

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİBRİT DERİN ÖĞRENME MODELİ İLE
ELEKTRİK TÜKETİM TAHMİNİ

Vildan KARA

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

İstatistik Programı

Danışman

Prof. Dr. Fatma NOYAN TEKELİ

Haziran, 2025

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİBRİT DERİN ÖĞRENME MODELİ İLE ELEKTRİK
TÜKETİM TAHMİNİ

Vildan KARA tarafından hazırlanan tez çalışması 19.06.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, İstatistik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Fatma NOYAN TEKELİ
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Fatma NOYAN TEKELİ, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Gülhayat GÖLBAŞI ŞİMŞEK, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Selay GİRAY YAKUT, Üye
Marmara Üniversitesi

Danışmanım Prof. Dr. Fatma NOYAN TEKELİ sorumluluğunda tarafımda hazırlanan “Hibrit Derin Öğrenme Modeli ile Elektrik Tüketim Tahmini” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Vildan KARA

İmza



Değerli aileme.

TEŐEKKÜR

Tez alıřmamda deęerli katkıları ve yksek lisans eęitimim sresince akademik bilgi ve deneyimlerinden yararlandıęım sayın tez danıřmanım Prof. Dr. Fatma NOYAN TEKELİ'ye teőekkrlerimi sunarım.

Tez alıřmam boyunca her daim yanımda olan ve desteęini esirgemeyen Dr. Fatih SAęLAM'a; ayrıca, yardımları iin alıřma arkadařım Dr. ęr. yesi İsmet BİRBIER'e teőekkr ederim.

Eęitimim iin yaptıkları fedakarlıklar ve bugnlere gelmemde gsterdikleri aba iin aileme itenlikle teőekkr ederim. Sevginiz hep yanımda oldu ve bana g verdi.

Vildan KARA

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	x
ÖZET	xi
ABSTRACT	xiii
1 GİRİŞ	1
1.1 Literatür Taraması.....	1
1.2 Tezin Amacı	6
2 ELEKTRİK TÜKETİMİ	8
2.1 Elektrik Enerjisi Tüketim Tahmini	8
2.2 Türkiye’de Elektrik Tüketimi.....	9
3 METODOLOJİ	10
3.1 Zaman Serilerine Derin Öğrenme Yaklaşımı	10
3.2 Derin Öğrenme Yöntemleri.....	12
3.2.1 Yapay Sinir Ağları (Artificial Neural Networks- ANN)	12
3.2.2 Yinelemeli Sinir Ağları (Recurrent Neural Networks- RNN)	14
3.2.3 Uzun Kısa Vadeli Bellek (Long Short-Term Memory - LSTM)	16
3.2.4 Çift Yönlü Uzun Kısa Vadeli Bellek (Bidirectional Long Short-Term Memory - BiLSTM)	18
3.2.5 Geçitli Tekrarlayan Birim (Gated Recurrent Unit - GRU)	19
3.2.6 Önerilen Hibrit Model (GRU-BiLSTM)	21
3.3 Model Performans Değerlendirme Metrikleri	23
3.3.1 RMSE(Root Mean Square Error)	24
3.3.2 MAPE(Mean Absolute Percentage Error)	24
3.3.3 R² (Coefficient of Determination)	25
3.3.4 MAE (Mean Absolute Error)	25
4 UYGULAMA	26
4.1 Veri	26
4.2 Veri Ön İşleme.....	30

4.3 Modeller	32
4.4 Bulgular	37
5 SONUÇ VE ÖNERİLER	42
KAYNAKÇA	44
TEZDEN ÜRETİLMİŞ YAYINLAR	49



SİMGE LİSTESİ

Σ	Toplama İşlemi
b	Bias
f	Frekans
\tanh	Hiperbolik Tanjant
y_i	Gerçek Değerler
\hat{y}_i	Tahmin Değerleri
W	Ağırlık Parametreleri
\odot	Hadamard Çarpımı
σ	Sigmoid Aktivasyon Fonksiyonu

KISALTMA LİSTESİ

AI	Artificial Intelligence
ARIMA	Autoregressive Integrated Moving Average
ANN	Artificial Neural Networks
BiLSTM	Bidirectional Long Short-Term Memory
CNN	Convolutional Neural Network
DL	Deep Learning
FL	Fuzzy Logic
GRU	Gated Recurrent Unit
KNN	k -Nearest Neighbors
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
ML	Machine Learning
MSE	Mean Square Error
MWh	Megawatt Saat
RF	Random Forest
RMSE	Root Mean Square Error
RNN	Recurrent Neural Network
SARIMA	Seasonal Autoregressive Integrated Moving Average
SVR	Support Vector Regression
SWT	Stationary Wavelet Transform
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
TÜİK	Türkiye İstatistik Kurumu

ŞEKİL LİSTESİ

Şekil 3.1 Yapay sinir hücresi yapısı [33]	13
Şekil 3.2 Yapay sinir ağı katmanları [35].....	14
Şekil 3.3 RNN mimarisinin açılmamış yapısı	15
Şekil 3.4 RNN mimarisin açılmış yapısı	16
Şekil 3.5 LSTM mimari yapısı [41]	17
Şekil 3.6 BiLSTM mimari yapısı [45]	19
Şekil 3.7 GRU mimari yapısı [48]	20
Şekil 3.8 Önerilen hibrit modelin yapısı	22
Şekil 3.9 Önerilen modelin uygulama adımları	23
Şekil 4.1 Saatlik elektrik tüketim verisi	27
Şekil 4.2 Günlük elektrik tüketim verisi	28
Şekil 4.3 Yıllık elektrik tüketim dağılımı.....	28
Şekil 4.4 Aylık elektrik tüketim dağılımı	29
Şekil 4.5 Günlük elektrik tüketim dağılımı	29
Şekil 4.6 Saatlik elektrik tüketim dağılımı	30
Şekil 4.7 Ölçeklendirilmiş veri kümesi	31
Şekil 4.8 Eğitim- test ayrımı.....	32
Şekil 4.9 ANN modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi	39
Şekil 4.10 LSTM modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi	39
Şekil 4.11 BiLSTM modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi	40
Şekil 4.12 GRU modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi	40
Şekil 4.13 GRU-BiLSTM modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi	41

TABLO LİSTESİ

Tablo 1.1 Literatür taramasının kısa bir özeti	5
Tablo 2.1 Türkiye Elektrik Dağıtım ve Tüketim İstatistikleri	9
Tablo 3.1 Yapay sinir ağı adlandırmalarının biyolojik sinir sistemi adlandırmaları ile karşılaştırılması	12
Tablo 4.1 Veri Kümesinin Karakteristikleri.....	26
Tablo 4.2 Önerilen Hibrit Modelin Yapısı.....	33
Tablo 4.3 GRU modelinin yapısı.....	34
Tablo 4.4 BiLSTM modelinin yapısı.....	34
Tablo 4.5 LSTM modelinin yapısı	35
Tablo 4.6 ANN modelinin Yapısı	35
Tablo 4.7 Tüm modeller için katman, optimizatör ve yığın boyutu bilgisi	37
Tablo 4.8 Tüm modeller için model performans değerlendirme sonuçları	38

Hibrit Derin Öğrenme Modeli İle Elektrik Tüketim Tahmini

Vildan KARA

İstatistik Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Fatma NOYAN TEKELİ

Günümüzde elektrik enerjisi, modern dünyanın sürdürülebilirliği bakımından temel bir ihtiyaç haline gelmiştir. Bu doğrultuda, doğru ve güvenilir tahminler yapabilmek, arz ve talep dengesinin sağlanması, maliyet optimizasyonu ve enerji politikalarının geliştirilmesinde önemli bir rol oynamaktadır.

Derin öğrenme alanındaki hızlı gelişmeler zaman serisi verilerinin tahmininde büyük ilgi uyandırmıştır. Her ne kadar geleneksel zaman serisi yöntemlerinden daha başarılı sonuçlar elde edilse de tek bir derin öğrenme modelinin karmaşık zaman serisi verilerinde her zaman yeterli olmadığı görülmüştür. Bu eksiklikten yola çıkılarak, bu tez çalışmasında Geçitli Tekrarlayan Birim (Gated Recurrent Unit- GRU) ve Çift Yönlü Uzun Kısa Vadeli Bellek (Bidirectional Long Short-Term Memory- BiLSTM) modellerini birlikte kullanarak hibrit bir derin öğrenme modeli önerilmiştir. Çalışmada farklı hiperparametreler denenmiş olup optimal sonuçları elde eden parametre sayıları ile analizler yapılmıştır.

Çalışmada, 2020-2024 yıllarına ait Türkiye’de toplanan saatlik elektrik tüketim verisi ele alınmıştır. İlgili veri kümesi günlük ölçeğe dönüştürülerek tahminleme süreci günlük düzeyde yapılmıştır.

Önerilen hibrit derin öğrenme modelinin performansı, klasik derin öğrenme modelleri ile ortalama karekök hata (Root Mean Square Error- RMSE), determinasyon katsayısı (Coefficient of Determination- R^2), ortalama mutlak hata (Mean Absolute Error – MAE) ve Ortalama mutlak yüzde hata (Mean Absolute Percentage Error- MAPE) metrikleri kullanılarak karşılaştırılmıştır. GRU-BiLSTM modeli için RMSE, R^2 , MAE ve MAPE değerleri sırasıyla 1427.0374, 0.9011, 890.2839 ve 2.3707 şeklinde sonuçlanmıştır.

Elde edilen bulgulara göre, önerilen hibrit model geleneksel derin öğrenme modellerine kıyasla daha yüksek doğruluk göstermiş ve daha düşük hata oranları sağlamıştır.

Anahtar Kelimeler: Hibrit model, derin öğrenme, elektrik tüketim tahmini

Electricity Consumption Forecasting with Hybrid Deep Learning Model

Vildan KARA

Department of Statistics
Master of Science Thesis

Supervisor: Prof. Dr. Fatma NOYAN TEKELİ

Nowadays, electrical energy has become a fundamental necessity for the sustainability of the modern world. In this context, making accurate and reliable forecasts plays a crucial role in maintaining the balance between supply and demand, optimizing costs, and developing energy policies.

The rapid advancements in the field of deep learning have attracted significant interest in the forecasting of time series data. Although more successful results have been achieved compared to traditional time series methods, it has been observed that a single deep learning model is not always sufficient for complex time series data. Based on this shortcoming, this thesis proposes a hybrid deep learning model that combines Gated Recurrent Unit (GRU) and Bidirectional Long Short-Term Memory (BiLSTM) models. In the study, various hyperparameters were tested, and analyses were carried out using the parameter settings that yielded optimal results.

The study focuses on hourly electricity consumption data collected in Turkey from 2020 to 2024. The dataset was converted to a daily scale, and the forecasting process was carried out daily.

The performance of the proposed hybrid deep learning model was compared with classical deep learning models using metrics such as Root Mean Square Error

(RMSE), Coefficient of Determination (R^2), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE). For the GRU-BiLSTM model, the RMSE, R^2 , MAE, and MAPE values were found to be sırasıyla 1427.0374, 0.9011, 890.2839 and 2.3707 respectively.

According to the findings, the proposed hybrid model demonstrated higher accuracy and provided lower error rates compared to traditional deep learning models.

Keywords: Hybrid model, deep learning, electricity consumption forecasting



1.1 Literatür Taraması

Elektrik tüketim tahmini, sürdürülebilirlik, arz-talep dengesi, maliyet optimizasyonu ve enerji politikalarının belirlenmesi açısından kritik bir rol oynamaktadır. Bu alanda literatürde istatistiksel yöntemlerden derin öğrenme tabanlı modellere kadar çeşitli çalışmalar yapılmıştır.

Nebati ve diğ. [1] Türkiye’de doğru elektrik talep tahmini için regresyon analizi ve zaman serisi tekniklerini uygulamıştır. Çalışmada elde edilen sonuçlar, TÜİK tarafından paylaşılan verilerle karşılaştırılmış olup analiz sonuçları ile uyumlu olduğu gözlenmiştir.

Türkiye’nin günlük elektrik tüketimini tahminlemek için model geliştiren Haliloğlu ve Tuttu sıcaklık ve mevsimselliğin etkilerini incelemiştir. Literatürdeki yıllık frekansta yapılan tahminlerin aksine kısa vadede daha yüksek başarı sağlamak için günlük frekansta tahmin yapılmıştır. Çalışmada 2012-2017 yılları arasındaki verilerle model kurulmuş ve Ocak-Nisan 2018 arasındaki verilerle test edilmiştir. Analiz sonucunda %92.8 oranında açıklayıcılık elde etmiş olsa da farklı modeller geliştirilerek kısa vadeli tahmin sonuçlarının iyileştirilmesi gerektiğine dikkat çekmektedir. [2]

Sharma ve Mishra elektrik talep tahmininde zaman serilerinin ayrıştırılması için ARIMA modelini ele almıştır. Çalışmada, hane ve ticari kullanım için yapılan elektrik tahmininde düşük hata oranları yakalamıştır. Ancak araştırmacılar, gelecekteki çalışmalarda karmaşıklığı azaltmak amacıyla hibrit bir metodoloji geliştirmeyi planlamaktadır. [3]

Enerji yoğun üretim tesislerindeki kısa vadeli yük tahminini yapan Ribeiro ve diğ. kullanılan manuel teknikten daha başarılı sonuçlar elde etmek amacıyla ARIMA, makine öğrenmesi modelleri (Support Vector Regression -SVR, RF Random Forest) ve derin öğrenme modelleri (Recurrent Neural Network- RNN, Gated Recurrent Unit- GRU, Long Short-Term Memory- LSTM) uygulamıştır. Çalışmada, Brezilya'daki bir termoplastik reçine üretim tesisinden alınan veriler kullanılmış ve analiz sonuçlarına göre, manuel tahmin yöntemi en düşük performansı gösterirken GRU modeli 0.0305 RMSE değeri ile diğer tüm modellerden daha üstün performans göstermiş ve tahmin doğruluğu açısından öne çıkmıştır. [4]

Banik ve diğ. Hindistan'ın Agartala şehrinde elektrik tüketim tahmini üzerine bir çalışma geliştirmişlerdir. Bu çalışmada, topluluk makine öğrenimi yöntemlerinin nasıl çalıştığı gösterilmiştir. RF ve XGBoost modellerinin performansları topluluk haliyle karşılaştırılmıştır ve sonucunda topluluk yönteminin daha başarılı sonuçlar elde ettiği gözlenmiştir. [5]

Akıllı şebekelerin gelişmesiyle enerji tüketimi üzerinde yaşanan zorlukları azaltmak isteyen Shaikh ve diğ. N-BEAST modelini geliştirmişlerdir. Zaman serisi verilerini işleyebilen bu model, 169 müşterinin enerji tüketim verileri ele alınarak çalışılmış ve farklı modellerle karşılaştırılması sonucunda başarı yakalamıştır. [6]

Al-Ani ve diğ., kısa vadeli yük talep tahmini için daha etkili yöntemler bulmak adına makine öğrenmesi modelleri ile bir çalışma yapmışlardır. Çalışmada, Türkiye Elektrik İletim A.Ş. (TEİAŞ) verisi kullanılmış olup Yapay Sinir Ağları (Artificial Neural Networks - ANN) ve Bulanık Mantık (Fuzzy Logic - FL) yöntemleri uygulanmıştır. MAPE ile yapılan değerlendirmede ANN ve FL regresyon analizlerinden daha başarılı olduğu sonucuna varılmıştır. [7]

Reddy ve diğ., enerji dağıtım maliyetlerini optimize etmek için elektrik tüketim tahmin doğruluğunu arttırmak istemiştir. Bu amaçla, makine öğrenmesi alanındaki gelişmelerden yararlanarak farklı modeller ile tahminler yapılmıştır. Test edilen modeller arasında K En Yakın Komşu (KNN) algoritması %90,92 doğruluk oranıyla en iyi performansı göstermiştir. [8]

Başoğlu ve Bulut, kısa dönem elektrik talep tahminlerinin doğruluğunu arttırmak için uzman sistemler ve yapay sinir ağlarını birleştirmiştir. Geliştirilen tahmin

sistemi ile günlük talep tahminini elde edilir. Yapılan çalışma, elektrik talep tahmininde kullanılan geleneksel yöntemlerden daha iyi başarı sağlayarak ANN(Artificial Neural Networks- Yapay Sinir Ağları) ve uzman sistemlerin birleşimiyle daha güvenilir tahminler yapılabileceğini göstermektedir. [9]

Yan ve diğ. bireysel hanelerin enerji tüketimini tahmin etmek için sabit dalgacık dönüşümü (Stationary Wavelet Transform- SWT) ile birleştirilmiş LSTM tabanlı bir model geliştirmiştir. SWT, enerji tüketim verilerindeki dalgalanmaları azaltrarak sinyali birden fazla alt sinyale ayırır. Bu alt sinyaller LSTM modeliyle işlenir ve sonuçların birleştirilmesiyle nihai tahmin elde edilir. Çeşitli hata metrikleri ile yapılan değerlendirmede önerilen model (SWT-LSTM), diğer modellerden (SVR, LSTM, CNN-LSTM) daha başarılı sonuçlar vermiştir. [10]

Farklı bina türlerini içeren veri kümelerindeki enerji tüketim tahmin performansını arttırmak isteyen Jogunola ve diğ. CBLSTM-AE hibrit modelini geliştirmiştir. Model CNN (Convolutional Neural Network), AE (Autoencoder) ve BiLSTM (Bidirectional Long Short-Term Memory) bileşenlerinden oluşur. Veri kümeleri ortalama karesel hata (MSE) ve hesaplama süresi gibi kriterler kullanılarak değerlendirilmiştir. Önerilen hibrit model hem hız açısından hem de düşük hata oranlarıyla farklı veri kümelerinde başarı yakalamıştır. Ancak çalışmada hiperparametre seçimi deneme yanılma yöntemiyle yapılması bir kısıt olarak yorumlanmış ve gelecekte otomatikleştirilmesi üzerine çalışılacağı bildirilmiştir. [11]

Hane enerji tüketiminin çok adımlı tahmini için geleneksel yöntemlerin yetersiz kaldığını gözlemleyen Saoud ve diğ. derin öğrenme tabanlı iki farklı model geliştirmiştir. İlk model, sabit dalgacık dönüşümü (SWT) ile CNN ve LSTM modellerini birleştirir. İkinci model ise, sabit dalgacık dönüşümünü Transformer mimarisi ile birleştirir. Farklı performans metrikleri (RMSE, MAE, MAPE) ile yapılan değerlendirme sonuçlarında her iki model de geleneksel yöntemlerden daha yüksek başarı sağlamış olup Transformer-SWT modeli en iyi performansı göstermiştir. Önerilen modellerin, özellikle enerji tüketim verilerindeki dalgalanmaları açıklamada etkili olduğu belirlenmiştir. [12]

Ghimire ve diğ. elektrik talep tahmini doğruluğunu arttırmak amacıyla ICMD-ANN-EDLSTM adlı bir hibrit model önermişlerdir. Bu model, zaman serilerindeki

yüksek ve düşük frekanslı verileri analiz ederek karmaşık desenleri anlamayı hedefler. ICMD ile zaman serisi verilerinin bileşenlere ayrılır ve yüksek frekanslı bileşenler ANN modeli ile, düşük frekanslı bileşenler ise EDLSTM ile tahmin edilir. Bu adımlar sonucunda elde edilen tahminler birleştirilerek nihai elektrik talep tahmini elde edilir. Çalışmada önerilen model, klasik modellerle ve diğer hibrit modellerle karşılaştırılmış ve değerlendirmeler sonucunda %2.82'lik en düşük RMAE değerine sahip olduğu tespit edilmiştir. [13]

Kaysal ve diğ. yenilenebilir enerji kaynaklarından elde edilen elektrik üretimini tahmin etmek için CNN-BiLSTM hibrit modelini önermişlerdir. Derin öğrenme modellerinin performanslarını arttırmak amacıyla tasarlanan hibrit modelde, hiperparametre değerleri Grid search algoritması kullanılarak optimize edilmiştir. Optimizasyon sürecinin sonunda CNN-BiLSTM hibrit modeli, yalnızca BLSTM modelinden daha yüksek başarı göstermiştir. Önerilen model 0.984 R^2 değeri ile yüksek bir doğrulukla zaman serisi tahminlerinde etkili bir araç olduğunu ortaya koymuştur. [14]

Doğan ve diğ. artan enerji tüketiminden dolayı sürdürülebilir şehirlerin elektrik yük talebini tahmin etmeyi amaçlamaktadır. Bu amaç doğrultusunda araştırmacılar, CNN ve LSTM modellerini birleştiren bir hibrit derin öğrenme modeli önermişlerdir. Çalışmada, 2017-2021 yılları arasında Türkiye'deki bir şehrin elektrik tüketimi ve hava tahmini verileri kullanarak orta vadeli tahmin yapılmıştır. Sonuçlar MAPE, RMSE, MAE ve R^2 metrikleriyle değerlendirilmiş ve önerilen hibrit modelin yalnızca LSTM modeline kıyasla daha başarılı tahminler yaptığı göstermektedir. [15]

Daha önce bahsedilmiş olan çalışmaların içerikleri Tablo1.1'de sunulmuştur. Tabloda koyu renkle belirtilen yöntemler o çalışmadaki en iyi sonuçların elde edildiği yöntemlerdir. Bu tablo, ilgili çalışmaların kapsamını ve yöntemsel farklılıklarını özetleyerek literatürdeki yaklaşımlar arasındaki farkları ve benzerlikleri vurgulamaktadır.

Tablo 1.1 Literatür taramasının kısa bir özeti

Tahmin modelleri	Referans	Yöntem	Periyot	Yıl	Metrik
Yapay Zeka Tabanlı Modeller	[4]	ARIMA SVR, RF, RNN GRU, LSTM	Günlük	2020	RMSE MAPE MAE
	[5]	SVR, ANN, RF, Tuned RF, XGBoost AdaBoost Regressor RF-XGBoost	Saatlik Günlük Haftalık	2021	R^2 RMSE
	[6]	TCN LSTM GRU N-BEAST	Günlük Haftalık Aylık	2022	MAPE MAE MSE RMSE
	[7]	ANN, FL	Saatlik, Haftalık, Aylık	2022	MAPE
	[8]	Lineer Regresyon KNN, RF, ANN XGBoost	Saatlik	2023	MAE RMSE R^2
Hibrit Modeller	[9]	EPSIM-NN	Günlük	2016	MAPE RMSE
	[10]	SWT-LSTM SVR, LSTM CNN-LSTM	6 saniyelik 5 dakikalık	2019	MAPE MBE RMSE
	[11]	CBLSTM-AE	30 dakikalık Günlük	2022	MSE RMSE MAE

Tablo 1.2 Literatür taramasının kısa bir özeti (devamı)

Hibrit Modeller	[12]	CNN-LSTM-SWT Transformer-SWT	Dakikalık Saatlik, Günlük Haftalık	2022	RMSE MAE MAPE
	[13]	ICMD-ANN-EDLSTM ICMD-ANN-CLSTM ICMD-RFR-CLSTM ICMD-RFR-LSTM CLSTM, RFR, LSTM, ANN	Günlük	2023	RMAE RMSE KGE APB
	[14]	BLSTM CNN-BLSTM	Saatlik	2023	RMSE MSE MAE R^2
	[15]	LSTM CNN-LSTM	Saatlik	2024	MAPE RMSE MAE R^2

1.2 Tezin Amacı

Bu tez çalışmasının amacı, Türkiye’de elektrik tüketim tahmin doğruluğunu arttırmak için hibrit derin öğrenme modelinin uygulanmasıdır. Enerji talebinin gün geçtikçe artıyor olması, elektrik tüketiminin doğru tahmin edilmesini önemli bir hale getirmiştir. Ayrıca doğru tahminler enerji üretim kaynaklarının verimli kullanımı açısından da kritik rol oynamaktadır.

Geleneksel zaman serilerinin yetersiz kaldığı durumlarda, daha güçlü tahmin modellerine duyulan ihtiyaç giderek artmaktadır. Bu doğrultuda, tahmin performansını iyileştirmek için GRU ve BiLSTM modellerini hibrit bir yapı çerçevesinde birleştirerek modelin zaman serisi verilerindeki karmaşık örüntüleri

açıklamasını kolaylaştırmıştır. Çalışma kapsamında, Türkiye'nin 2020-2024 yıllarına ait saatlik elektrik verisi ele alınarak analiz edilmiştir. Bu veri kümesine hem derin öğrenme hem de hibrit önerilen model uygulanmış ve tahmin sonuçları MAE, RMSE, R^2 ve MAPE gibi istatistiksel metrikler kullanılarak karşılaştırmalı olarak değerlendirilmiştir.

Bu tezin amacı, zaman serisi analizlerindeki geleneksel yöntemlerin uygulanmasında yaşanan kısıtların önüne geçmek adına derin öğrenme tabanlı hibrit bir model oluşturmaktadır. Bu kapsamda oluşturulan hipotezler aşağıdaki gibidir:

- 1- Oluşturulan hibrit model, derin öğrenme modellerine kıyasla daha yüksek doğruluk ve daha düşük hata oranları elde edecektir.
- 2- Hibrit model, elektrik tüketim verisindeki mevsimsel ve zamansal değişimlerden kaynaklanan karmaşık yapıların etkin bir şekilde öğrenilmesini sağlayacaktır.
- 3- Doğru elektrik tüketim tahminleri, enerji arz-talep dengesini sağlayarak sürdürülebilir enerji politikalarına katkıda bulunulacaktır.

2

ELEKTRİK TÜKETİMİ

2.1 Elektrik Enerjisi Tüketim Tahmini

Elektrik enerjisi, çağdaş ve modern bir hayat sürdürülebilmesi için temel bir gerekliliktir. Günümüzde en yaygın kullanılan enerji kaynaklarından biri olan elektrik enerjisi sanayi, ulaşım, konut gibi birçok alanda geniş bir kullanım alanına sahiptir. [16]

Elektrik tüketimi, belirli bir zaman aralığında kullanılan elektrik miktarını ifade etmektedir. Elektrik enerjisi depolama açısından çok başarılı olmadığından dolayı elektrik üretildiği anda tüketilmesi gereken bir enerji türüdür. Bu durumdan dolayı, elektrik arzı ile talebinin eşleşmesi gerekmektedir. [14] Eğer gerçek zamanlı olarak uyum olmazsa, arzın talep miktarından büyük olduğu durumlarda elektrik kesintileri yaşanabilir. [17] Ayrıca üretim süreçlerinde ciddi problemler ortaya çıkarabilir. Öte yandan elektrik enerjisi arzı talepten yüksek olduğu durumlarda ise elektrik israfı yaşanarak finansal kayıplar meydana gelmektedir. Bu nedenle elektrik tüketim tahminlerinin başarılı olması, sistemlerin üretim gereksinimlerinin önceden tanınmasına olanak tanımaktadır.

Elektrik tüketim tahmini, bir zaman serisi problemi olarak kabul edilmektedir. Yıl içerisinde elektrik talebi zamansal, mevsimsel ve bölgesel faktörlere dayalı olarak değişim göstermektedir. Bunlara ek olarak, uzun vadede artan nüfus ve ekonomik olaylar elektrik tüketimini etkilerken kısa vadede ise sıcaklık şartları, resmi tatiller gibi faktörler de elektrik talebi üzerinde belirleyici etkiye sahiptir. Elektrik santrallerinin büyük çoğunluğu anlık ayarlamalarla arz ve talep dengesini yakalaması pek mümkün olmadığından, talebin doğru tahmini oldukça önemlidir. Günümüz koşullarında yüksek miktarda elektrik enerjisi depolanmadığı için elektrik enerji talep tahmininin doğruluğu daha da önemli hale gelmektedir. [18]

2.2 Türkiye’de Elektrik Tüketimi

Türkiye’de elektrik tüketimi, büyüyen ekonomi ve artan nüfusa paralel olarak yıllar içinde sürekli bir artış göstermiştir. Bir diğer etken ise şehirleşme sürecinin hızla gelişmesidir. Şehirlerdeki artan nüfusla birlikte altyapı çalışmaları da geliştirilmiş olup elektrik şebekelerinin genişletilmesine olanak tanınmıştır. Gelecek yıllarda ekonomik büyümenin yanı sıra elektrikli araçların yaygınlaşması da elektrik ihtiyacını arttıracığı yönünde çıkarım yapılmaktadır. Bu faktörler göz önüne alındığında Türkiye’nin elektrik tüketimindeki artış kaçınılmaz olmuştur. [15] Elektrik tüketimine sektörel olarak bakıldığında, sanayi sektörü en fazla elektrik tüketimine sahip olmakla birlikte, son yıllarda mesken ve ticarethanelerin tüketim oranları belirgin artış göstermiştir. [19] Meskenlerdeki elektrik tüketiminin artışına şehirleşme ve elektrik altyapısının gelişmesi gibi faktörler etken olmuştur.

Tablo 2.1 Türkiye Elektrik Dağıtım ve Tüketim İstatistikleri [20]

Yıl	Toplam (GWh)	Mesken	Ticaret	Resmi daire	Sanayi	Aydınlatma	Diğer ⁽¹⁾
					(%)		
1970	7 308	15,9	4,8	4,1	64,2	2,6	8,4
1980	20 398	21,5	5,6	3,0	63,8	1,4	4,7
1990	46 820	19,6	5,5	3,1	62,4	2,6	6,8
2000	98 296	24,3	9,5	4,2	49,7	4,6	7,7
2010	172 051	24,1	16,1	4,1	46,1	2,2	7,4
2020	262 702	23,1	17,3	4,9	45,7	2,0	7,0

Türkiye’de elektrik arzının sürekli olarak artması talep artışını da beraberinde getirmektedir. Bu artışın sürdürülebilir şekilde planlanması için arz ve talep dengesini sağlamak önemlidir. Türkiye’de elektrik tüketim tahminin doğru yapılması yalnızca üretim ve dağıtım açısından değil, bunlara ilave olarak ekonomik ve sürdürülebilirlik açısından da son derece önemlidir.

3.1 Zaman Serilerine Derin Öğrenme Yaklaşımı

Zaman serileri, bir olayın ya da sürecin belirli bir zaman aralığında ardışık gözlemlerle ölçülmesi sonucu elde edilen veri kümesidir. [21] Bu veriler, belirli bir zaman aralığındaki olayın davranışını analiz etmek için kullanılır. Bir serinin zaman serisi olabilmesi için zamana bağlı bir durum olmalıdır. Zaman serisi verileri genellikle ekonomi, finans, enerji ve meteoroloji gibi alanlarda sıklıkla karşımıza çıkmaktadır. [22] Bu farklı alanlardaki zaman serilerini modellemek ve tahmin etmek için genellikle istatistiksel ve yapay zeka (AI) tabanlı yöntemler tercih edilmektedir.

Zaman serisi analizleri, verinin zamana bağlı değişimini anlayarak bu değişimler üzerinde tahminler yapabilmek amacıyla uygulanan bir işlemdir. [23] Temel amaç, geçmiş ve mevcut veri kümelerinden gelen bilgilere dayanarak gelecekteki bir değeri mümkün olduğunca uygun bir şekilde modelleme ve tahmin etmektir.

Zaman serilerinde bazı belirgin özellikler vardır;

Trend, mevsimsellik ve durağanlık kavramları bir zaman serisi analizinde doğru modeller geliştirebilmek adına önemlidir. Bir zaman serisinin uzun zaman aralığında artma veya azalma yönünde gösterdiği eğilime trend adı verilir. Trend doğrusal olabileceği gibi aynı zamanda eğrisel de olabilir ve verinin genel yapısını anlamada kritik bir rol oynamaktadır. Mevsimsellik, zaman serilerinde sıklıkla karşılaşılan ve belirli zaman aralıklarında tekrarlayan periyodik değişimlerdir. [24] Bu dalgalanmalar genellikle bir yıl veya daha kısa süre içerisinde belli bir düzenle kendini gösterir. Sıklıkla mevsim geçişleriyle ilişkilendirilir. Tarım, turizm faaliyetlerinde mevsimsellik etkilerine örnek verilebilir. Durağanlık ise, bir zaman serisinin ortalaması, varyansı ve iki dönem arasındaki kovaryansı zaman içerisinde

değişim göstermiyor yani sabit kalma durumu olarak kabul edilmektedir. Bu kapsamda durağanlık, bir zaman serisinin tahmin edilebilir bir yapıya sahip olduğunu göstermekle birlikte analiz aşamalarında bir önkoşul olarak kabul edilmektedir. [25]

Geleneksel zaman serisi analiz yöntemleri, özellikle ARIMA, SARIMA gibi modeller zaman serilerinde sıklıkla kullanılmaktadır. Modeller başarı sağlasa da bazı önemli kısıtlamaları da beraberinde getirir. Geleneksel zaman serilerindeki bu kısıtlar karmaşık yapılı, büyük ölçekli ve doğrusal olmayan veri kümelerinde daha belirgin hale gelir. [26]

Geleneksel yöntemler genellikle durağanlık varsayımı aramaktadır ve eğer veri durağanlık sağlamıyorsa bazı ön işleme adımlarıyla durağanlık sağlanmaya çalışılır. Ancak durağanlık sağlanırken veride bilgi kaybı olması mümkündür. Bir diğer kısıt ise doğrusal ilişkilere dayanmasıdır. Gerçek dünya verileri çoğunlukla doğrusal ilişki göstermediğinden karmaşık ve doğrusal olmayan yapıları modelleme ve tahminlemede yetersiz kalabilir. [27] Bunlara ek olarak, uzun dönem bağımlılıklarını yakalamadaki zorluklar, gürültüye karşı duyarlı olmaları geleneksel zaman serilerini yetersiz kılmaktadır. [28] [18]

Derin öğrenme doğal dil işleme, görüntü tanıma, zaman serisi analizleri gibi pek çok alanda başarılı sonuçlar elde etmektedir. [29] Bu yöntemler, karmaşık yapıları ve doğrusal olmayan bağımlılıkları açıklama konusunda büyük avantaj sağlamaktadır. Aynı zamanda derin öğrenme modeller otomatik özellik çıkarımı potansiyeline sahiptir. Böylelikle derin öğrenme, tıp, finans, enerji ve mühendislik alanları başta olmak üzere birçok farklı alanda popüler hale gelmiştir.

Son yıllarda zaman serisi analizlerinde alternatif yöntemler tercih edilmeye başlanmıştır. Bu alternatiflerden biri olan derin öğrenme yaklaşımları, geleneksel zaman serisi yaklaşımındaki kısıtlamaları içermediğinden dolayı tercih edilme sıklığı giderek artmaktadır. Geleneksel zaman serisi yöntemlerinin aksine derin öğrenme yöntemleri katı varsayımlar gerektirmez ve zaman serisi verisindeki karmaşık yapıları ve uzun vadeli bağımlılıkları daha iyi bir şekilde modelleyebilir. [30] Bu avantajlar derin öğrenmeye olan ilgiyi arttırmış ve zaman serisi analizlerinde güçlü bir araç haline gelmiştir.

3.2 Derin Öğrenme Yöntemleri

3.2.1 Yapay Sinir Ağları (Artificial Neural Networks- ANN)

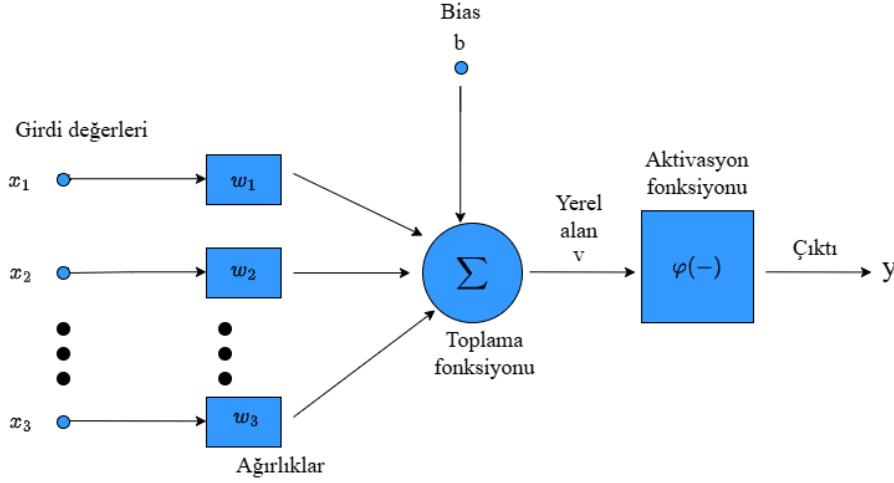
Yapay sinir ağları, insan beyninin özelliklerini taklit etmek amacıyla geliştirilmiş bir sinir ağıdır. Beynin öğrenme, hatırlama, üretme gibi yeteneklerinin matematiksel olarak modellenmesi ile ortaya çıkmıştır. İnsanın biyolojik sinir sistemine benzerliğinden dolayı yapay sinir ağları adını almıştır. İlk yapay sinir ağının modellenmesi McCulloch ve Pitts tarafından 1943 yılında gerçekleştirilmiştir. [31]

Yapay sinir ağlarındaki terimlerin adlandırılmalarının biyolojik sinir ağlarındaki karşılığı Tablo 3.1’de verilmiştir. [32]

Tablo 3.1 Yapay sinir ağı adlandırmalarının biyolojik sinir sistemi adlandırmaları ile karşılaştırılması

Yapay Sinir Ağı	Biyolojik Sinir Sistemi
İşleyici Eleman	Nöron
Ağırlık	Sinaps
Toplama Fonksiyonu	Dendrit
Transfer Fonksiyonu	Hücre Gövdesi
Çıktı	Akson

Yapay sinir ağları aralarında bağ kurarak sinir hücrelerinin birleşmesiyle oluşan yapılardır. Bir yapay sinir hücresi beş temel bileşenden oluşmaktadır. Yapay sinir hücresinin yapısı Şekil3.1’de verilmiştir.



Şekil 3.1 Yapay sinir hücresi yapısı [33]

Girdiler (x_i): Yapay sinir hücresine gelen bilgiler dış dünyadan ya da bir önceki katmandan gelebilir. Girdiler, belirli ağırlıklarla çarpılarak nöron çekirdeğine gönderilir.

Ağırlıklar (w_i): Girdilerin üretilecek çıktı üzerindeki etkilerini ayarlayabilmek adına ağırlıklar kullanılır. Pozitif, negatif veya sıfır değer alabilecek ağırlıklar sinir ağındaki bağlantıları temsil eden katsayılardır.

Toplama fonksiyonu (Σ): hücrenin net girdisini hesaplayan fonksiyondur.

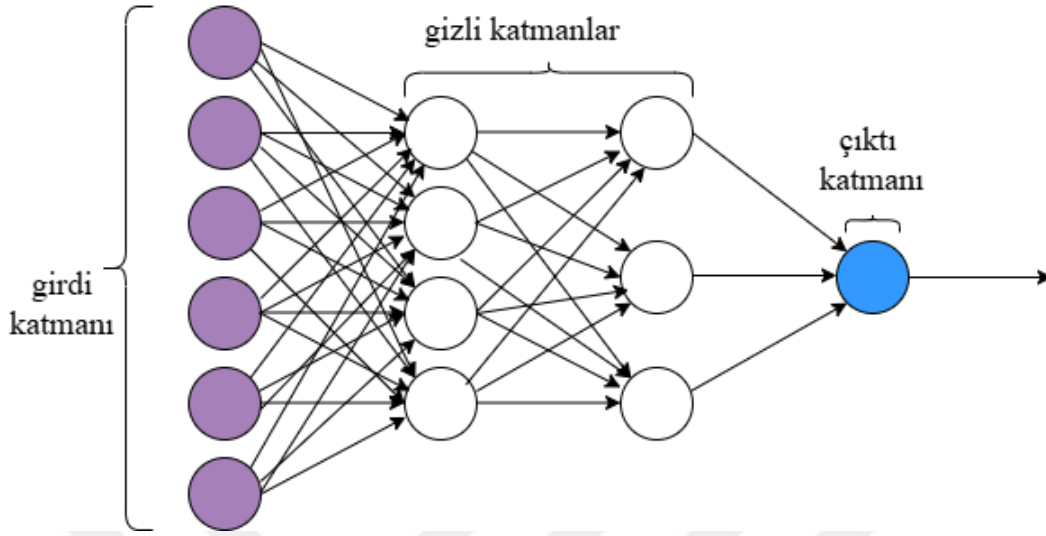
$$z = \sum_{i=1}^n w_i x_i + b \quad (3.1)$$

Aktivasyon fonksiyonu ($f(x)$): Hücreye gelen net girdi üzerinden üretilecek çıktıyı belirleyen fonksiyondur. Yaygın olarak kullanılan aktivasyon fonksiyonlarına sigmoid aktivasyon fonksiyonu, tanh (hiperbolik tanjant) aktivasyon fonksiyonu, ReLU (rectified linear unit) aktivasyon fonksiyonu örnek verilebilir. Yapay sinir ağlarının karmaşık yapılarından ötürü çoğunlukla doğrusal olmayan aktivasyon fonksiyonları tercih edilmektedir. [34]

Çıktı (y): Aktivasyon fonksiyonundan elde edilen değer hücrenin çıktısıdır.

Yapay sinir ağları üç ana katmandan oluşur. Bu katmanlar, giriş katmanı, gizli katman ve çıkış katmanıdır. Giriş katmanında girdi verileri herhangi bir işlem görmeden gizli katmana gönderilir. Gizli katman veri işlemlerinin yapıldığı katmandır. Birden fazla gizli katman olabilmektedir. Gizli katmanda verilerin

işlenmesinin ardından veriler çıktı katmanına gönderilir ve modelin tek bir çıktısı elde edilir.



Şekil 3.2 Yapay sinir ağı katmanları [35]

Yapay sinir ağları yapılarına göre ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olarak ikiye ayrılmaktadır. [36] İleri beslemeli yapay sinir ağlarında, bilgi işleme aşaması giriş katmanından çıkış katmanına doğru düzenli olarak ilerlemektedir. Bağlantılar sadece ileri katmanlara doğru olur. Geri beslemeli yapay sinir ağlarında ise ileri beslemeli ağlardan farklı olarak nöronun çıktısı sadece sonraki katmanlara değil ek olarak çıktılar aynı katmanda kalabilir ya da bir önceki katmana iletilebilir. Bu durum nöronlar arasındaki tüm bağlantıları denemeye olanak tanımaktadır.

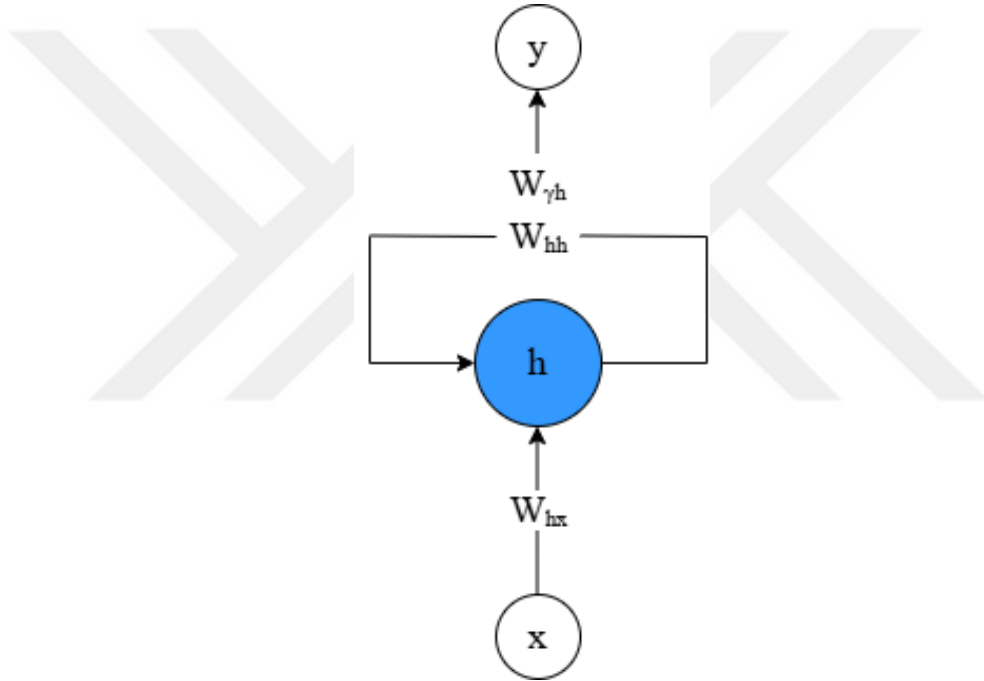
3.2.2 Yinelemeli Sinir Ağları (Recurrent Neural Networks- RNN)

Yinelemeli sinir ağları (RNN), sıralı veriler üzerinde etkili çözümler sunan ve katmanlar arasında ağırlık paylaşımı yapan bir sinir ağı modelidir. Bu model, hem anlık veriyi işleyebilirken hem de geçmiş bilgiler üzerinden analiz yapma yeteneğine sahiptir. [37] Yinelemeli sinir ağları önceki adımlardaki gizli durum çıktılarını kullanarak yeni girdilerle birleştirilmesine olanak tanımaktadır. Başka bir deyişle, RNN'ler modelin zaman içerisindeki bağlantılarını hafızada tutmakta ve işlemlerini sağlamaktadır. Bu sayede zaman serileri gibi sıralı veriler üzerinde etkili olan bir modeldir.


Klasik sinir ağlarında veriler arasında sıralama önemli değilken yinelemeli sinir ağlarında girdi akışı dikkate alınmaktadır. RNN modelinde, tahmin çıktısına ek

olarak hafıza çıktısı da oluşmaktadır ve her adımda hafıza çıktısı kullanılmaktadır. Böylece geçmişe ait bilgiler güncel bilgiler kullanılabilir. Bu durum, modelin yinelenen kısmını açıklamaktadır.

Temel bir RNN mimarisinde nöronun kendini tekrarlama döngüsü vardır ve bu sayede önceden gelen bilgiler kullanılmaktadır. Bu döngü gizli durumu ifade etmektedir ve h_t ile gösterilmektedir. Şekil 3.3'te RNN mimarisinin açılmamış ve Şekil 3.4'te açılmış yapısını göstermektedir. [38] Yinelemeli sinir ağlarında gizli durumlar aracılığıyla önceki bilgilerin nasıl hatırlandığını göstermektedir. Gizli durum her adımda güncellenerek önceki girdilerden öğrenilen bilgileri taşımaktadır.



Şekil 3.3 RNN mimarisinin açılmamış yapısı



Şekil 3.4 RNN mimarisin açılmış yapısı

RNN modeli x_t girdisi, y_t çıktısı ve h_t gizli durumundan oluşmaktadır. Çıktı (y_t) gizli durumdan gelen bilgiye göre hesaplanmaktadır. RNN modelinin matematiksel gösterimi eşitlik(3.2) ve (3.3)'te verilmiştir. [39]

$$h_t = \tanh(W_h h_{t-1} + W_x x_t) \quad (3.2)$$

$$y_t = W_y h_t \quad (3.3)$$

Bu eşitliklerde,

W_h, W_x, W_y : ağırlık matrisleri

h_t : gizli durum

x_t : girdi vektörü

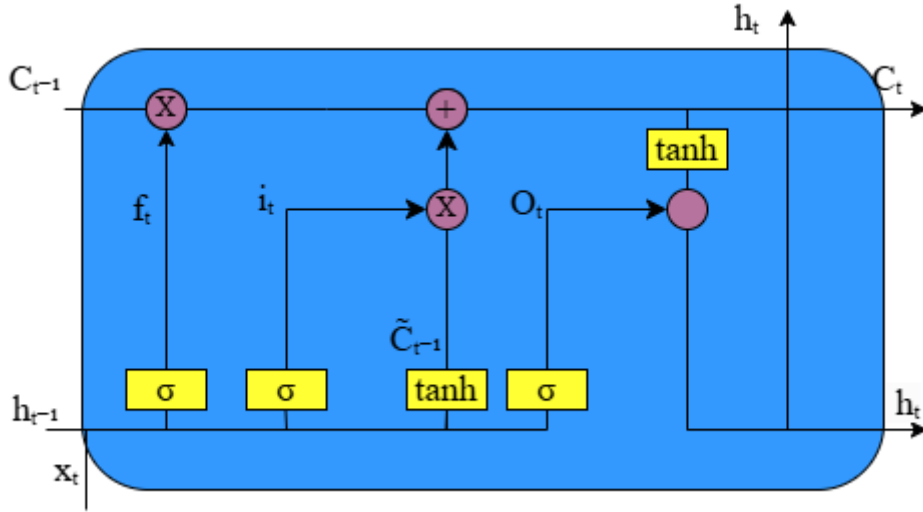
y_t : çıktı vektörü

h_{t-1} : önceki gizli durum terimlerini ifade etmektedir.

3.2.3 Uzun Kısa Vadeli Bellek (Long Short-Term Memory - LSTM)

Uzun Kısa Vadeli Bellek (Long Short-Term Memory - LSTM) ağları, sıralı veriler üzerinde çalışırken kaybolan ve patlayan gradyan sorununu çözmek için geliştirilmiş bir tür tekrarlayan sinir ağıdır. LSTM tekrarlayan sinir ağlarının (Recurrent Neural Network - RNN) özel bir türü olup, kısa süreli bağımlılıklara ek olarak uzun süreli bağımlılıkları da etkin bir şekilde tahmin etmek için tasarlanmıştır. Özellikle zaman serisi tahminlerinde önemli bir bakış açısı sunmaktadır.

Klasik tekrarlayan sinir ağlarından farklı olarak LSTM modeli, bilgi akışını etkin bir şekilde yönetebilmesi için girdi, unutmaya ve çıktı kapılarından oluşan üçlü bir mekanizmaya sahiptir. Girdi kapısı giriş verilerinden hangi bilgilerin bellek durumunu güncellemek için kullanılacağına karar verir. Unutmaya kapısı hangi bilgilerin bellekte kalacağına ve hangi bilgilerin bellekten atılacağına karar verir. Çıkış kapısı ise neyin çıktı alınacağına karar vermektedir. Bu kapılar, sinir hücresine bilgi ekleme ve çıkarma işlemleriyle bilgi akışını sağlayan ağırlıklı fonksiyonlardır. [40] Aynı zamanda LSTM'in uzun süreli bağımlılıkları yakalamasına ve kaybolan gradyan (vanishing gradient) riskini azaltmaya olanak tanımaktadır. Tüm bu özellikler LSTM modelinin zaman serisi verilerinin işlenmesini uygun hale getirmektedir.



Şekil 3.5 LSTM mimari yapısı [41]

Şekil 3.5'te yer verilen LSTM algoritma şeması f_t (unutma), i_t (giriş) ve o_t (çıkış) kapılarından oluşmaktadır. [42]

LSTM'in iç dinamiklerini açıklayan matematiksel gösterimler için oluşturulan denklemler şunlardır;

Unutmaya kapısı:

$$f_t = \sigma(W_{f,x} \times X_t + W_{f,h} \times h_{t-1} + b_f) \quad (3.4)$$

f_t unutmaya kapısının çıktısını ifade eder ve aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılır.

Giriş kapısı:

$$i_t = \sigma(W_{i,x} \times X_t + W_{i,h} \times h_{t-1} + b_i) \quad (3.5)$$

Eşitlik (3.6) ile yeni bilgiyi oluşturma işlemi tanh fonksiyonu aracılığıyla belirlenir. Burada \tilde{C}_t , mevcut zaman adımındaki aday hücre durumu olarak adlandırılır. Sonrasında eşitlik (3.7) ile yeni hücre durumu hesaplanır.

$$\tilde{C}_t = \tanh(W_{c,x} \times X_t + W_{c,h} \times h_{t-1} + b_c) \quad (3.6)$$

$$C_t = C_{t-1} \times f_t + i_t \times \tilde{C}_t \quad (3.7)$$

Çıkış kapısı:

$$o_t = \sigma(W_{o,x} \times X_t + W_{o,h} \times h_{t-1} + b_o) \quad (3.8)$$

$$h_t = o_t \times \tanh(C_t) \quad (3.9)$$

Eşitlik (3.8) ve eşitlik (3.9) kullanılarak çıktı değerleri elde edilir. [10]

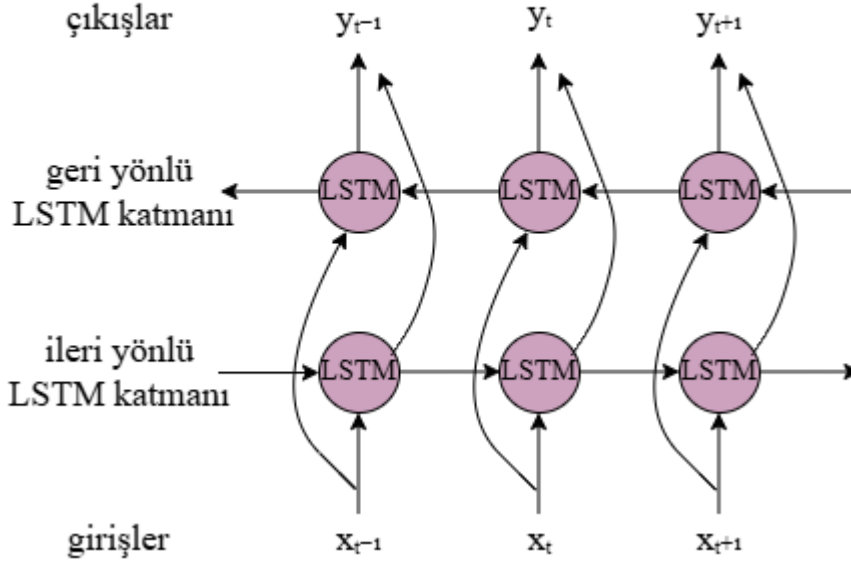
Yukarıdaki açıklanan süreç tekrarlanarak devam eder. Ağırlık parametreleri W ve bias parametreleri b LSTM çıktıları ile gerçek eğitim verileri arasındaki hatayı minimize edecek şekilde model tarafından öğrenilmektedir.

3.2.4 Çift Yönlü Uzun Kısa Vadeli Bellek (Bidirectional Long Short-Term Memory - BiLSTM)

Çift Yönlü Uzun Kısa Vadeli Bellek (Bidirectional Long Short-Term Memory - BiLSTM), LSTM modelinin geliştirilmiş bir versiyonudur. Temel farkı, veriyi hem ileri hem de geri yönde işleyebilmesidir. [43] Bu çift yönlü işleme, özellikle zaman serisi tahmini, duygu analizi gibi bağlam bilgisinin önemli olduğu anlarda modelin doğruluğunu artırarak daha güçlü tahminler yapılmasını sağlamaktadır.

BiLSTM, zaman serisi verilerini işlerken hem geçmişten geleceğe hem de gelecekte geçmişe giden bilgiyi dikkate alır. [44] Modelde bir ileri yönde çalışan, bir de geri yönde çalışan iki ayrı LSTM ağı bulunmaktadır. İleri yönlü LSTM, girdi verisini geçmişten geleceğe doğru işlerken; geri yönlü LSTM, girdi verisini gelecekte geçmişe doğru işlemektedir. Bu iki LSTM katmanı paralel olarak çalışır ve her bir zaman adımına karşılık gelen iki farklı gizli durum üretir. Bu gizli durumlar birleştirilerek her bir zaman adımı için hem geçmişten hem de gelecekte gelen bağlam bilgisi modele entegre edilmiş olur.

Sonuç olarak, BiLSTM, LSTM'in güçlü yönlerini daha da geliştirerek modelin derin ilişkiler öğrenmesini sağlar ve hem geçmiş hem de gelecek bilgilerini aynı anda kullanabilmesini sağlamaktadır.



Şekil 3.6 BiLSTM mimari yapısı [45]

$$\vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \quad (3.10)$$

$$\tilde{h}_t = LSTM(x_t, \tilde{h}_{t+1}) \quad (3.11)$$

$$y_t = W_{\vec{h}_y} \vec{h}_t + W_{\tilde{h}_y} \tilde{h}_t + b_y \quad (3.12)$$

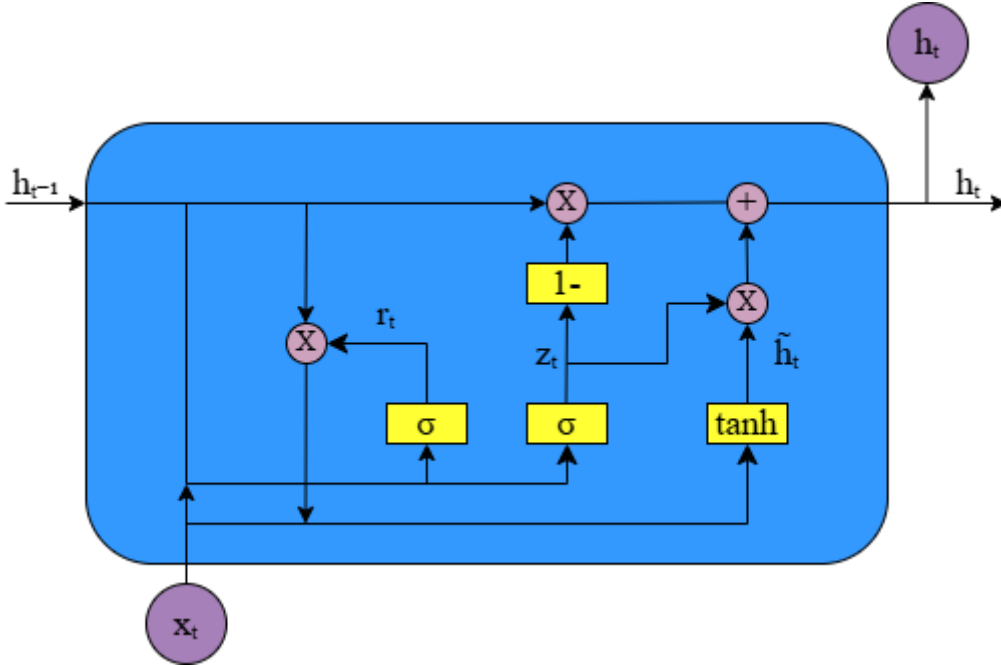
LSTM (\cdot) gösterimi, eşitlik 3.4–3.9'da tanımlanan LSTM işlemlerini ifade etmektedir. Bu gösterimde, $W_{\vec{h}_y}$ ileri yönlü LSTM ağırlığını, $W_{\tilde{h}_y}$ geri yönlü LSTM ağırlığını, b_y çıktı katmanındaki bias değerini, \vec{h}_t ve \tilde{h}_t gizli durumları, y_t ise modelin çıktısını temsil etmektedir. [46]

Bu eşitlikler, BiLSTM modelinde ileri ve geri yönde hesaplanan gizli durumların birleştirilerek, çıktı katmanında ağırlıklar ve bias değeri ile birlikte kullanıldığını göstermektedir.

3.2.5 Geçitli Tekrarlayan Birim (Gated Recurrent Unit - GRU)

Tekrarlayan sinir ağlarının bir varyasyonu olan Geçitli Tekrarlayan Birim (Gated Recurrent Unit- GRU) Cho ve arkadaşları tarafından 2014 yılında geliştirilmiştir.

[47] GRU uzun dönem bağımlılık sorunlarını çözmek için tasarlanmış olup LSTM modeline bir alternatif olmuştur. LSTM hücresine benzer bir yapıya sahip olmasına rağmen GRU modeli daha basit bir mimari sunarak parametre sayısını azaltır ve böylelikle eğitim sürecini hızlandırmış olur.



Şekil 3.7 GRU mimari yapısı [48]

Geçitli tekrarlayan birim iki temel kapıya sahiptir:

Güncelleme kapısı: Hangi bilgilerin hafıza tutulacağını ve mevcut duruma hangi yeni bilgilerin ekleneceğini belirler. Çıkış sigmoid aktivasyon fonksiyonu ile hesaplanır ve 0-1 aralığında değer alır. 1'e yakın değerler bilginin güncellenmesi gerektiğini, 0'a yakın değerler mevcut durumun korunacağını söylemektedir.

Sıfırlama kapısı: Eski bilgilerin ne kadarının unutulması gerektiğini belirler. Daha az önemli olan geçmiş bilgileri sıfırlayarak gereksiz verilerin sıfırlanmasını sağlar. Çıkış, yine sigmoid aktivasyon fonksiyonu ile hesaplanır. 1'e yakın değerler belleğin sıfırlanmasını ifade ederken, 0'a yakın değerler eski belleğin korunacağını ifade eder. [49]

GRU ağının mimari yapısına ait denklemler şu şekilde ifade edilir; [50]

Güncelleme Kapısı:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (3.13)$$

Sıfırlama Kapısı:

$$r_t = \sigma(W_r X_t + U_r h_{t-1} + b_r) \quad (3.14)$$

Aday Gizli Durum:

$$\hat{h}_t = \tanh(W_h X_t + (r_t \odot h_{t-1})) U_h + b_h \quad (3.15)$$

Gizli Durum:

$$h_t = (1 - Z_t) \odot h_{t-1} + Z_t \odot \hat{h}_t \quad (3.16)$$

Burada W_z , W_r ve W_h ağırlık matrislerini, σ sigmoid aktivasyon fonksiyonu, \tanh ise hiperbolik tanjant aktivasyon fonksiyonunu ifade etmektedir.

3.2.6 Önerilen Hibrit Model (GRU-BiLSTM)

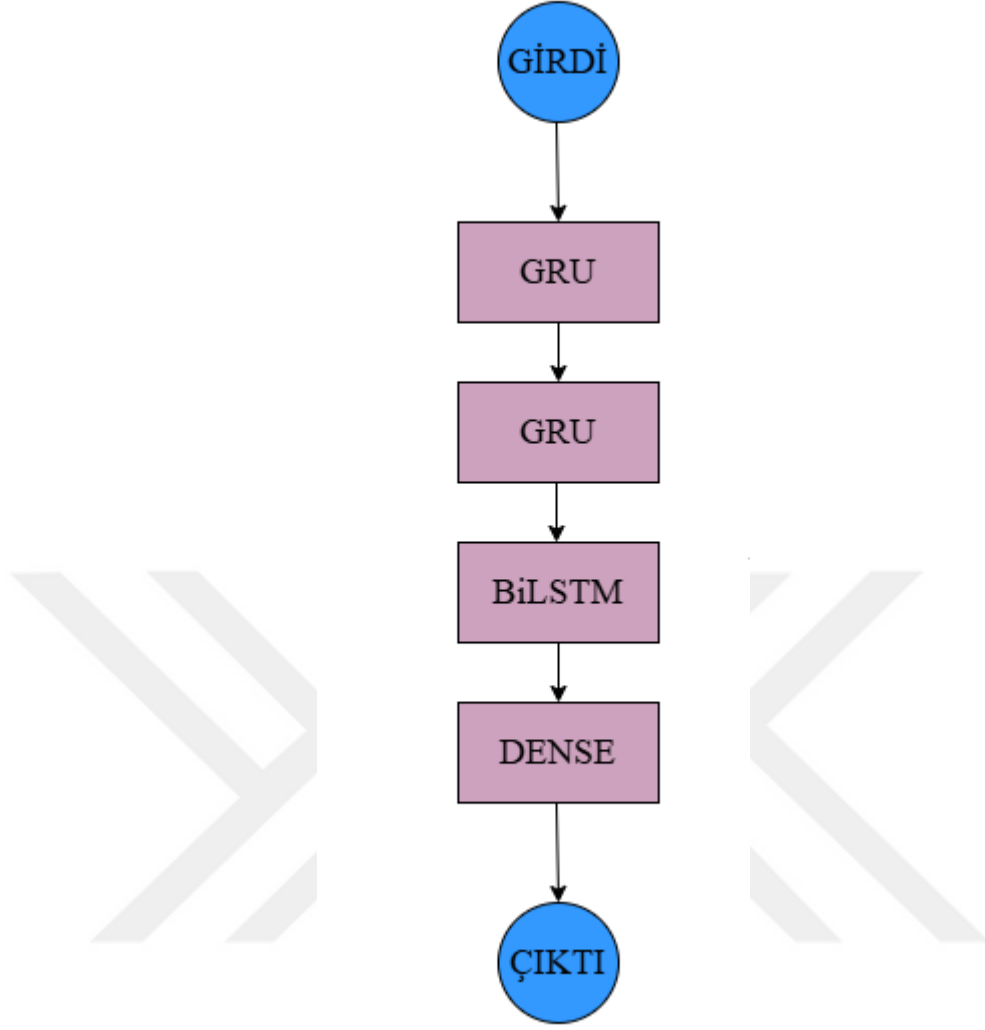
Türkiye'deki elektrik tüketim tahminine yeni bir bakış açısı kazandırmak amacıyla hibrit bir derin öğrenme modeli önerilmiştir. Önerilen hibrit model, zaman serileri üzerinde güçlü sonuçlar elde eden GRU ve BiLSTM modellerinin birleşiminden oluşmaktadır. Her iki mimari de karmaşık yapıları zaman serisi verileri üzerinde etkili olup, tahmin başarıları yüksektir.

Önerilen hibrit modelde öncelikle GRU modeline yer verilmiştir. GRU modeli, basit bir yapıya sahip olması ve hızlı çalışmasından dolayı öncelik kazanmıştır. Aynı zamanda BiLSTM modeline göre daha az parametre sayısı içerdiği için öğrenme sürecini hızlandırır. Böylelikle GRU model yapısı, kısa vadeli örüntüleri etkili bir şekilde yakalayıp gelecek katmana hazır hale getirir.

GRU katmanından elde edilen çıktılar sonrasında BiLSTM katmanına iletilir. BiLSTM katmanı, veriyi hem ileri hem de geri yönlü işlemesinden dolayı daha karmaşık bir yapıdır. Bu nedenle, önceden öğrenilmiş bilgiler üzerinden çalışması avantaj sağlar. BiLSTM katmanının çift yönlü öğrenmesi ise geçmiş ve gelecek zaman adımlarındaki bilgiyi dikkate alarak çalışmaktadır.

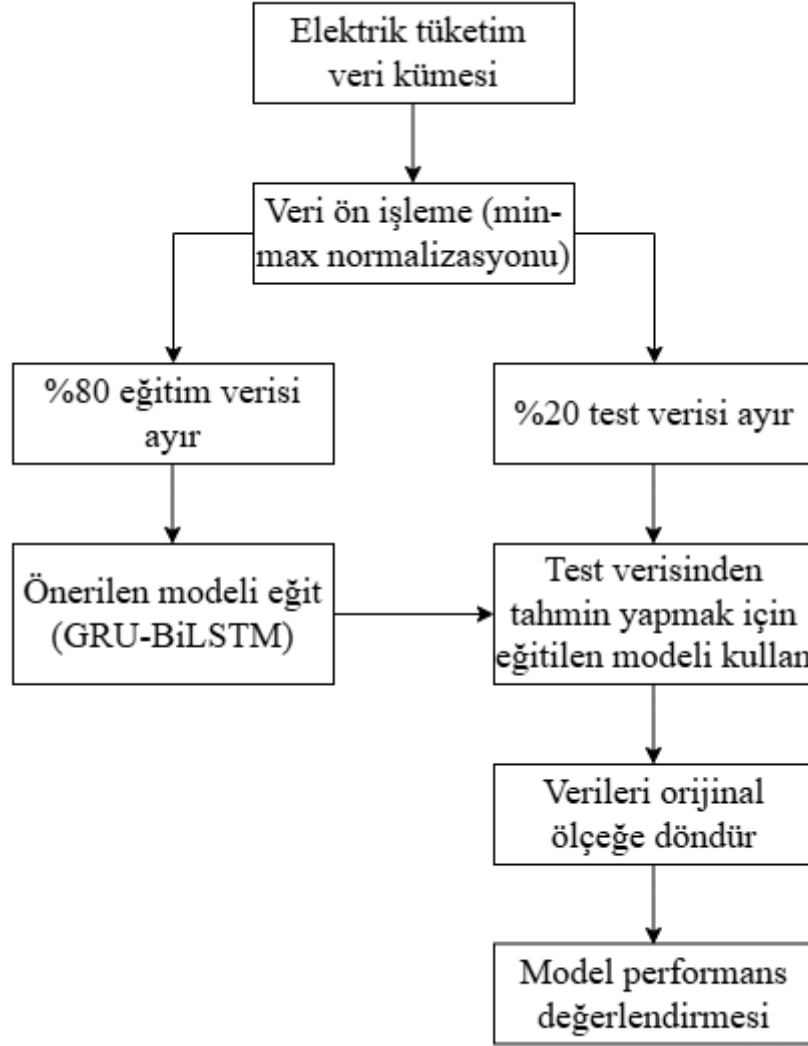
GRU-BiLSTM hibrit modelinin yapısı Şekil 3.8'de verilmiştir. Bu model, iki GRU ve bir BiLSTM katmanından oluşmaktadır. BiLSTM katmanının ardından, modelin nihai sonuçlarını elde etmek adına dense katmanı ile birlikte çıkış katmanına iletilir. Çıkış katmanı, modelin elektrik tüketim tahminlerini üretmektedir.

Önerilen hibrit model, daha önce tarımsal verimlilik ve deprem büyüklüğü tahmini gibi farklı alanlarda kullanılmış olmasına rağmen, elektrik tüketim tahmini özelinde uygulanmamış bir yaklaşımdır. [51] [52]



Şekil 3.8 Önerilen hibrit modelin yapısı

Önerilen hibrit modelin tez çalışmasında nasıl uygulanacağı ve hangi adımlardan geçeceği Şekil 3.9'da verilmiştir.



Şekil 3.9 Önerilen modelin uygulama adımları

3.3 Model Performans Değerlendirme Metrikleri

Elektrik tüketim tahmini çalışmalarında kullanılan hibrit derin modellerin performans değerlendirme için çeşitli istatistiksel metrikler mevcuttur. Literatürde, tüketim tahmin modellerinin karşılaştırmalı performansı için genellikle RMSE(Root Mean Square Error), MAPE(Mean Absolute Percentage Error), MAE (Mean Absolute Error) ve R^2 (Determinasyon Katsayısı) gibi kriterler tercih edilmiştir. [23] Bu tez çalışmasında da benzer bir yaklaşım benimsenerek burada bahsedilen metrikler ile karşılaştırma yapılmıştır.

3.3.1 RMSE(Root Mean Square Error)

Ortalama karekök hata (RMSE), tahmin edilen değerlerin gerçek değerlerden ne kadar saptığını ölçen bir performans metriğidir. Model performans değerlendirilmesinde öklid mesafesi kullanılarak sapma belirlenir. [53] Tahmin değerleri ile gerçek değerler arasındaki hata kareler ortalaması alınır ve ardından karekökü alınması işlemidir. RMSE tahmin doğruluğunu ölçer ve RMSE değerinin düşük olması modelin daha iyi performans gösterdiği anlamına gelmektedir.

Matematiksel gösterim; [54]

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.17)$$

y_i : gerçek değer

\hat{y}_i : model tarafından tahmin edilen değer

n : toplam veri sayısı

3.3.2 MAPE(Mean Absolute Percentage Error)

Ortalama mutlak yüzde hata (MAPE), tahmin edilen değerlerin gerçek değerlerden yüzde kaç sapma gösterdiğini ölçen bir performans metriğidir. Modelin tahmin performansı yüzde cinsinden ifade edildiği için hatanın yorumu farklı modelleri karşılaştırmak için uygundur. [55] MAPE değerinin düşük olması, model tahmin sonuçlarının gerçek değerlere yakın olduğunu ifade etmektedir.

Matematiksel gösterim;

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (3.18)$$

y_i : gerçek değer

\hat{y}_i : model tarafından tahmin edilen değer

n : toplam veri sayısı

3.3.3 R^2 (Coefficient of Determination)

Belirleme katsayısı (R^2), bir bağımlı değişkendeki değişimin, bağımsız değişken(ler) yardımıyla ne kadar açıklandığını ölçen bir performans metriğidir. Tahmin doğruluğunu ölçmek için kullanılan R^2 0-1 arasında değer alır. [48] R^2 değeri 1'e yaklaştıkça modelin başarısı artmaktadır.

Matematiksel gösterim; [56]

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (3.19)$$

y_i : gerçek değer

\hat{y}_i : model tarafından tahmin edilen değer

\bar{y} : gerçek değerlerin ortalaması

SS_{res} : $\sum(y_i - \hat{y}_i)^2$: Residual sum of squares

SS_{tot} : $\sum(y_i - \bar{y})^2$: Total sum of squares

3.3.4 MAE (Mean Absolute Error)

Ortalama mutlak hata (MAE), regresyon modellerinin performans değerlendirmelerinde sıklıkla kullanılan bir metriktir. MAE, bir modelin tahmin doğruluğunu değerlendirerek tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını hesaplayan istatistiksel bir ölçümdür. [57] MAE değerinin 0'a yakın olması istenen bir durumdur.

Matematiksel gösterim;

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.20)$$

N : Toplam gözlem sayısı

\hat{y}_i : Model tarafından tahmin edilen değer

y_i : Gerçek değer

4.1 Veri

Tez çalışmasında, Türkiye'deki elektrik tüketim verilerini içeren bir zaman serisi veri kümesi materyal olarak kullanılmıştır. Veri kümesi, Enerji Piyasaları İşletme A.Ş. (EPIAŞ) şeffaflık platformu üzerinden temin edilmiş olup, EPIAŞ'ın veri kaynağı Türkiye Elektrik İletim A.Ş. (TEİAŞ) olarak belirtilmiştir. [58] Çalışmada, 01.01.2020 ile 31.12.2024 tarihleri arasındaki Türkiye'nin gerçek zamanlı saatlik elektrik tüketim verileri kullanılmıştır.


Orijinal veri kümesi, saatlik elektrik tüketim verilerinden oluşan 43848 gözlem içermektedir. Bu çalışmada, analizlerin günlük bazda yapılabilmesi için saatlik elektrik tüketim verilerinin günlük ortalamaları alınarak veri kümesi günlük formata dönüştürülmüştür. Böylece, veri kümesi günlük elektrik tüketimini temsil edecek şekilde düzenlenmiş ve mevcut gözlem sayısı 1827 olmuştur.

Tablo 4.1 Veri Kümesinin Karakteristikleri

Özellik	Değer
Toplam gözlem sayısı	1827
Başlangıç tarihi	01.01.2020
Bitiş tarihi	31.12.2024
Ortalama tüketim (MWh)	36686.543272
Minimum tüketim (MWh)	19053.005417
Maksimum tüketim (MWh)	50149.461667

Bu çalışmada kullanılan elektrik tüketim verisinin genel özellikleri Tablo4.1de sunulmaktadır.

Şekil 4.1’de orijinal veri aracılığıyla saatlik elektrik tüketim değeri görselleştirilmiştir. Bu grafik, elektrik tüketiminin zaman içerisindeki değişimlerini ortaya koymaktadır. Belli dönemlerde artış ve azalışlar gözlenmektedir.




Şekil 4. 1 Saatlik elektrik tüketim verisi

Veri kümesinin dönüştürülmüş halinden sonra günlük elektrik tüketiminin görselleştirilmesi şekil 4.2’de sunulmaktadır. Grafik tüketim değerlerinin zaman içindeki değişimini ve genel eğilimleri açıkça ortaya koymaktadır.

Veri kümesindeki tüketim miktarlarına ait karakteristikleri daha iyi açıklayabilmek adına Şekil4.3 ile Şekil4.6 arasındaki grafiklerle görselleştirilmiştir. Bu grafikler, günlere, aylara ve yıllara göre tüketim miktarlarındaki değişiklikleri göstermektedir. Böylelikle belirli dönemlerde meydana gelen değişimler daha iyi bir şekilde açıklanmaktadır.

Her bir kutu grafiği veri dağılımını iyi bir şekilde açıklayabilmek için medyan, çeyreklikler ve aralık hakkında bilgi vermektedir. Ayrıca grafiklerde tüketim miktarlarındaki en düşük ve en büyük değerler gözlemlenebilmektedir.


Şekil 4.4’te aylık elektrik tüketim grafiğinde yaz aylarındaki tüketim miktarlarının daha fazla olduğu görülmektedir.



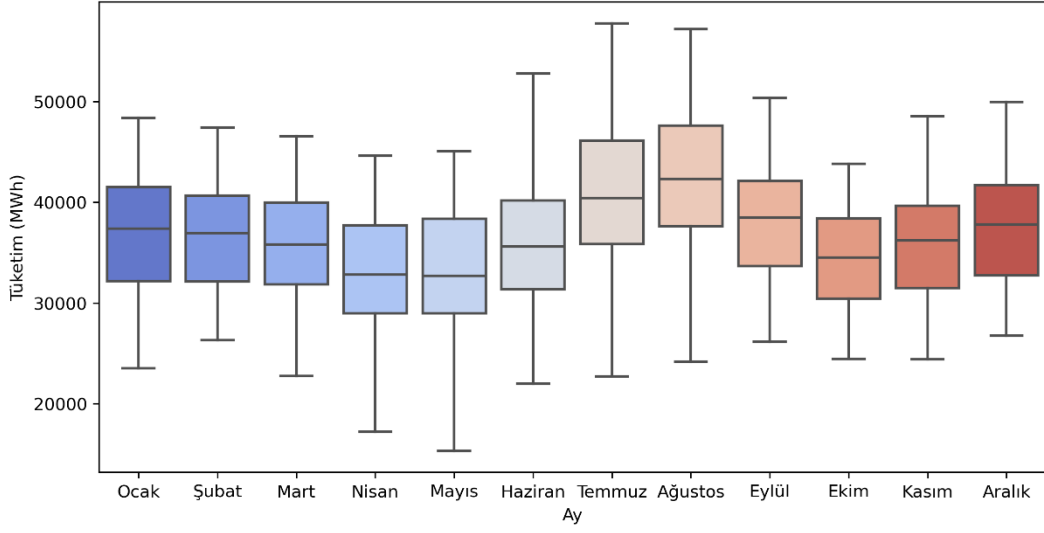
Şekil 4.2 Günlük elektrik tüketim verisi

Şekil 4.5'te günlük elektrik tüketim grafiğine bakıldığında ise hafta içi günlerde elektrik tüketimi daha yüksekken hafta sonları elektrik tüketiminde düşüş gözlenmektedir.

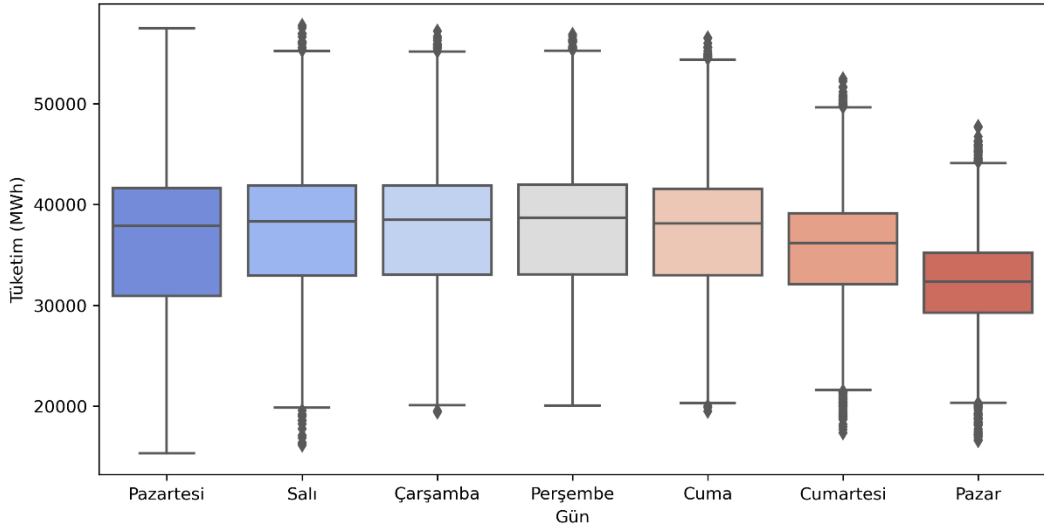
Şekil 4.6'da saatlik elektrik tüketim grafiğinde gün içerisinde saatler arasındaki değişimleri göstermek için görselleştirilmiştir. Günün gece saatlerinde elektrik tüketimi düşüken gündüz saatlerinde bir artış eğilimi göstermektedir.




Şekil 4.3 Yıllık elektrik tüketim dağılımı



Şekil 4.4 Aylık elektrik tüketim dağılımı




Şekil 4.5 Günlük elektrik tüketim dağılımı



Şekil 4.6 Saatlik elektrik tüketim dağılımı

4.2 Veri Ön İşleme

Veri kümesini modelleme sürecine hazır hale getirmek için belirli ön işleme adımlarının uygulanması gerekmektedir. Verilerin daha iyi işlenebilmesi ve etkili sonuçlar almak amacıyla Min-Manormalizasyon tekniği uygulanmıştır. Bu teknik ile veriler 0-1 aralığında ölçeklendirilmiş ve her bir değişkenin önem seviyesi eşitlenmiştir. Ölçeklendirme işlemi sayesinde modelin hızlı ve etkili bir şekilde öğrenmesi sağlanarak modelin genelleme yapabilmesine olanak tanınmıştır. Veri kümesine Min-Max normalizasyon tekniği uygulandıktan sonra güncel veri kümesi grafiği Şekil4.7’de verilmiştir.




Şekil 4.7 Ölçeklendirilmiş veri kümesi

Normalizasyon işleminin ardından, modelin eğitimi ve değerlendirme süreçlerinde kullanılmak üzere veri kümesi belirli oranlarda ikiye ayrılmıştır. Modelin öğrenme ve genelleme yeteneği için bu bölme işlemi gerekli bir adımdır. Veri kümesi %80 eğitim ve %20 test verisi olarak ikiye ayrılmıştır. Bu bölme işleminin ardından elektrik tüketim verisinin 2020-2024 yılları arası eğitim verisi olurken 2024-2025 arası test verisi olarak kaydedilmiştir.

Eğitim kümesi modelin çeşitli parametreleri öğrenmesi sürecinde kullanılır. Bu küme, modelin girdi ve çıktı arasındaki ilişkiyi öğrenmesini sağlamaktadır. Eğitim kümesi kullanılarak bulunan tahmin değerleri ile gerçek değerler arasındaki farklar minimize edilmeye çalışılır. Sonuç olarak eğitim kümesi, modelin genelleme yeteneğini geliştirerek modelin doğru tahminler yapabilmesi için uygun bir ortam oluşturmaktadır.

Öte yandan, test kümesi ise modelin performansının değerlendirilmesi amacıyla kullanılmaktadır. Eğitim sürecinin tamamlanmasının ardından, test verisi ile modelin daha önce görmediği veriler kullanılarak modelin başarısını değerlendirmek için önemli bir adım atılmaktadır. Burada test verisi, daha önce eğitilmediğinden dolayı bilinmeyen veriler üzerindeki tahmin başarısı ölçülmüş olur. Bu süreç, modelin genelleme yeteneğini test eder ve sadece eğitim verisi kullanılarak ortaya çıkacak aşırı uyuma engel olarak gerçek veriler üzerindeki

tahmin başarısını test etmektedir. Şekil 4.8’de veri kümesinin eğitim ve test ayrımı görsellendirilmiştir.



Şekil 4.8 Eğitim- test ayrımı

4.3 Modeller

Veri ön işleme adımlarının tamamlanmasının ardından, veri modelleme sürecine hazır hale gelmiştir. Çalışmada, elektrik tüketim tahminleri için farklı derin öğrenme modelleri ile önerilen hibrit model kullanılmış olup modellerin performans değerlendirmesi yapılmıştır.

Önerilen hibrit (GRU-BiLSTM) model, 3 katmandan oluşmaktadır. Her bir katman 128 nöron sayısına sahiptir. Hibrit modelinin ilk iki katmanı GRU modelinden oluşurken son katman ise BiLSTM’den oluşmaktadır. Farklı katman sayıları da denenmiş olup optimum sonuçları veren hibrit model GRU-GRU-BiLSTM şeklinde oluşturulmuştur. Bu katman yapısı, zaman serisi verisindeki karmaşık yapıyı öğrenebilmesi için gerekli kapasiteyi sağlamak için geliştirilmiştir. Her bir katmandan sonra dropout uygulanarak modelin aşırı öğrenmeye gidilmesi engellenmesi sağlanmıştır ve dropout kısmında nöron sayısı bulunmamaktadır. Modeldeki parametre sayılarının fazla olması ezberleme yeteneğini artırır. O yüzden her bir katmandan sonra dropout eklenmiş ve modelin genelleme yeteneği artırılmıştır. Tablo 4.2’de modelin hibrit yapısı detaylı bir şekilde açıklanmıştır.

Tablo 4.2 Önerilen Hibrit Modelin Yapısı

Sıra	Katman Türü	Nöron Sayısı	Parametre Sayısı
1	GRU	128	50304
2	Dropout	-	0
3	GRU	128	99072
4	Dropout	-	0
5	BiLSTM	128	263168
6	Dropout	-	0
7	Çıkış(Dense)	1	257

Hibrit modelin performansını karşılaştırmak için seçilen diğer modellerin ayrıntılı yapıları da Tablo 4.3 ile 4.6 arasında gösterilmiştir. Bu tablolar, her bir modelin katman yapılarını, nöron sayılarını ve parametre sayılarını açıklamaktadır. GRU, LSTM, BiLSTM ve ANN modelleri de hibrit modelde olduğu gibi 3 katmandan oluşacak şekilde modellenmiş ve her bir katman 128 nöron sayısından oluşmaktadır.

Çalışmada, GRU-BiLSTM modelinin performansını değerlendirmek amacıyla ANN, LSTM, BiLSTM ve GRU gibi farklı derin öğrenme modelleri ile karşılaştırmalar yapılmıştır. Bu derin öğrenme modellerinin performansları incelenirken, yalnızca kullanılan ağı yapısına odaklanılmak istendiği için tüm hiperparametreler sabit tutulmuştur.

Tablo 4.3 GRU modelinin yapısı

Sıra	Katman Türü	Nöron Sayısı	Parametre Sayısı
1	GRU	128	50304
2	Dropout	-	0
3	GRU	128	99072
4	Dropout	-	0
5	GRU	128	99072
6	Dropout	-	0
7	Çıkış(Dense)	1	129

Tablo 4.4 BiLSTM modelinin yapısı

Sıra	Katman Türü	Nöron Sayısı	Parametre Sayısı
1	BiLSTM	128	133120
2	Dropout	-	0
3	BiLSTM	128	394240
4	Dropout	-	0
5	BiLSTM	128	394240
6	Dropout	-	0
7	Çıkış(Dense)	1	257

Tablo 4.5 LSTM modelinin yapısı

Sıra	Katman Türü	Nöron Sayısı	Parametre Sayısı
1	LSTM	128	66560
2	Dropout	-	0
3	LSTM	128	131584
4	Dropout	-	0
5	LSTM	128	131584
6	Dropout	-	0
7	Çıkış(Dense)	1	129

Tablo 4.6 ANN modelinin Yapısı

Sıra	Katman Türü	Nöron Sayısı	Parametre Sayısı
1	Dense	128	1024
2	Dropout	-	0
3	Dense	128	16512
4	Dropout	-	0
5	Dense	128	16512
6	Dropout	-	0
7	Çıkış(Dense)	1	129

Tüm modellerde katman sayısı 3 tercih edilmiştir. Optimizasyon algoritması olarak Adam optimizatörü tercih edilmiştir. Adam optimizatörü, zaman serisi verilerinde dalgalanmalara karşı başarı sağlamakla birlikte karmaşık verilerde de verimli sonuçlar elde etmektedir.

Yığın boyutunda ise modelin eğitimi gerçekleşirken veri işleme düzeni bozulmaması adına sabit tutulmuştur. Batch size küçük tutulduğu takdirde güncellemeler gürültü içerir ve eğitim kararsız hale gelebilirken büyük boyutlarda olduğunda ise modelin genelleştirme yeteneği düşmektedir. Bu yüzden optimum sonuçlar elde etmek adına 32 olarak tercih edilmiştir.

Tüm bu parametreler model performansı bakımından başarılı sonuçlar elde etmek için literatür baz alınarak ve çeşitli denemeler yapılarak belirlenmiştir. Buradaki amaç, elektrik tüketim verisinin en iyi şekilde öğrenmesini sağlamakla birlikte mümkün olan en yüksek doğruluk ve en düşük hata oranlarını elde etmektir. Karmaşık yapılar oluşturmaktan kaçınarak uygun katman sayısı, optimizasyon yöntemi ve yığın boyutu için farklı denemeler yapılmış olup optimum sonuçların elde edildiği hiperparametreler tercih edilmiştir.

Oluşturulan modellerin eğitilmesinin ardından, test verisi üzerinden tahmin yapılması beklenmektedir. Ancak veri ön işleme adımlarında ilk önce veri 0-1 aralığında ölçeklendirilmiştir. Modelin eğitimi de normalleştirilmiş verilerle gerçekleştiği için elde edilen sonuçlar da 0-1 aralığında olacaktır. O yüzden bu adımda ters dönüşüm uygulanarak tahmin sonuçları ve gerçek test verileri orijinal ölçeğe dönüştürülür. Yani burada, eğitimde kullanılan ölçeklendirme işlemi geri alınmış olur. Tüm bu işlemlerin tamamlanmasıyla birlikte model performans değerlendirmeleri yapılır.

Klasik derin öğrenme modellerini ve önerilen hibrit modelin yapısal özelliklerini açıklamak adına katman sayılarını, kullanılan optimizasyon algoritmasını ve yığın boyut bilgileri Tablo 4.7'de özetlenmiştir.

Tablo 4.7 Tüm modeller için katman, optimizatör ve yığın boyutu bilgisi

Model	Katmanlar	Optimizatör	Yığın Boyutu
ANN	3	Adam	32
LSTM	3	Adam	32
BiLSTM	3	Adam	32
GRU	3	Adam	32
GRU-BiLSTM	2(GRU)+1(BiLSTM)	Adam	32

4.4 Bulgular

Modelleme çalışmaları, Türkiye'nin 2020-2024 yıllarına ait elektrik verileri kullanılarak yürütülmüş ve bu doğrultuda 2024-2025 dönemine yönelik elektrik tüketim tahminleri yapılmıştır. Tüm bu uygulamalar, Python Notebook programı üzerinden gerçekleştirilmiştir. Veriler ölçeklendirme, eğitim- test ayrımı gibi adımlardan geçtikten sonra modeller uygulanmıştır. Çalışmada, ANN, LSTM, BiLSTM ve GRU gibi farklı derin öğrenme modelleri klasik yöntemler olarak ele alınmış ve geliştirilen hibrit derin öğrenme modeli ile karşılaştırılarak model performans değerlendirilmesi incelenmiştir. Değerlendirme yapılırken, RMSE, R^2 , MAE ve MAPE metrikleri kullanılmıştır.

Çalışma sonucunda model performanslarını detaylı bir şekilde incelemek için sonuçlar Tablo4.8'de verilmiştir.


Her bir model için RMSE, R^2 , MAE ve MAPE metrikleri kullanılarak model performans sonuçları karşılaştırılmıştır. Değerlendirme sonuçları incelendiğinde bireysel derin öğrenme modelleri (ANN, LSTM, BiLSTM, GRU) tüm metrikler için benzer sonuçlar elde ederken oluşturduğumuz GRU-BiLSTM modeli diğer modellerin performans sonuçlarına kıyasla daha belirgin bir fark elde etmiştir.

Tablo 4.8 Tüm modeller için model performans değerlendirme sonuçları

Model	RMSE	R^2	MAE	MAPE
ANN	1874.4118	0.8294	1319.1459	3.3862
LSTM	1837.1576	0.8361	1118.1489	3.0315
BiLSTM	1683.0431	0.8624	1004.9980	2.6719
GRU	1611.6459	0.8739	951.8369	2.5640
GRU-BiLSTM	1427.0374	0.9011	890.2839	2.3707


RMSE değerlerine bakıldığında, 1427.0374 sonucu ile oluşturduğumuz hibrit model sonucu elde etmiştir. Bireysel modeller arasında değerlendirme yapacak olursak GRU modeli hibrit modele en yakın olan RMSE değerine sahiptir. R^2 değerlerinde ise GRU-BiLSTM modeli 0.9011 en yüksek R^2 değerine sahiptir. Bu sonuç hibrit modelin gerçek elektrik tüketim değerini en iyi açıklayan model olduğunu göstermektedir. Diğer modellere bakıldığında, GRU 0.8739, BiLSTM 0.8624, LSTM 0.8361 ve ANN 0.8294 R^2 değerlerine sahiptir. MAE değerlerinde yine GRU-BiLSTM sonucu en düşük değere sahipken GRU 951.8369 değeri ile hibrit modele en yakın sonuçlara sahiptir. Son olarak modellerin MAPE sonuçlarına bakıldığında, tahmin hatası en düşük olan model 2.3707 değeri ile GRU-BiLSTM modeli olmuştur ve en iyi performansı göstermiştir. En yüksek MAPE değerini ise 3.3862 değeriyle ANN modeli göstermiştir.

Çalışmada kullanılan modellerin test tahmin sonuçlarının daha iyi analiz edilmesi adına, şekil4.9 ile 4.13 arasında gerçek test değerleri ile tahmin edilen değerleri aynı grafik üzerinde görselleştirilmiştir. Grafiklerde mavi çizgiler gerçek değerleri ifade ederken kırmızı noktalı çizgiler tahmin edilen değerleri göstermektedir.




Şekil 4.9 ANN modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi

ANN grafiğinde gerçek değerler ile tahmin edilen değerler arasındaki fark açıkça görülmektedir. Tahmin edilen değerler gerçek tüketim değerlerinin altında kalmıştır.




Şekil 4.10 LSTM modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi

LSTM modelinin grafiğinde ilk aylarda tahmin değerleri gerçek tüketim değerlerinin altında kalırken ağustos- eylül aylarından sonra tahmin edilen değerler gerçek değerlere göre daha yüksek sonuçlar göstermektedir.




Şekil 4.11 BiLSTM modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi

BiLSTM modelinde tahmin edilen değerler genel olarak gerçek değerlerin altında kalmıştır. Ani yükseliş ve düşüşlerde sapma gösterdiği görülmekte ancak diğer dönemlerde başarılı sonuçlar görülmektedir.



Şekil 4.12 GRU modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi

GRU modeli grafiği BiLSTM modelinin grafiğine oldukça benzer bir çıktı göstermekle birlikte dalgalanmaları iyi sayılabilecek şekilde yakalamıştır. Modelin doğruluk seviyesinin yüksek olduğu söylenebilir.



Şekil 4.13 GRU-BiLSTM modelinin gerçek değerleri ile tahmin edilen değerlerinin görselleştirilmesi

Oluşturduğumuz GRU-BiLSTM hibrit modelinde ise, gerçek tüketim değerleri ile tahmin edilen tüketim değerleri oldukça yakın sonuçlar göstermiş olup modelin doğruluk seviyesinin yüksek olduğu görülmektedir. Genel olarak mevsimsel eğilimler başarılı bir şekilde yakalanmıştır. Diğer modellerde olduğu gibi ani değişimlerde bazı sapmalar görülmektedir ancak diğer modellere kıyasla bu sapmalar daha küçüktür.

5

SONUÇ VE ÖNERİLER

Bu tez çalışmasında, hibrit bir model oluşturarak günlük elektrik tüketim tahmin başarısı arttırılmaya çalışılmıştır. Çalışma kapsamında, Türkiye'nin 2020-2024 yıllarına ait elektrik tüketim verileri kullanılmıştır. Zaman serileri üzerinde etkili olan derin öğrenme modelleri (ANN, LSTM, GRU ve BiLSTM) ile iki farklı derin öğrenme modelinden oluşan GRU-BiLSTM hibrit modelinin karşılaştırılması için model performans değerlendirmesi yapılmıştır.

Kullanılan derin öğrenme modelleri elektrik tüketim verilerinde sık kullanılan modellerden tercih edilmiş olup aynı şekilde hibrit derin öğrenme modeli için de farklı kombinasyonlar denenmiştir. Bu deneme sonuçlarında, hızlı çalışmasından dolayı GRU ve uzun vadeli bağımlıklar üzerindeki etkilerinden dolayı ise BiLSTM modelleri hibrit bir yapıyla birleştirilmiştir. Model performans değerlendirmesi için MAE, RMSE, R² ve MAPE metrikleri kullanılmıştır.

Elde edilen sonuçlar, hibrit modelin tek başına kullanılan ANN, LSTM, GRU ve BiLSTM modellerine göre daha yüksek doğruluk ve daha düşük hata oranları sağladığı sonucuna varılmıştır. Bu durum, hibrit yapıların elektrik tüketimi gibi zaman serisi verileri üzerinde etkin bir şekilde modelleme yaptığını göstermektedir. Aynı zamanda, zaman serisi uygulamalarında geleneksel yöntemler yerine gelişen teknolojiye uyum sağlayarak hibrit derin öğrenme modellerini uygulamanın başarıyı arttırdığı da gözlemlenmiştir.

Yapılan analizler doğrultusunda elektrik tüketimindeki tahmin başarısını arttırmanın, elektrik şirketlerinin kaynaklarını daha verimli planlamasına olanak tanımakla birlikte sürdürülebilir enerji politikalarının geliştirilmesine de katkı sağlamaktadır.

Sonuç olarak, geliştirilen hibrit model Türkiye'deki elektrik tüketim tahmini konusunda etkili sonuçlar elde etmiştir ve zaman serisi verilerine yenilikçi bir yaklaşım sunmaktadır.

Gelecek alıřmalarda, tkretim verilerine ek olarak farklı deęiřkenlerin modele etkileri de incelenerek tkretim tahmin performansları geliřtirilebilir. Hava durumu, coęrafi konum, ekonomik řartlar gibi deęiřkenler gz nnde bulundurulduęunda hibrit modelin performansının arttırılacaęı nerilmektedir.



- [1] E. E. Nebati, M. Taş and G. Ertaş, "Türkiye’de elektrik tüketiminde talep tahmini: zaman serisi ve regresyon analizi ile karşılaştırma," *Avrupa Bilim ve Teknoloji Dergisi*, pp. 348-357, 2021.
- [2] E. Y. Haliloğlu and B. E. Tutu, "Türkiye için kısa vadeli elektrik enerjisi talep tahmini," *Journal of Yasar University*, pp. 243-255, 2018.
- [3] S. Sharma and S. K. Mishra, "Electricity demand estimation using ARIMA forecasting model," *Recent Developments in Electronics and Communication Systems*, 2023.
- [4] A. M. N. Ribeiro, P. R. X. Carmo, I. R. Rodrigues, D. Sadok, T. Lynn and P. T. Endo, " Short-term firm-level energy-consumption forecasting for energy-intensive manufacturing: a comparison of machine learning and deep learning models," *Algorithms*, pp. 1-19, 2020.
- [5] R. Banik, P. Das, S. Ray and A. Biswas, "Prediction of electrical energy consumption based on machine learning technique," *Electrical engineering*, pp. 909-920, 2021.
- [6] A. K. Shaikh, A. Nazir, I. Khan and A. S. Shah, "Short term energy consumption forecasting using neural basis expansion analysis for interpretable time series," *Scientific reports*, p. 22562, 2022.
- [7] B. R. K. Al-Ani and T. E. Erkan, " A study of load demand forecasting models in electricity using artificial neural networks and fuzzy logic model," *International Journal of Engineering*, pp. 1111-1118, 2022.
- [8] G. V. Reddy, L. J. Aitha, C. Poojitha, A. N. Shreya, D. K. Reddy and G. S. Meghana, "Electricity consumption prediction using machine learning," *In E3S Web of Conferences*, 2023.
- [9] B. Başoğlu and M. Bulut, "Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi," *Journal of the Faculty of Engineering and Architecture*, pp. 575-583, 2016.
- [10] K. Yan, W. Li, Z. Ji, M. Qi and Y. Du, " A hybrid LSTM neural network for energy consumption forecasting of individual households," *Ieee Access*, p. 157633, 2019.
- [11] O. Jogunola, B. Adebisi, K. V. Hoang, Y. Tsado, S. I. Popoola, M. Hammoudeh and R. Nawaz, " CBLSTM-AE: a hybrid deep learning framework for predicting energy consumption," *Energies*, p. 810, 2022.

- [12] L. S. Saoud, H. AlMarzouqi and R. Hussein, "Cascaded deep hybrid models for multistep household energy consumption forecasting," *arXiv preprint arXiv:2207.02589*, p. 3, 2022.
- [13] S. Ghimire, R. C. Deo, D. Casillas-Pérez and S. Salcedo-Sanz, "Efficient daily electricity demand prediction with hybrid deep-learning multi-algorithm approach," *Energy Conversion and Management*, p. 117707, 2023.
- [14] K. Kaysal, A. H. Yurttakal and F. O. Hoccoğlu, "Hibrit derin öğrenme yöntemi kullanılarak hiperparametre optimizasyonu ile yenilenebilir elektrik enerjisi tahmini," *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, pp. 770-777, 2023.
- [15] G. Yıldız Doğan, A. Aksoy and N. Öztürk, "A hybrid deep learning model to estimate the future electricity demand of sustainable cities," *Sustainability*, p. 6503, 2024.
- [16] X. Li, Z. Wang, C. Yang and A. Bozkurt, "An advanced framework for net electricity consumption prediction: Incorporating novel machine learning models and optimization algorithms," *Energy*, p. 131259, 2024.
- [17] M. Kim, W. Choi, Y. Jeon and L. Liu, "A hybrid neural network model for power demand forecasting," *Energies*, pp. 931-932, 2019.
- [18] N. Tsalikidis, A. Mystakidis, C. Tjortjis, P. Koukaras and D. Ioannidis, "Energy load forecasting: one-step ahead hybrid model utilizing ensembling," *Computing*, pp. 244-245, 2024.
- [19] H. Altıntaş and Ö. Koçbulut, "Türkiye'de elektrik tüketiminin dinamikleri ve ekonomik büyüme: sınır testi ve nedensellik analizi," *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, pp. 37-65, 2014.
- [20] "Türkiye Elektrik Dağıtım ve Tüketim İstatistikleri," TÜRKİYE ELEKTRİK DAĞITIM A.Ş. , 2021.
- [21] Z. Han, J. Zhao, H. Leung, K. F. Ma and W. Wang, "A review of deep learning models for time series prediction," *IEEE Sensors Journal*, pp. 7833-7848, 2019.
- [22] Z. Chen, M. Ma, T. Li, H. Wang and C. Li, "Long sequence time-series forecasting with deep learning: A survey," *Information Fusion*, p. 101819, 2023.
- [23] E. Özkan, E. Güler and Z. Aladağ, "Elektrik enerjisi tüketim verileri için uygun tahmin yöntemi seçimi," *Journal of Industrial Engineering*, p. 199, 2020.

- [24] B. Aksel, "Derin öğrenme ile döviz kurları değişimlerinin zaman serisi analizi," in *Gazi Üniversitesi*, Ankara, 2023.
- [25] A. K. H. Hassoo, "Estimating time series data on energy production in Türkiye by comparing bayesian and classical models," in *Van Yuzuncu Yıl University*, Van, 2023.
- [26] C. Cheng, A. Sa-NGasoongsong, O. Beyca, L. T. H. Yang, Z. Kong and S. T. Bukkapatnam, "Time series forecasting for nonlinear and non-stationary processes: a review and comparative study," *Transactions*, pp. 1053-1071, 2015.
- [27] E. Egrioglu and E. Bas, "A new hybrid recurrent artificial neural network for time series forecasting," *Neural computing and applications*, pp. 2855-2865, 2023.
- [28] R. Baidya and S. W. Lee, "Addressing the Non-Stationarity and Complexity of Time Series Data for Long-Term Forecasts," *Applied Sciences*, p. 4436, 2024.
- [29] M. C. Yılmaz and Z. Orman, "LSTM derin öğrenme yaklaşımı ile Covid-19 pandemi sürecinde twitter verilerinden duygu analizi," *Acta Infologica*, pp. 359-372, 2021.
- [30] J. F. Torres, D. Hadjout, A. Sebaa, F. Martínez-Álvarez and A. Troncoso, "Deep learning for time series forecasting: a survey," *Big Data*, pp. 3-21, 2021.
- [31] J. R. Raol and S. S. Mankame, "Artificial neural networks," *Resonance*, pp. 47-54, 1996.
- [32] K. Öztürk and M. E. Şahin, "Yapay sinir ağları ve yapay zekâ'ya genel bir bakış," *Takvim-i Vekayi*, pp. 25-36, 2018.
- [33] T. Efendigil, S. Önüt and C. Kahraman, "A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis.," *Expert systems with applications*, pp. 6697-6707, 2009.
- [34] E. İdman, "Zaman serisi analiz yöntemleri ve yapay sinir ağları algoritmalarını kullanarak güneş enerjisi santrallerinde üretilen gücün tahminlenmesi," in *Arel Üniversitesi*, İstanbul, 2024.
- [35] Z. Allam, "Achieving neuroplasticity in artificial neural networks through smart cities," *Smart Cities*, pp. 118-134, 2019.
- [36] B. Arslan and İ. Ertuğrul, "Çoklu regresyon, arıma ve yapay sinir ağı yöntemleri ile türkiye elektrik piyasasında fiyat tahmin ve analizi," *Journal of Management and Economics Research*, pp. 331-353, 2022.

- [37] M. S. Bhutta, Y. Li, M. Abubakar, F. M. Almasoudi, K. S. S. Alatawi, M. R. Altmania and M. Al-Barashi, "Optimizing solar power efficiency in smart grids using hybrid machine learning models for accurate energy generation prediction," *Scientific Reports*, p. 17101, 2024.
- [38] Q. H. M. IMTIAZ ULLAH, " Design and Development of RNN Anomaly Detection Model for IoT Networks," *IEEE Xplore* , pp. 62727-62728, 2022.
- [39] T. Yi-Ting, Z. Yu-Ren and C. Yue-Shan, "Air pollution forecasting using RNN with LSTM," *IEEE*, p. 1075, 2018.
- [40] A. Nugaliyadde, U. Somaratne and K. W. Wong, "Predicting Electricity Consumption using Deep Recurrent Neural Networks," p. 5, 2019.
- [41] Y. Xiao and Y. Yin, " Hybrid LSTM neural network for short-term traffic flow prediction," *Information*, p. 105, 2019.
- [42] Y. Zhang, P. Tiwari, D. M. X. Song, P. Wang, X. Li and H. M. Pandey, "Learning interaction dynamics with an interactive LSTM for conversational sentiment analysis," *Neural Networks*, pp. 40-56, 2021.
- [43] P. Lalwani and R. Ganeshan, "A Novel CNN-BiLSTM-GRU Hybrid Deep Learning Model for Human Activity Recognition," *International Journal of Computational Intelligence Systems*, pp. 1-20, 2024.
- [44] M. Yang and J. Wang, "Adaptability of financial time series prediction based on BiLSTM," *Procedia Computer Science*, pp. 18-25, 2022.
- [45] F. Alrowais, R. Marzouk, M. K. Nour, H. Mohsen, A. M. Hilal, I. Yaseen and G. P. Mohammed, " Intelligent intrusion detection using arithmetic optimization enabled density based clustering with deep learning," *Electronics*, p. 3541, 2022.
- [46] T. Xia, Y. Song, Y. Zheng, E. Pan and L. Xi, " An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation," *Computers in Industry*, p. 103182, 2020.
- [47] M. S. Islam and E. Hossain, "Foreign exchange currency rate prediction using a GRU-LSTM hybrid network," *Soft Computing Letters*, p. 100009, 2021.
- [48] H. Ragb, A. Muntaser, E. Jera, A. Saide and I. Elwarfalli, "Hybrid GRU-LSTM Recurrent Neural Network-Based Model for Real Estate Price Prediction," *Authorea Preprints*, 2023.
- [49] T. Liu, S. Qi, X. Qiao and S. Liu, "A hybrid short-term wind power point-interval prediction model based on combination of improved preprocessing methods and entropy weighted GRU quantile regression network," *Energy*, p. 129904, 2024.

- [50] M. Ravanelli, P. Brakel, M. Omologo and Y. Bengio, "Light gated recurrent units for speech recognition," *IEEE Transactions on Emerging Topics in Computational Intelligence*, pp. 92-102, 2018.
- [51] R. A. Y. A. K. & R. Abhiraj, "Earthquake Magnitude and Depth Prediction Based on Hybrid GRU-BiLSTM Model," *In International Conference on Data Intelligence and Cognitive Informatics*, pp. 303-315, 2023.
- [52] S. K. P. & T. M. C. Vashisht, "Enhanced GRU-BiLSTM Technique for Crop Yield Prediction," *Multimedia Tools and Applications*, pp. 1-26, 2024.
- [53] W. Wang and Y. Lu, "Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model," *In IOP conference series: materials science and engineering*, vol. 324, 2018.
- [54] W. Lu, J. Li, J. Wang and L. Qin, "A CNN-BiLSTM-AM method for stock price prediction," *Neural Computing and Applications*, pp. 4741-4753, 2021.
- [55] S. Prayudani, A. Hizriadi, Y. Y. Lase and Y. Fatmi, "Analysis accuracy of forecasting measurement technique on random K-nearest neighbor (RKNN) using MAPE and MSE," *In Journal of Physics: Conference Series*, vol. 1361, 2019.
- [56] A. V. Tatachar, "Comparative assessment of regression models based on model evaluation metrics," *International Research Journal of Engineering and Technology*, 2021.
- [57] J. Kaliappan, K. Srinivasan, S. Mian Qaisar, K. Sundararajan and C. Y. Chang, "Performance evaluation of regression models for the prediction of the COVID-19 reproduction rate," *Frontiers in Public Health*, p. 729795, 2021.
- [58] "EPIAŞ ŞEFFAFLIK PLATFORMU," ENERJİ PİYASALARI İŞLETME A.Ş., 2025. [Online]. Available: <https://seffaflik.epias.com.tr/electricity/electricity-consumption/ex-post-consumption/real-time-consumption>.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. V. Kara, ve F.N. Tekeli, “ Electricity Consumption Prediction With Hybrid Deep Learning Algorithm”, 8th International Researchers, Statisticians and Young Statisticians Congress IRSYSC, 28 - 30 Kasım 2024.

