



**DERİN ÖĞRENME MODELLERİYLE
ELEKTRİK TÜKETİMİ TAHMİNİ**

Yüksek Lisans Tezi

Emrah DEMİR

Eskişehir 2024

DERİN ÖĞRENME MODELLERİYLE ELEKTRİK TÜKETİMİ TAHMİNİ

Emrah DEMİR

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Donanımı Bilim Dalı

Danışman: Prof. Dr. Serkan GÜNAL

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Nisan 2024

Bu tez çalışması, BAP Komisyonu tarafından kabul edilen 22LÖT247 no.lu proje kapsamında desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Emrah DEMİR'nin DERİN ÖĞRENME MODELLERİYLE ELEKTRİK TÜKETİMİ TAHMİNİ başlıklı çalışması 03/04/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Bilgisayar Mühendisliği Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Prof. Dr. Serkan GÜNAL

Üye

: Doç. Dr. Alper BİLGE

Üye

: Dr. Öğr. Üye. Mehmet KILIÇARSLAN

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

DANIřMAN ONAYI

Daniřmanlıęını yrttęm Yksek Lisans ęrencisi Emrah DEMİR, DERİN ÖĞRENME MODELLERİYLE ELEKTRİK TÜKETİMİ TAHMİNİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduęu tez tarafımca incelenmiř ve ęrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Prof. Dr. Serkan GNAL

ÖZET

DERİN ÖĞRENME MODELLERİYLE ELEKTRİK TÜKETİMİ TAHMİNİ

Emrah DEMİR

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Donanımı Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Nisan 2024

Danışman: Prof. Dr. Serkan GÜNAL

Nüfus artışı, sanayileşme ve teknolojik gelişmelerdeki eğilimler, küresel elektrik tüketiminde önemli bir artışa neden olmaktadır. Yenilenebilir enerji kaynaklarında önemli ilerlemeler kaydedilirken, sınırlı ve çevresel kaygılara neden olan fosil yakıtları hâlâ elektrik üretiminin birincil kaynağı olmaya devam etmektedir. Bu sorunun üstesinden gelmek ve enerji kullanımını optimize etmek için elektrik talebinin doğru tahmin edilmesi oldukça önemlidir. Bu nedenle bu tez çalışmasında, kısa vadeli (gelecek 24 saat) elektrik tüketimi tahmini için uzun kısa süreli bellek (LSTM) ağı, evrişimli sinir ağı (CNN) ve bu mimarileri birleştiren topluluk öğrenimi temelli derin öğrenme modelleri önerilmektedir. Modeller yalnızca elektrik tüketimi verilerini değil, aynı zamanda sıcaklık, bağıl nem ve rüzgar hızı gibi ilgili meteorolojik parametreleri ve zaman damgaları da dahil olmak üzere ek öznitelikler kullanmaktadır. Modellerin eğitimi ve değerlendirilmesi için coğrafi olarak farklı iki bölgeden alınan yaklaşık 2,5 yıllık saatlik elektrik tüketim, meteoroloji ve zaman damgası verileri kullanılmıştır. Kapsamlı deneysel çalışmalar, söz konusu modellerin uygun öznitelik kümeleriyle eğitilmeleri halinde, elektrik tüketimi tahminine yönelik normalleştirilmiş kök ortalama kare hata (N-RMSE) değerini “0,16”, normalleştirilmiş ortalama mutlak hata (N-MAE) değerini “0,13” ve ortalama mutlak yüzde hata (MAPE) değerini “%4,05” seviyesine kadar düşürebileceğini ortaya koymuştur. Sonuç olarak, bu tez çalışması, elektrik tüketimi tahmini için etkili modeller sunmasının yanı sıra meteorolojik özniteliklerin tahmin performansı üzerindeki etkisine ilişkin değerli bilgiler de vermektedir. Bu katkılar, daha doğru ve gürbüz tahmin yöntemlerinin geliştirilmesine yönelik gelecekteki araştırmalara rehberlik edebilecektir.

Anahtar Sözcükler: Elektrik tüketimi tahmini, Derin öğrenme, Yapay zeka, LSTM, CNN, Topluluk öğrenmesi.

ABSTRACT

ELECTRICITY CONSUMPTION FORECASTING WITH DEEP LEARNING MODELS

Emrah DEMİR

Department of Computer Engineering

Programme in Computer Hardware

Eskişehir Technical University, Institute of Graduate Programs, April 2024

Supervisor: Prof. Dr. Serkan GÜNAL

Current trends in population growth, industrialization, and technological advancements are driving a significant increase in global electricity consumption. While renewable energy sources are making significant strides, fossil fuels still remain the primary source of electricity generation, posing challenges due to resource limitations and environmental concerns. To address these challenges and optimize energy use, accurate prediction of electricity demand is crucial. Therefore, in this thesis dissertation, deep learning models based on long short-term memory (LSTM) network, convolutional neural network (CNN), and ensemble learning combining both architectures are proposed for short-term (next 24 hours) electricity consumption forecasting. The models utilize not only electricity consumption data but also additional features including timestamps and relevant meteorological parameters such as temperature, relative humidity, and wind speed. Two geographically diverse datasets encompassing approximately 2.5 years of hourly electricity consumption data as well as meteorology and timestamp data were utilized for training and evaluating the models. Extensive experimental studies demonstrated that the proposed models utilizing appropriate feature sets can achieve normalized root mean square error (N-RMSE) values as low as “0.16”, normalized mean absolute error (N-MAE) values as low as “0.13”, and mean absolute percentage error (MAPE) values as low as “4.05%”. In conclusion, this dissertation presents not only effective models for short-term electricity consumption forecasting but also valuable insights into the impact of meteorological features on forecasting performance. These contributions can guide future research efforts in developing even more accurate and robust forecasting methods.

Keywords: Electricity consumption forecasting, Deep learning, Artificial intelligence, LSTM, CNN, Ensemble learning.

TEŞEKKÜR

Öncelikle, danışmanlığımı üstlenen, değerli tecrübeleri ve zamanıyla bana yol gösterip destek olan Prof. Dr. Serkan GÜNAL hocama sonsuz teşekkürlerimi sunarım.

Tez savunma jürimde yer alarak değerli görüşleriyle araştırmamın şekillenmesinde önemli rol oynayan Doç. Dr. Alper BİLGE ve Dr. Öğr. Üye. Mehmet KILIÇARSLAN hocalarıma teşekkürü bir borç bilirim.

Başta annem ve babam olmak üzere, hayatım boyunca beni destekleyen aileme teşekkürü bir borç bilirim. Hayatımın her alanında olduğu gibi, çalışmalarımda beni destekleyen sevgili eşim Rabia DEMİR'e sonsuz teşekkür ederim.

Emrah DEMİR

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Emrah DEMİR

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ.....	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ.....	XIV
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	8
3. ÖNERİLEN TAHMİN MODELLERİ	14
3.1. Veri Setleri.....	14
3.1.1. Dayton.....	14
3.1.2. Houston.....	16
3.2. Tahmin Modelleri	18
3.2.1. LSTM.....	18
3.2.2. CNN	20
3.2.3. Topluluk	22
3.3. Performans Metrikleri.....	23
3.3.1. N-RMSE	23
3.3.2. N-MAE	24
3.3.3. MAPE	25
4. DENEYSEL ÇALIŞMA VE TARTIŞMALAR	26

4.1. Dayton Veri Setiyle Eğitilen Modeller.....	28
4.1.1. LSTM modeli	28
4.1.2. CNN modeli.....	32
4.1.3. Topluluk modeli.....	35
4.1.4. Günlük performans analizi.....	39
4.2. Houston Veri Setiyle Eğitilen Modeller	41
4.2.1. LSTM modeli	41
4.2.2. CNN modeli.....	45
4.2.3. Topluluk modeli.....	49
4.2.4. Günlük performans analizi.....	53
4.3. Literatürle Karşılaştırma	55
5. SONUÇLAR.....	57
KAYNAKÇA.....	58
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 3.1. Dayton veri seti: eğitim, validasyon ve test verilerinin dağılımı	15
Tablo 3.2. Houston veri seti: eğitim, validasyon ve test verilerinin dağılımı	17
Tablo 3.3. LSTM hiperparametreleri	19
Tablo 3.4. CNN hiperparametreleri	21
Tablo 4.1. Tahmin modellerinde kullanılan öznitelik setleri	26
Tablo 4.2. Önerilen modellerin performansının literatürle karşılaştırılması.....	56



ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Dünya, 1973 sektörlere göre elektrik tüketim oranları (World total final consumption by source, 2021)	2
Şekil 1.2. Dünya, 2019 sektörlere göre elektrik tüketim oranları (World total final consumption by source, 2021)	3
Şekil 1.3. Türkiye, 2021 dünya geneli elektrik tüketim sırası (Türkiye elektrik üretim ve tüketim bilgileri, 2021)	4
Şekil 1.4. Türkiye, 2021 sektörlere göre elektrik tüketim oranları (Türkiye elektrik üretim ve tüketim bilgileri, 2021)	4
Şekil 3.1. Dayton şehrine ait günlük elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı verisi	15
Şekil 3.2. Dayton şehrine ait elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı korelasyon matrisi	16
Şekil 3.3. Houston şehrine ait günlük elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı verisi	17
Şekil 3.4. Houston şehrine ait elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı korelasyon matrisi	18
Şekil 3.5. Bir LSTM hücresinin şeması (Torres, Martínez-Álvarez, & Troncoso, 2022)	19
Şekil 3.6. Önerilen CNN mimarisi	21
Şekil 4.1. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin kayıp grafiği	28
Şekil 4.2. Dayton veri seti: farklı öznitelik setleri için LSTM modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri	29
Şekil 4.3. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı	30
Şekil 4.4. Dayton veri seti: Elec+Temp+Humid+Time öznitelikleriyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı	31
Şekil 4.5. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin kayıp grafiği	32
Şekil 4.6. Dayton veri seti: farklı öznitelik setleri için CNN modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri	33

Şekil 4.7. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı	34
Şekil 4.8. Dayton veri seti: Elec+Temp+Humid+Wind+Time öznitelikleriyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı	35
Şekil 4.9. Dayton veri seti: farklı öznitelik setleri için Topluluk modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri	36
Şekil 4.10. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen Topluluk modelinin test setinin tamamındaki tahmin performansı.....	37
Şekil 4.11. Dayton veri seti: Elec+Temp+Humid+Time öznitelikleriyle eğitilen Topluluk modelinin test setinin tamamındaki tahmin performansı	38
Şekil 4.12. Dayton veri seti: yaz mevsimi hafta içinde LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması	39
Şekil 4.13. Dayton veri seti: yaz mevsimi hafta sonunda LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması	40
Şekil 4.14. Dayton veri seti: kış mevsimi hafta içinde LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması	40
Şekil 4.15. Dayton veri seti: kış mevsimi hafta sonunda LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması	41
Şekil 4.16. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin kayıp grafiği.....	42
Şekil 4.17. Houston veri seti: farklı öznitelik setleri için LSTM modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri	43
Şekil 4.18. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı.....	44
Şekil 4.19. Houston veri seti: Elec+Temp+Time öznitelikleriyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı.....	45
Şekil 4.20. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin kayıp grafiği.....	46
Şekil 4.21. Houston veri seti: farklı öznitelik setleri için CNN modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri	47
Şekil 4.22. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı.....	48

Şekil 4.23. Houston veri seti: Elec+Temp+Time öznitelikleriyle eğitilen CNN	
modelinin test setinin tamamındaki tahmin performansı.....	49
Şekil 4.24. Houston veri seti: farklı öznitelik setleri için Topluluk modeliyle elde	
edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri	50
Şekil 4.25. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen Topluluk	
modelinin test setinin tamamındaki tahmin performansı.....	51
Şekil 4.26. Houston veri seti: Elec+Temp+Time öznitelikleriyle eğitilen Topluluk	
modelinin test setinin tamamındaki tahmin performansı.....	52
Şekil 4.27. Houston veri seti: yaz mevsimi hafta içinde LSTM, CNN ve Topluluk	
modellerinin tahmin performanslarının karşılaştırması	53
Şekil 4.28. Houston veri seti: yaz mevsimi hafta sonunda LSTM, CNN ve	
Topluluk modellerinin tahmin performanslarının karşılaştırması	54
Şekil 4.29. Houston veri seti: kış mevsimi hafta içinde LSTM, CNN ve Topluluk	
modellerinin tahmin performanslarının karşılaştırması	54
Şekil 4.30. Houston veri seti: kış mevsimi hafta sonunda LSTM, CNN ve	
Topluluk modellerinin tahmin performanslarının karşılaştırması	55

SİMGELER VE KISALTMALAR DİZİNİ

ANN	: Artificial Neural Network (Yapay Sinir Ağı)
AR	: Autoregressive (Otoregresif)
ARIMA	: Autoregressive Integrated Moving Average (Otoregresif Entegre Hareketli Ortalama)
ARMA	: Autoregressive Moving Average (Otoregresif Hareketli Ortalama)
BRBNN	: Bayesian Regularization Backpropagation Neural Networks (Bayesian Düzenleştirme Geriye Yayımlı Sinir Ağları)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
CSGBNN	: Conjugate Scaled Gradient Backpropagation Neural Networks (Eşlenik Ölçekli Gradyan Geriye Yayımlı Sinir Ağları)
DCPR	: Daily Energy Consumption Pattern Recognition (Günlük Enerji Tüketim Deseni Tanıma)
DeepAR	: Deep Autoregressive (Derin Otoregresif)
DNNs	: Deep Neural Networks (Derin Sinir Ağları)
Elec	Electricity Consumption (Elektrik Tüketimi)
EMD	: Empirical Mode Decomposition (Ampirik Mod Ayrışımı)
ES	: Exponential Smoothing (Üstel Düzeltme)
GA	: Greedy Algorithm (Açgözlü Algoritma)
GEC	: Gross Electricity Consumption (Toplam Elektrik Tüketimi)
GOA	: Grasshopper Optimization Algorithm (Çekirge Optimizasyon Algoritması)
GRU	: Gated Recurrent Unit (Kapılı Tekrarlayan Birim)
Humid	: Relative Humidity (Bağıl Nem)
IEA	: International Energy Agency (Uluslararası Enerji Ajansı)
ITFT	: Improved Temporal Fusion Transformer (Geliştirilmiş Zamansal Birleşim Dönüştürücüsü)
LMBNN	: Levenberg-Marquardt Backpropagation Neural Networks (Levenberg-Marquardt Geriye Yayımlı Sinir Ağları)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MHA	: Multi-Headed Attention (Çok Başlı Dikkat)
ML-LSTM	: Multi-Layer Long Short-Term Memory (Çok Katmanlı Uzun Kısa Süreli Bellek)

N-BEATS	: Neural Basis Expansion Analysis for Interpretable Time Series (Yorumlanabilir Zaman Serileri için Nöral Temel Genişleme Analizi)
R-CNN	: Residual Convolutional Neural Network (Artık Evrişimsel Sinir Ağı)
RMSE	: Root Mean Square Error (Kök Ortalama Kare Hata)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
SARIMA	: Seasonal Autoregressive Integrated Moving Average (Mevsimsel Otoresif Entegre Hareketli Ortalama)
SD	: Similar Days (Benzer Günler)
STL	: Seasonal and Trend Decomposition (Mevsimsel ve Eğilim Ayırıştırma)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TCN	: Temporal Convolutional Network (Zamansal Evrişimsel Ağ)
Temp	: Temperature (Sıcaklık)
TFT	: Temporal Fusion Transformer (Zamansal Birleşim Dönüştürücüsü)
Time	: Time Stamp (Zaman Damgası)
TL	: Transfer Learning (Transfer Öğrenme)
Wind	: Wind Speed (Rüzgar Hızı)
XgBoost	: Extreme Gradient Boosting (Ekstrem Gradyan Artırma)

1. GİRİŞ


Modern dünyamızda yüksek nüfus yoğunluğuna sahip kentsel alanlar, dikkat edilmesi gereken çeşitli zorlukları bünyesinde barındırmaktadır. En kritik konulardan biri istikrarlı bir elektrik arzının sağlanmasıdır. Günümüz toplumlarında elektrik evlere, endüstrilere, ulaşım, sağlık hizmetlerine, eğlenceye ve sanata güç vererek çağdaş yaşamın hayati bir unsuru haline gelmiştir. Elektriğe olan talep günden güne artmaya devam ederken, enerji kaynaklarımızı akıllıca kullanmak büyük bir önem taşımaktadır. Rüzgar, su, güneş, doğal gaz, kömür, petrol ve nükleer enerji gibi çeşitli elektrik enerjisi kaynakları olsa da bu kaynakları sorumlu ve sürdürülebilir bir şekilde kullanmalıyız. Üretilen elektriğin depolanması pahalı ve işlevsel olarak zor olduğundan, elektrik güç sistemi istikrarı arz ve talep arasında sarsılmaz bir denge gerektirir (Shahidehpour, Yamin, & Li, 2003). Enerji yönetimi verimliliği açısından elektrik üretimi ve tüketimini dengelemek oldukça önemlidir. Enerji ihtiyacımızı doğru bir şekilde değerlendirerek fazla veya eksik elektrik üretmekten kaçınmamız gerekmektedir. Kaynakların verimli ve sürdürülebilir kullanımı için enerji üretimi ve tüketimi arasındaki dengenin sağlanması büyük önem taşımaktadır.

Yetersiz elektrik üretiminin bir dizi olumsuz etkisi olmaktadır (Kambule, Yessoufou, & Nwulu, 2018), (Hunt, Stilpen, & de Freitas, 2018). Örneğin enerji talebinin karşılanamamasına neden olabilir ve bu durum çeşitli sektörlerin işleyişini önemli ölçüde etkileyebilir. Elektrik talebinin karşılanamaması ile elektrik kesintileri sıklaşarak ticari faaliyetler ve endüstriyel üretimin durması gibi günlük yaşamın çeşitli yönleri üzerinde oldukça önemli olumsuzluklar ortaya çıkabilir. Bu tür kesintiler farklı sektörlerde operasyonel aksamalara yol açarak iş kayıplarına ve diğer olumsuz sonuçlara yol açabilir. Bu olumsuzluklar aynı zamanda ülkelerin ekonomik kalkınmasının önünde engel teşkil edebilmektedir. Yetersiz elektrik üretimi, hastanelerde ve diğer sağlık kuruluşlarında tıbbi cihaz ve sistemlerin düzgün çalışmasını engelleyebileceği gibi, güvenlik sistemlerini ve aydınlatmayı da etkisiz hale getirebilir. Elektrik kesintileri okul, üniversite ve diğer kurumlardaki eğitim faaliyetlerini de aksatabilir, iletişim kanallarında, ürün tedarikinde ve toplumsal istikrarda önemli aksamalara neden olabilir.


İhtiyaç fazlası elektrik üretimi çevreyi ve ekonomiyi olumsuz etkileyebilir. Günümüzde, elektrik üretiminde kömür, petrol, doğalgaz gibi fosil yakıtların kullanımı yaygındır. Aşırı üretim, bu yakıtların tüketiminin artmasına ve daha yüksek sera gazı emisyonlarına yol açabilir. Ayrıca hidroelektrik ve nükleer enerji gibi elektrik üretiminde

kullanılan kaynakların aşırı tüketimi su kaynaklarının olumsuz etkilenmesinin yanında nükleer atık sorunlarına da yol açabilmektedir. İhtiyaç duyulandan daha fazla elektrik üretmenin ekonomik sonuçları da olabilir. İhtiyaçtan fazla elektrik üretmenin ekonomik sonuçları da bulunmaktadır. Enerji fiyatlarının düşmesine neden olarak, enerji şirketlerinin gelirlerini azaltabilir ve yatırımları olumsuz etkileyebilir. Ayrıca, enerji iletim ve dağıtım altyapısının kapasitesini aşarak elektrik piyasasında gereksiz yatırımlara yol açabilir.

Gelişen toplumlarla birlikte elektrik enerjisine olan ihtiyaç her geçen gün artmaktadır. Bu artan talebi karşılamak ve sürdürülebilir enerji kaynaklarını güvence altına almak amacıyla, Uluslararası Enerji Ajansı (International Energy Agency - IEA) 1974 yılında kurulmuştur. IEA'nın sağladığı bilgiler, hükümetler ve endüstrinin enerji arz güvenliğini sağlama, enerji verimliliğini artırma ve yenilenebilir enerji kaynaklarına geçiş gibi konularda bilinçli kararlar almasına yardımcı olmaktadır. 2021 yılında, IEA dünya genelinde tüketilen enerji kaynakları ve miktarları hakkında kapsamlı veriler paylaşmıştır, bu da enerji politikalarının ve stratejilerinin belirlenmesinde önemli bir rol oynamaktadır. IEA tarafından paylaşılan 1973 ve 2019 yıllarına ait dünya genelinde elektrik tüketiminin sektörlere göre dağılımı, sırasıyla Şekil 1.1'de ve Şekil 1.2'de sunulmuştur.




Şekil 1.1. Dünya, 1973 sektörlere göre elektrik tüketim oranları (World total final consumption by source, 2021)



Şekil 1.2. Dünya, 2019 sektörlere göre elektrik tüketim oranları (World total final consumption by source, 2021)


Söz konusu şekillerde görüldüğü üzere, sektörlere göre en çok elektrik tüketimi endüstri alanında gerçekleşmiştir. 1973 yılında, dünya genelinde endüstriyel faaliyetler için tüketilen elektrik, toplam tüketiminin %53,5'ini oluştururken, bu oran 2019 yılında %41,9'a gerilemiştir. Yıllar içinde dünya genelindeki endüstriyel sektörün toplam elektrik kullanım oranındaki düşüşüne karşılık, konutlar, ticari - kamu hizmetleri ve diğer alanlardaki elektrik kullanım oranı artarken, ulaşımda kullanılan elektriğin oranı düşmüştür. Endüstri sektörü gibi elektrik kullanım oranı düşen ulaşım, %2,4'ten %1,8'e gerilemiştir. Endüstri ve ulaşımın aksine yıllar içinde dünya genelinde elektrik kullanım oranı yükselen konutlardaki elektrik tüketiminin oranı %23,1'den %26,6'ya yükselmiştir. Ticari ve kamu hizmetlerindeki elektrik kullanım oranı %15,3'ten %21,2'ye, diğer alanlarda kullanılan elektriğin oranı %5,8'den %8,5'e yükselmiştir.

IEA tarafından paylaşılan 2021 raporuna göre, Türkiye, kişi başına düşen yıllık elektrik tüketim miktarı açısından dünya ülkeleri arasında 63. sırada yer almaktadır. Bu sıralama, Türkiye'nin enerji tüketimindeki yerini ve küresel enerji piyasasındaki rolünü anlamamıza yardımcı olmaktadır. Kişi başı yıllık elektrik tüketim miktarının, Türkiye, dünya ortalaması ve sıralamada Türkiye ile benzer bölgede olan diğer ülkelerin genel görünümü, Şekil 1.3'te sunulmuştur.



Şekil 1.3. Türkiye, 2021 dünya geneli elektrik tüketim sırası (Türkiye elektrik üretim ve tüketim bilgileri, 2021)

Ülkemizin 2021 yılındaki toplam elektrik tüketiminin sektörlere göre dağılımı Şekil 1.4’te sunulmuştur.



Şekil 1.4. Türkiye, 2021 sektörlere göre elektrik tüketim oranları (Türkiye elektrik üretim ve tüketim bilgileri, 2021)

Söz konusu şekilde görüldüğü üzere, 2021 yılında endüstri sektörü %47,2'lik elektrik tüketim oranı ile en üst sırada yer alırken, %25,6 oranı ile ticari ve kamu hizmetleri 2. Sırada bulunmaktadır. Bu iki sektörü, %21,8'lik elektrik tüketim oranı ile konut sektörü takip etmektedir.

Elektriğe duyulan ihtiyacın artması ve toplumlarımızda hayati bir rol oynuyor olması sebebi ile elektrik üretim ve tüketim miktarlarının doğru tahmin edilmesi büyük önem taşımaktadır. Günümüzde elektrik arz ve talebinin sağlanması için hükümetler ve elektrik üretim firmaları çeşitli çalışmalar yapmaktadır. Son zamanlarda akademik çalışmaların da üzerinde yoğunlaştığı bir alan olan zaman serisi tahmin modelleri bu çalışmaların bir koludur.

Zaman serisi tahmin modelleri, belirli bir zaman serisinin geçmiş verilerini analiz ederek gelecekteki değerlerini tahmin etmek için kullanılan modellerdir. Bu modellerin kullanımı çok sayıda alana yayılmaktadır; bu alanlardan biri de elektrik üretimi ve tüketiminin tahminidir. Bu modeller, elektrik kaynaklarının kullanımının optimize edilmesi ve olası olumsuz etkilerin dikkatle ele alınması açısından özellikle önemlidir. Tahmin modelleri, kısa vadeli, orta vadeli ve uzun vadeli (Weron, 2014) olmak üzere üç farklı tahmin ufkuna göre kategorize edilmiştir. Birkaç dakikadan birkaç güne kadar uzanan zaman aralığı içindeki tahminler, kısa vadeli tahminler olarak tanımlanır. Orta vadeli tahmin alanı, birkaç günden birkaç aya kadar değişen tahminleri kapsar. Daha uzun sürelerle yönelik tahminler ise uzun vadeli tahminler olarak sınıflandırılmaktadır. Akademik çalışmalar, uzun bir süre boyunca bu modellerin araştırılmasına ve geliştirilmesine büyük önem vermiştir.

Literatürde istatistiksel ve makine öğrenmesine dayalı tahmin modelleri yaygın olmakla birlikte, makine öğrenmesinin bir alt dalı olan derin öğrenme modelleri, üstün performansları nedeniyle gelecek vaat eden bir yaklaşım olarak ortaya çıkmıştır. Karmaşık sinir ağı mimarileriyle karakterize edilen derin öğrenme modelleri, zaman serisi verileri içindeki karmaşık kalıpları ve bağımlılıkları yakalamada üstün yetenekler sergilemektedir. Derin öğrenme tabanlı modellerin bu doğal yetenekleri, tahmin doğruluğunu artırmakta ve onları tahmin uygulamaları için cazip bir seçim haline getirmektedir.

Bu tez çalışmasında, kısa vadeli elektrik tüketimi tahmini için uzun kısa süreli bellek ağı (LSTM), evrişimli sinir ağı (CNN) ve her iki mimariyi birleştiren bir topluluktan (Ensemble) oluşan derin öğrenme modelleri önerilmiştir. Önerilen modellerin

etkinliđi, sistematik bir yaklaşıml kullanarak değerdendirilmiş ve elde edilen sonuçların kapsamlı bir analizi sunulmuştur. Modelleri eğitmek ve performanslarını analiz etmek için coğrafi olarak farklı bölgelerde bulunan iki farklı şehrin elektrik tüketimi, meteoroloji ve zaman verilerinden oluşan 2 farklı veri seti üzerinde kapsamlı çalışmalar gerçekleştirilmiştir.

Önerilen modellerin mimarisi için, çok adımlı tahmin yaklaşımı benimsenerek, geçmiş 7 günün (168 saatlik veri) verileri kullanarak, bir sonraki günün (24 saatlik tahmin) saatlik frekansta tahminleri yapılmıştır. Geliştirilen modellerin tahmin performanslarını ölçmek için çeşitli performans metriklerinden faydalanılmıştır. Bu tez çalışmasının ana katkıları aşağıdaki gibidir:

1. Kısa vadeli elektrik tüketimi tahmini için yüksek doğruluğa sahip özgün tahmin modelleri geliştirilmiştir.
2. Bu çalışma, çeşitli uygulamalar için derin öğrenme tabanlı zaman serisi tahmin modellerinden yararlanmak isteyen araştırmacılar, uygulayıcılar ve endüstri profesyonelleri için değerli bir kaynak olarak hizmet edecektir.
3. Çalışmanın bulgularının enerji sektörüne yönelik etkileri dikkate değerdir, çünkü elektrik tüketiminin tahmin edilmesine yönelik daha doğru ve verimli modellerin geliştirilmesine yol açma potansiyeline sahiptirler. Karar verme ve kaynak tahsisini daha bilinçli ve stratejik bir şekilde bilgilendirebileceği için bunun sektöre geniş kapsamlı faydaları olacaktır.
4. Bu çalışma, kısa vadeli elektrik tüketimi tahmini için etkili modeller sunmasının yanında, aynı zamanda meteorolojik ve zaman damgası gibi özniteliklerin tahmin performansı üzerindeki etkisine ilişkin değerli analizler sunmaktadır.
5. Bu katkılar, daha doğru ve sağlam tahmin yöntemlerinin geliştirilmesine yönelik gelecekteki araştırma çabalarına ışık tutacaktır.

Tez çalışmasının geri kalanı şu şekilde organize edilmiştir: İkinci bölümde, literatürdeki zaman serisi tahmin modellerinin kapsamlı bir incelemesi yapılmış, aralarındaki farklar vurgulanmış ve bu çalışmaya katkıları açıklanmıştır. Üçüncü bölümde, tez çalışması kapsamında önerilen tahmin modelleri tanıtılmıştır. Bu doğrultuda, modellerin eğitilmesi ve test edilmesi için kullanılan veri setleri açıklanmış, modellerin mimarileri sunulmuş ve modellerin tahmin performanslarının belirlenmesi

iin kullanılan metrikler belirtilmiřtir. Drdnc blmde, deneysel sonuların kapsamlı bir analizi yapılmıř ve nerilen modellerin performansları tartıřılmıřtır. Son blmde ise tez alıřmasında elde edilen sonuların bir zeti sunulmuř ve gelecek alıřma planlarına deėinilmiřtir.



2. LİTERATÜR TARAMASI

Zaman serisi tahmin problemlerinin üstesinden gelmek için ilk aşamalarda, kendine özgü eğilimler veya mevsimsellik içermeyen durağan zaman serilerini modellemek ve tahminler üretmek için Otoregresif (AR) modeli önerilmiştir. AR modeli, önceki zaman adımlarından elde edilen gözlemlerin doğrusal bir kombinasyonunu kullanarak tahminler üretebilmektedir. Daha sonra bu klasik modele dayanarak Otoregresif Hareketli Ortalama (ARMA) modeli önerilmiştir (Pappas, et al., 2008). Ancak ARMA modeli durağan olmayan yani trend ve mevsimsellik içeren zaman serisi verileri için uygun değildir. Bu nedenle daha sonra Otoregresif Entegre Hareketli Ortalama (ARIMA) önerilmiştir (Bowden & Payne, 2008). ARIMA, zaman serisi verileri üzerinde bir veya daha fazla farklılaştırma yöntemi kullanılarak zaman serilerini durağan hale getirilebildiği için zaman serilerindeki trend ve mevsimsellik sorunlarının üstesinden gelebilmektedir.

Destek Vektör Makinesi (SVM), örnekleri orijinal uzaydan yüksek boyutlu bir uzaya eşleyerek çalışmaktadır. SVM, bu dönüşümden yararlanarak doğrusal regresyonu gerçekleştirmektedir (Yan & Chowdhury, 2014). Bu model, özellikle verileri iki kategoriye ayırmayı hedeflediği sınıflandırma yöntemlerinde etkili olmuştur. ARIMA ve SVM, doğrusal seriler üzerinde çalışan geleneksel zaman serisi tahmin modelleridir.

İlerleyen aşamalarda, verilerdeki son değişiklikleri ön plana çıkararak tahminleri güncelleme uygulamasını içeren Üstel Düzeltme (ES) modeli tanıtılmıştır (Rendon-Sanchez & de Menezes, 2019). Bu zaman serisi modeli, hesaplamada yeni verilere daha yüksek önem atfeder ve eski verilere kıyasla onlara tahminde daha fazla ağırlık vermektedir. Zaman serisi tahminlerinde üstel düzeltme uygulamaları genellikle üç temel yöntemi kullanmaktadır: basit üstel düzeltme, trend düzeltmeli üstel düzeltme ve mevsimsel değişim.

Sonrasında, doğrusal zaman serileri üzerinde iyi sonuçlar veren geleneksel zaman serisi modellerinden farklı olarak, doğrusal olmayan problemlerin çözümünde büyük avantajlara sahip olan Yapay Sinir Ağları zaman serisi modelleri sunulmuştur. Türkiye’de aylık elektrik talebini tahmin etmeye yönelik bir çalışma yapılmıştır (Hamzaçebi, Es, & Çakmak, 2019). Söz konusu çalışmada, mevsimsellik ve trendin etkilerini modellemek için dört farklı yapay sinir ağı (YSA) modeli kullanılmıştır. Sonrasında, en iyi performans gösteren YSA modelinin performansı ile mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modelinin performansı ile karşılaştırılmıştır. İlerleyen zamanlarda,

iyi bilinen üç tahmin modeli kullanılarak denetimli makine öğrenimi algoritmalarının kapsamlı bir incelemesi yapılmıştır (Ahmad & Chen, 2020). Bayesian Düzenleme Geri Yayılımlı Sinir Ağları (BRBNN), Levenberg-Marquardt Geri Yayılımlı Sinir Ağları (LMBNN) ve Eşlenik Ölçekli Gradyan Geri Yayılımlı Sinir Ağları (CSGBNN) modelleri arasında yapılan tahmin performanslarının analizlerinde, BRBNN ve LMBNN modellerinin daha iyi sonuçlar verdiği gözlemlenmiştir.

Topluluk öğrenimi (ensembling learning) olarak da bilinen topluluk oluşturma, makine öğreniminde güçlü bir teknik olarak kullanılmaktadır. Bu, esasen, herhangi bir modelin tek başına elde edebileceğinden daha iyi sonuçlar elde etmek amacıyla birden fazla modeli tek bir modelde birleştirmenin bir yolu olarak öne sürülmüştür. Kısa vadeli gaz talebini tahminlemesi üzerine yapılan bir çalışmada 4 farklı topluluk tahmincisi oluşturulmuş ve temel tahmin modelleri ile karşılaştırılmıştır (Marziali, Fabbiani, & Nicolao, 2021). Yazarların elde ettiği sonuçlara göre topluluk öğrenimi yaklaşımı sürekli olarak temel modellerden daha iyi sonuç göstermiştir.

Son yıllarda makine öğrenmesinin bir alt modeli olan derin öğrenme modelleri, zaman serisi tahminlerindeki yüksek performanslarıyla daha popüler hale gelmiştir. Çok Başlı Dikkat (MHA) ile CNN'yi birleştiren hibrit bir derin öğrenme modeli, 2.075.259 zaman serisi içeren Kaliforniya Üniversitesi, Irvine (UCI) ev elektriği veri seti kullanılarak test edilmiştir (Bu & Cho, 2020). Elde edilen sonuçlara göre, önerilen modelin performans açısından mevcut derin öğrenme modellerini geride bıraktığını gözlemlenmiştir. Yakın zamanda yapılan bir çalışmada, Türkiye'de Covid-19 dönemindeki saatlik elektrik tüketimi verileri kullanılarak GoogleNet, AlexNet, SqueezeNet ve ResNet18 gibi önceden eğitilmiş modellerin yanı sıra giriş sinyali algoritmasına sahip CNN yönteminin de yer aldığı bir araştırma gerçekleştirilmiştir (Atik, 2022). Yazarlar, önerilen CNN modelinin doğruluk ve verimlilik açısından diğer önceden eğitilmiş modellerden daha iyi performans gösterdiğini ortaya koymuştur. Başka bir çalışmada, bir LSTM modelinin performansı üç farklı hibrit ANFIS modeliyle karşılaştırılmıştır (Bilgili, Arslan, Şekertekin, & Yaşar, 2022). Yazarlara göre, LSTM modelinin genel olarak tüm ANFIS modellerinden daha iyi performans gösterdiği belirtilmiştir. Başka bir çalışmada araştırmacılar, kısa vadeli elektrik tüketimini tahmin etmek için LSTM zaman serisi tahmin modelini kullanmışlardır (Torres, Martínez-Álvarez, & Troncoso, 2022). Yazarlar, İspanya'nın 10 dakikalık elektrik üretim verilerini

kullanarak 4 saatlik tahminler üretmiş ve LSTM modelinin etkinliğini gözlemlemiştir. Başka bir çalışmada, kanal iletişimini sağlamak için bir C3 bloğu, verimli özellik çıkarımı için iki evrişimli katman içeren bir CNN modeli ve kesin tahmin için bir LSTM modelinden oluşan yeni bir hibrit yaklaşım tanıtılmıştır (Saeed, Paul, & Seo, 2022). Yazarların elektrik yükü verileri üzerinde yaptığı ampirik analizler sonucunda, önerilen hibrit modelin son derece doğru sonuçlar verdiği öne sürülmüştür. Sonrasında, gerçek elektrik enerjisi tüketim verilerine dayanarak kısa vadeli elektrik yüklerini tahmin etmek için artık CNN ve yığılmış LSTM katmanlarını birleştiren bir derin öğrenme mimarisi sunulmuştur (Khan, et al., 2022). Yazarlara göre önerilen model, temel modellerle karşılaştırıldığında en düşük hata oranını vermiştir. Yapılan başka bir çalışmada kısa vadeli elektrik yükü tahmini için yeni bir hibrit yaklaşım önerilmiştir (Alsharekh, et al., 2022). Önerilen model hem konut IHEPC hem de ticari PJM veri setleri ile değerlendirilmiştir. Deneyler sonucunda yazarlar, Çok Katmanlı LSTM (ML-LSTM) mimarisi ile Artık CNN (R-CNN) modellerinin birleşiminden oluşan hibrit modelin, diğer temel modellere göre önemli ölçüde düşük hata oranı sergilediğini bulmuştur. Son olarak, Türkiye’de aylık brüt elektrik tüketimini (GEC) tahmin etmek için bir LSTM modeli önerilmiştir (Bilgili & Pinar, 2023). Yazarlar, önerilen modeli SARIMA ile karşılaştırılmış ve önerilen LSTM modelinin SARIMA’ya göre daha doğru sonuçlar ürettiğini belirtmiştir.

Extreme Gradient Boosting (XgBoost), doğruluk elde etmek için Açgözlü Algoritmayı (GA) kullanan başka bir zaman serisi modelidir. Algoritma, verileri daha küçük alt kümelerle böler ve modeli her bir alt kümeye uygulayarak daha iyi doğruluk elde edilmesini sağlamaktadır. Ancak bu aynı zamanda eğitim süresini de arttırmaktadır. Zheng ve arkadaşları, kısa vadeli yük tahmini için XgBoost algoritmasını Benzer Günler (SD) seçimi ve Ampirik Mod Ayırıştırma (EMD) yöntemleriyle birleştiren yeni bir hibritleştirilmiş model önermiştir (Zheng, Yuan, & Chen, 2017). Yazarlara göre, önerilen Xgboost-k-means yönteminin karşılaştırılan diğer modellere göre daha iyi sonuçlar verdiği gözlemlenmiştir. Yakın zamanda yapılan başka bir akademik çalışmada araştırmacılar, pencereli XGBoost modeline dayalı ultra kısa vadeli bir yük tahmin yöntemini önermiştir (Zhao, et al., 2022). Yapılan bu çalışma ile, Singapur elektrik piyasasının gerçek zamanlı elektrik fiyatı tahmin edildi ve yazarların elde ettiği sonuçlar, önerilen modelin karşılaştırılan diğer modellerden daha iyi performans gösterdiğini ortaya koymuştur.

Facebook'un veri bilimi ekibi, Prophet olarak bilinen ve zaman serisi verileri üzerinde güvenilir günlük, haftalık, periyodik ve yıllık tahminler sunabilen güçlü bir araç geliştirmiştir. Yakın zamanda yapılan bir çalışmada, Prophet ve ARIMA tahmin modellerinin doğruluğunu ve performansını değerlendirmek için Kaggle kaynaklı doğrulanmış vakaları, ölümleri ve iyileşmeleri içeren bir veri seti kullanılmıştır (Satrio, Darmawan, Nadia, & Hanafiah, 2021). Elde edilen sonuçlara göre Prophet'in ARIMA'dan daha iyi performans gösterdiği ve daha doğru tahminler ürettiği saptanmıştır. Sonrasında, yavaş geleneksel modellerin ve karmaşık yapay zeka modellerinin yarattığı zorlukların üstesinden gelmek için yeni bir hibrit model tanıtılmıştır (Bashir, Haoyong, Tahir, & Liqiang, 2022). Bu hibrit yaklaşım, Prophet ve LSTM modellerinin entegre edilmesiyle geliştirilmiştir. Önerilen yaklaşımın etkinliğini değerlendirmek için model, 2014 – 2021 yılları arasındaki gerçek zamanlı elektrik yükü verileri üzerinde eğitilmiş ve hibrit model tarafından oluşturulan tahminler diğer temel modellerin ürettiği tahminler ile karşılaştırılmıştır. Bulgular, önerilen modelin diğer temel modellerle karşılaştırıldığında üstün doğruluk gösterdiğini ortaya koymuştur.

Derin Otoregresif (DeepAR), yakın zamanda Amazon tarafından geliştirilen ve piyasaya sürülen, otoregresif tekrarlayan sinir ağlarına dayanan olasılıksal bir tahmin modelidir. Salinas ve arkadaşları, birbirine bağlı beş zaman serisini kullanarak DeepAR ile farklı zaman serisi modelleri arasında karşılaştırmalı bir analiz gerçekleştirmiştir (Salinas, Flunkert, Gasthaus, & Januschowski, 2020). Yazarların yaptığı deney sonuçları, DeepAR'ın diğer modellere göre çok daha düşük hata oranlarına sahip tahminler ürettiğini göstermiştir. Başka bir çalışmada, çekirge optimizasyon algoritması (GOA) ve DeepAR algoritmalarını birleştirerek derin sinir ağları (DNNs) için hiperparametrelerin optimizasyonunu ele alan NGOA-DeepAR adı verilen yeni bir hibrit model tanıtılmıştır (Arora, et al., 2022). Önerilen model iki farklı rüzgar veri seti üzerinde eğitilerek test edilmiştir. Yazarlar, önerilen modelin diğer DeepAR tabanlı modellerden daha iyi performans gösterdiğini saptamıştır. Yakın zamanda yapılan bir çalışmada Li ve arkadaşları, bir rulmanın kalan faydalı ömrünü tahmin etme aracı olarak kapılı tekrarlayan birim derinliğinde otoregresif (GRU-DeepAR) modelini tanıtmıştır (Li, Wang, Liu, & Feng, 2023). Yazarlara göre yaklaşımları, karşılaştırılan diğer modellere kıyasla üstün doğruluk göstermiştir. Daha sonra önerilen farklı bir çalışmada, Deng ve arkadaşları araştırmalarında önerdikleri D-former modelinin rulmanların kalan kullanım ömrüne ilişkin oldukça doğru bir tahmin sağladığını ileri sürmüştür (Deng, Li, & Zhang, 2023).

Yakın zamanda yapılan bir çalışmaya göre, kısa vadeli elektrik tahmini için KNNA-DeepAR adlı yeni bir hibrit model tanıtılmıştır (Qiu, et al., 2023). Bu model en yakın komşu ve DeepAR yaklaşımlarını birleştirmektedir. Deneyler, Amerika Birleşik Devletleri'ndeki on dört bölgenin elektrik yüklerini kapsayan zaman serisi verileri üzerinde gerçekleştirilmiştir. Yazarlara göre, KNNA-DeepAR modeli diğer modellere göre daha iyi performans göstermiştir.

Bir başka mevcut zaman serisi modeli olan Yorumlanabilir Zaman Serisi Tahmini için Sinir Temelli Genişleme Analizi (N-BEATS), tek değişkenli zaman serisi noktalarını doğru bir şekilde tahmin etmek için geriye ve ileriye doğru kalan bağlantılardan yararlanan son teknoloji ürünü bir derin öğrenme algoritmasıdır. N-BEATS, gelecek vaat eden güncel zaman serisi modellerinden biri olmasının yanında, zaman serisi tahmininin doğruluk ve yorumlanma özelliklerini geliştirme potansiyeline sahiptir. Oreshkin ve arkadaşları, orta vadeli yük tahmini için yeni bir model olan N-BEATS'i tanıtmıştır (Oreshkin, Dudek, Peřka, & Turkina, 2021). Yazarlar, modelin performansını 35 aylık elektrik talebini içeren bir veri seti üzerinde eğiterek tahminler üretmiş ve N-BEATS'in rakiplerinden daha iyi performans gösterdiği sonucuna ulaşmıştır. Başka bir çalışmada, uzun vadeli yüksek frekanslı elektrik fiyatlarını tahmin etmek için mevsimsel ve trend ayrıştırmasıyla (STL), zamansal evriřimli ağla (TCN) ve N-BEATS modellerini birleřtiren hibrit bir yaklaşım öne sürölmüřtür (Zhang, Song, Jiang, & Li, 2023). Yazarlar tarafından belirtilen deneylerin sonuçlarına göre, önerilen modelin hassasiyet ve verimlilik açısından dięer modellerden daha iyi performans gösterdiğini belirtilmiştir. Daha sonra Olivares ve arkadaşları, N-BEATS modelinin geliştirilmiş bir versiyonu olan NBEATSx'i önermiştir (Olivares, Challu, Marcjasz, Weron, & Dubrawski, 2023). Yazarlar tarafından 5 farklı veri seti üzerinde yapılan deneylerde önerilen model, orijinal N-BEATS ve dięer rakiplerinden daha iyi sonuçlar vermiştir.

Google, dikkat tabanlı derin bir sinir ağı kullanan, Zamansal Füzyon Transformatörü (TFT) adı verilen son teknoloji ürünü bir zaman serisi tahmin modeli geliřtirmiřtir. Lim ve arkadaşları tarafından yakın zamanda yürütölen bir çalışmada TFT ve dięer temel zaman serisi modelleri, elektrik, trafik ve perakende veri setleri üzerinde eğitilmiş ve ürettikleri tahminler karşılařtırılmıştır (Lim, Arık, Loeff, & Pfister, 2021). Yazarların elde ettięi sonuçlara göre, TFT rakiplerini geride bırakmış ve daha doğru tahminler üretmiştir. Sonrasında, Hanoi řehrine ait 2014-2020 yılları arasındaki elektrik

yükü verileri kullanılarak kısa vadeli elektrik yükünü tahmin etmeye yönelik bir çalışma yapılmıştır (Huy, Minh, Tien, & Anh, 2022). Tahmin oluşturmak için TFT ve diğer temel modelleri kullanan çalışmada, TFT'nin önemli ölçüde daha düşük hata oranına sahip tahminler üreterek diğer temel modellerden daha iyi performans gösterdiği gözlemlenmiştir. Yakın zamanda yapılan bir araştırmaya göre araştırmacılar, aynı bölgedeki binalar için kısa vadeli elektrik yükü tahminleri yapmak amacıyla transfer öğrenmeyi (TL) ve TFT mimarisini birleştiren hibrit bir model öne sürmüştür (Santos, et al., 2023). Model, saatlik geçmiş yük verileri, hava durumu verileri ve bölgeye özel zaman dilimi verileri kullanılarak eğitilmiştir. Çalışmanın yazarları, önerilen modelin son derece düşük hata oranlarıyla son derece kesin tahminler sağladığını keşfetmiştir. Daha sonrasında Zheng ve arkadaşları, kısa vadeli bina enerji tüketimini tahmin etmek için günlük enerji tüketim modeli (DECPR) ile TFT modelini birleşiminden oluşan yeni bir hibrit model önermiştir (Zheng, Zhou, Liu, & Nakanishi, 2023). Yazarlara göre önerilen hibrit model, bu alandaki diğer mevcut modellerden daha iyi performans göstermiştir. Son olarak, orta vadeli saatlik elektrik yükü tahmini için geliştirilmiş zamansal füzyon transformatör modeli (ITFT) modeli Li ve arkadaşları tarafından önerilmiştir (Li, Tan, Zhang, Miao, & He, 2023). Yapılan deneysel analiz sonuçlarına göre önerilen modelin, söz konusu diğer dört modelle karşılaştırıldığında daha üstün sonuçlar verdiği ifade edilmiştir.

3. ÖNERİLEN TAHMİN MODELLERİ

Bu tez çalışmasında, kısa vadeli (gelecek 24 saat) elektrik tüketimi tahmini için LSTM ve CNN modelleri ve her iki mimariyi birleştiren bir topluluk modeli önerilmektedir. Önerilen modeller, elektrik tüketim verilerinin yanında meteorolojik ve zaman damgası gibi verileri de kullanmaktadır. Modellerin eğitimi ve değerlendirilmesi için coğrafi olarak farklı bölgelerde olan Ohio/Dayton ve Texas/Houston şehirlerine ait yaklaşık 2,5 yıllık saatlik elektrik tüketim, sıcaklık, bağıl nem ve zaman damgası verilerinden oluşan iki farklı veri seti kullanılmıştır. Her bir veri seti için önerilen modeller 16 farklı öznitelik seti ile eğitilmiş ve eğitilen modellerin performansları incelenmiştir.

Bu bölümün ait bölümlerinde değinilen konular şu şekildedir: Bölüm 3.1'de, önerilen modelleri eğitmek ve performanslarını ölçmek için kullanılan veri setleri ayrıntılı olarak anlatılmıştır. Bölüm 3.2'de, önerilen tahmin modellerinin mimarisi açıklanmıştır. Bölüm 3.3'te, modellerin performansını ölçmek için kullanılan metrikler açıklanmıştır.

3.1. Veri Setleri

Önerilen modellerin eğitilmesi ve tahmin performanslarının analiz edilmesi için iki farklı veri seti kullanılmıştır. Bu veri setlerinin detayları, takip eden alt bölümlerde açıklanmaktadır.

3.1.1. Dayton


İlk olarak, Kaggle üzerinden açık bir şekilde paylaşılan ve Amerika Birleşik Devletleri'ndeki bölgesel bir iletim organizasyonu olan PJM Interconnection tarafından sağlanmış olan Amerika'nın Ohio eyaletindeki Dayton şehrine ait elektrik tüketimi verileri kullanılmıştır (Dayton, Hourly Electricity Consumption Data, 2023). Önerilen modellerin analizlerinde, 120.840 saatten (5.035 gün) oluşan verinin 20.424 saati (851 gün) kullanılmıştır. Bunun sebebi, seçilen diğer şehire ait elektrik tüketimi verisi ile aynı miktarda verinin kullanılmak istenmesidir. Analizler için kullanılan veriler 04/01/2016 ile 03/05/2018 arasındaki saatlik tüketim değerlerini içermektedir. Dayton şehrinin söz konusu zaman aralığına ait meteorolojik verilerine (sıcaklık, bağıl nem ve rüzgar hızı) ise

Open-Meteo üzerinden ulaşılmıştır (Dayton, Hourly Weather Data, 2023). Dayton veri setine ait eğitim, validasyon ve test verilerinin dağılımı Tablo 3.1’de listelenmiştir.

Tablo 3.1. Dayton veri seti: eğitim, validasyon ve test verilerinin dağılımı


Açıklama	Saat
Eğitim	9.144
Validasyon	2.352
Test	8.928
Toplam	20.424

Dayton şehrine ait günlük elektrik tüketimi (Elec), sıcaklık (Temp), bağıl nem (Humid) ve rüzgar hızı (Wind) verilerinin, söz konusu zaman aralığındaki değişimleri Şekil 3.1’de yer almaktadır. Günlük elektrik tüketimi verisi, ilgili günün saatlik tüketimlerinin toplamıyla hesaplanırken sıcaklık, bağıl nem ve rüzgar hızı verileri, ilgili günün saatlik değerlerinin ortalaması alınarak hesaplanmıştır.



Şekil 3.1. Dayton şehrine ait günlük elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı verisi

Bu veri setinde kullanılan elektrik tüketimi ve meteoroloji verilerinin aralarındaki ilişkiyi gösteren korelasyon matrisi Şekil 3.2’de sunulmuştur.



Şekil 3.2. Dayton şehrine ait elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı korelasyon matrisi

Söz konusu matriste görüldüğü üzere Dayton şehrine ait elektrik tüketimi ve meteoroloji verileri arasındaki korelasyon oldukça düşüktür.


3.1.2. Houston

İkinci veri seti olarak, Amerika'nın Texas eyaletindeki Houston şehrine ait 20.424 saatlik (851 gün) elektrik tüketimi verisine de Kaggle üzerinden erişilmiştir (Houston, US Top 10 Cities - Electricity Data, 2020). Söz konusu veriler, 01/01/2018 ve 30/04/2020 tarihleri arasındaki saatlik elektrik tüketimi değerlerinden oluşmaktadır. Houston şehrinin söz konusu zaman aralığına ait meteorolojik verilerine (sıcaklık, bağıl nem ve rüzgar hızı) de yine Open-Meteo üzerinden ulaşılmıştır (Houston, Historical Weather Api, 2024). Houston veri setinin eğitim, validasyon ve test verilerinin dağılımı Tablo 3.2’de sunulmuştur.

Tablo 3.2. Houston veri seti: eğitim, validasyon ve test verilerinin dağılımı


Açıklama	Saat
Eğitim	9.144
Validasyon	2.352
Test	8.928
Toplam	20.424

Houston şehrine ait günlük elektrik tüketimi, sıcaklık, bağıl nem ve rüzgar hızı verilerinin, söz konusu zaman aralığındaki değişimleri Şekil 3.3'te yer almaktadır.



Şekil 3.3. Houston şehrine ait günlük elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı verisi

Dayton veri setinin aksine, Houston şehri için elektrik tüketimi ve sıcaklık arasındaki korelasyon değeri yüksek çıkmıştır. Houston şehrine ait günlük elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı bilgilerinin verildiği şekle baktığımızda, elektrik tüketimi ve sıcaklık arasındaki bu ilişki daha net görülebilmektedir. Houston şehrine ait elektrik tüketimi, sıcaklık, bağıl nem ve rüzgar hızı verilerinin korelasyon matrisi Şekil 3.4'te sunulmuştur.



Şekil 3.4. Houston şehrine ait elektrik tüketim, sıcaklık, bağıl nem ve rüzgar hızı korelasyon matrisi

3.2. Tahmin Modelleri

Bu tez çalışmasında, kısa vadeli elektrik tüketimi tahmini için, LSTM, CNN ve Topluluk temelli derin öğrenme modelleri önerilmiştir. Bu modellerin yapısı, alt bölümlerde detaylı şekilde açıklanmaktadır.


3.2.1. LSTM

LSTM, sıralı verilerdeki uzun vadeli bağımlılıkları ve ilişkileri yakalamak için tasarlanmış bir RNN mimarisidir. LSTM ağlarının temel özelliği, uzun diziler boyunca bilgi depolayabilen ve alabilen bir bellek hücresi sürdürme yetenekleridir. Bu sayede, RNN'lerin eğitimi engelleyebilecek kaybolan gradyan sorununun üstesinden gelmelerine yardımcı olmaktadır (Torres, Martínez-Álvarez, & Troncoso, 2022). LSTM mimarisi, bellek hücresi giren ve çıkan bilgi akışını kontrol eden üç kapı içermektedir:

1. **Forget Gate:** Önceki durumdan hangi bilginin atılması gerektiğini belirler.
2. **Input Gate:** Hangi yeni bilginin ilgili olduğuna ve bellek hücresinde saklanması gerektiğine karar verir.

3. Output Gate: Bellek hücresinden hangi bilginin tahmin olarak çıkarılacağını seçer.

Bu kapıların birleşimi, LSTM'lerin uzun diziler boyunca bilgileri seçici olarak depolamasına ve almasına olanak tanır; bu da onları zaman serisi verileri, doğal dil işleme ve diğer sıralı veri uygulamalarını içeren görevler için çok uygun hale getirmektedir. Bir LSTM hücresinin şeması Şekil 3.5'te, optimizasyonlar sonucunda elde edilen hiperparametre değerleri ise Tablo 3.3'te verilmiştir.



Şekil 3.5. Bir LSTM hücresinin şeması (Torres, Martínez-Álvarez, & Troncoso, 2022)

Tablo 3.3. LSTM hiperparametreleri

Hiperparametre	Değer
Units	14
Batch size	168
Max epochs	300
Early stopping patience	15 (monitor: val_loss, restore_best_weight: True)
Model	Sequential
Activation	Relu
Optimizer	Adam
Dense	24 (saat)
Learning rate	0.001
Dropout rate	0
Loss	MSE

3.2.2. CNN


CNN modelleri, görüntü ve doğal dil işleme konularındaki performansının yanı sıra zaman serisi verilerin tahmininde de yüksek performans gösterebilmektedir (Khan, et al., 2022). Bir CNN'nin temel mimari bileşenleri şunları içerir:

1. **Convolutional Layers:** Bu katmanlar, filtreleri (çekirdek olarak da bilinir) kullanarak giriş verilerine evrişimsel işlemler uygular. Filtreler, yerel özellikleri çıkarmak için giriş verilerinin üzerinde kayan küçük matrislerdir. Evrişimli katmanlar, verilerdeki hiyerarşik özellikleri yakalama yeteneğine sahiptir.
2. **Pooling Layers:** Havuzlama katmanları, girişin uzamsal boyutlarını alt örnekleyerek ağıdaki hesaplama miktarını azaltır. Maksimum havuzlama, bir bölge içindeki maksimum değerin korunduğu yaygın bir havuzlama işlemi türüdür.
3. **Fully Connected Layers:** Bu katmanlar, bir katmandaki her nöronu bir sonraki katmandaki her nörona bağlar. Genellikle sınıflandırma görevleri için ağı son katmanlarında kullanılırlar.
4. **Activation Functions:** ReLU (Düzeltilmiş Doğrusal Birim) gibi doğrusal olmayan aktivasyon fonksiyonları, ağı doğrusal olmamayı kazandırmak ve karmaşık kalıpları öğrenmesini sağlamak için uygulanır.

Yapılan optimizasyon çalışmaları sonucunda elde edilen ve bu çalışma için önermiş olduğumuz CNN mimarisi Şekil 3.6'da önerilen model için kullanılan hiperparametre değerleri ise Tablo 3.4'te sunulmuştur.

Bu tez çalışmasında önerilen CNN modelinde 4 adet Convolutional Layer ve Max Pooling katmanı bulunmaktadır. Tek değişkenli elektrik tüketimi tahminleri için genelde Conv1D ve MaxPooling1D kullanılmaktadır. Ancak Conv1D aldığı girdiyi verilen "Filters" değerine göre çıktı olarak vermektedir. Birden fazla öznitelik girdi olarak verilince tek bir çıktı değeri oluşmakta ve girdi olarak verilen birden fazla öz niteliğin model boyunca eğitimi mümkün olmamaktadır. Örnek verecek olursak; (168,7) lik girdilerimiz olsun. Buradaki girdi verileri geçmiş 168 saati ve 7 farklı öz niteliği ifade etmektedir. Conv1D için "Filters" değeri 32 seçildiği durumda çıktı (168,32) olacaktır. MaxPooling1D aşamasından sonra bir sonraki Conv1D için girdi (84,32) olacak ve farklı öz niteliklerin bilgileri kaybedilecektir. Bu sorunun üstesinden gelmek için Conv2D ve MaxPooling2D katmanları kullanılmıştır. Conv2D katmanlarına girdileri (168,7,1)

şeklinde gönderdiğimizde katmanların çıktıları (168,7,32) şeklinde olmaktadır. Bu sayede, model eğitiminde kullandığımız her bir öznetelik değeri bütün katmanlar boyunca korunmuş olacaktır. Bu yaklaşım, önermiş olduğumuz ve birden fazla öznetelik ile eğitilen CNN modelimizin tahmin performansını önemli ölçüde geliştirmiştir.



Tablo 3.4. CNN hiperparametreleri

Hiperparametre	Değer
Conv2D - 1	Filters: 4, Kernel_size: 5, padding: 'same'
MaxPooling2D - 1	Pool_size: 4, padding: 'same'
Conv2D - 2	Filters: 8, Kernel_size: 5, padding: 'same'
MaxPooling2D - 2	Pool_size: 4, padding: 'same'
Conv2D - 3	Filters: 16, Kernel_size: 5, padding: 'same'
MaxPooling2D - 3	Pool_size: 4, padding: 'same'
Conv2D - 4	Filters: 32, Kernel_size: 5, padding: 'same'
MaxPooling2D - 4	Pool_size: 4, padding: 'same'
Batch size	128
Max epochs	300
Early stopping patience	30 (monitor: val_loss, restore_best_weight: True)
Model	Sequential
Activation	Relu
Optimizer	Adam
Dense	24 (saat)
Learning rate	0.001
Dropout rate	0.4
Loss	MSE

3.2.3. Topluluk

Topluluk öğrenimi, makine öğreniminde kullanılan güçlü bir tekniktir. Bu teknik aslında, daha doğru tahminler üreten bir model oluşturmak için birden fazla modelin ürettikleri tahminlerin birleştirildiği stratejidir.

Topluluk yöntemlerinin geliştirilmiş doğruluk, genellenebilirlik, azaltılmış varyans/önyargı ve esneklik gibi avantajları bulunmaktadır. Bu yöntem ile birden fazla model birleştirildiğinden, genellikle tek bir modele kıyasla görünmeyen veriler üzerinde daha iyi doğruluk ve genelleştirilebilirlik elde edilebilir. Ayrıca, bireysel modellerden kaynaklanan hataların ortalamasını almaya yardımcı olarak daha sağlam tahminlere yol açabilir. Son olarak modellerin güçlü yönlerinden yararlanmak için farklı model türleri bir topluluk gurubu içinde birleştirilebilir.

Topluluk yöntemlerinin, yukarıda bahsedilen avantajlarının yanında artan karmaşıklık, yorumlamada zorluk gibi dezavantajları da bulunmaktadır. Topluluk yöntemi kullanılarak birden fazla model oluşturmak ve eğitmek, tek bir model kullanmaya kıyasla hesaplama açısından daha masraflı olabilir. Ayrıca, bireysel modellere göre daha az yorumlanabilir olabileceği için bu da üretilen tahminin nedeninin anlaşılmasını zorlaştırmaktadır.

Ortalama Alma (Averaging), Oylama (Voting), Torbalama-Önyükleme Toplama (Bagging-Bootstrap Aggregating), Yükseltme (Boosting) ve İstifleme (Stacking) gibi topluluk yöntemi türleri mevcuttur. Bu yöntemleri biraz daha detaylandıracak olursak, Averaging, regresyon sorunları için basit ama etkili bir yaklaşımdır. Nihai tahmini elde etmek için tüm temel modellerden gelen tahminlerin ortalaması alınır. Bu, bireysel modellerden kaynaklanan hataların sapmasını azaltarak daha düzgün ve daha doğru bir genel tahmine yol açmaktadır. Voting, genellikle sınıflandırma problemlerinde kullanılmaktadır. Her temel model, en olası sınıfa oy verir ve son tahmin, en çok oyu alan sınıftır. Bu yaklaşım, herhangi bir tek modelin tahminindeki aykırı değerlerin veya hataların etkisini azaltmaya yardımcı olmaktadır. Bagging-Bootstrap Aggregating yönteminde, orijinal verilerin farklı alt kümeleri (değiştirme ile) eğitilerek birden fazla model oluşturulmaktadır. Bu, topluluğa çeşitlilik katarak varyansı azaltarak ve potansiyel olarak doğruluğu artırmaktadır. Boosting, temel modellerin sırayla eğitildiği bir yaklaşımdır. Her model, bir önceki modelin tahmin hatalarından öğrenmeye odaklanır. Bu yaklaşım doğrulukta önemli gelişmelere yol açabilir, ancak aynı zamanda aşırı uyum

sağlamaya da daha yatkındır. Stacking, bir meta-model oluşturmayı içerir. Temel modeller tahminlerini eğitim verileri üzerinde yapar ve bu tahminler meta modelin özellikleri haline gelir. Meta-model daha sonra nihai tahminleri yapmak için bu özellikleri birleştirmeyi öğrenir. İstifleme, farklı modellerin güçlü yanlarından yararlanırken potansiyel olarak zayıf yönlerinin üstesinden gelmenize olanak tanır.

Bu tez çalışmasında, topluluk modeli olarak ortalama yaklaşımı tercih edilmiş ve LSTM ile CNN modellerine ait tahminlerin ortalamaları hesaplanmıştır.

3.3. Performans Metrikleri

Önerilen modellerin performanslarını karşılaştırmak için normalleştirilmiş kök ortalama kare hata (N-RMSE), normalleştirilmiş ortalama mutlak hata (N-MAE) ve ortalama mutlak yüzde hata (MAPE) metrikleri kullanılmıştır.

3.3.1. N-RMSE

RMSE, tahmine dayalı bir modelin doğruluğunu değerlendirmek için yaygın olarak kullanılan bir hata metriğidir (Chai & Draxler, 2014). Özellikle regresyon analizi alanında popülerdir. RMSE, tahmin edilen değerler ile gerçek değerler arasındaki hataların ortalama büyüklüğünü hesaplar. N-RMSE ise RMSE'yi veri aralığına göre ölçeklendirerek farklı veri kümeleri arasında daha yorumlanabilir ve karşılaştırılabilir hale getirmektedir. RMSE ve N-RMSE'nin formülleri sırası ile (1) ve (2)'de verilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.1)$$

$$N-RMSE = \frac{RMSE}{\max(y) - \min(y)} \quad (3.2)$$

Formül (3.1) ve (3.2)'de, n gözlemlerin veya veri noktalarının sayısı, y_i i indeksindeki veri noktasının gerçek (gözlenen) değeri, $\hat{y}_i$ ise i indeksindeki veri noktası için tahmin edilen değeri, $\max(y)$ gerçek (gözlenen) değerlerin maksimum değerini, $\min(y)$ ise gerçek (gözlenen) değerlerin minimum değerini ifade etmektedir.

RMSE, gerçek ve tahmin edilen değerler arasındaki kare farkların ortalamasının karekökü alınarak hesaplanır. Bu işlem, RMSE değerinin orijinal verilerle aynı birimlerde

yorumlanabilir olmasını sağlamak için uygulanmaktadır. Düşük bir RMSE değeri, modelin doğruluk oranının yüksek olduğu anlamına gelmektedir.

3.3.2. N-MAE

MAE, tahmine dayalı bir modelin performansını değerlendirmek için yaygın olarak kullanılan başka bir hata metriğidir. Tahmin edilen değerler ile gerçek değerler arasındaki hataların ortalama büyüklüğünü hesaplayarak tahminlerin doğruluğunu gösterir (Chai & Draxler, 2014). N-MAE, MAE'yi veri aralığına göre ölçeklendirerek farklı veri kümeleri arasında daha yorumlanabilir ve karşılaştırılabilir hale getirmektedir. MAE ve N-MAE'nin formülleri sırası ile (3) ve (4)'te verilmiştir.

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

$$N-MAE = \frac{MAE}{\max(y) - \min(y)} \quad (3.4)$$

Formül (3.3) ve (3.4)'te, n gözlemlerin veya veri noktalarının sayısı, y_i i indeksindeki veri noktasının gerçek (gözlenen) değeri, $\hat{y}_i$ ise i indeksindeki veri noktası için tahmin edilen değeri, $\max(y)$ gerçek (gözlenen) değerlerin maksimum değerini, $\min(y)$ ise gerçek (gözlenen) değerlerin minimum değerini ifade etmektedir.

MAE, gerçek ve tahmin edilen değerler arasındaki mutlak farkların ortalaması alınarak hesaplanmaktadır. RMSE'den farklı olarak MAE, hataların karesini almaz; bu da MAE'nin büyük hatalara karşı daha az duyarlı olmasını sağlamaktadır. Büyük hataların kabul edilebilir olduğu veya tüm hatalara eşit ağırlık vermek istediğiniz durumlarda bir avantaj olabilmektedir. RMSE'ye benzer şekilde, daha düşük bir MAE, modelin tahminlerinin ortalama olarak gerçek değerlere daha yakın olduğunu gösterdiğinden daha iyi model performansını göstermektedir. Tersine, daha yüksek bir MAE, modelin tahminlerinde daha büyük hatalara sahip olduğunu göstermektedir. RMSE ve MAE arasındaki seçim genellikle var olan problemin belirli karakteristiğine ve değerlendirme ölçütünün istenen özelliklerine bağlıdır.

3.3.3. MAPE

MAPE, zaman serisi verileri için tahmin modellerinin doğruluğunu değerlendirmek için kullanılan yaygın bir hata metriğidir. MAPE, tahminlerinizin gerçek değerlere ne kadar yakın olduğunu gösterir. MAPE'nin formülü (5)' te verilmiştir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100 \quad (3.5)$$

Formül (3.5)' te, n gözlemlerin veya veri noktalarının sayısı, y_i i indeksindeki veri noktasının gerçek (gözlenen) değeri, $\hat{y}_i$ ise i indeksindeki veri noktası için tahmin edilen değeri ifade etmektedir. Her gözlem için mutlak yüzdelik hata hesaplanır, hesaplanan değerler toplanır ve ardından ortalama hatayı elde etmek için toplam gözlem sayısına bölünür. Son olarak sonucu yüzde olarak ifade etmek için elde edilen değer 100 ile çarpılır.

MAPE, gerçek değerlere göre gerçek ve tahmin edilen değerler arasındaki ortalama mutlak farkın bir ölçüsünü sağlar. Özellikle, talep tahmini (örn: elektrik talebi), satış tahmini ve finansal tahmin gibi alanlarda tahmin modellerinin doğruluğunu değerlendirmek için kullanılan yaygın bir performans metriği olarak kullanılmaktadır. Daha düşük bir MAPE, daha yüksek bir doğruluğa karşılık gelmektedir.

4. DENEYSEL ÇALIŞMA VE TARTIŞMALAR

Bu tez çalışmasında, kısa vadeli (24 saat) elektrik tüketimini tahmin edebilmek için LSTM, CNN ve topluluk temelli derin öğrenme modelleri önerilmiştir. Modellerin eğitimi için coğrafi olarak farklı bölgelerdeki iki şehire ait elektrik tüketim, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası verileri kullanılmıştır. Önerilen modeller, her bir veri seti üzerinde 16 farklı öznitelik seti ile eğitilmiş ve her modelin tahmin performansı karşılaştırmalı şekilde analiz edilmiştir. Söz konusu öznitelik setleri, Tablo 4.1'de listelenmektedir.

Tablo 4.1. Tahmin modellerinde kullanılan öznitelik setleri

No	Öznitelik Seti
1	Elec
2	Elec+Temp
3	Elec+Humid
4	Elec+Wind
5	Elec+Time
6	Elec+Temp+Humid
7	Elec+Temp+Wind
8	Elec+Temp+Time
9	Elec+Time+Humid
10	Elec+Time+Wind
11	Elec+Humid+Wind
12	Elec+Temp+Humid+Wind
13	Elec+Temp+Humid+Time
14	Elec+Time+Humid+Wind
15	Elec+Temp+Time+Wind
16	Elec+Temp+Humid+Wind+Time

Ön işlemler kapsamında, ilk olarak sayısal verilerin formatları düzenlenmiştir. Veri setlerini, eksik ve aykırı değerlerden arındırmak için ilgili değerler, 24 saat öncesinin verileri kullanılarak güncellenmiştir. Yanlılığı önlemek için elektrik tüketimi, meteoroloji ve zaman damgası öznitelik verileri, eğitim seti temel alınarak 0 ile 1 arasına normalize edilmiştir. Veri setlerine ait zaman damgası öznitelik değerleri, elektrik tüketiminin gerçekleştiği “Ay” için [1-12], “Gün” için [1-7] ve “Saat” için [0-23] aralığındaki değerler kullanılarak döngüsel olarak kodlanmıştır.

Tahminlerde, kayan pencere (sliding window) yaklaşımı kullanılmıştır. 168 saatlik (7 gün) veriler kullanılarak, sonraki 24 saatin (1 gün) tüketim değerleri tahmin

edilmiştir. Modeller, çok adımlı tahmin yaklaşımı ile tasarlanarak bir defada 24 saatlik tahminler yapılmıştır. Toplam 20.424 saatten (851 gün) oluşan her bir veri setinin ilk 9.144 saati (381 gün) eğitim için kullanılarak 374 girdi-çıkı çifti elde edilmiştir. Söz konusu veri setinin takip eden 2.352 saati (98 gün) validasyon için kullanılarak 91 girdi-çıkı çifti elde edilmiştir. Veri setinin son 8.928 saatlik (372 gün) kısmı ise test için kullanılarak 365 girdi-çıkı çifti elde edilmiştir.

Modellerin eğitimlerinde, maksimum epoch değeri 300 olarak belirlenmiştir. Ayrıca, modelin aşırı uyma (overfitting) durumuna düşmesini engellemek için erken durdurma (early stopping) yaklaşımından faydalanmıştır. Bu kapsamda, modeller eğitim sürecinin herhangi bir aşamasındayken belirlenen epoch değeri süresince validasyon verisinin tahmin performansında bir gelişim gözlenmez ise eğitim sonlandırılmıştır. Yapılan analizler sonucunda early stopping değeri, LSTM modeli için 15, CNN modeli için ise 30 olarak belirlenmiştir. Bundan dolayı, her modelin eğitim süreleri ve epoch sayıları farklılık gösterebilmektedir.

Meteoroloji ve zaman özniteliklerinin, önerilen modellerin tahmin performansına etkilerini doğru bir şekilde hesaplamak amacıyla rastgele tohum (Random Seed) değeri belirlenmiştir. Rastgele tohumun belirlenmesi, zaman serisi modelleri içerisindeki birtakım işlemlerin rastgeleliğini kontrol altına almak için kullanılan bir yöntemdir. Önerilen modellerimiz için rastgele tohum değeri ayarlandığında, her seferinde rastgele sonuçlar üretilen süreçlerden tutarlı bir şekilde aynı sonuçlar alınabilmektedir. Örnek verecek olursak; Elec+Temp+Time öznitelik seti ile eğitilen LSTM modelimiz için rastgele tohumu belirlediğimiz zaman, modeli farklı zamanlarda kaç defa eğitip tahminler ürettiğimizden bağımsız olarak modelimiz her zaman aynı tahminleri üretecektir. Bu yaklaşım, farklı model konfigürasyonlarında hata ayıklamak ve karşılaştırmak için çok önemlidir. Ayrıca, farklı öznitelikler ile eğitilen modelleri veya eğitim tekniklerini karşılaştırırken eşit şartlar sağlanması oldukça önemlidir. Rastgele bir başlangıç noktası ayarlamak, tüm modellerin aynı rastgele sayı dizisini kullanmasını garanti ederek bunu başarmaya yardımcı olmaktadır. Yaptığımız analizler sonucunda iki farklı veri setimiz için rastgele tohum değerinin 47 olduğunu hesaplanmış ve hiperparametre optimizasyonları seçilen rastgele tohum değerine göre yapılmıştır. Bu sayede farklı öznitelikler seçilerek eğitilen modellerin tekrarlanabilir ve adil değerlendirilmiş olduğundan emin olabiliriz.


Deneysel çalışmalarda, Python 3.9 programlama dili kullanılmıştır. Derin öğrenme modelleri için Tensorflow ve Keras kütüphaneleri kullanılmıştır. Yazılım geliştirme aracı olarak, gelişmiş hata ayıklama ve zengin bir arayüze sahip olmasından dolayı PyCharm kullanılmıştır. Geliştirilen modellerin düzenlenmesine (Regularization) yönelik hiperparametre optimizasyonları, Keras-Tuner kütüphanesi yardımıyla yapılmıştır.

4.1. Dayton Veri Setiyle Eğitilen Modeller

Bu bölümde, Dayton veri setiyle eğitilen tahmin modellerinin performansları kapsamlı şekilde incelenmiştir.


4.1.1. LSTM modeli

Dayton veri setinin sadece elektrik tüketimi özniteliği ile eğitilen LSTM modelinin kayıp grafiği Şekil 4.1’de sunulmuştur. Söz konusu kayıp grafiğinde görüldüğü üzere, elektrik tüketimi özniteliği ile eğitilen modelin early-stopping parametresiyle sonlandırılmadan 300 epochta eğitim sürecinin tamamlandığı görülmektedir. Bu modelin eğitim süresi “77,18” saniye olarak ölçülmüş olup, kayıp grafiğine bakıldığında önerilen modelde overfitting gerçekleşmediği görülebilmektedir. Bu veri seti kullanılarak eğitilen diğer LSTM modellerinin kayıp grafikleri de benzer karakteristiğe sahip olup, eğitim verisine aşırı uyma durumu söz konusu değildir.




Şekil 4.1. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin kayıp grafiği


Farklı öznitelik setleriyle eğitilen LSTM modelleriyle elde edilen ortalama N-RMSE, N-MAE ve MAPE değerleri Şekil 4.2’de verilmiştir.



(a)



(b)




(c)

Şekil 4.2. Dayton veri seti: farklı öznitelik setleri için LSTM modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri


Söz konusu şekilde görüldüğü üzere, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinin her biri elektrik tüketimi özniteliğiyle birlikte kullanıldığında, tahmin performansını genel olarak iyileştirdiği görülmektedir. N-RMSE, N-MAE ve MAPE değerleri sırasıyla “%19,79”, “%20,38” ve “%22,31” oranına kadar iyileşmiştir.

Elektrik tüketimi özniteliğinin yanında sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinden sadece biri eklenip model eğitildiğinde, en iyi tahmin performansı Elec+Time öznitelik setinde elde edilmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,24”, “0,20” ve “%5,96” olurken Elec+Time özniteliği ile eğitilen modelde bu değerler “0,19”, “0,16” ve “%4,67” olarak hesaplanmıştır. Bu veri seti için, zaman damgası özniteliği diğer özniteliklere göre tahmin performansını daha çok iyileştirmiştir. Birden fazla öznitelik kullanılarak yapılan eğitim ve testler sonucunda, Elec+Temp+Humid+Time öznitelik seti ile eğitilen LSTM modelinin, en iyi tahmin performansını gösterdiği anlaşılmıştır. Bu modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,19”, “0,16” ve “%4,63” olarak hesaplanmıştır. Şekil 4.3’te ise elektrik tüketimi özniteliği ile eğitilen LSTM modelinin, test setinin tamamındaki tahmin performansı verilmiştir.



Şekil 4.3. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı

Söz konusu şekilde görüldüğü üzere, ilgili model kış aylarında en iyi tahmin performansını gösterirken, yaz aylarında en düşük tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%4,94”, “%6,02”, “%7,08” ve “%5,28” şeklinde hesaplanmıştır. Ayrıca, modelin tahmin edilen yıl genelinde hafta içi ve hafta sonu günlerindeki ortalama MAPE değerleri sırası ile “%5,28” ve “%7,65” olarak hesaplanmıştır. Şekil 4.4’te ise Elec+Temp+Humid+Time öznitelikleri ile eğitilen LSTM modelinin, test setinin tamamındaki tahmin performansı verilmiştir.




Şekil 4.4. Dayton veri seti: Elec+Temp+Humid+Time öznitelikleriyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı

Bu şekilden anlaşılabacağı üzere, model, sadece elektrik tüketimi özniteliği ile eğitilen LSTM modelinde olduğu gibi, kış aylarında en iyi, yaz aylarında ise en kötü tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%4,22”, “%4,35”, “%5,01” ve “%4,91” şeklinde hesaplanmıştır. LSTM modelinin eğitimine sıcaklık, zaman damgası ve bağıl nem özniteliklerinin eklenmesi ile mevsim tahminleri genel olarak iyileşmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelin aksine bu model hafta sonu günleri

için daha iyi tahminler üretmiştir. Hafta içi ve hafta sonu günlerinin ortalama MAPE değerleri “%4,66” ve “%4,54” olarak hesaplanmıştır. Burada zaman damgası özneliliğinin modelin tahmin performansına önemli ölçüde katkı sağladığı görülmüştür.

4.1.2. CNN modeli


Dayton veri setinin sadece elektrik tüketimi özneliliği ile eğitilen CNN modelinin kayıp grafiği Şekil 4.5’te verilmiştir.




Şekil 4.5. Dayton veri seti: elektrik tüketimi özneliliğiyle eğitilen CNN modelinin kayıp grafiği

Söz konusu kayıp grafiğinde görüldüğü üzere, elektrik tüketimi özneliliği ile eğitilen modelin 231 epochta eğitim sürecinin tamamlandığı görülmektedir. Bu modelin eğitim süresi “34,93” saniye olarak ölçülmüş olup, kayıp grafiğine bakıldığında önerilen modelde overfitting gerçekleşmediği görülebilmektedir. Bu veri seti kullanılarak eğitilen diğer CNN modellerinin kayıp grafikleri de benzer karakteristiğe sahip olup, eğitim verisine aşırı uyma durumu söz konusu değildir. Farklı öznelilik setleriyle eğitilen CNN modelleriyle elde edilen ortalama N-RMSE, N-MAE ve MAPE değerleri Şekil 4.6’da verilmiştir.


Söz konusu şekilde görüldüğü üzere, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özneliliklerinin her biri elektrik tüketimi özneliliğiyle birlikte kullanıldığında, tahmin performansını genel olarak iyileştirdiği görülmektedir. N-RMSE, N-MAE ve MAPE değerleri sırasıyla “%25,58”, “%27,24” ve “%26,85” oranına kadar iyileşmiştir.



(a)



(b)




(c)

Şekil 4.6. Dayton veri seti: farklı öznitelik setleri için CNN modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri

Elektrik tüketimi özniteliğinin yanında sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinden sadece biri eklenip model eğitildiğinde, en iyi tahmin performansı Elec+Time öznitelik setinde elde edilmiştir. Sadece elektrik tüketimi


özniteliği ile eğitilen modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,22”, “0,19” ve “%5,55” olurken Elec+Time özniteliği ile eğitilen modelde bu değerler “0,18”, “0,16” ve “%4,53” olarak hesaplanmıştır. Birden fazla öznitelik kullanılarak yapılan eğitim ve testler sonucunda, Elec+Temp+Humid+Wind+Time öznitelik seti ile eğitilen CNN modelinin, en iyi tahmin performansını gösterdiği anlaşılmıştır. Bu modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,16”, “0,14” ve “%4,05” olarak hesaplanmıştır. Şekil 4.7’de ise elektrik tüketimi özniteliği ile eğitilen CNN modelinin, test setinin tamamındaki tahmin performansı verilmiştir.



Şekil 4.7. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı

Söz konusu şekilde görüldüğü üzere, ilgili model kış aylarında en iyi tahmin performansını gösterirken, yaz aylarında en düşük tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%5,11”, “%5,21”, “%6,16” ve “%5,68” şeklinde hesaplanmıştır. Ayrıca, modelin tahmin edilen yıl genelinde hafta içi ve hafta sonu günlerindeki ortalama MAPE değerleri sırasıyla “%5,15” ve “%6,53” olarak hesaplanmıştır. Modelin, hafta içi günlerini daha iyi tahmin ettiği anlaşılmaktadır. Şekil 4.8’de ise Elec+Temp+Humid+Wind+Time

öznitelikleri ile eğitilen CNN modelinin, test setinin tamamındaki tahmin performansı verilmiştir.




Şekil 4.8. Dayton veri seti: Elec+Temp+Humid+Wind+Time öznitelikleriyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı


Bu şekilden anlaşılabacağı üzere, model, sadece elektrik tüketimi özniteliği ile eğitilen CNN modelinde olduğu gibi, kış aylarında en iyi, yaz aylarında ise en kötü tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%3,41”, “%3,80”, “%4,87” ve “%4,13” şeklinde hesaplanmıştır. CNN modelinin eğitimine sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinin eklenmesi ile mevsim tahminleri genel olarak iyileşmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelde olduğu gibi bu model de hafta içi günlerini daha iyi tahmin etmiştir. Hafta içi ve hafta sonu günlerinin ortalama MAPE değerleri “%3,99” ve “%4,22” olarak hesaplanmıştır.

4.1.3. Topluluk modeli


Farklı öznitelik setleriyle eğitilen Topluluk modelleriyle elde edilen ortalama N-RMSE, N-MAE ve MAPE değerleri Şekil 4.11’de verilmiştir.



(a)



(b)




(c)

Şekil 4.9. Dayton veri seti: farklı öznitelik setleri için Topluluk modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri

Söz konusu şekilde görüldüğü üzere, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinin her biri elektrik tüketimi özniteliğiyle birlikte kullanıldığında,

tahmin performansını genel olarak iyileştirdiği görülmektedir. N-RMSE, N-MAE ve MAPE değerleri sırasıyla “%21,10”, “%22,30” ve “%22,80” oranına kadar iyileşmiştir.


Elektrik tüketimi özniteliğinin yanında sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinden sadece biri eklenip model eğitildiğinde, en iyi tahmin performansı Elec+Time öznitelik setinde elde edilmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,22”, “0,18” ve “%5,40” olurken Elec+Time özniteliği ile eğitilen modelde bu değerler “0,18”, “0,15” ve “%4,39” olarak hesaplanmıştır. Birden fazla öznitelik kullanılarak yapılan eğitim ve testler sonucunda, Elec+Temp+Humid+Time öznitelik seti ile eğitilen Topluluk modelinin, en iyi tahmin performansını gösterdiği anlaşılmıştır. Bu modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,17”, “0,14” ve “%4,17” olarak hesaplanmıştır. Şekil 4.12’de ise elektrik tüketimi özniteliği ile eğitilen Topluluk modelinin, test setinin tamamındaki tahmin performansı verilmiştir.



Şekil 4.10. Dayton veri seti: elektrik tüketimi özniteliğiyle eğitilen Topluluk modelinin test setinin tamamındaki tahmin performansı

Söz konusu şekilde görüldüğü üzere, ilgili model kış aylarında en iyi tahmin performansını gösterirken, yaz aylarında en düşük tahmin performansını göstermiştir.

Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%4,77”, “%5,44”, “%6,00” ve “%5,38” şeklinde hesaplanmıştır. Ayrıca, modelin tahmin edilen yıl genelinde hafta içi ve hafta sonu günlerindeki ortalama MAPE değerleri sırası ile “%4,86” ve “%6,75” olarak hesaplanmıştır. Şekil 4.13’te ise Elec+Temp+Humid+Time öz nitelikleri ile eğitilen Topluluk modelinin, test setinin tamamındaki tahmin performansı verilmiştir.




Şekil 4.11. Dayton veri seti: Elec+Temp+Humid+Time öz nitelikleriyle eğitilen Topluluk modelinin test setinin tamamındaki tahmin performansı

Bu şekilden anlaşılacağı üzere, model, sadece elektrik tüketimi öz niteliği ile eğitilen Topluluk modelinde olduğu gibi, kış aylarında en iyi, yaz aylarında ise en kötü tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%3,69”, “%3,91”, “%4,71” ve “%4,37” şeklinde hesaplanmıştır. Topluluk modelinin eğitimine sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası öz niteliklerinin eklenmesi ile mevsim tahminleri genel olarak iyileşmiştir. Modelin, hafta içi ve hafta sonu günlerinin ortalama MAPE değerleri “%4,16” ve “%4,19” olarak hesaplanmıştır. Bu model, sadece elektrik tüketimi öz niteliği


ile eğitilen modelde olduğu gibi hafta içi günlerini çok az bir fark ile daha iyi tahmin etmiştir.

4.1.4. Günlük performans analizi


Önerilen modellerin tahmin performanslarını daha yakından gözlemleyebilmek ve karşılaştırmak amacıyla, Dayton veri setine ait yaz ve kış mevsimlerinden ikişer gün seçilmiştir. Elektrik tüketim örüntüleri mevsimlere ve günlere göre farklılık gösterdiği için, seçilen günlerin birinin hafta içi, diğerinin ise hafta sonu olmasına özen gösterilmiştir. Bu şekilde, modellerin farklı koşullar altında nasıl performans gösterdiği daha net bir şekilde değerlendirilebilecektir. Önerilen modellerin ilgili günlere ait tahminlerini, tahmin performanslarını ve gerçek tüketim değerlerini gösteren grafikler Şekil 4.12, Şekil 4.13, Şekil 4.14 ve Şekil 4.15'te verilmiştir. Söz konusu grafikler, modellerin performanslarını görsel olarak karşılaştırmamıza ve her bir modelin doğruluğunu ve tutarlılığını değerlendirmemize olanak tanımaktadır.




Şekil 4.12. Dayton veri seti: yaz mevsimi hafta içinde LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması



Şekil 4.13. Dayton veri seti: yaz mevsimi hafta sonunda LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması



Şekil 4.14. Dayton veri seti: kış mevsimi hafta içinde LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması



Şekil 4.15. Dayton veri seti: kış mevsimi hafta sonunda LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması


Söz konusu grafiklerden anlaşılabileceği üzere, genel olarak seçilen günler için Topluluk modellerinin daha iyi tahmin performansı gösterdiği görülmektedir. Elbette bu durum, farklı günler arasında değişiklik gösterebilir. Bazı günler için LSTM veya CNN modelleri daha iyi tahminler üretebilmektedir. Ancak, yıl geneline bakıldığında, önerilen modellerin tahmin performansları sırasıyla Topluluk, CNN ve LSTM olarak hesaplanmıştır.

4.2. Houston Veri Setiyle Eğitilen Modeller

Bu bölümde, Houston veri setiyle eğitilen tahmin modellerinin performansları kapsamlı şekilde incelenmiştir.

4.2.1. LSTM modeli

Houston veri setinin sadece elektrik tüketimi özneliği ile eğitilen LSTM modelinin kayıp grafiği Şekil 4.16’da sunulmuştur.




Şekil 4.16. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin kayıp grafiği

Söz konusu kayıp grafiğinde görüldüğü üzere, elektrik tüketimi özniteliği ile eğitilen modelin 87 epochta eğitim sürecinin tamamlandığı görülmektedir. Bu modelin eğitim süresi “22.73” saniye olarak ölçülmüş olup, kayıp grafiğine bakıldığında önerilen modelde overfitting gerçekleşmediği görülebilmektedir. Bu veri seti kullanılarak eğitilen diğer LSTM modellerinin kayıp grafikleri de benzer karakteristiğe sahip olup, eğitim verisine aşırı uyma durumu söz konusu değildir. Farklı öznitelik setleriyle eğitilen LSTM modelleriyle elde edilen ortalama N-RMSE, N-MAE ve MAPE değerleri Şekil 4.17’de verilmiştir.


Söz konusu şekilde görüldüğü üzere, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinin her biri elektrik tüketimi özniteliğiyle birlikte kullanıldığında, tahmin performansını genel olarak iyileştirdiği görülmektedir. N-RMSE, N-MAE ve MAPE değerleri sırasıyla “%21,34”, “%21,53” ve “%20,19” oranına kadar iyileşmiştir.

Elektrik tüketimi özniteliğinin yanında sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinden sadece biri eklenip model eğitildiğinde, en iyi tahmin performansı Elec+Temp öznitelik setinde elde edilmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,25”, “0,21” ve “%6,31” olurken Elec+Temp özniteliği ile eğitilen modelde bu değerler “0,21”, “0,18” ve “%5,53” olarak hesaplanmıştır. Bu veri seti için, sıcaklık özniteliği diğer özniteliklere göre tahmin performansını daha çok iyileştirmiştir. Birden fazla öznitelik kullanılarak yapılan eğitim ve testler sonucunda, Elec+Temp+Time öznitelik seti ile


eğitilen LSTM modelinin, en iyi tahmin performansını gösterdiği anlaşılmıştır. Bu modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,19”, “0,16” ve “%5,04” olarak hesaplanmıştır.



(a)




(b)



(c)

Şekil 4.17. Houston veri seti: farklı öznelilik setleri için LSTM modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri

Şekil 4.18’de ise elektrik tüketimi özniteliği ile eğitilen LSTM modelinin, test setinin tamamındaki tahmin performansı verilmiştir.




Şekil 4.18. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı

Söz konusu şekilde görüldüğü üzere, ilgili model kış aylarında en iyi tahmin performansını gösterirken, yaz aylarında en düşük tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%5,41”, “%7,27”, “%5,69” ve “%6,88” şeklinde hesaplanmıştır. Ayrıca, modelin tahmin edilen yıl genelinde hafta içi ve hafta sonu günlerindeki ortalama MAPE değerleri sırası ile “%6,02” ve “%7,03” olarak hesaplanmıştır. Şekil 4.19’da ise Elec+Temp+Time öznitelikleri ile eğitilen LSTM modelinin, test setinin tamamındaki tahmin performansı verilmiştir.

Söz konusu şekilden anlaşılacağı üzere, model, sadece elektrik tüketimi özniteliği ile eğitilen LSTM modelinde olduğu gibi, kış aylarında en iyi, yaz aylarında ise en kötü tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%3,50”, “%6,37”, “%4,53” ve “%5,75” şeklinde hesaplanmıştır. LSTM modelinin eğitimine sıcaklık ve zaman damgası

özniteliklerinin eklenmesi ile mevsim tahminleri genel olarak iyileşmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelde olduğu gibi bu model de hafta içi günlerini çok az bir fark ile daha iyi tahmin etmiştir. Hafta içi ve hafta sonu günlerinin ortalama MAPE değerleri “%5,03” ve “%5,07” olarak hesaplanmıştır.




Şekil 4.19. Houston veri seti: Elec+Temp+Time öznitelikleriyle eğitilen LSTM modelinin test setinin tamamındaki tahmin performansı

4.2.2. CNN modeli

Houston veri setinin sadece elektrik tüketimi özniteliği ile eğitilen CNN modelinin kayıp grafiği Şekil 4.20’de verilmiştir.

Söz konusu kayıp grafiğinde görüldüğü üzere, elektrik tüketimi özniteliği ile eğitilen modelin 145 epochta eğitim sürecinin tamamlandığı görülmektedir. Bu modelin eğitim süresi “11,01” saniye olarak ölçülmüş olup, kayıp grafiğine bakıldığında önerilen modelde overfitting gerçekleşmediği görülebilmektedir. Bu veri seti kullanılarak eğitilen diğer CNN modellerinin kayıp grafikleri de benzer karakteristiğe sahip olup, eğitim verisine aşırı uyma durumu söz konusu değildir.




Şekil 4.20. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin kayıp grafiği


Farklı öznitelik setleriyle eğitilen CNN modelleriyle elde edilen ortalama N-RMSE, N-MAE ve MAPE değerleri Şekil 4.21’de verilmiştir.

Söz konusu şekilde görüldüğü üzere, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinin her biri elektrik tüketimi özniteliğiyle birlikte kullanıldığında, tahmin performansını genel olarak iyileştirdiği görülmektedir. N-RMSE, N-MAE ve MAPE değerleri sırasıyla “%26,24”, “%27,45” ve “%28,99” oranına kadar iyileşmiştir.


Elektrik tüketimi özniteliğinin yanında sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinden sadece biri eklenip model eğitildiğinde, en iyi tahmin performansı Elec+Temp öznitelik setinde elde edilmiştir. Sadece elektrik tüketimi özniteliği ile eğitilen modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,26”, “0,23” ve “%7,16” olurken Elec+Temp özniteliği ile eğitilen modelde bu değerler “0,22”, “0,23” ve “%5,65” olarak hesaplanmıştır. Birden fazla öznitelik kullanılarak yapılan eğitim ve testler sonucunda, Elec+Temp+Time öznitelik seti ile eğitilen CNN modelinin, en iyi tahmin performansını gösterdiği anlaşılmıştır. Buradan, önerilen CNN modeli için sıcaklık ve zaman damgası özniteliklerinin, diğer özniteliklere kıyasla elektrik tüketimi tahminine katkısının daha çok olduğu anlaşılmaktadır. En iyi tahmin performansının elde edildiği bu modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,19”, “0,17” ve “%5,09” olarak hesaplanmıştır.



(a)




(b)



(c)

Şekil 4.21. Houston veri seti: farklı öznitelik setleri için CNN modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri

Şekil 4.22’de ise elektrik tüketimi özniteliği ile eğitilen CNN modelinin, test setinin tamamındaki tahmin performansı verilmiştir.




Şekil 4.22. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı

Söz konusu şekilde görüldüğü üzere, ilgili model kış aylarında en iyi tahmin performansını gösterirken, yaz aylarında en düşük tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%5,37”, “%7,39”, “%8,33” ve “%7,57” şeklinde hesaplanmıştır. Ayrıca, modelin tahmin edilen yıl genelinde hafta içi ve hafta sonu günlerindeki ortalama MAPE değerleri sırası ile “%7,18” ve “%7,13” olarak hesaplanmıştır. Bu modelin hem hafta içi hem de hafta sonu günleri için tahmin performansının birbirine yakın olduğu görülmektedir. Şekil 4.23’te ise Elec+Temp+Time öznitelikleri ile eğitilen CNN modelinin, test setinin tamamındaki tahmin performansı verilmiştir.

Söz konusu şekilde anlaşılacağı üzere, model, sadece elektrik tüketimi özniteliği ile eğitilen CNN modelinin aksine, kış aylarında en iyi, ilkbahar aylarındaysa en kötü tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%3,82”, “%6,33”, “%4,68” ve “%5,52” şeklinde hesaplanmıştır. CNN modelinin eğitimine sıcaklık ve zaman damgası özniteliklerinin eklenmesi ile mevsim tahminleri genel olarak iyileşmiştir. Sadece elektrik

tüketimi özneliği ile eğitilen modelin aksine bu model de hafta sonu günlerini daha iyi tahmin etmiştir. Hafta içi ve hafta sonu günlerinin ortalama MAPE değerleri “%5,15” ve “%4,93” olarak hesaplanmıştır.




Şekil 4.23. Houston veri seti: Elec+Temp+Time öznelilikleriyle eğitilen CNN modelinin test setinin tamamındaki tahmin performansı


4.2.3. Topluluk modeli

Farklı öznelilik grupları ile eğitilen Topluluk modelleri ile elde edilen N-RMSE, N-MAE ve MAPE değerleri Şekil 4.24’te verilmiştir.


Söz konusu şekilde görüldüğü üzere, sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özneliliklerinin her biri elektrik tüketimi özneliğiyle birlikte kullanıldığında, modelin öğrenme kapasitesini artırdığı ve tahmin performansını genel olarak iyileştirdiği görülmektedir. Önerilen Topluluk modelinin, N-RMSE, N-MAE ve MAPE değerleri sırasıyla “%24,95”, “%25,71” ve “%24,84” oranına kadar iyileşmiştir.



(a)



(b)




(c)

Şekil 4.24. Houston veri seti: farklı öznitelik setleri için Topluluk modeliyle elde edilen ortalama (a) N-RMSE, (b) N-MAE ve (c) MAPE değerleri

Elektrik tüketimi özniteliğinin yanında sıcaklık, bağıl nem, rüzgar hızı ve zaman damgası özniteliklerinden sadece biri eklenip model eğitildiğinde, en iyi tahmin performansı Elec+Temp öznitelik setinde elde edilmiştir. Sadece elektrik tüketimi


özniteliği ile eğitilen modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,25”, “0,21” ve “%6,42” olurken Elec+Temp özniteliği ile eğitilen modelde bu değerler “0,21”, “0,18” ve “%5,36” olarak hesaplanmıştır. Birden fazla öznitelik kullanılarak yapılan eğitim ve testler sonucunda, Elec+Temp+Time öznitelik seti ile eğitilen Topluluk modelinin, en iyi tahmin performansını gösterdiği anlaşılmıştır. Bu modelin N-RMSE, N-MAE ve MAPE değerleri sırası ile “0,18”, “0,16” ve “%4.83” olarak hesaplanmıştır. Şekil 4.25’te ise elektrik tüketimi özniteliği ile eğitilen Topluluk modelinin, test setinin tamamındaki tahmin performansı verilmiştir.



Şekil 4.25. Houston veri seti: elektrik tüketimi özniteliğiyle eğitilen Topluluk modelinin test setinin tamamındaki tahmin performansı

Söz konusu şekilde görüldüğü üzere, ilgili model kış aylarında en iyi tahmin performansını gösterirken, ilkbahar aylarında en düşük tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%5,33”, “%7,25”, “%6,10” ve “%7,00” şeklinde hesaplanmıştır. Ayrıca, modelin tahmin edilen yıl genelinde hafta içi ve hafta sonu günlerindeki ortalama MAPE değerleri sırası ile “%6,31” ve “%6,71” olarak hesaplanmıştır. Şekil 4.26’da ise

Elec+Temp+Time öznitelikleri ile eğitilen Topluluk modelinin, test setinin tamamındaki tahmin performansı verilmiştir.




Şekil 4.26. Houston veri seti: Elec+Temp+Time öznitelikleriyle eğitilen Topluluk modelinin test setinin tamamındaki tahmin performansı

Bu şekilden anlaşılacağı üzere, model, sadece elektrik tüketimi özniteliği ile eğitilen Topluluk modelinde olduğu gibi, kış aylarında en iyi, ilkbahar aylarında ise en kötü tahmin performansını göstermiştir. Modelin kış, ilkbahar, yaz ve sonbahar mevsimlerindeki ortalama MAPE değerleri sırası ile “%3,38”, “%6,10”, “%4,44” ve “%5,39” şeklinde hesaplanmıştır. Topluluk modelinin eğitimine sıcaklık ve zaman damgası özniteliklerinin eklenmesi ile mevsim tahminleri genel olarak iyileşmiştir. Modelin, hafta içi ve hafta sonu günlerinin ortalama MAPE değerleri “%4,88” ve “%4,69” olarak hesaplanmıştır. Sadece elektrik tüketimi özniteliği ile eğitilen modelin aksine bu model, hafta sonu günlerini daha iyi tahmin etmiştir. Burada zaman damgası özniteliğinin modelin tahmin performansına önemli ölçüde katkı sağladığı görülmüştür.

4.2.4. Günlük performans analizi


Önerilen modellerin tahmin performanslarını daha yakından gözlemleyebilmek ve karşılaştırmak adına, Houston veri setine ait yaz ve kış mevsimlerinden ikişer gün seçilmiştir. Elektrik tüketim örüntüleri mevsimlere ve günlere göre farklılık gösterdiği için, seçilen günlerin birinin hafta içi, diğerinin ise hafta sonu olmasına özen gösterilmiştir. Bu şekilde, modellerin farklı koşullar altında nasıl performans gösterdiği daha net bir şekilde değerlendirilebilecektir. Önerilen modellerin ilgili günlere ait tahminlerini, tahmin performanslarını ve gerçek tüketim değerlerini gösteren grafikler Şekil 4.27, Şekil 4.28, Şekil 4.29 ve Şekil 4.30’da verilmiştir.

Söz konusu grafiklerden anlaşılacağı üzere, genel olarak seçilen günler için Topluluk modellerinin daha iyi tahmin performansı gösterdiği görülmektedir. Elbette bu durum, farklı günler arasında değişiklik gösterebilir. Bazı günler için LSTM veya CNN modelleri daha iyi tahminler üretebilmektedir. Ancak, yıl geneline bakıldığında, önerilen modellerin tahmin performansları sırasıyla Topluluk, LSTM ve CNN olarak hesaplanmıştır.




Şekil 4.27. Houston veri seti: yaz mevsimi hafta içinde LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması

LSTM (Elec):	RMSE= 856.68 MAE= 768.73 MAPE= 5.38%
LSTM (Elec+Temp+Time):	RMSE= 262.13 MAE= 223.83 MAPE= 1.60%
CNN (Elec):	RMSE= 521.21 MAE= 417.90 MAPE= 2.99%
CNN (Elec+Temp+Time):	RMSE= 262.55 MAE= 224.91 MAPE= 1.53%
Ensemble (Elec):	RMSE= 415.89 MAE= 358.67 MAPE= 2.58%
Ensemble (Elec+Temp+Time):	RMSE= 245.70 MAE= 217.92 MAPE= 1.52%




Şekil 4.28. Houston veri seti: yaz mevsimi hafta sonunda LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması

LSTM (Elec):	RMSE= 424.08 MAE= 349.43 MAPE= 3.15%
LSTM (Elec+Temp+Time):	RMSE= 263.93 MAE= 239.29 MAPE= 2.18%
CNN (Elec):	RMSE= 415.57 MAE= 330.68 MAPE= 3.00%
CNN (Elec+Temp+Time):	RMSE= 186.91 MAE= 147.65 MAPE= 1.32%
Ensemble (Elec):	RMSE= 416.03 MAE= 333.20 MAPE= 3.01%
Ensemble (Elec+Temp+Time):	RMSE= 160.11 MAE= 131.90 MAPE= 1.17%



Şekil 4.29. Houston veri seti: kış mevsimi hafta içinde LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması

LSTM (Elec):	RMSE= 492.46 MAE= 365.30 MAPE= 3.72%
LSTM (Elec+Temp+Time):	RMSE= 379.52 MAE= 344.31 MAPE= 3.34%
CNN (Elec):	RMSE= 463.17 MAE= 380.01 MAPE= 3.81%
CNN (Elec+Temp+Time):	RMSE= 499.41 MAE= 397.96 MAPE= 3.67%
Ensemble (Elec):	RMSE= 473.39 MAE= 367.60 MAPE= 3.71%
Ensemble (Elec+Temp+Time):	RMSE= 412.88 MAE= 349.26 MAPE= 3.28%



Şekil 4.30. Houston veri seti: kış mevsimi hafta sonunda LSTM, CNN ve Topluluk modellerinin tahmin performanslarının karşılaştırması

4.3. Literatürle Karşılaştırma

Tez çalışması kapsamında geliştirilen modeller ile literatürdeki modellerin karşılaştırması Tablo 4.2'de sunulmuştur. Söz konusu tabloda, ilgili modellerle ulaşılan en iyi sonuçlara yer verilmiştir.

Söz konusu tabloda görüldüğü üzere, önerilen modellerin literatürdeki çalışmalara oranla daha iyi tahminler ürettiği açık bir şekilde görülmektedir. Dayton şehrine ait elektrik tüketim verilerinin kullanıldığı (Khan, et al., 2022) tarafından yapılan çalışmada, farklı modeller eğitilmiş ve bir saatlik elektrik tüketim tahmini yapılmıştır. Bu modeller içerisinde en iyi performansı gösteren LSTM modelinin, N-RMSE ve N-MAE değerleri sırasıyla “0,383” ve “0,251” olarak hesaplanmıştır. Söz konusu çalışmada elde edilen sonuçlara kıyasla, bu tez çalışmasında önerilen modellerin tahmin performansı oldukça iyidir. Ayrıca, bu tez çalışmasında önerilen modellerin 24 saat için elektrik tüketim tahmini yaptığı düşünüldüğünde, literatürde belirtilen modellere kıyasla daha üstün performans gösterdikleri açıkça görülmektedir.

İlgili tabloda, (Butt, Hussain, Mahmood, & Lone, 2021) ve (Almaleck, et al., 2024) tarafından yapılan çalışmalarda, solo ve hibrit modeller eğitilerek 24 saatlik elektrik tüketimi tahminleri yapılmıştır. Modellerin tahmin performansını

değerlendirmek için MAPE kullanılmış ve en iyi sonucun elde edildiği MLP için bu değer “%4,97” olarak hesaplanmıştır. Bu tez çalışmasında, önerilen LSTM, CNN ve Topluluk modelleri için MAPE değerlerinin sırasıyla “%4,63”, “%4,06” ve “%4,17” olduğu göz önüne alındığında, 24 saatlik elektrik tüketimi tahminlerinde de önerilen modellerin literatürde bulunan modellere kıyasla daha iyi tahminler ürettiği anlaşılmaktadır.

Tablo 4.2. Önerilen modellerin performansının literatürle karşılaştırılması

Yöntem	N-RMSE	N-MAE	MAPE	Tahmin Ufku (Saat)	
CNN (Khan, et al., 2022)	0,502	0,373	-	1	
SVR (Khan, et al., 2022)	0,620	0,493	-	1	
GRU (Khan, et al., 2022)	0,614	0,488	-	1	
MLP (Khan, et al., 2022)	0,519	0,382	-	1	
LSTM (Khan, et al., 2022)	0,383	0,251	-	1	
Linear Regression (Khan, et al., 2022)	0,570	0,404	-	1	
Decision Tree (Khan, et al., 2022)	0,571	0,359	-	1	
ELM (Khan, et al., 2022)	0,563	0,427	-	1	
MLP (Butt, Hussain, Mahmood, & Lone, 2021)			%4,97	24	
LSTM (Butt, Hussain, Mahmood, & Lone, 2021)			%5,17	24	
CNN (Butt, Hussain, Mahmood, & Lone, 2021)			%5,62	24	
SDA (Almaleck, et al., 2024)			%12,39	24	
MLR (Almaleck, et al., 2024)			%11,24	24	
BEM (Almaleck, et al., 2024)			%9,09	24	
ARIMAX (Almaleck, et al., 2024)			%14,74	24	
ARIMAX+BEM (Almaleck, et al., 2024)			%10,41	24	
BEM+ARIMAX (Almaleck, et al., 2024)			%9,03	24	
Önerilen Modeller	LSTM	0,191	0,159	4,63	24
	CNN	0,163	0,137	4,06	24
	Topluluk	0,171	0,143	4,17	24

5. SONUÇLAR

Bu çalışmada, kısa vadeli (sonraki 24 saat) elektrik tüketimi tahmini için LSTM, CNN ve bu iki mimarinin birleşiminden oluşan Topluluk modelleri önerilmiştir. Modellerin eğitim ve test aşamaları için Amerika'nın Ohio ve Texas eyaletlerinde bulunan Dayton ve Houston şehirlerine ait elektrik tüketim, meteoroloji ve zaman damgası verileri kullanılmıştır. Modellerin eğitim süreçlerine geçilmeden önce, birtakım optimizasyon adımları gerçekleştirilmiştir. Bu adımlar sırası ile önerilen model mimarilerinin tasarlanması, rastgele tohum değerinin belirlenmesi ve hiperparametre optimizasyonları şeklinde gerçekleştirilmiştir. Modellerin tahmin performanslarını değerlendirmek için N-RMSE, N-MAE ve MAPE metrikleri kullanılmıştır.

Ayrıca, meteoroloji ve zaman özniteliklerinin önerilen modellerin elektrik tüketim tahmin performanslarına etkilerini gözlemlemek amacıyla 16 farklı öznitelik seti ile modeller eğitilmiş ve 24 saatlik tahminler üretilmiştir. Yapılan analizler sonucunda, önerilen modeller, elektrik tüketimi verilerinin yanında meteoroloji ve zaman verileriyle eğitildiğinde, genel olarak tahmin performanslarının iyileştiği gözlemlenmiştir. Houston veri seti kullanılarak eğitilen modellerde, LSTM modellerinin tahmin performansı daha iyi olurken, Dayton veri seti kullanılarak eğitilen modellerde CNN modellerinin tahmin performansı daha iyi olmuştur. Deneysel çalışmalar sonucunda, modellerin tahmin performansı sıralaması, Topluluk, CNN ve LSTM şeklinde gerçekleşmiştir. LSTM modelinin tahmin performansı, Dayton ve Houston veri setleri için sırası ile “%22,31” ve “%21,53” oranına kadar iyileşme göstermiştir. Bu iyileşme oranları, CNN modeli için “%27,24” ve “%28,99”, Topluluk modeli için ise “%22,75” ve “%25,71” olarak hesaplanmıştır. Bu tez çalışmasında, meteoroloji ve zaman verilerinin, önerilen modellerin elektrik tüketimi tahmin performanslarını önemli ölçüde iyileştirdiği açık bir şekilde görülmüştür. Her iki veri seti için önerilen modellerin tahmin performansları, kış ayları için en iyi olurken, Dayton veri seti için yaz, Houston veri seti için ise ilkbahar ayları en kötü olmuştur.

Google tarafından geliştirilen, çok değişkenli derin öğrenme tabanlı TFT modeli ile benzer çalışmalar yapmak, gelecek çalışma planlarımız arasında yer almaktadır. Ayrıca, N-BEATS ve DeepAR gibi tek değişkenli derin öğrenme tabanlı zaman serisi tahmin modellerinden, hibrit yaklaşımlar ile çok değişkenli modeller geliştirmek, uzun vadeli planlarımız arasında yer almaktadır.

KAYNAKÇA

- Ahmad, T., & Chen, H. (2020). A review on machine learning forecasting growth trends and their real-time applications in different energy systems. *Sustainable Cities and Society*, 54, 102010.
- Almaleck, P., Massucco, S., Mosaico, G., Saviozzi, M., Serra, P., & Silvestro, F. (2024). Electrical consumption forecasting in sports venues: A proposed approach based on neural networks and ARIMAX Models. *Sustainable Cities and Society*, 100, 105019.
- Alsharekh, M. F., Habib, S., Dewi, D. A., Albattah, W., Islam, M., & Albahli, S. (2022). Improving the Efficiency of Multistep Short-Term Electricity Load Forecasting via R-CNN with ML-LSTM. *Sensors*, 22, 6913.
- Arora, P., Jalali, S. M., Ahmadian, S., Panigrahi, B. K., Suganthan, P. N., & Khosravi, A. (2022). Probabilistic Wind Power Forecasting Using Optimized Deep Auto-Regressive Recurrent Neural Networks. *IEEE Transactions on Industrial Informatics*, 19, 2814–2825.
- Atik, I. (2022). A New CNN-Based Method for Short-Term Forecasting of Electrical Energy Consumption in the Covid-19 Period: The Case of Turkey. *IEEE Access*, 10, 22586–22598.
- Bashir, T., Haoyong, C., Tahir, M. F., & Liqiang, Z. (2022). Short term electricity load forecasting using hybrid prophet-LSTM model optimized by BPNN. *Energy Reports*, 8, 1678–1686.
- Bilgili, M., & Pinar, E. (2023). Gross electricity consumption forecasting using LSTM and SARIMA approaches: A case study of Türkiye. *Energy*, 284, 128575.
- Bilgili, M., Arslan, N., Şekertekin, A. L., & Yaşar, A. B. (2022). Application of long short-term memory (LSTM) neural network based on deeplearning for electricity energy consumption forecasting. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30, 140–157.
- Bowden, N., & Payne, J. E. (2008). Short term forecasting of electricity prices for MISO hubs: Evidence from ARIMA-EGARCH models. *Energy Economics*, 30, 3186–3197.
- Bu, S.-J., & Cho, S.-B. (2020). Time series forecasting with multi-headed attention-based deep learning for residential energy consumption. *Energies*, 13, 4722.
- Butt, F. M., Hussain, L., Mahmood, A., & Lone, K. J. (2021). Artificial Intelligence based accurately load forecasting system to forecast short and medium-term load demands. *Mathematical Biosciences and Engineering*, 18, 400–425.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7, 1247–1250.
- Dayton. (2023, 10 30). *Hourly Electricity Consumption Data*. Hourly Eelectricity Consumption Data: <https://www.kaggle.com/datasets/robikscube/hourly-energy-consumption> adresinden alındı

- Dayton. (2023, 10 30). *Hourly Weather Data*. Hourly Weather Data: <https://open-meteo.com/en/docs/historical-weather-api> adresinden alındı
- Deng, L., Li, W., & Zhang, W. (2023). Intelligent prediction of rolling bearing remaining useful life based on probabilistic DeepAR-Transformer model. *Measurement Science and Technology*, 35, 015107.
- Hamzaçebi, C., Es, H. A., & Çakmak, R. (2019). Forecasting of Turkey's monthly electricity demand by seasonal artificial neural network. *Neural Computing and Applications*, 31, 2217–2231.
- Houston. (2020, May 1). *US Top 10 Cities - Electricity Data*. Kaggle: https://www.kaggle.com/datasets/shubhamkulkarni01/us-top-10-cities-electricity-and-weather-data/data?select=cleaned_texas_data.csv adresinden alındı
- Houston. (2024, 3 14). *Historical Weather Api*. Open Meteo: https://open-meteo.com/en/docs/historical-weather-api/#latitude=29.7633&longitude=-95.3633&start_date=2018-01-01&end_date=2020-04-30&hourly=temperature_2m,relative_humidity_2m,wind_speed_10m adresinden alındı
- Hunt, J. D., Stilpen, D., & de Freitas, M. A. (2018). A review of the causes, impacts and solutions for electricity supply crises in Brazil. *Renewable and Sustainable Energy Reviews*, 88, 208–222.
- Huy, P. C., Minh, N. Q., Tien, N. D., & Anh, T. T. (2022). Short-term electricity load forecasting based on temporal fusion transformer model. *IEEE Access*, 10, 106296–106304.
- Kambule, N., Yessoufou, K., & Nwulu, N. (2018). A review and identification of persistent and emerging prepaid electricity meter trends. *Energy for sustainable development*, 43, 173–185.
- Khan, Z. A., Ullah, A., Haq, I. U., Hamdy, M., Mauro, G. M., Muhammad, K., . . . Baik, S. W. (2022). Efficient short-term electricity load forecasting for effective energy management. *Sustainable Energy Technologies and Assessments*, 53, 102337.
- Li, D., Tan, Y., Zhang, Y., Miao, S., & He, S. (2023). Probabilistic forecasting method for mid-term hourly load time series based on an improved temporal fusion transformer model. *International Journal of Electrical Power & Energy Systems*, 146, 108743.
- Li, J., Wang, Z., Liu, X., & Feng, Z. (2023). Remaining Useful Life Prediction of Rolling Bearings Using GRU-DeepAR with Adaptive Failure Threshold. *Sensors*, 23, 1144.
- Lim, B., Arik, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37, 1748–1764.
- Marziali, A., Fabbiani, E., & Nicolao, G. D. (2021). Ensembling methods for countrywide short-term forecasting of gas demand. *International Journal of Oil, Gas and Coal Technology*, 26, 184–201.

- Olivares, K. G., Challu, C., Marcjasz, G., Weron, R., & Dubrawski, A. (2023). Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with NBEATSx. *International Journal of Forecasting*, 39, 884–900.
- Oreshkin, B. N., Dudek, G., Pełka, P., & Turkina, E. (2021). N-BEATS neural network for mid-term electricity load forecasting. *Applied Energy*, 293, 116918.
- Pappas, S. S., Ekonomou, L., Karamousantas, D. C., Chatzarakis, G. E., Katsikas, S. K., & Liatsis, P. (2008). Electricity demand loads modeling using AutoRegressive Moving Average (ARMA) models. *Energy*, 33, 1353–1360.
- Qiu, X., Ru, Y., Tan, X., Chen, J., Chen, B., & Guo, Y. (2023). A k-nearest neighbor attentive deep autoregressive network for electricity consumption prediction. *International Journal of Machine Learning and Cybernetics*, 1–12.
- Rendon-Sanchez, J. F., & de Menezes, L. M. (2019). Structural combination of seasonal exponential smoothing forecasts applied to load forecasting. *European Journal of Operational Research*, 275, 916–924.
- Saeed, F., Paul, A., & Seo, H. (2022). A hybrid channel-communication-enabled CNN-LSTM model for electricity load forecasting. *Energies*, 15, 2263.
- Salinas, D., Flunkert, V., Gasthaus, J., & Januschowski, T. (2020). DeepAR: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, 36, 1181–1191.
- Santos, M. L., García, S. D., García-Santiago, X., Ogando-Martínez, A., Camarero, F. E., Gil, G. B., & Ortega, P. C. (2023). Deep learning and transfer learning techniques applied to short-term load forecasting of data-poor buildings in local energy communities. *Energy and Buildings*, 292, 113164.
- Satrio, C. B., Darmawan, W., Nadia, B. U., & Hanafiah, N. (2021). Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET. *Procedia Computer Science*, 179, 524–532.
- Shahidehpour, M., Yamin, H., & Li, Z. (2003). *Market operations in electric power systems: forecasting, scheduling, and risk management*. John Wiley & Sons.
- Torres, J. F., Martínez-Álvarez, F., & Troncoso, A. (2022). A deep LSTM network for the Spanish electricity consumption forecasting. *Neural Computing and Applications*, 34, 10533–10545.
- Türkiye elektrik üretim ve tüketim bilgileri*. (2021, 3 1). Türkiye - Countries & Regions - IEA: <https://www.iea.org/countries/turkiye/electricity> adresinden alındı
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30, 1030–1081.
- World total final consumption by source*. (2021, March 1). International Energy Agency: <https://www.iea.org/reports/key-world-energy-statistics-2021/final-consumption> adresinden alındı
- Yan, X., & Chowdhury, N. A. (2014). Mid-term electricity market clearing price forecasting: A multiple SVM approach. *International Journal of Electrical Power & Energy Systems*, 58, 206–214.

- Zhang, B., Song, C., Jiang, X., & Li, Y. (2023). Electricity price forecast based on the STL-TCN-NBEATS model. *Heliyon*, 9.
- Zhao, X., Li, Q., Xue, W., Zhao, Y., Zhao, H., & Guo, S. (2022). Research on ultra-short-term load forecasting based on real-time electricity price and window-based XGBoost model. *Energies*, 15, 7367.
- Zheng, H., Yuan, J., & Chen, L. (2017). Short-term load forecasting using EMD-LSTM neural networks with a Xgboost algorithm for feature importance evaluation. *Energies*, 10, 1168.
- Zheng, P., Zhou, H., Liu, J., & Nakanishi, Y. (2023). Interpretable building energy consumption forecasting using spectral clustering algorithm and temporal fusion transformers architecture. *Applied Energy*, 349, 121607.



ÖZGEÇMİŞ

ORCID NO: 0000-0003-4657-3261

Ad Soyad : Emrah DEMİR

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2007-2011, Anadolu Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Lisans-Anadal
- 2012-2013, Yazılım Uzmanı, 2N İnovasyon
- 2014-2017, Araştırma Görevlisi, Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü
- 2018-2020, Yazılım uzmanı, MEDITAGEM
- 2020-devam ediyor, Araştırma Görevlisi, Eskişehir Teknik Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

Ödülleri:

Mesleki Birlik/Dernek/Kuruluş Üyelikleri: