Sigmoid aktivasyon fonksiyonu)
y_i	Actual load values (Gerçek yük değerleri)
$\hat{y}_i$	Predicted load values from LSTM (LSTM'den tahmin edilen yük değerleri)
r_t	Residual errors at time t (Artık hatalar)
$\hat{r}_t$	Predicted residual errors from XGBoost (XGBoost ile tahmin edilen artık hatalar)
y_t	Actual load value at time t (t . zamandaki gerçek yük değeri)
$\hat{y}_t^{\text{final}}$	Final predicted load value at time t (Son tahmin edilen yük değeri)

$L(r)$	Objective function for XGBoost (XGBoost amaç fonksiyonu)
f_k	k -th decision tree in XGBoost (XGBoost'taki k . karar ağacı)
$\ell(r_i, \hat{r}_i)$	Loss function (squared error) for residuals (Artık hatalar için kayıp fonksiyonu)
$\Omega(f_k)$	Regularization term in XGBoost (XGBoost düzenleme terimi)



KISALTMA LİSTESİ

ARIMA	Autoregressive Integrated Moving Average (Oto regresif Tmleik Hareketli Ortalama)
COVID-19	Coronavirus Disease 2019 (Koronavirs Hastalığı 2019)
DWT	Discrete Wavelet Transform (Ayrık Dalgaık Dnm)
dbN	Daubechies Wavelet (e.g., db5: Daubechies-5 wavelet) (Daubechies Dalgaığı)
GDP	Gross Domestic Product (Gayri Safı Yurtii Hasıla)
GRU	Gated Recurrent Unit (Kapılı Tekrarlayan Birim)
LSTM	Long Short-Term Memory (Uzun Kısa Sreli Hafıza)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yzde Hata)
MSE	Mean Squared Error (Ortalama Kare Hata)
RNN	Recurrent Neural Network (Tekrarlayan Sinir Ağı)
RMSE	Root Mean Squared Error (Kk Ortalama Kare Hata)
SARIMA	Seasonal Autoregressive Integrated Moving Average (Mevsimsel Oto regresif Tmleik Hareketli Ortalama)
RF	Random Forests (Rastgele Ormanlar)
SVR	Support Vector Regression (Destek Vektr Regresyonu)
U/V	Horizontal/Vertical wind components (in meteorological data) (Yatay/Dey rzgr bileenleri)
WI	Willmott Index (Willmott İndeksi)
XGBoost	Extreme Gradient Boosting (Aırđ Gradyan Artırma)
Adam	Adaptive Moment Estimation (optimizer) (Uyarlanabilir Moment Tahmini)

ŞEKİL LİSTESİ

Şekil 2.1	Temel Uzun Kısa Süreli Bellek (LSTM) Birimi	12
Şekil 2.2	XGBoost Algoritma Yapısı	14
Şekil 2.3	Özyinelemeli Sinir Ağı Mimarisi Yapısı	15
Şekil 2.4	Kapılı Özyinelemeli Sinir Ağı Yapısı	16
Şekil 3.1	COVID-19'un elektrik tüketimi üzerindeki etkisi.	22
Şekil 3.2	Eğitim süresi sonuçlarının dağılımı	24
Şekil 3.3	Eğitim süresi sonuçlarının dağılımı	25
Şekil 3.4	Zaman içinde saatlik yük ve haftalık hareketli ortalama eğilimleri.	26
Şekil 3.5	Modelde kullanılan özelliklerin korelasyon matrisi.	27
Şekil 3.6	Dalgacıklarla zenginleştirilmiş LSTM-XGBoost hibrit modelinin akış şeması.	28
Şekil 3.7	Enerji yük verisinin dalgacık ayrıştırması.	30
Şekil 3.8	Farklı modeller kullanılarak gerçek ve tahmin edilen yükün (kW) karşılaştırması.	32
Şekil 3.9	Hibrit modelin ve en güncel modellerin hata dağılımı.	33

TABLO LİSTESİ

Tablo 2.1	MAPE değerine göre tahmin doğruluğu yorumları	20
Tablo 3.1	Model parametreleri ve değerleri	23
Tablo 3.2	Model eğitim parametreleri	23
Tablo 3.3	LSTM mimarileri için elde edilen en iyi sonuçlar	23
Tablo 3.4	GRU mimarileri için elde edilen en iyi sonuçlar	24
Tablo 3.5	LSTM Modeli Parametreleri	30
Tablo 3.6	XGBoost Model Parametreleri	31
Tablo 3.7	Farklı Modeller için Hata Metikleri	32
Tablo 3.8	Yük Tahmini Metriği için Günün Zamanına Göre Analiz	34

DALGA DÖNÜŞÜMÜ ENTEGRELİ DERİN ÖĞRENME KULLANILARAK ÖNGÖRÜLEMİYEN OLAYLARI İÇEREN ELEKTRİK TÜKETİMİ TAHMİNİ

Hisham Alnour Adam HAMZA

Elektrik Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Danışman: Doç. Dr. Ali AJDER
Eş-Danışman: Dr. Öğr. Üyesi Ramazan AYAZ

Zaman serisi verilerinin tahmini, özellikle öngörülemeyen olayların varlığında, ekonomi, sağlık ve enerji gibi birçok alanda büyük bir zorluk teşkil etmektedir. Bu tezde, elektrik talebini tahmin etmek için dalgacık entegrasyonlu hibrit bir derin öğrenme modeli sunulmuştur. Bu model, LSTM ağlarını ve XGBoost algoritmasını birleştirmektedir. Çalışmada, ani ve yıkıcı olayların enerji talep desenleri üzerindeki etkilerini incelemek amacıyla COVID-19 pandemisi bir vaka çalışması olarak kullanılmıştır. Önerilen yaklaşım, zaman serisi verilerini farklı frekans bileşenlerine ayırmak için Ayrık Dalgacık Dönüşümü DWT kullanmakta ve modelin hem kısa vadeli hem de uzun vadeli eğilimlere karşı daha duyarlı olmasını sağlamaktadır. Bu güçlü hibrit model, sıralı verilerden zamansal bağımlılıkları öğrenen bir LSTM bileşeni ile artık hataları düzelten ikinci bir XGBoost bileşenini bir araya getirmektedir.

Araştırmada kullanılan veri seti, IEEE Dataport'tan alınmış olup, Mart 2017 ile Kasım 2020 tarihleri arasındaki saatlik elektrik tüketim verileri ve meteorolojik değişkenleri içermektedir. Bu veri aralığı, COVID-19 öncesi ve sonrası dönemleri kapsamaktadır. Deneysel sonuçlar, bu hibrit LSTM-XGBoost modelinin yalnızca LSTM modellerine kıyasla daha iyi bir performans sergilediğini ortaya koymuştur. Modelin başarımları ölçütleri sırasıyla MAE 19.875,15; RMSE 26.595,62; MAPE

1,78% ve WI 0,98 olarak hesaplanmıştır. Model, COVID-19 pandemisi gibi ani değişimlere karşı dayanıklılık göstermekte ve günün farklı saatlerinde değişen performans sergilemekte olup, sabah ve öğleden sonraki tahminlerde daha yüksek doğruluk elde edilmiştir.

Dalgacık ayrıştırmasının hibrit derin öğrenmeyle entegrasyonu, dalgalı ve belirsiz ortamlar için ölçeklenebilir bir çerçeve sunmaktadır. Bu çalışmanın sınırlılıkları arasında tatil verilerinin eksikliği ve potansiyel arz kaynaklı kesintiler yer almakta olup, gelecekteki çalışmalar için gerçek zamanlı veri entegrasyonu ve uyarlanabilir yeniden eğitme yöntemlerinin kullanılması önerilmektedir.

Anahtar Kelimeler: Ayrık dalgacık dönüşümü, elektrik tüketimi, hibrit LSTM-XGBoost, zaman serisi tahmini, öngörülemeyen olaylar, dalgacık destekli tahmin.

ABSTRACT

Forecasting of Electricity Consumption with Unpredictable Events using Wavelet-Integrated Deep Learning

Hisham Alnour Adam HAMZA

Department of of Electrical Engineering
Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Ali AJDER

Co-supervisor: Assist. Prof. Dr. Ramazan AYAZ

Forecasting time series data, particularly in the presence of unpredictable events, is a major challenge in various fields, including economics, health, and energy. In this thesis, a novel approach is presented to predict electricity demand using a wavelet-integrated hybrid deep learning model, which combines LSTM networks and XGBoost. This study uses the COVID-19 pandemic as a case study to explore the effect of sudden disruptive events on the patterns of energy demand. The suggested approach utilizes DWT to break up time series data down to several frequencies, allowing the model to be more sensitive towards both short-term and long-term trends. This is a strong hybrid model as it combines an LSTM element that learns the temporal dependencies from sequential data and a second XGBoost element that corrects the residual errors.

The dataset utilized in the research is taken from IEEE Dataport, which consists of hourly electricity consumption data and meteorological variables from March 2017 to November 2020, thus covering pre- and post-COVID-19 periods. Experimental results showed that this hybrid LSTM-XGBoost model has better performance than LSTM models used alone, with a MAE of 19,875.15, RMSE of 26,595.62, MAPE of 1.78%, and a WI of 0.98. The model exhibits strength in handling abrupt changes, such as those induced by the COVID-19 pandemic, and shows varying performance across various times of day, with morning and afternoon forecasts being more accurate.

The integration of wavelet decomposition with hybrid deep learning offers a scalable framework suitable for volatile environments. Limitations of this research, such as the absence of holiday data and potential supply-side disruptions, are discussed, alongside recommendations for future work, including the incorporation of real-time data and adaptive retraining methodologies.

Keywords: Discrete wavelet transform, electricity consumption, hybrid LSTM-XGBoost, time series prediction, unpredictable events, wavelet- enhanced forecasting.



1.1 Literatür Özeti

Elektrik tüketimi tahmini, enerji yönetiminde hem ekonomik hem de operasyonel zorlukların üstesinden gelmede hayati bir rol oynamaktadır. Doğru tahminler, elektrik şirketlerinin bilinçli kararlar almasına, arz stratejilerini optimize etmesine ve endüstriyel ve ticari enerji tedarikinde karşılaşılan operasyonel zorluklar ile maliyetlere ilişkin riskleri en aza indirmesine olanak tanır. Özellikle talebin zirve yaptığı dönemlerde arz ve talep dengesinin sağlanması, sistem güvenilirliğinin korunması açısından kritik öneme sahiptir [1–4].

ARIMA ve SARIMA gibi geleneksel istatistiksel yöntemler, doğrusal desenleri ve mevsimselliği etkili biçimde modelleyebilme yetenekleri nedeniyle zaman serisi tahmini için yaygın olarak kullanılmıştır. ARIMA, sınırlı veriyle satışları tahmin etmede etkili olduğunu kanıtlamış ve diğer geleneksel modellere kıyasla önemli doğruluk artışları sağlamıştır [5]. Benzer şekilde SARIMA, elektrik tüketim verilerindeki mevsimsel eğilimleri analiz etmekte başarılıdır ve periyodik desenler hakkında değerli bilgiler sağlar [6]. Ancak bu modeller, doğrusal olmayan desenler ve öngörülemeyen olaylarla baş etmekte zorlanır ve bu durum, değişken koşullara uyumlarını sınırlar. Ayrıca, parametre ayarlaması için uzman bilgisine bağımlı olmaları, pratikte zorluklara neden olmaktadır [7]. Bu çalışmada, söz konusu kısıtlamalar, COVID-19 pandemisi gibi olayların yarattığı düzensiz dalgalanmaları yönetebilen gelişmiş modellere duyulan ihtiyacı vurgulamaktadır.

SVM, RF ve XGBoost gibi makine öğrenimi teknikleri, özellikle karmaşık ve gürültülü veri kümelerinde zaman serisi tahmini için güçlü araçlar olarak ortaya çıkmıştır. Rastgele Ormanlar, kısa zaman serilerinde gecikmeli değişkenlerden faydalanarak hava durumu tahmini ve lojistik gibi uygulamalarda üstün performans göstermiştir [8], [9]. Özellik tabanlı ilişkileri modellemedeki verimliliğiyle tanınan XGBoost, hibrit yapılarda tahmin doğruluğunu artırmaktadır [10]. Bu modeller, elektrik fiyatlandırması gibi ani değişimlerin veya sınırlı verilerin söz konusu

olduğu senaryolarda üstün performans sergiler; dinamik özellik ölçeklendirmesiyle desteklenen hibrit yaklaşımlar yüksek hassasiyeti korur [11]. Bu çalışma, hibrit LSTM-XGBoost modelinde XGBoost'un artık hata düzeltme yeteneklerinden faydalanarak, öngörülemeyen olaylar için tahmin doğruluğunu artırmaktadır.

Zaman serisi tahmininde RNN, LSTM ağları ve GRU gibi derin öğrenme yöntemleri, karmaşık zamansal bağımlılıkları yakalayarak büyük bir devrim yaratmıştır. Bu modeller, finans ve enerji gibi çeşitli alanlarda doğrusal olmayan ve gürültülü verileri işlerken geleneksel yöntemlere kıyasla üstün performans sergilemektedir [12], [13]. Özellikle LSTM ağları, uzun süreli dizi bilgilerini koruyabilme yetenekleri sayesinde elektrik yük tahmini için son derece etkilidir. LSTM'nin, XGBoost gibi tekniklerle birleştirildiği hibrit mimariler, hem zamansal hem de özellik tabanlı desenleri ele alarak performansı daha da artırmaktadır [14]. Bu araştırma, COVID-19 pandemisi sırasında gözlemlenen öngörülemeyen olaylarla başa çıkmak amacıyla, LSTM'nin dizi tahmin yeteneklerini dalgacık ayrıştırmasıyla entegre etmektedir.

Kısa vadeli elektrik tüketimi tahmini, enerji yönetimi ve şebeke istikrarı için hayati öneme sahiptir. Son yıllarda, tahmin doğruluğunu artırmak amacıyla hibrit modeller ve derin öğrenme yöntemleri kullanılmaktadır. mevsimsel değişimleri ele almak için GRU ve Prophet modellerini birleştirmiş, [15] ise çok boyutlu hanehalkı tüketim verileri üzerinde LSTM ağlarını kullanmıştır. [16], çevresel değişkenleri içeren hibrit bir RNN-LSTM modeli önererek kısa vadeli tahmin doğruluğunu artırmıştır. Transformer ağları da RNN'nin sınırlamalarını aşarak gün öncesi tahminlerde başarılı sonuçlar vermiştir [17]. Bu gelişmeler, bu çalışmanın normal koşullar altındaki kısa vadeli tahmin doğruluğunu sağlamaya odaklanan yaklaşımıyla örtüşmekte olup, öngörülemeyen durumları dalgacık tabanlı tekniklerle ele alarak kapsamını genişletmektedir.

COVID-19 pandemisi gibi anormal olaylar sırasında tahmin yapmak, tüketim desenlerindeki ani değişimler nedeniyle oldukça zordur. Geleneksel modeller bu tür değişimlere genellikle uyum sağlayamaz ve bu da doğruluğun azalmasına neden olur [18], [19]. Yenilenebilir enerji kaynaklarının entegrasyonu ise tahminleri daha da karmaşık hale getiren ek değişkenlikler oluşturur [20], [21]. Bu araştırma, dalgacık ayrıştırmasını kullanarak hibrit LSTM-XGBoost modelini ani değişimlere karşı hassas hale getirerek bu sorunları ele almaktadır. Böylece pandemi gibi öngörülemeyen olaylar sırasında güçlü bir performans sağlanmaktadır. Bu uyarlanabilirlik, değişken koşullar altında güvenilir enerji yönetimi için kritik öneme sahiptir.

DWT, zaman serilerini çoklu frekans bileşenlerine ayırmak için kullanılan temel bir araçtır ve çok çözünürlüklü analiz yapılmasına olanak tanır. DWT, durağan olmayan verilerle özellikle başarılıdır; kısa vadeli dalgalanmalarla uzun vadeli eğilimleri aynı anda yakalayabilmek için farklı ölçeklerde özellikler çıkarır. Bu çalışmada, DWT elektrik tüketim verilerini yaklaşık ve detay katsayılarına ayırarak, modelin anormallikleri tespit etme yeteneğini artırmaktadır.

Dalgacık dönüşümleri, özellikle karmaşık veri kümeleri için zaman-frekans bilgisi sağlayarak tahmin doğruluğunu artırır. [22], [23], dalgacık dönüşümlerinin elektrik ve finansal tahminlerdeki etkinliğini vurgulamaktadır. Bu araştırmada, DWT, hibrit modelin COVID-19 pandemisi gibi öngörülemez olaylara karşı duyarlılığını artırmakta ve modelin sık sık yeniden eğitilmesine gerek kalmadan uzun dönemli doğru tahminler yapılmasını sağlamaktadır. Bu yaklaşım, dalgacık dönüşümlerinin düzensiz dalgalanmaları yakalama konusundaki başarısını ortaya koyan önceki çalışmalarla uyumludur.

LSTM'nin, XGBoost veya Rastgele Ormanlar gibi tekniklerle birleştirildiği hibrit modeller, elektrik tüketimi tahmininde doğruluğu önemli ölçüde artırmıştır. [24], Rastgele Ormanlar ile çift yönlü LSTM'yi entegre ederek kısa vadeli tahminlerde tekil modellere kıyasla üstün performans elde etmiştir. [25] ise, ilk XGBoost tahminlerini LSTM ile iyileştirerek doğrusal olmayan desenler için doğruluğu artırmıştır. Bu çalışmada önerilen hibrit LSTM-XGBoost modeli, LSTM'nin zamansal öğrenme yeteneklerini ve XGBoost'un hata düzeltme gücünü bir araya getirerek öngörülemez olaylara karşı sağlam bir performans sunmaktadır.

Spektral ayrıştırma teknikleri, dalgacık dönüşümleri gibi yöntemler aracılığıyla, hibrit modellerin dalgalı verilerle başa çıkma yeteneklerini artırmaktadır.[26], çok değişkenli tahmin performansını artırmak amacıyla Transformer yapılarıyla birlikte spektral kümeleme yöntemini kullanmıştır. Bu çalışmada ise, dalgacık tabanlı özellikler LSTM-XGBoost modeline entegre edilerek farklı zaman ölçeklerinin analiz edilmesi sağlanmış ve COVID-19 pandemisi gibi olaylar sırasında hem kısa hem de uzun vadeli tahmin ufukları için modelin uyarlanabilirliği geliştirilmiştir. Bu entegrasyon, karmaşık zamansal dinamiklerin yakalanması açısından kritik bir rol oynamaktadır.

Bu çalışma, COVID-19 gibi öngörülemez olayları hedef alan, LSTM ve XGBoost'u birleştiren dalgacık-entegreli bir hibrit model önererek literatüre katkıda bulunmaktadır. Dalgacık ayrıştırma, frekans bileşenlerini izole ederek modelin hem mevsimsel değişimlere hem de anormal dalgalanmalara karşı duyarlılığını artırır. Bu hibrit yaklaşım, geleneksel modellerin sınırlamalarını etkili

bir şekilde aşarken, LSTM'nin zamansal öğrenme yetenekleri ve XGBoost'un özellik öğrenme gücünden faydalanır. Ortaya çıkan model, özellikle doğrusal olmayan desenler ve öngörülemeyen değişimlerin söz konusu olduğu senaryolarda güçlü tahmin doğruluğu sergilemektedir. Ayrıca, dalgacık tabanlı özellikler, modelin farklı tahmin ufuklarına uyarlanabilirliğini artırmakta ve modern enerji şebekeleri için yanıt verebilir tahmin modellerinin geliştirilmesine değerli katkılar sağlamaktadır [27–30].

1.2 Tezin Amacı

Bu tezin amacı, öngörülemeyen olayların varlığında elektrik tüketim tahmininin doğruluğunu ve sağlamlığını artırmak için dalga dönüşümüyle geliştirilmiş bir hibrit LSTM-XGBoost modeli geliştirmek ve değerlendirmektir. Model, Ayrık Dalga Dönüşümü'nü kullanarak zaman serisi verilerini çoklu frekans bileşenlerine ayırarak kısa vadeli dalgalanmaları ve uzun vadeli eğilimleri yakalamayı hedefler. LSTM'nin sıralı öğrenme yeteneklerini ve XGBoost'un kalan hata düzeltme gücünü birleştirerek, özellikle COVID-19 pandemisi gibi düzensiz ve anormal tüketim kalıplarını içeren senaryolarda tahmin doğruluğunu artırmayı amaçlar. Araştırma, IEEE Dataport'tan alınan ve COVID-19 pandemisinden etkilenen gerçek dünya elektrik tüketim verilerini kullanarak modelin performansını değerlendirir ve bunu tek başına LSTM modelleriyle karşılaştırarak etkinliğini gösterir. Bu metodolojinin başarılı uygulaması, akıllı şebeke yönetimi, sürdürülebilir enerji planlaması ve öngörülemeyen kesintilere karşı güç sistemlerinin dayanıklılığını artırabilir.

1.3 Hipotez

Bu tez, aşağıdaki hipotezi test etmeyi amaçlamaktadır, Dalga dönüşümüyle geliştirilmiş hibrit LSTM-XGBoost modeli, öngörülemeyen olayların (örneğin, COVID-19 pandemisi) neden olduğu düzensiz elektrik tüketim kalıplarını tahmin etmede, tek başına LSTM modellerine kıyasla daha yüksek doğruluk ve sağlamlık sağlayacaktır. Bu hipotez, dalga dönüşümünün çok çözünürlüklü analizinin, LSTM'nin zamansal bağımlılıkları öğrenme yeteneğiyle ve XGBoost'un özellik tabanlı hata düzeltme kapasitesiyle birleştiğinde, karmaşık ve değişken zaman serisi verilerini daha etkili bir şekilde modelleyeceği varsayımına dayanmaktadır. Modelin performansı, MAE, RMSE, MAPE ve WI gibi metrikler kullanılarak değerlendirilecektir.

2.1 Veri Toplama ve Ön İşleme

Bu araştırmada kullanılan veri seti, IEEE Dataport'tan [31] alınmıştır ve Mart 2017'den Kasım 2020'ye kadar isimsiz bir bölgenin saatlik elektrik tüketim verilerini içermektedir. Bu dönem, hem pandemi öncesi tüketim kalıplarını hem de COVID-19 pandemisi nedeniyle yaşanan aksamaları kapsadığı için özellikle önemlidir ve beklenmedik olayların enerji talebi üzerindeki etkisini modellemek için güçlü bir vaka çalışması sunar.

Veri seti, 31.912 saatlik gözlem içerir ve elektrik tüketimini etkilediği bilinen birkaç meteorolojik değişkeni kapsar, örneğin:

- Sıcaklık
- Nem
- Bulut örtüsü
- Basınç
- Rüzgar bileşenleri (yatay ve dikey)

Ayrıca, elektrik talebinin döngüsel doğasını yakalamak için zamansal değişkenler eklenmiştir, bunlar:

- Aylar
- Haftanın günleri
- Saatler

Bu zamansal özellikler, elektrik tüketim kalıplarındaki doğal periyodikliği modellemek için çok önemlidir.

2.1.1 Eksik Değerler ve Aykırı Değerlerin İşlenmesi

Veri setinin güvenilirliğini ve bütünlüğünü sağlamak için eksik değerler ve aykırı değerleri ele almak amacıyla ön işleme adımları uygulanmıştır. Özellikle meteorolojik değişkenlerdeki eksik değerler, istatistiksel ve makine öğrenimi tabanlı tekniklerin bir kombinasyonu kullanılarak doldurulmuştur. Bu yöntemler, geçmiş verilerle olan korelasyonlardan yararlanarak eksik girişleri tahmin etmiş ve veri setinde sürekliliği korumuştur.

Verilerdeki aykırı değerler, modelin performansını çarpıtmalarını önlemek için tespit edilmiş ve düzeltilmiştir. Kaynak makalede belirli aykırı değer düzeltme yöntemleri detaylandırılmamış olsa da, winsorizasyon veya istatistiksel eşiklere dayalı kaldırma gibi standart uygulamaların muhtemelen kullanıldığı düşünülmektedir.

2.2 Yöntem ve Modelleme

2.2.1 Zaman Serisi Analizinde Dalgacık Dönüşümleri

Dalgacık dönüşümleri, zamanla değişen desenler sergileyen elektrik tüketimi gibi durağan olmayan zaman serilerini analiz etmek için çok yönlü bir araçtır. Fourier dönüşümlerinin zaman çözünürlüğü eksikliğinin aksine, dalgacık dönüşümleri çoklu çözünürlük analizi sağlar, böylece hem zaman hem de frekans bileşenlerini eşzamanlı olarak yakalayabilir. Bu özellik, karmaşık ve zamana bağlı yapılar içeren verilerin daha etkili şekilde analiz edilmesine olanak tanır.

2.2.2 Ayrık Dalgacık Dönüşüm Teorisi

DWT, ayrık zamanlı sinyaller üzerinde yaygın olarak kullanılan ve hesaplama açısından verimli bir dalgacık dönüşüm çeşididir. DWT, bir sinyali, Daubechies dalgacı gibi bir dalgacık temeli kullanarak yaklaşık (düşük frekanslı) ve detay (yüksek frekanslı) katsayılar ayırır [32]. Bu süreç, eğilimleri yakalamak için alçak geçiren filtreleme ve dalgalanmaları yakalamak için yüksek geçiren filtreleme adımlarının yinelemeli olarak uygulanması ve ardından aşağı örnekleme işlemini içerir. Böylece sinyal, çoklu ölçeklerde farklı frekans bileşenlerine ayrılarak analiz edilebilir hale gelir.

Matematiksel olarak, DWT bir $x(t)$ sinyalini şu şekilde temsil eder:

$$x(t) = \sum_j \sum_k A_{j,k} \psi_{j,k}(t) \quad (2.1)$$

Burada $\psi_{j,k}(t)$, dalgacık fonksiyonlarını; $A_{j,k}$ ise j ölçeğinde ve k konumunda elde edilen katsayıları ifade etmektedir [33]. Bu çok seviyeli ayrıştırma işlemi, kısa vadeli dalgalanmaları ve uzun vadeli eğilimleri birbirinden ayırarak, DWT'yi karmaşık zaman serilerinin ön işlenmesi için ideal bir yöntem haline getirmektedir.

2.3 Zaman serisi tahmin teknikleri

2.3.1 Geleneksel istatistiksel yöntemler (ARIMA, SARIMA)

Zaman serisi tahmini, enerji yönetimi, finans, ekonomi ve meteoroloji gibi birçok alanda hayati bir rol oynamaktadır. Zaman serisi tahmini için kullanılan klasik istatistiksel yaklaşımlar arasında, ARIMA ve onun mevsimsel uzantısı olan Mevsimsel ARIMA SARIMA, doğrusal zaman serilerini modellemedeki yorumlanabilirliği ve etkinliği nedeniyle yaygın olarak benimsenmiştir. Box ve Jenkins tarafından tanıtılan ARIMA modeli [34], ARMA çerçevesini genişletir ve durağan olmayan zaman serilerini analiz etmek üzere tasarlanmıştır. Klasik ARMA modeli zaman serisinin durağan olduğunu varsayarken, ARIMA bu verileri önce durağan hale getirerek modelleyebilir. Bu genellikle, eğilimlerin ve mevsimselliğin sonlu fark alma yöntemiyle giderilmesiyle gerçekleştirilir [35]. Durağan bir zaman serisi hem sinyal hem de gürültü bileşenlerini içerir. ARIMA modeli, önce gürültüden ayrılan sinyal bileşenini modellemeye odaklanır ve ardından gelecekteki zaman noktaları için tahminler üretir [36]. Adından da anlaşılacağı gibi, üç bileşenin birleşiminden oluşur [37]:

- AR: Otoresresyon. Bir gözlem ile önceki gözlemler arasındaki bağımlılık ilişkisini kullanan regresyon modeli (model parametresi p).
- I: Entegrasyon. Zaman içindeki farklı gözlemler arasındaki farkların hesaplanması (model parametresi d), zaman serisini durağan hale getirmeyi amaçlar.
- MA: Hareketli Ortalama. Zaman gecikmeli gözlemler üzerine uygulanan hareketli ortalama modeliyle oluşturulan hata terimleri ile gözlemler arasındaki olası bağımlılığı dikkate alan yaklaşım (model parametresi q).

p dereceli AR modeli, $AR(p)$, aşağıdaki gibi doğrusal bir süreç olarak yazılabilir:

$$x_t = c + \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t \quad (2.2)$$

burada x_t statik değişkeni, c sabit terim, ϕ_i zaman gecikmesi adımlarındaki $(1, 2, \dots, p)$ otokorelasyon katsayıları ve ε_t sıfır ortalamalı ve σ^2 varyanslı Gauss beyaz gürültü serisinin örnekleridir.

q dereceli basit bir hareketli ortalama modeli, MA(q), şu şekilde verilebilir:

$$x_t = \mu + \sum_{i=0}^q \theta_i \varepsilon_{t-i} \quad (2.3)$$

burada μ genellikle 0 olan x_t 'nin beklenen değeri, θ_i ise zaman serisinin stokastik teriminin mevcut ve geçmiş değerlerine uygulanan ağırlıklardır ve $\theta_0 = 1$ 'dir. ε_t sıfır ortalamalı ve σ^2 varyanslı Gauss beyaz gürültü serisi olarak kabul edilir.

Bu iki model, yani otoregresyon ve hareketli ortalama modellerinin birleşimi ile (p, q) sınıfında ARMA modeli oluşturulur:

$$x_t = c + \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t + \sum_{i=0}^q \theta_i \varepsilon_{t-i} \quad (2.4)$$

burada $\phi_i \neq 0$, $\theta_i \neq 0$, $\sigma^2 > 0$.parametreleri sırasıyla AR ve MA modellerinin derecelerini temsil eder.

Genel ARIMA modeli, zaman serisinin durağanlığını garanti eden entegrasyon terimini de içerecek şekilde ARIMA(p, d, q) olarak yazılır [37] ve şu şekilde ifade edilir:

$$\nabla^d x_t = c + \sum_{i=1}^p \phi_i \nabla^d x_{t-i} + \sum_{i=0}^q \theta_i \varepsilon_{t-i} \quad (2.5)$$

burada ∇^d , d derecesinde bir fark operatörüdür ve x_t zaman serisinin durağan olmama özelliğini ortadan kaldırmayı amaçlar [38].

ARIMA mevsimsiz veriler için uygunken, SARIMA (Mevsimsel ARIMA) modeli ARIMA'yı mevsimselliği içerecek şekilde genişletir. SARIMA modeli şu şekilde gösterilir:

$$\text{SARIMA}(p, d, q)(P, D, Q)_s \quad (2.6)$$

Matematiksel formu ise şöyledir:

$$\Phi(B^s)\phi(B)(1-B)^d(1-B^s)^D y_t = \Theta(B^s)\theta(B)\varepsilon_t \quad (2.7)$$

Burada:

- s mevsimsel periyodun uzunluğudur,
- $\Phi(B^s) = 1 - \Phi_1 B^s - \dots - \Phi_P B^{sP}$ mevsimsel AR (otoregresif) operatörüdür,
- $\Theta(B^s) = 1 + \Theta_1 B^s + \dots + \Theta_Q B^{sQ}$ mevsimsel MA (hareketli ortalama) operatörüdür,
- $(1 - B^s)^D$ mevsimsel fark alma operatörüdür.

SARIMA modelleri hem trendi hem de mevsimselliği yakalayabilir ve bu nedenle aylık satışlar veya elektrik talebi gibi güçlü mevsimsel bileşenlere sahip tahmin görevleri için oldukça uygundur. [39] SARIMA'nın gerçek dünya mevsimsel zaman serisi uygulamalarındaki dayanıklılığını vurgulamaktadır.

Örneğin, [40] İspanya'daki elektrik fiyatlarını tahmin etmek için SARIMA'yı uygulamış ve modelin günlük ve haftalık elektrik fiyatı döngüselliğini doğru şekilde yakaladığını bulmuştur. Benzer şekilde, [41] SARIMA'nın endüstriyel talep tahminlerinde mevsimsel verilerle çalışırken ARIMA'dan daha iyi performans gösterdiğini ortaya koymuştur.

2.3.2 Destek Vektör Makineleri

SVM esas olarak sınıflandırma görevlerinde kullanılan denetimli bir makine öğrenmesi algoritmasıdır; ancak regresyon ve zaman serisi tahmini gibi alanlarda da kullanılabilir. SVM, vektör uzayında iki sınıfı ayıran en uygun hiperdüzlemi belirlemek için doğrusal bir model oluşturur. Bu en uygun hiperdüzlem, her sınıfa ait en yakın veri noktaları ile hiperdüzlem arasındaki mesafe olan marjın maksimize edilmesiyle belirlenir. Bu en yakın veri noktalarına “destek vektörleri” denir [42]. -1 ve +1 olarak etiketlenmiş iki sınıf, d boyutlu bir uzayda tanımlandığında, bu sınıfları ayıran hiperdüzlem şu denklemle ifade edilebilir:

$$\vec{w} \cdot \vec{x} + b = 0 \quad (2.8)$$

Negatif (-1) ve pozitif (+1) örneklerdeki $\vec{x}_i$ örüntüsü (pattern) şu şekilde formüle edilebilir:

$$\vec{w} \cdot \vec{x} + b \leq -1 \quad (2.9)$$

$$\vec{w} \cdot \vec{x} + b \geq +1 \quad (2.10)$$

En büyük marj değeri $\frac{1}{\|\vec{w}\|}$ 'i bulmak için kuadratik programlama kullanılır ve bu, aşağıdaki ifadeyi minimize ederek gerçekleştirilir:

$$\min_{\vec{w}} \tau(\vec{w}) = \frac{1}{2} \|\vec{w}\|^2 \quad (2.11)$$

Lagrange çarpanları kullanılarak, kuadratik programlamanın asal (primal) formu aşağıdaki denklemle ikili (dual) forma dönüştürülebilir:

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i (\vec{x}_i \cdot \vec{w} + b) - 1) \quad (2.12)$$

2.3.3 Rastgele Ormanlar

Breiman tarafından geliştirilen RF, birden fazla karar ağacı oluşturarak ve bunların tahminlerini birleştirerek doğruluk ve sağlamlığı artırmayı amaçlayan topluluk (ensemble) makine öğrenme yöntemidir [43]. RF algoritmasının tek adımlı zaman serisi tahmini için uygulanması oldukça basittir ve standart regresyon görevlerindeki yöntemle benzerlik gösterir. Eğitilmiş RF modelinin öğrendiği fonksiyon g , giriş dizisi $x_1, \dots, x_n$ kullanılarak x_{n+1} 'in tahmininde kullanılır. k adet gecikmeli değişken (lagged variable) kullanıldığında, $t = n + 1$ anındaki x_{n+1} tahmini şu şekilde ifade edilebilir:

$$x_t = g(x_{t-1}, \dots, x_{t-k}), \quad t = k + 1, \dots, n + 1 \quad (2.13)$$

Fonksiyon g kapalı formda değildir ancak, boyutu $n - k$ olan bir eğitim veri kümesi kullanılarak Rastgele Orman algoritması ile öğrenilebilir. Her bir eğitim örneğinde hedef (bağımlı) değişken x_t olup, burada $t = k + 1, \dots, n + 1$, ve giriş (bağımsız) değişkenler $x_{t-1}, \dots, x_{t-k}$ gecikmeli değerlerinden oluşur. Gecikmeli değişken sayısı k arttıkça, eğitim veri kümesinin boyutu olan $n - k$ buna karşılık azalır. Bu eğitim.

2.3.4 Uzun Kısa Süreli Bellek Ağları


Yıllar içinde, RNN eğitimindeki zorlukları aşmaya yönelik çeşitli girişimlerde bulunulmuştur. Bu zorluklar, Hochreiter ve Schmidhuber tarafından 1997 yılında önerilen LSTM ağlarıyla büyük ölçüde giderilmiştir. LSTM ağları, yinelemeli sinir ağı yapısından türetilmiş bir model varyasyonudur. Bu ağlar, geleneksel RNN'lerin büyük giriş boşlukları karşısında ilgili bilgiyi koruyamaması nedeniyle öğrenmekte zorlandığı uzun vadeli bağımlılıkların öğrenilmesinde önemli bir rol oynamaktadır [44].

LSTM'ler, geleneksel RNN'lerde yaygın olarak görülen "kaybolan gradyan" problemini azaltmak için tasarlanmıştır. LSTM, ileri beslemeli (feedforward) sinir ağları temelinde geri besleme bağlantılarına sahip bir yinelemeli sinir ağı yapısıdır ve bilgi arasındaki uzun vadeli bağımlılıkları öğrenme yetisine sahiptir. En büyük avantajlarından biri, yalnızca tekil veri noktalarını değil, tüm veri yapısını işleyebilmesidir. Bu özelliği sayesinde makine çevirisi, konuşma tanıma gibi yeni teknolojilerde yaygın bir şekilde kullanılmaktadır [45].

İlk ortaya çıktığında giriş-çıkış-hücre yapısını içeren LSTM'ler, zamanla geliştirilmiş ve daha yetkin hale getirilmiştir. Günümüzdeki LSTM yapısı genel hatlarıyla hücreler, giriş-çıkışlar ve unutulacak bilgilere ilişkin kapılardan (gates) oluşmaktadır. Bu yapının içindeki "hafızalar", hücreler olarak adlandırılmaktadır. LSTM hücre yapısına yeni bilgi durumları eklenebilir, mevcut hücrelerden bilgi çıkarılabilir ve bu süreç kapılar aracılığıyla koordine edilir. Kapılar, hücreye bilgi giriş ve çıkışını sağlar. Hücreler, önceki bilgileri ve mevcut durumda işlenecek yeni girdileri bir arada tutar.

Olah'a [46] göre, LSTM'ler bir zincir yapısı şeklinde tasarlanmıştır; ancak bu zincir içinde bulunan yinelemeli modülün yapısı klasik RNN'lerden farklıdır. Standart bir yinelemeli sinir ağı gibi tek bir nöral ağ katmanı yerine, birbirleriyle özel bir etkileşim yöntemine sahip dört katmandan oluşur.

LSTM ağı, hücreler olarak adlandırılan hafıza bloklarından oluşur. Hücre durumu ve gizli durum (hidden state), bir sonraki hücreye aktarılır. Hücre durumu, verilerin esasen değişmeden ileriye doğru akmasına olanak tanıyan ana akış veri zinciridir. Ancak bazı doğrusal dönüşümler meydana gelebilir. Hücre durumuna veri eklemek veya veriyi çıkarmak gibi işlemler, sigmoid kapıları aracılığıyla yapılabilir. Bir kapı, farklı ağırlıklara sahip bir katman veya bir dizi matris işlemiyle benzer şekilde çalışır. LSTM'ler, uzun vadeli bağımlılık sorununu önlemek için hafızalama sürecini kontrol eden kapılardan oluşur.



Şekil 2.1 Temel Uzun Kısa Süreli Bellek (LSTM) Birimi

Bir LSTM ağı oluşturmanın iki aşaması vardır: birincisi, gerekli olmayan ve hücreden çıkarılacak bilgilerin belirlenmesidir. Verilerin tanımlanıp dışlanması süreci, son LSTM biriminin $(h_t - 1)$ t-1 zamanındaki çıktısını ve mevcut girdiyi (X_t) t zamanında alarak belirleyen sigmoid fonksiyonu ile yapılır. Ayrıca, sigmoid fonksiyonu eski çıktının hangi kısmının silineceğini de belirler. Bu kapıya unutma kapısı (forget gate veya f_t) denir; burada f_t , hücre durumu $(C_t - 1)$ içindeki her bir değere karşılık gelen 0 ile 1 arasında değişen değerlere sahip bir vektördür.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (2.14)$$

Burada σ , sigmoid fonksiyonunu, W_f ve b_f ise unutma kapısının ağırlık matrisleri ve önyargısını (bias) ifade etmektedir. Bir sonraki adım, yeni giriş (X_t) bilgisini hücre durumunda saklamak ve güncellemektir. Bu adım iki bölümden oluşur: sigmoid katmanı ve tanh katmanı. İlk olarak, sigmoid katmanı yeni bilginin güncellenip güncellenmeyeceğine (0 veya 1) karar verir, ikinci olarak ise tanh fonksiyonu, geçen değerlere (-1 ile 1 arasında) önem düzeylerine göre ağırlık verir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2.15)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (2.16)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t, \quad (2.17)$$

Burada, C_{t-1} ve C_t , sırasıyla $t - 1$ ve t zamanlarındaki hücre durumlarını ifade ederken, W ve b , hücre durumunun ağırlık matrisleri ve önyargısını (bias) temsil etmektedir. N_t yeni hücreyi ifade eder. Son adımda, çıktı değerleri (h_t) çıkış hücre durumuna (O_t) dayanır, ancak filtrelenmiş bir versiyon olarak. İlk olarak, bir sigmoid katmanı, hücre durumunun hangi bölümlerinin çıkışa ulaşacağına karar verir. Ardından, sigmoid kapısının çıktısı (O_t), hücre durumundan (C_t) elde edilen yeni değerlerle, tanh katmanından geçirilerek çarpılır ve -1 ile 1 arasında bir değer bulunur.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (2.18)$$

$$h_t = \tanh(C_t), \quad (2.19)$$

Burada, W_o ve b_o , sırasıyla çıkış kapısının ağırlık matrisleri ve önyargısını (bias) ifade etmektedir [47].

2.3.5 XGBoost

XGBoost, ifadesinin kısaltmasıdır. Bu, özellikle veri araştırmacıları tarafından pek çok veri yarışmasında ve makine öğrenimi yarışmalarında kullanılan, diğer yöntemlere kıyasla daha üstün performans gösteren bir makine öğrenimi yöntemidir. XGBoost, sınıflandırma ve regresyon alanlarında uygulanabilir olup, birçok pratik durumda doğruluğu kanıtlanmıştır [48]. XGBoost, 2016 yılında Tianqi Chen ve Carlos Guestrin tarafından gradyan artırma tekniğinin geliştirilmesiyle tanıtılmıştır. Gradyan artırma tekniğinde analiz, kayıp fonksiyonunun birinci türevi ile yapılırken, XGBoost tekniğinde kayıp fonksiyonu Taylor serisi genişlemesiyle iyileştirilmiştir. XGBoost algoritmasındaki tahmin fonksiyonu, Denklem 2.20'de gösterildiği şekilde oluşturulmuştur.

$$L(\Phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (2.20)$$


İlk terim, kayıp fonksiyonunu temsil eder ve hedef sınıfı (y_i) ile tahmin edilen sınıfı ($\hat{y}_i$) arasındaki farkı ölçer. İkinci terim, modelin karmaşıklığını kontrol ederek aşırı öğrenmeyi (overfitting) önlemek amacıyla kullanılan bir ceza terimidir. Bu ceza terimi, Denklem 2.8'de gösterilmiştir.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda ||w||^2 \quad (2.21)$$

Bu ifadede, T ağaçtaki dal sayısını, w her dalın performans skorunu ve γ ile λ düzenleme parametrelerini temsil eder. Tahmin fonksiyonunu optimize etmek için iteratif bir yaklaşım benimsenir ve bu iterasyon, adım t Denklem 2.9'a kadar devam eder. Optimizasyon sürecini hızlandırmak için, tahmin fonksiyonuna ikinci dereceden bir Taylor serisi genişlemesi uygulanabilir.

$$L^{(t)} = \sum_{i=1}^n l \left(y_i, \hat{y}_i^{(t-1)} + f_t(x_i) \right) + \Omega(f_t) \quad (2.22)$$

XGBoost modelinin şematik açıklaması Şekil 2.2'de verilmiştir.



Şekil 2.2 XGBoost Algoritma Yapısı

2.3.6 Tekrarlayan Sinir Ağları

RNN, zamansal bilgiyi koruma yetenekleri sayesinde ardışık verileri modellemede özellikle uygun olan bir yapay sinir ağı sınıfıdır [49]. RNN'ler, önceki zaman adımlarının belleği olarak işlev gören gizli bir durumu koruyarak ardışık verileri işlemek üzere tasarlanmıştır. İleri beslemeli sinir ağlarının aksine, RNN'ler zaman adımları boyunca bilginin kalıcılığını sağlayan döngüler içerir [50]. Bir RNN'in temel yapısı, bir giriş katmanı, bir tekrarlayan gizli katman ve bir çıkış katmanından


oluşur. Her bir zaman adımında t , ağ bir girdi x_t alır, gizli durumunu h_t olarak günceller ve bir çıktı y_t üretir. Gizli durum aşağıdaki denklemlerle güncellenir:

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b_h), \quad (2.23)$$

$$y_t = W_y h_t + b_y, \quad (2.24)$$

Burada W_h gizli durum için ağırlık matrisi, W_x giriş ağırlık matrisi, W_y çıkış ağırlık matrisi, b_h ve b_y ise bias terimleridir; σ ise aktivasyon fonksiyonudur (genellikle tanh veya sigmoid kullanılır). Bu özyineli yapı, RNN'lerin zaman serisi verilerindeki zamansal ilişkileri modellemesine olanak tanır [51]. Ancak, standart RNN'ler uzun vadeli bağımlılıkları öğrenme yeteneklerini kısıtlayan "azalan gradyan" (vanishing gradient) problemiyle karşı karşıyadır [52]. Bu sınırlama, bilgi akışını düzenlemek ve gradyan sorunlarını hafifletmek amacıyla geçit (gate) mekanizmaları içeren GRU [53] ve LSTM [54] gibi gelişmiş mimarilerin geliştirilmesine yol açmıştır.

Bu yöntem, zaman serileri, ses, metin gibi sıralı verilerdeki bağımlılıkları modellemek için tasarlanmıştır. Sıralı veriler, aynı ağırlıklar kullanılarak tekrar tekrar işlenir. RNN modelinin mimari yapısı Şekil 2.3'te verilmiştir [55]. Şekil incelendiğinde, sonucun, bir sonraki adımda kullanılacak olan giriş verisini beslediği açıkça ortaya konmuştur. Diğer bir deyişle, h_0 ve X_1 kullanılarak h_1 için giriş X_0 elde edilir. Sonraki adımlar aynı şekilde devam eder.



Şekil 2.3 Özyinelemeli Sinir Ağı Mimarisi Yapısı

2.3.7 Kapılı Tekrarlayan Birimler

GRU, LSTM'nin giriş ve unutma kapılarını bir güncelleme kapısı altında birleştirir ve buna ek olarak bir sıfırlama kapısı ekler [56]. Ayrıca, LSTM'deki hücre ve gizli durum vektörlerini tek bir vektör altında birleştirir. Sonuç olarak, standart

LSTM'den daha az karmaşık modeller oluşturur ve çeşitli konularda LSTM'den daha iyi doğruluk sağlayabilir.

Denklemler (2.11–2.15)'te, $h_t \in R^d$ hücrenin gizli durumunu, $x_t \in R^m$ hücrenin girdisini gösterir ve m girişin boyutunu ifade eder. $z_t \in R^d$ hücrenin çıktısıdır. $W_u, W_r, W_h \in R^{d \times d}$ sırasıyla giriş, çıkış, unutmaya kapıları ve hücre durumu ile ilişkili ağırlıkları gösterir. $V_u, V_r, V_h \in R^{d \times m}$ ve $b_i, b_o, b_f, b_c \in R^d$ mevcut girişle ilişkili ağırlıkları ve sapma (bias) vektörlerini ifade eder. $i_t, o_t, f_t \in R^d$ sırasıyla giriş, çıkış ve unutmaya kapısı vektörleridir. σ , $[0, 1]$ aralığında çıktı veren sigmoid fonksiyonu, $\tanh$ ise $[-1, 1]$ aralığında çıktı veren hiperbolik tanjant fonksiyonudur. $\odot$ eleman bazında çarpımı (Hadamard çarpımı olarak da bilinir) ifade eder.

Denklemler (2.11–2.15)'te, $u_t, r_t \in R^d$ sırasıyla güncelleme ve sıfırlama kapılarını [57] temsil eder. $\hat{h}_t \in R^d$ aday gizli durum, $h_t \in R^d$ ise mevcut gizli durumdur.


$$u_t = \sigma(W_u \cdot h_{t-1} + V_u \cdot x_t + b_u) \quad (2.25)$$

$$r_t = \sigma(W_r \cdot h_{t-1} + V_r \cdot x_t + b_r) \quad (2.26)$$

$$\hat{h}_t = \tanh(W_h \cdot r_t \cdot h_{t-1} + V_h \cdot x_t + b_h) \quad (2.27)$$

$$h_t = u_t \odot \hat{h}_t + (1 - u_t) \odot h_{t-1} \quad (2.28)$$

$$z_t = h_t \quad (2.29)$$



Şekil 2.4 Kapılı Özyinelemeli Sinir Ağı Yapısı

2.3.8 LSTM-XGBoost Hibrit Modeline Genel Bakış

Bu çalışmada kullanılan veri seti, IEEE Dataport web sitesinde mevcuttur ve meteorolojik verilerin yanı sıra COVID-19 döneminde ismi verilmeyen bir bölgenin elektrik tüketimindeki öngörülemeyen değişiklikleri içermektedir [58]. Önerilen hibrit model, sırasıyla ardışık öğrenme için LSTM ve hata düzeltme için XGBoost olmak üzere iki ana bileşenden oluşmaktadır. Bu şekilde, COVID-19 öncesi düzenli desenler ve pandemi sırasında ortaya çıkan düzensiz “öngörülemeyen olaylar” içeren veri setindeki yük tüketimini modellemek amaçlanmıştır. Meteorolojik verilere ek olarak ayrık DWT eğitim verilerine dahil edilmesi, zaman serilerinin çok çözünürlüklü analizine olanak tanımakta ve verideki öngörülemeyen dalgalanmaların ele alınmasında kritik olan hem yüksek hem de düşük frekans bileşenlerinin yakalanmasını sağlamaktadır.

2.3.9 Öznitelik Çıkarımı için Ayrık Dalgacık Dönüşümü

$x(t)$ orijinal zaman serisini temsil etsin. Ayrık Dalgacık Dönüşümü (DWT), $x(t)$ 'yi birden fazla frekans bandına ayırarak hem zaman hem de frekans alanında bir temsil sunar. DWT şu şekilde ifade edilebilir:

$$x(t) = \sum_{k=1}^N \sum_j A_{j,k} \psi_{j,k}(t) \quad (2.30)$$

Burada, $\psi_{j,k}(t)$ dalgacık temel fonksiyonlarını, $A_{j,k}$ ise yaklaşık katsayıları (düşük frekans bileşenleri) temsil eder; j ve k sırasıyla ölçek (scale) ve kaydırma (translation) parametreleridir. Bu çalışmada, dbN kullanılarak seviye 5'e kadar dalgacık ayrıştırması uygulanmıştır ve bu işlem sonucunda hem yaklaşık A_j hem de detay D_j katsayıları elde edilmiştir. Yaklaşık katsayılar, zaman serisindeki düzgün, uzun vadeli eğilimleri yakalarken; detay katsayıları, ani dalgalanmaları ve "öngörülemeyen olaylar" gibi potansiyel anormallikleri yakalar. Seviye 5'teki dalgacık ayrıştırması şu şekilde özetlenebilir:

$$x(t) = A_5 + D_5 + D_4 + D_3 + D_2 + D_1 \quad (2.31)$$

Bu katsayılar daha sonra LSTM-XGBoost hibrit modeli için giriş öznitelikleri olarak kullanılır.

2.3.10 Dizi Tahmini için LSTM

LSTM, hücre durumları ve kapı mekanizmaları sayesinde uzun vadeli bağımlılıkları öğrenebilen bir RNN mimarisidir. LSTM modelini yöneten temel denklemler

aşağıdaki gibidir:

Unutma kapısı (Forget gate):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (2.32)$$

Giriş kapısı (Input gate):

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2.33)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (2.34)$$

Hücre durumu güncelleme (Cell state update):

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t, \quad (2.35)$$

Çıkış kapısı (Output gate):

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (2.36)$$

$$h_t = \tanh(C_t), \quad (2.37)$$

Burada, W_f , W_i , W_o sırasıyla unutma, giriş ve çıkış kapıları için ağırlık matrisleridir. σ sigmoid aktivasyon fonksiyonu, $\tanh$ ise hiperbolik tanjant fonksiyonudur. h_t gizli durumu, C_t ise zaman t 'teki hücre durumunu temsil eder. LSTM modeli, orijinal zaman serisinden ve dalgacık özniteliklerinden üretilen dizileri giriş olarak alır. $\mathbf{X}_{\text{LSTM}} \in R^{T \times d}$ giriş dizisi olsun, burada T zaman adımı ve d öznitelik (dalgacık öznitelikleri dahil) bulunur ve $y \in R^T$ hedef yük değerlerini temsil eder. LSTM, aşağıdaki gibi tanımlanan ortalama kare hata (MSE) fonksiyonunu minimize etmek üzere eğitilir:

$$\text{MSE}_{\text{LSTM}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.38)$$

Burada, y_i gerçek yük değerlerini ve $\hat{y}_i$ LSTM modelinden elde edilen tahmin edilen yük değerlerini temsil eder.

2.3.11 XGBoost ile Artık Hata Düzeltmesi

LSTM tahminleri elde edildikten sonra, artık hatalar r_t şu şekilde hesaplanır:

$$r_t = y_t - \hat{y}_t \quad (2.39)$$

Burada, y_t gerçek yük değeri ve $\hat{y}_t$ zaman t 'teki LSTM tahminini temsil eder. Bu artık hatalar r_t , LSTM'nin yakalayamadığı veri kısmını temsil eder; bu genellikle öngörülemez olaylar ve kısa vadeli dalgalanmalarla ilişkilidir. XGBoost, bu artık hataları modellemek ve düzeltmek için kullanılır. XGBoost, artık hatalara uyan zayıf öğrencileri (karar ağaçları) sırasıyla ekleyerek çalışır. XGBoost için hedef fonksiyon, artık kaybı (residual loss) minimize etmek olup, şu şekilde ifade edilir:

$$L(r) = \sum_{i=1}^N l(r_i, \hat{r}_i) + \sum_k \Omega(f_k) \quad (2.40)$$

Burada, $l(r_i, \hat{r}_i)$ artıklar için kayıp fonksiyonunu (kare hata) temsil eder, $\omega(f_k)$ modelin karmaşıklığını cezalayan düzenleme terimini, f_k ise ansambldeki k nci karar ağacını temsil eder. XGBoost'un parametreleri, örneğin 'max_depth' (maksimum derinlik), 'learning_rate' (öğrenme oranı) ve 'n_estimators' (karar ağacı sayısı), modelin performansını daha da artırmak için RandomizedSearchCV kullanılarak optimize edilir.

2.3.12 Hibrit LSTM-XGBoost Tahmini

Hibrit modelden elde edilen nihai tahmin $\hat{y}^{final}$, LSTM tahminleri $\hat{y}_t$ ile XGBoost düzeltmeleri $\hat{r}_t$ 'nin birleştirilmesiyle elde edilir:

$$\hat{y}^{final} = \hat{y}_t + \hat{r}_t \quad (2.41)$$

2.3.13 Model Değerlendirmesi

Tahmin modellerinin performansını değerlendirmek için, tahmin edilen değerlerle gerçek değerler arasındaki farkı nicelendiren sağlam istatistiksel doğruluk ölçütlerinin kullanılması gereklidir. Zaman serisi tahmininde en yaygın kullanılan ölçütler arasında MAE, RMSE, MAPE ve WI yer almaktadır. Bu göstergeler, tahmin hatalarının büyüklüğü, yönü ve oransallığı hakkında tamamlayıcı bilgiler sunar.

Hibrit model, aşağıdaki metrikler kullanılarak değerlendirilir:

2.3.13.1 Ortalama Kare Hata (MSE)

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i^{\text{final}})^2 \quad (2.42)$$

2.3.13.2 Kök Ortalama Kare Hatası (RMSE)

RMSE, tahmin edilen değerlerle gerçek değerler arasındaki farkların karesinin ortalamasının karekökünü hesaplar.

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i^{\text{final}})^2} \quad (2.43)$$

2.3.13.3 Ortalama Mutlak Hata (MAE)

MAE, bir tahmin kümesindeki hataların ortalama büyüklüğünü, yönlerini dikkate almadan ölçer. Gerçek ve tahmin edilen değerler arasındaki mutlak farkların ortalamasıdır.

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i^{\text{final}}| \quad (2.44)$$

2.3.13.4 Ortalama Mutlak Yüzde Hatası (MAPE)

MAPE, tahmin modellerinin doğruluğunu değerlendirmek için yaygın olarak kullanılan bir ölçüttür. Hataları yüzde cinsinden ifade ettiği için, farklı ölçekler ve veri setleri arasında anlaşılması sezgisel ve kolaydır.

$$\text{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i^{\text{final}}|}{|y_i|} \quad (2.45)$$

Tablo 2.1 MAPE değerine göre tahmin doğruluğu yorumları

MAPE	Yorum
< 10	Yüksek doğrulukta tahmin
10 – 20	İyi tahmin
20 – 50	Makul tahmin
> 50	Düşük doğrulukta tahmin

2.3.13.5 Willmott İndeksi (WI)

WI, ya da bilinen adıyla Willmott'un Uyum İndeksi, model tahminlerinin gözlemlenen verilerle olan doğruluğunu değerlendirmek amacıyla C.J. Willmott tarafından geliştirilen istatistiksel bir ölçüttür [59]. Enerji tüketimi tahminleri, hava durumu tahminleri ve çevresel modelleme gibi öngörü çalışmaları kapsamında yaygın olarak kullanılır.

$$WI = 1 - \frac{\sum_{i=0}^{N-1} (\hat{y}_i - y_i)^2}{\sum_{i=0}^{N-1} (|\hat{y}_i - \text{mean}(y)| + |y_i - \text{mean}(y)|)^2} \quad (2.46)$$

Yorumlama

- $WI = 1$: Tahmin edilen ve gözlemlenen değerler arasında **mükemmel uyum**
- $WI = 0$: **Hiçbir uyum yok** (model mümkün olan en kötü durumdadır)
- $WI < 0$: Model, yalnızca gözlemlenen değerlerin ortalamasını kullanmaktan daha kötüdür

Burada y_i gerçek değerleri, $\hat{y}_i^{\text{final}}$ tahmin edilen değerleri ve N ise toplam veri sayısını temsil etmektedir. MSE, RMSE ve MAE'nin daha düşük değerleri, hem düzenli desenleri hem de öngörülemeyen olayları yakalamada model performansının daha iyi olduğunu gösterir.

DWT, LSTM ve XGBoost birleşimi, öngörülemeyen olaylar içeren veri setlerinin etkili bir şekilde işlenmesini sağlar. DWT'nin çok çözünürlüklü analizi, LSTM'nin sekans öğrenme kabiliyeti ve XGBoost'un artık hata düzeltilmesi bir araya gelerek, değişken zaman serisi verilerinde yük değerlerini doğru bir şekilde tahmin edebilen sağlam bir model ortaya koyar.


3

ANALİZ SONUÇLARI

3.1 Standart Derin Öğrenme Mimarileri ile Karşılaştırma

Bu çalışmada kullanılan veriler, ortalama elektrik tüketimi 1.1 GW olan bir bölgeye aittir [60]. Bu deneyde, en iyi performansı gösteren LSTM modeli, 1 haftalık tahminler için doğrulama RMSE olarak 0.0891 değerine ulaşırken, GRU modeli daha yüksek bir RMSE olan 0.1098 vermiştir.

Şekil 3.1, Mart 2020’de COVID-19 pandemisinin neden olduğu bozulmayı göstermektedir.



Şekil 3.1 COVID-19’un elektrik tüketimi üzerindeki etkisi.

Bu deneyde, LSTM ve GRU için farklı yapılar ve hiperparametreler kullanılarak derin öğrenme modellerinin performansları karşılaştırılmıştır. Tüm bu modeller için yapılandırılması gereken hiperparametre sayısı, geleneksel makine öğrenme tekniklerine göre daha fazladır. Bu nedenle, bu parametrelerin uygun şekilde ayarlanması karmaşık bir iştir, önemli bir uzmanlık gerektirir ve çoğu zaman sezgiye dayanır. Derin öğrenme mimarileri, en iyi performansları bulmak için

MATLAB Deney Yöneticisi Aracı ile yapılandırılmıştır. Modellerin daha az hata veren optimum hiperparametrelerini bulmak için grid search (kafes arama) kullanılmıştır. Bu, hiperparametrelerin en uygun değerlerini hesaplamak için kullanılan bir ayarlama tekniğidir.

Katman sayısı, gizli birim sayısı ve öğrenme oranı için birkaç olasılığı denedim. Tablo 3.1 ve Tablo 3.2, yaygın olarak kullanılan değerler için seçtiğim varyasyonları göstermektedir.

Tablo 3.1 Model parametreleri ve değerleri

Model	Parametreler	Değerleri
LSTM	Katman derinliği	1, 3
- - -	Gizli birim sayısı	50, 100, 200
GRU	Katman derinliği	1, 3
- - -	Gizli birim sayısı	50, 100, 200

Adam (uyarlamalı moment tahmininden türetilmiş) optimizasyon algoritması seçilmiştir. Bu algoritma, birçok derin öğrenme problemi için sağlam olan uyarlamalı stokastik bir optimizasyon yöntemi uygular. Adam, parametre güncellemelerine moment terimi ekler. Parametre gradyanlarının ve bunların karelerinin eleman bazlı hareketli ortalamasını tutar.

Tablo 3.2 Model eğitim parametreleri

Modeller	Parametreler
Optimizasyon yöntemi	Adam
Mini Yığın Boyutu	128
Başlangıç Öğrenme Oranı	0.001, 0.05, 0.01
Veri Karıştırma	Bir kez

Tablo 3.3 ve 3.4, sırasıyla LSTM ve GRU mimarileri için farklı parametrelerle elde edilen en iyi sonuçların daha ayrıntılı bir görünümünü sunmaktadır.

Tablo 3.3 LSTM mimarileri için elde edilen en iyi sonuçlar


Deneme	Geçen Süre	LSTM Derinliği	Gizli birim sayısı	Başlangıç öğrenme oranı	Eğitim RMSE	Doğrulama RMSE
3	5 dk 13 sn	1	100	0.01	0.1877	0.0891
1	3 dk 1 sn	1	50	0.01	0.1843	0.0958
5	11 dk 30 sn	3	200	0.01	0.1742	0.0991
7	2 dk 34 sn	1	50	0.05	0.2479	0.1048
⋮	⋮	⋮	⋮	⋮	⋮	⋮

Tablo 3.3 ve 3.4’de, LSTM ve GRU modellerinin benzer davranış sergilediği ve doğrulama veri kümesinde yakın sonuçlar verdiği görülmektedir. 1 haftalık

Tablo 3.4 GRU mimarileri için elde edilen en iyi sonuçlar


Deneme	Geçen Süre	LSTM Derinliği	Gizli birim sayısı	Başlangıç öğrenme oranı	Eğitim RMSE	Doğrulama RMSE
3	2 dk 34 sn	1	100	0.01	0.1958	0.0891
17	6 dk 13 sn	1	200	0.01	0.184	0.1103
4	9 dk 47 sn	3	100	0.01	0.2091	0.1145
1	1 dk 22 sn	1	50	0.01	0.1944	0.1195
⋮	⋮	⋮	⋮	⋮	⋮	⋮

tahmin için LSTM ve GRU modelleri sırasıyla 0.0891 ve 0.1098 doğrulama RMSE değerlerine ulaşmıştır. Tahmin doğruluğuna ek olarak, derin öğrenme mimarilerinin değerlendirildiği ikinci yön, hesaplama verimliliğidir. Şekil 3.2, tüm mimariler için eğitim süresi sonuçlarının dağılımını karşılaştırmaktadır.

**Şekil 3.2** Eğitim süresi sonuçlarının dağılımı

Doğrulama RMSE'sinde benzer sonuçlar olmasına rağmen [61], GRU modelleri LSTM'e göre daha az karmaşık bir mimariye sahip olduklarından hesaplama süreleri daha kısadır. Bir zaman serisinde bir sonraki adımı tahmin etmenin bir yöntemi yalnızca giriş verilerini kullanmaktır [62]. Bu yöntemde, gerçek değerler veri kaynağından toplanır ve sonraki zaman adımları için tahmin yapılırken giriş olarak kullanılır. Başka bir deyişle, t anındaki bir zaman serisinin değeri, 1'den $t - 1$


'e kadar toplanan verilerden tahmin edilir. $t + 1$ anındaki değeri tahmin etmek için, önce t anındaki gerçek değer kaydedilir ve ardından bir sonraki tahmin için giriş olarak kullanılır. Özellikle gün içi piyasalarda gerçek değerlere ulaşılabildiğinden, bu yöntem kısa vadeli tahminlerde modellerin performanslarını karşılaştırmak için kullanılmıştır. En iyi performans gösteren LSTM ve GRU modellerinin 1 haftalık tahminleri Şekil 3.3'de gösterilmiştir.



Şekil 3.3 Eğitim süresi sonuçlarının dağılımı

3.2 Genel Model Performansı

Bu çalışmada, ani ekonomik değişimler, doğal afetler veya pandemiler gibi tahmin edilemeyen gelişmelerin zaman serisi tahminleri için nasıl büyük zorluklar yarattığını açıkladım. Bu sorunları tartışmak için, COVID-19'un enerji talebi üzerindeki etkisini, tahmin doğruluğunu artırmak için önerdiğim dalgacık ile güçlendirilmiş hibrit LSTM-XGBoost modelinin bir vaka çalışması olarak kullanıyorum. Analizimde, Şekil 3.4'deki haftalık hareketli ortalama ile saatlik yük verilerini inceledim ve saatlik verilerin yüksek değişkenlik gösterdiğini, ancak haftalık hareketli ortalamanın trendi yumuşatarak mevsimsel etkileri daha görünür hale getirdiğini fark ettim. Ayrıca, yıl boyunca talep değişimlerinin, enerji tüketimi üzerindeki soğutma ve ısıtma sistemlerinin etkisini yansıttığını gözlemledim.




Şekil 3.4 Zaman içinde saatlik yük ve haftalık hareketli ortalama eğilimleri.


Çalışmada kullanılan özellikler arasındaki korelasyon Şekil 3.5’de gösterilmektedir. Şekilde, kırmızı renkler pozitif korelasyonu, mavi renkler negatif korelasyonu gösterirken, renk yoğunluğu korelasyonun gücünü belirtmektedir. Özellikle, elektrik tüketimi ile sıcaklık arasında anlamlı bir pozitif korelasyon (+0.56) gözlemlenmiştir. Bu, sıcaklık arttıkça güç talebinin arttığı anlamına gelir, bu da enerji kullanımının arttığı, örneğin sıcak günlerde klima kullanımının yaygınlaştığı durumlar için önemlidir. Ayrıca, rüzgarı yalnızca rüzgar yönü ve hızını veri setinde sağlanan şekilde okumak yerine yatay (u) ve dikey (v) bileşenlerine ayırarak daha anlamlı bir analiz yapılabilir. Rüzgar bileşenleri yük ile anlamlı bir şekilde ilişkilendirilmemekle birlikte, yine de modelin ifade gücünü artırabilir.

Şekil 3.6, modelin bir akış diyagramını göstermektedir. Veri seti IEEE Dataport’tan alınmıştır [58]. Veri setinin dönemi Mart 2017’den Kasım 2020’ye kadar uzanmakta olup, COVID-19 pandemisinin öncesini ve başlangıç etkisi aşamasını kapsamaktadır ve saatlik elektrik tüketimi verileri, günlük ve hafta içi/hafta sonu desenlerini göstermektedir. Eğitim veri setinde 31.912 saatlik gözlem bulunmaktadır ve meteorolojik değişkenler, sıcaklık, nem, bulut örtüsü, basınç ve rüzgar bileşenleri gibi özelliklerdir. Ham verilerde eksik değerler kontrol edilerek, elektrik talebi tahminleri için oldukça ilgili olan aylar, haftanın günleri ve saatler veri setine özellik olarak eklenmiştir.

Bu çalışmada, eksik değerleri istatistiksel ve makine öğrenimi tabanlı tahmin teknikleriyle ele alarak veri bütünlüğünü sağlamak için adımlar attım. Eksik meteorolojik değişkenleri, bunların geçmiş özelliklerle olan korelasyonlarını kullanarak tahmin ettim. Bu ön işleme sonrasında, veriyi çeşitli frekans bileşenlerine ayırmak için dalgacık dönüşümünü uyguladım. Bu yaklaşım, veriyi



Şekil 3.5 Modelde kullanılan özelliklerin korelasyon matrisi.




Şekil 3.6 Dalgacıklarla zenginleştirilmiş LSTM-XGBoost hibrit modelinin akış şeması.

farklı zaman ölçeklerinde bileşenlere ayırmamı sağlayarak, hem trendleri hem de ayrıntılı desenleri etkili bir şekilde öğrenmeyi kolaylaştırdı.

Ayrıca, dalgacık katsayılarını farklı frekanslar arasında hizalamak için doğrusal enterpolasyon kullandım ve böylece veri setinin tutarlılığını sağladım. Bu ön işleme adımları, özellikle COVID-19 gibi düzensiz dalgalanmalarla başa çıkarken verinin sağlam kalmasına yardımcı oldu ve modelin zamansal bağımlılıkları ve özellik tabanlı ilişkileri etkili bir şekilde yakalamasını sağladı. Ardından, dalgacık katsayılarını özellik setine dahil ederek, modelin ani ve tahmin edilemeyen olayları, COVID-19 gibi olayları daha etkili bir şekilde tespit etme yeteneğini artırdım. Şekil 3.7’te görüldüğü gibi, dalgacık dönüşümünü kullanarak enerji talebi verilerini farklı frekans bileşenlerine ayırdım, bu da zaman serisindeki tahmin edilemeyen olayların etkisini analiz etmenin ana adımıdır ve çalışmamın odak noktasıdır. Veri seti, beş detay seviyesi ve bir yakınsama seviyesi olarak ayrıldı. Yakınsama bileşeni, uzun vadeli trendleri yansıtırken, Detay 1 ve Detay 2 en yüksek frekans bileşenlerini yakalar, yük verilerindeki gürültü ve hızlı değişiklikleri içeren kısa vadeli dalgalanmaları tespit eder. Bu yüksek frekanslı detaylar genellikle genel eğilimleri tahmin etmek için kritik olmasa da, anormallikleri veya beklenmedik zirveleri tespit etmek için önemlidir. Örneğin, D1 en hızlı değişimleri yakalar, bunlar geçici gürültü ile ilişkili olabilir, D2 ise biraz daha yavaş, yüksek frekanslı değişimleri yansıtır. Detay 3, Detay 4 ve Detay 5 ise daha düşük frekanslı bileşenlere karşılık gelir ve verilerdeki önemli dalgalanmaları vurgulayan orta ve uzun vadeli değişimleri yakalar. Şekil 4’te açıkça görüldüğü gibi, frekans bileşenlerinin uzunlukları farklıdır, bu yüzden uzunluklarını standartlaştırmak için enterpolasyon uyguladım ve bunları modele entegre etmeden önce tutarlı bir özellik seti sağladım.

Zaman serisi verilerinin tahminini eğitmek için LSTM modelini kullandım. Dalga dönüşümlü verilerle LSTM’nin olağanüstü performans göstereceğini bekliyordum, çünkü uzun vadeli bağımlılıkları yakalama gücüne sahiptir. Bu süreçte, modelin hiperparametrelerini dikkatlice seçtim ve ince ayar yaptım, katman sayısı ve öğrenme oranı gibi parametreleri, en iyi performansı sağlamak için optimizasyon teknikleri kullanarak Table 3.5’de belirtildiği şekilde belirledim. LSTM modelinin çıktılarından tahmin hatalarını (artıklar) hesapladım. Doğruluğu artırmak için, bu hataları düzeltmek için XGBoost modelini kullandım ve Table 4.6’de listelenen çeşitli parametre değerleriyle onu optimize ettim. XGBoost’u, LSTM’nin hatalarından öğrenmesi için kullanarak tahmin doğruluğunu artırmayı başardım. Bu iki modelin birleşimi, daha güçlü ve etkili bir hibrit tahmin modeli oluşturdu.

Modelin performansını değerlendirmek için bir doğrulama süreci uyguladım.



Şekil 3.7 Enerji yük verisinin dalgacık ayrıştırması.

Tablo 3.5 LSTM Modeli Parametreleri

Parametre	Değer
LSTM Katmanları	1 veya 2 (ayar sonucu olarak)
Her LSTM Katmanındaki Birim Sayısı	50-200 (hiperparametre ayarlamasına göre)
Dropout Oranı	0.2-0.5 (her LSTM katmanı için ayarlanmış)
Öğrenme Oranı	0.01, 0.001 veya 0.0001 (ayar sonucu belirlenmiş değer)
Regülerizasyon	(L2) 0.01-0.05 (her LSTM katmanı için)
Maksimum Epok	50
Erken Durdurma Kriteri	5 epok sabırlılık
Yığın Boyutu (Batch Size)	32, 64 veya 128 (ayar sonucuna bağlı olarak)
Optimizasyon Algoritması	Adam
Öğrenme Oranı Zamanlayıcısı	10 epoktan sonra üssel azalma (exponential decay)

Doğrulama setindeki tahmin hatalarını inceleyerek bir durdurma kriteri oluşturduğum ve doğrulama kaybını belirli bir eşiğe indirmek için iyileştirdiğim, belirli sayıda yineleme içinde deney yaptım. Kriter karşılanmazsa, sonuçları iyileştirmek için farklı hiperparametre değerlerini test ettim. Hiperparametreleri ayarlamak, modelin tahmin doğruluğunu artırmada kritik öneme sahipti. LSTM modeli için optimal ayarları 100 birim, 0.07 L2 düzenleyicisi, 0.3 dropout

Tablo 3.6 XGBoost Model Parametreleri

Parametre	Değer
Maksimum Derinlik	3, 4, 5 veya 6 (hiperparametre ayarlamasına göre)
Öğrenme Oranı	0.001, 0.01, 0.1 veya 0.2 (ayar sonucu belirlenmiş değer)
Tahminleyici Sayısı	50, 100 veya 200 (ayar sırasında seçilmiştir)
Minimum Çocuk Ağırlığı	1, 5 veya 10 (ayar ile belirlenmiştir)
Alt Örnekleme Oranı	0.8 veya 1.0
Sütun Alt Örnekleme Oranı	0.8 veya 1.0 (colsample bytree)
Çapraz Doğrulama Kat Sayısı	3
Rastgele Arama sonucuna bağlı olarak)	20
Değerlendirme Metriği	Değerlendirme Metriği (Negative Mean Squared Error - MSE)

oranı ve 0.0001 öğrenme oranı olarak belirledim. XGBoost modeli için ise RandomizedSearchCV kullanarak en iyi yapılandırmayı belirledim; bu yapılandırma, 6 maksimum derinlik, 1 minimum çocuk ağırlığı, 0.1 öğrenme oranı ve 200 tahminci içeriyordu.

Optimizasyonu sağlamak için Keras Tuner kütüphanesinde RandomSearch kullandım, LSTM modelini 5 denemede doğrulama kaybını en aza indirerek, her denemede üç yürütme yaparak tutarlı sonuçlar elde ettim. XGBoost için ise Scikit-Learn'ün RandomizedSearchCV'sini kullandım, hiperparametre alanında 20 iterasyon ve 3 katmanlı çapraz doğrulama ile verimli bir şekilde gezindim, hedef olarak negatif ortalama kare hata (MSE) metriğini kullandım.

Bu optimizasyonlar, hibrit LSTM-XGBoost modelimin doğruluğunu büyük ölçüde artırdı, genelleme ve hesaplama verimliliği arasında bir denge sağladı. Optimizasyon tamamlandığında, model gelecekteki tahminler için hazır hale geldi. Dalgacık dönüşümüyle zenginleştirilmiş bir veri seti üzerinde eğitilen ve tahmin hatalarını düzeltmek için ince ayar yapılan modelim, dalgacık dönüşümünün, veriyi farklı frekans bileşenlerine ayırarak tahmin edilemeyen olayları etkili bir şekilde yakaladığını ve hibrit LSTM-XGBoost yaklaşımının genel tahmin performansını önemli ölçüde artırdığını gösterdi.


3.3 Temel Modellerle Karşılaştırmalı Analiz

Veri seti, IEEE Dataport'tan alınan bir tahmin yarışması için, tam veri setiyle günlük tahminler içermekte olup, gerçek değerler günlük olarak açıklanarak bir sonraki günün tahminleri için yeniden eğitim yapılmasını sağlamaktadır. Çalışmamda, yarışmanın kapsamı içinde bir ay süresince tahmin yapmak için modeli eğitmeyi hedefledim. Hibrit LSTM-XGBoost modelimi değerlendirmek için, tek başına bir LSTM modeli ve dalgacık bileşenleri olmayan bir LSTM modeli ile karşılaştırmalı bir çalışma yaptım. Şekil 3'te görüldüğü gibi, hibrit modelim, MAE, RMSE, MAPE ve WI metrikleri açısından bu tek başına yöntemleri sürekli olarak geride bırakmıştır.

Tablo 3.7 Farklı Modeller için Hata Metrikleri

Model	MAE	RMSE	MAPE	WI
LSTM-XGBoost Hibrit	19875.15	26595.62	1.78	0.98
Sadece LSTM	43284.72	57403.58	3.86	0.94
Dalgacık Olmadan LSTM	52681.58	67329.62	4.64	0.92


Bulduğum sonuçlar, hibrit yaklaşımının birleşik güçlü yönlerini vurgulamaktadır; burada, LSTM'yi zamansal bağımlılıkları etkili bir şekilde yakalamak için, XGBoost'u ise özellik tabanlı öğrenmeyi güçlendirmek için kullandım. Ayrıca, hibrit modelim, yük verilerindeki ani değişikliklerle başa çıkmada daha fazla uyum sağladı ve gerçek dünya tahmin uygulamaları için değerini kanıtladı. Karşılaştırmalı çalışmamın bir aylık tahmin sonuçları, Şekil 4.8'te gösterilmektedir.



Şekil 3.8 Farklı modeller kullanılarak gerçek ve tahmin edilen yükün (kW) karşılaştırması.

3.4 Tahmin Edilemeyen Olayları Ele Alma: COVID-19 Pandemisi Sırasındaki Performans

Şekil 3.9, hibrit LSTM-XGBoost modelimin üstün uyum yeteneğini, özellikle COVID-19'un tetiklediği elektrik tüketimindeki yapısal değişikliği ele alırken gösteriyor. COVID öncesi verilerle bolca eğitim yapılmış modeller, yalnızca tarihi desenlere dayanan modeller dalgacık özellikli LSTM veya dalgacık olmadan LSTM post-COVID tahminlerinde pozitif bir sapma gösterme eğilimindedir, tüketimdeki keskin düşüş nedeniyle talebi aşırı tahmin ederler. Ancak, benim hibrit yaklaşımım bu sorunu, dalgacıkları ve XGBoost'u kullanarak doğrusal olmayan ilişkileri yakalayarak aşmaktadır. LSTM-XGBoost modelim, enerji talebindeki tahmin edilemeyen değişikliklere karşı dayanıklılığını göstererek, gerçek dünya uygulamaları için etkinliğini pekiştirmektedir.



Şekil 3.9 Hibrit modelin ve en güncel modellerin hata dağılımı.

Hibrit modelin performansı, Tablo 3.7'te gösterildiği gibi günün farklı zaman dilimlerinde (Sabah, Öğle, Akşam ve Gece) analiz edilmiştir. Bu sonuçlar, modelin doğruluğunun günün saatine bağlı olarak nasıl değiştiğini ortaya koymakta ve farklı tüketim kalıpları ile operasyonel zorlukları yansıtmaktadır. Ayrıca, saatlik analiz, elektrik tüketimi tahmininin zamansal boyutlarına dair içgörüler sunmakta ve modelin bu değişimlere uyum sağlama yeteneğini göstermektedir.

Her ne kadar hibrit model, geleneksel hata metriklerine göre sabah saatlerinde genel olarak iyi bir performans sergilese de, Willmott İndeksi'nin (WI) düşük olması,

modelin bu zaman dilimindeki tüketim dinamiklerini diğer saatlere kıyasla daha az başarıyla yakaladığını göstermektedir. Dahası, sabah saatleri için yalnızca LSTM ve Dalgacık (Wavelet) entegrasyonu olmayan LSTM modelleri sırasıyla 0.62 ve 0.73 WI değerlerine sahip olup, hibrit modele kıyasla bu dönemdeki tüketim desenlerini yakalama konusunda önemli ölçüde daha kötü performans sergilemektedir.

Ayrıca, akşam ve gece saatlerinde artan hata oranları, bu dönemler için ek özelliklerin dahil edilmesi veya özel olarak eğitilmiş modellerin kullanılmasının doğruluğu artırabileceğini göstermektedir. Bu zamansal analiz, yalnızca modelin güçlü ve zayıf yönlerini ortaya koymakla kalmaz, aynı zamanda enerji yönetim sistemlerinde tahmin doğruluğunu artırmak için temel içgörüler sunar. Tahmin modellerinin günlük tüketim desenleriyle uyumlu hale getirilmesi, daha güvenilir ve hızlı tepki veren enerji yönetim stratejilerine olanak sağlayabilir.

Tablo 3.8 Yük Tahmini Metriği için Günün Zamanına Göre Analiz

Günün Zamanı	MAE	RMSE	MAPE	WI
Sabah	13744.74	18588.75	1.39	0.79
Öğleden Sonra	14975.59	20090.96	1.34	0.99
Akşam	25554.87	32395.96	2.13	0.95
Gece	25225.38	32103.31	2.28	0.90

3.5 Sınırlamalar ve Gelecek Yönelimler

Önerilen hibrit LSTM-XGBoost modelinin cesaret verici sonuçlarına rağmen, bazı sınırlamaların dikkate alınması gerekmektedir. Bayram günlerindeki tüketim desenleri veri setine dahil edilmediğinden, tahminlerin tatil günlerine denk gelmesi durumunda modelin doğruluğu etkilenebilir. Şebeke arızaları ve elektrik kesintileri gibi arz taraflı aksaklıklar doğrudan modellenmediği için tahmin doğruluğu olumsuz etkilenebilir. Benzer şekilde, politika kaynaklı enerji dönüşümü veya büyük sanayilerdeki sistemsel değişim gibi nadir görülen olaylar eğitim verilerinde yeterince temsil edilmemektedir ve bu durum modelin performansını etkileyebilir. Ayrıca, ekonomik durgunluklar veya düzenleyici değişiklikler gibi zamanla ortaya çıkan kademeli değişiklikler, doğruluğun korunabilmesi için modelin düzenli olarak yeniden eğitilmesini gerektirebilir. Gelecekte yapılacak araştırmalar, dış bağlamsal verilerin entegrasyonu, arz tarafına dair gerçek zamanlı bilgilerin kullanımı ve uyarlanabilir yeniden eğitim süreçlerinin geliştirilmesiyle modelin dayanıklılığını artırabilir.

4 SONUÇ

Bu çalışmada, öngörülemeyen olayların etkisi altında elektrik tüketimini tahmin etmenin zorluklarını inceledim ve COVID-19 pandemisi, önemli bir örnek olay olarak kullanıldı. Temel amaç, enerji talebindeki ani ve düzensiz kesintilere uyum sağlayabilen sağlam bir tahmin modeli geliştirmek ve değerlendirmektir. Bu amacı başarmak için, LSTM ağları ve XGBoost modelini birleştiren, dalgacık tabanlı hibrit bir model önerdim. Zaman serisi verilerini birden fazla frekans bileşenine ayırmak için DWT kullanarak, model hem kısa vadeli dalgalanmaları hem de uzun vadeli eğilimleri etkili bir şekilde yakaladı. Bu çok çözünürlüklü yaklaşım, modelin pandeminin yol açtığı gibi anormal desenlere duyarlı hale gelmesinde önemli bir rol oynadı.

Yöntem, hem LSTM hem de XGBoost'un güçlü yönlerini tamamlayıcı bir şekilde kullanarak çalıştı. LSTM bileşeni, sıralı verilerdeki zamansal bağımlılıkları modellemede başarılı olurken, XGBoost, artık hataları düzelterek tahminleri iyileştirdi. Deneysel sonuçlar, hibrit modelin üstün performansını gösterdi; tek başına LSTM ve dalgacık özellikleri olmadan LSTM ile karşılaştırıldığında daha düşük hata metriklerine sahip oldu, MAE 19.875,15, RMSE 26.595,62, MAPE 1,78 ve WI 0,98. Bu bulgular, modelin sağlamlığını ve özellikle sabah ve öğleden sonra arasındaki günlük tahminler için değişken koşulları yönetme yeteneğini vurgulamaktadır. Bu çalışma, belirsizlikler altında tahmin doğruluğunu artırmak için derin öğrenme, makine öğrenmesi ve sinyal işleme tekniklerinin birleştirilmesinin değerini göstererek enerji tahmini alanına katkıda bulunmaktadır.

Bu araştırma boyunca, zaman serisi tahmini ile ilgili önemli içgörüler kazandım, özellikle de özellik mühendisliğinin durağan olmayan verileri ele almadaki kritik rolünü öğrendim. Dalgacık ayrıştırması ile çalışmak, düzensiz olaylara karşı modelin duyarlılığını artıran çok çözünürlüklü analiz gücünü vurgulayan özellikle ödüllendirici bir deneyim oldu. Ancak çalışma, modelin daha da iyileştirilebileceği alanları da ortaya koydu. Örneğin, modelin performansı günün farklı saatlerinde farklılık gösterdi, akşam ve gece saatlerinde daha yüksek hatalar gözlemlendi, bu

da gnlk tketim desenlerinin tahmin doęruluęunu etkiledięini gsteriyor.

Vaadedici sonularına raęmen, bu alıřmanın dikkate alınması gereken bazı sınırlamaları vardır. Model, Mart 2017 ile Kasım 2020 arasındaki elektrik tketimini kapsayan belirli bir IEEE Dataport veri seti zerinde eęitilmiř ve test edilmiřtir. Bu veri seti COVID-19'un etkisini etkili bir řekilde yakalamıř olsa da, bařka blgeler, dnemler veya ngrlemeyen olay trleri zerindeki genellenebilirlięi henz test edilmemiřtir. Ayrıca, eęitim setinde resmi tatil verilerinin, arz tarafı kesintilerinin (rneęin, řebeke arızaları) ve uzun vadeli deęiřimlerin (rneęin, ekonomik durgunluklar) eksiklięi, modelin daha geniř baęlamlarda uygulanabilirlięini sınırlayabilir. Hibrit yaklařımın hesaplama karmařıklıęı, gerek zamanlı uygulama iin de zorluklar oluřturmakta olup, bunun dinamik enerji ynetim sistemlerinde pratik kullanımını engelleyebilir.

Gelecekteki alıřmalar, modelin saęlamlıęını artırmak iin gerek zamanlı verileri, tatil desenlerini ve adaptif yeniden eęitimi ierebilir.

- [1] I. Barić, R. Grbić E. K. Nyarko, “Short-term forecasting of electricity consumption using artificial neural networks-an overview,” *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, IEEE, 2019, ss. 1076–1081.
- [2] G.-F. Fan, X. Wei, Y.-T. Li W.-C. Hong, “Forecasting electricity consumption using a novel hybrid model,” *Sustainable Cities and Society*, c. 61, s. 102 320, 2020.
- [3] N. E.-H. Bezzar, L. Laimeche, A. Meraoumia L. Houam, “Data analysis-based time series forecast for managing household electricity consumption,” *Demonstratio Mathematica*, c. 55, no. 1, ss. 900–921, 2022.
- [4] T. Hong, P. Pinson, Y. Wang, R. Weron, D. Yang H. Zareipour, “Energy forecasting: A review and outlook,” *IEEE Open Access Journal of Power and Energy*, c. 7, ss. 376–388, 2020.
- [5] S. Wu, Z. Zhang Y. Ru, “Research on product demand forecasting based on random forest and arima time series: Precision forecasting method for data-scarce environments,” *Trasactions on Computer Science and Intelligent Systems Research*, c. 5, 2024.
- [6] S. Zhao ve diğ., “Urban Electricity Consumption Forecasting Based on SARIMA and Random Forest Modeling,” *Journal of Electrotechnology, Electrical Engineering and Management*, c. 7, no. 1, ss. 113–118, 2024.
- [7] N. Talkhi, N. Akhavan Fatemi, M. Jabbari Nooghabi, E. Soltani A. Jabbari Nooghabi, “Using meta-learning to recommend an appropriate time-series forecasting model,” *BMC Public Health*, c. 24, no. 1, s. 148, 2024.
- [8] S. R. Alve, A. J. Pial, M. Z. Mahmud S. Islam, “Harnessing Historical Weather Data with Machine Learning for Rainfall Forecasting in Bangladesh: A Time Series Analysis,” *Cognizance Journal of Multidisciplinary Studies*, 2024. erişim adresi: <https://api.semanticscholar.org/CorpusID:272428920>.
- [9] L. Schmida M. Roidl, *Comparing statistical and machine learning methods for time series forecasting in data-driven logistics–A simulation study. arXiv–STAT–Machine Learning. March 2023*, 2023.
- [10] W. Li D. M. Becker, “Day-ahead electricity price prediction applying hybrid models of LSTM-based deep learning methods and feature selection algorithms under consideration of market coupling,” *Energy*, c. 237, s. 121 543, 2021.

- [11] S. Kumar, "Dynamic Feature Scaling in Time Series Forecasting: A Hybrid Machine Learning Framework for Electricity Pricing," *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, IEEE, 2024, ss. 1–7.
- [12] V. K. Pandey, S. Bisoy S. Panda, "Time series forecasting and prediction of Walmart data using hybrid machine learning techniques," *2023 1st International Conference on Circuits, Power and Intelligent Systems (CCPIS)*, IEEE, 2023, ss. 1–5.
- [13] X. Liu W. Wang, "Deep time series forecasting models: A comprehensive survey," *Mathematics*, c. 12, no. 10, s. 1504, 2024.
- [14] C. Li ve diğ., "Power load forecasting based on the combined model of LSTM and XGBoost," *Proceedings of the 2019 the international conference on pattern recognition and artificial intelligence*, 2019, ss. 46–51.
- [15] N. Son Y. Shin, "Short-and medium-term electricity consumption forecasting using Prophet and GRU," *Sustainability*, c. 15, no. 22, s. 15 860, 2023.
- [16] Z. Severiche-Maury, C. Uc-Ríos, J. E. Sierra A. Guerrero, "Predicting Energy Consumption and Time of Use of Home Appliances in an HEMS Using LSTM Networks and Smart Meters: A Case Study in Sincelejo, Colombia," *Sustainability*, c. 17, no. 11, s. 4749, 2025.
- [17] Z. Zhao ve diğ., "Short-term load forecasting based on the transformer model," *information*, c. 12, no. 12, s. 516, 2021.
- [18] E. G. Tajeuna, M. Bouguessa S. Wang, "Modeling regime shifts in multiple time series," *ACM Transactions on Knowledge Discovery from Data*, c. 17, no. 8, ss. 1–31, 2023.
- [19] S. H. Almuhaiani N. Sultana, "Bayesian-optimization-based long short-term memory (LSTM) super learner approach for modeling long-term electricity consumption," *Sustainability*, c. 15, no. 18, s. 13 409, 2023.
- [20] K. Chapagain, S. Gurung, P. Kulthanavit S. Kittipiyakul, "Short-term electricity demand forecasting using deep neural networks: An analysis for Thai data," *Applied System Innovation*, c. 6, no. 6, s. 100, 2023.
- [21] S. Lin, Y. Wang, H. Wei, X. Wang Z. Wang, "Hybrid Method for Oil Price Prediction Based on Feature Selection and XGBOOST-LSTM," *Energies*, c. 18, no. 9, s. 2246, 2025.
- [22] A. Guenoukpati, A. P. Agbessi, A. A. Salami Y. A. Bakpo, "Hybrid long short-term memory wavelet transform models for short-term electricity load forecasting," *Energies*, c. 17, no. 19, s. 4914, 2024.
- [23] Z. Li, P. Wang, Z. Su, H. Liu, Y. Duan C. Zhu, "Multilevel Discrete Wavelet Decomposition-Assisted Lightweight Multi-Order Gated Aggregation Network for Gas Concentration Retrieval in WMS," *Analytical Chemistry*, 2025.
- [24] Z. Ferdoush, B. N. Mahmud, A. Chakrabarty J. Uddin, "A short-term hybrid forecasting model for time series electrical-load data using random forest and bidirectional long short-term memory," *International Journal of Electrical and Computer Engineering*, c. 11, no. 1, ss. 763–771, 2021.

- [25] T. Liwei, F. Li, S. Yu G. Yuankai, "Forecast of LSTM-XGBoost in Stock Price Based on Bayesian Optimization.," *Intelligent Automation & Soft Computing*, c. 29, no. 3, 2021.
- [26] C. Zhou, C. Che, P. Wang Q. Zhang, "SCAT: A Time Series Forecasting with Spectral Central Alternating Transformers," *Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence*, 2024, ss. 5626–5634.
- [27] Y. Moon, Y. Lee, Y. Hwang J. Jeong, "Long Short-Term Memory Autoencoder and Extreme Gradient Boosting-Based Factory Energy Management Framework for Power Consumption Forecasting," *Energies*, c. 17, no. 15, s. 3666, 2024.
- [28] D. Manfre Jaimes, M. Zamudio López, H. Zareipour M. Quashie, "A Hybrid Model for Multi-Day-Ahead Electricity Price Forecasting considering Price Spikes," *Forecasting*, c. 5, no. 3, ss. 499–521, 2023.
- [29] A. Pandey, S. Kumar V. Sharma, "Wavelet Transform and Artificial Neural Network for Short-Term Load Forecasting," *Energy*, c. 183, ss. 122–130, 2019. doi: 10.1016/j.energy.2019.06.113.
- [30] C. Deina ve diğ., "Forecasting electricity demand by neural networks and definition of inputs by multi-criteria analysis," *Energies*, c. 16, no. 4, s. 1712, 2023.
- [31] M. Farrokhbabadi, *Day-Ahead Electricity Demand Forecasting: Post-COVID Paradigm*, 2020. doi: 10.21227/67vy-bs34. erişim adresi: <https://dx.doi.org/10.21227/67vy-bs34>.
- [32] I. Daubechies, *Ten Lectures on Wavelets*. Philadelphia, PA: Society for Industrial ve Applied Mathematics, 1992, isbn: 978-0-89871-274-2.
- [33] S. Mallat, "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, c. 11, no. 7, ss. 674–693, 1989. doi: 10.1109/34.192463.
- [34] S. Makridakis, E. Spiliotis V. Assimakopoulos, "Statistical and Machine Learning forecasting methods: Concerns and ways forward," *PloS one*, c. 13, no. 3, e0194889, 2018.
- [35] G. E. Box, G. M. Jenkins, G. C. Reinsel G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5. bs. John Wiley & Sons, 2015, isbn: 978-1-118-67502-1.
- [36] F. Rundo, F. Trenta, A. L. Di Stallo S. Battiato, "Machine learning for quantitative finance applications: A survey," *Applied Sciences*, c. 9, no. 24, s. 5574, 2019.
- [37] S. Siامي-Namini, N. Tavakoli A. S. Namin, "A comparison of ARIMA and LSTM in forecasting time series," *2018 17th IEEE international conference on machine learning and applications (ICMLA)*, Ieee, 2018, ss. 1394–1401.
- [38] B. Xue, N. Tong, X. Xu X. He, "Dynamical short-term prediction of rain attenuation in W band: A time-series model with simpler structure and higher accuracy," *IEEE Antennas and Propagation Magazine*, c. 61, no. 1, ss. 77–86, 2019.

- [39] J. Contreras, R. Espinola, F. J. Nogales A. J. Conejo, “ARIMA models to predict next-day electricity prices,” *IEEE transactions on power systems*, c. 18, no. 3, ss. 1014–1020, 2003.
- [40] R. J. Hyndman G. Athanasopoulos, *Forecasting: Principles and Practice*, 2. bs. OTexts, 2018, [https : / / otexts . com / fpp2/](https://otexts.com/fpp2/), isbn: 978-0-9942463-1-0.
- [41] Y. Borgianni, A. Cardillo, G. Cascini F. Rotini, “Systematizing new value proposition through a TRIZ-based classification of functional features,” *Procedia Engineering*, c. 9, ss. 103–118, 2011.
- [42] K. Sembiring, “PENERAPAN TEKNIK SUPPORT VECTOR MACHINE UNTUK PENDETEKSIAN INTRUSI PADA JARINGAN,” 2009. erişim adresi: [https : / / api . semanticscholar . org / CorpusID : 60212699](https://api.semanticscholar.org/CorpusID:60212699).
- [43] L. Breiman, “Random forests,” *Machine learning*, c. 45, ss. 5–32, 2001.
- [44] Y. Yu, X. Si, C. Hu J. Zhang, “A review of recurrent neural networks: LSTM cells and network architectures,” *Neural computation*, c. 31, no. 7, ss. 1235–1270, 2019.
- [45] *LSTM Explained*. erişim adresi: [https : // intellipaat . com / blog / what - is - lstm / # : ~ : text = LSTM % 20 stands % 20 for % 20 long % 20 short , especially % 20 in % 20 sequence % 20 prediction % 20 problems .](https://intellipaat.com/blog/what-is-lstm/#:~:text=LSTM%20stands%20for%20long%20short,especially%20in%20sequence%20prediction%20problems) (erişim tarihi 15/10/2024).
- [46] C. Olah, *Understanding LSTM Networks*, [https : // colah . github . io / posts / 2015 - 08 - Understanding - LSTMs/](https://colah.github.io/posts/2015-08-Understanding-LSTMs/), Accessed: 2025-05-01, 2015.
- [47] I. Sutskever, O. Vinyals Q. V. Le, “Sequence to Sequence Learning with Neural Networks,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2014, ss. 3104–3112.
- [48] J. Adamowski K. Sun, “Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds,” *Journal of Hydrology*, c. 390, no. 1-2, ss. 85–91, 2010.
- [49] J. L. Elman, “Finding structure in time,” *Cognitive science*, c. 14, no. 2, ss. 179–211, 1990.
- [50] D. E. Rumelhart, G. E. Hinton R. J. Williams, “Learning representations by back-propagating errors,” *nature*, c. 323, no. 6088, ss. 533–536, 1986.
- [51] A. Graves N. Jaitly, “Towards end-to-end speech recognition with recurrent neural networks,” *International conference on machine learning*, PMLR, 2014, ss. 1764–1772.
- [52] S. Hochreiter, “Recurrent neural net learning and vanishing gradient,” *International Journal Of Uncertainty, Fuzziness and Knowledge-Based Systems*, c. 6, no. 2, ss. 107–116, 1998.

- [53] K. Cho ve diğ., “Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation,” arXiv preprint arXiv:1406.1078, tek. rap., 2014. erişim adresi: <https://arxiv.org/abs/1406.1078>.
- [54] S. Hochreiter, “Long Short-term Memory,” *Neural Computation MIT-Press*, 1997.
- [55] *Recurrent Neural Network: Maths in 5 Minutes*. erişim adresi: <https://vidishajitani.medium.com/recurrent-neural-network-maths-69214e4d69e1> (erişim tarihi 21/09/2020).
- [56] K. Cho ve diğ., “Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation,” *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, A. Moschitti, B. Pang W. Daelemans, ed., Doha, Qatar: Association for Computational Linguistics, Ekim 2014, ss. 1724–1734. doi: 10 . 3115 / v1 / D14 – 1179. erişim adresi: <https://aclanthology.org/D14-1179/>.
- [57] R. Fu, Z. Zhang L. Li, “Using LSTM and GRU neural network methods for traffic flow prediction,” *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, 2016, ss. 324–328. doi: 10 . 1109/YAC.2016.7804912.
- [58] M. Farrokhhabadi, “Day-ahead electricity demand forecasting: Post-COVID paradigm,” *IEEE Dataport*, 2020.
- [59] C. J. Willmott, S. M. Robeson K. Matsuura, “A refined index of model performance,” *International Journal of climatology*, c. 32, no. 13, ss. 2088–2094, 2012.
- [60] M. Farrokhhabadi, J. Browell, Y. Wang, S. Makonin, W. Su H. Zareipour, “Day-ahead electricity demand forecasting competition: Post-covid paradigm,” *IEEE Open Access Journal of Power and Energy*, c. 9, ss. 185–191, 2022.
- [61] L. Mentaschi, G. Besio, F. Cassola A. Mazzino, “Problems in RMSE-based wave model validations,” *Ocean Modelling*, c. 72, ss. 53–58, 2013.
- [62] M. Q. Raza, Z. Baharudin, B. Islam, M. A. Zakariya M. Khir, “Neural network based STLF model to study the seasonal impact of weather and exogenous variables,” *Research Journal of Applied Sciences, Engineering and Technology*, c. 6, no. 20, ss. 3729–3735, 2013.

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Ali AJDER, Hisham A. A. HAMZA, and Ramazan AYAZ. "Wavelet-Enhanced Hybrid LSTM-XGBoost Model for Predicting Time Series Containing Unpredictable Events," IEEE Access, vol.13, 58671-58679, 2025

Konferans Bildirisi

1. Hisham A. A. HAMZA, Ali AJDER, and Ramazan AYAZ. "Comparison of Deep Learning Architectures to Evaluate the Effect of COVID-19 on Electricity Consumption," 3rd International Conference on Contemporary Academic Research, Konya, Turkey, 2024