

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**ELEKTRİK TÜKETİM VERİLERİNE YAPAY ZEKÂ MODELLERİNİN
UYGULANMASI**

YÜKSEK LİSANS TEZİ

AYŐEN CİHAN

TEZ DANIŐMANI
DR. ÖĐR. ÜYESİ VEDAT MARTTİN

BİLECİK, 2024

10598661

T.C.
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĐİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**ELEKTRİK TÜKETİM VERİLERİNE YAPAY ZEKÂ MODELLERİNİN
UYGULANMASI**

YÜKSEK LİSANS TEZİ

AYŐEN CİHAN

TEZ DANIŐMANI
DR. ÖĐR. ÜYESİ VEDAT MARTTİN

BİLECİK, 2024

10598661

BEYAN

Elektrik Tüketim Verilerine Yapay Zekâ Modellerinin Uygulanması adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğruluğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR	<input type="checkbox"/>	DESTEK ALINMAMIŞTIR	<input checked="" type="checkbox"/>
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:	/.....	

Ayşen CİHAN

Tarih

.....

İmza

.....

ÖN SÖZ

Bu tez çalışmasının gerçekleştirilmesinde bana rehberlik yapan ve her bir safhasında kıymetli tecrübesini ve bilgisini benden esirgemeyen yüksek lisans tez danışmanım Sayın Dr. Öğr. Üyesi Vedat MARTTİN'e sonsuz teşekkürlerimi iletir ve minnettarlığımı belirtmek isterim.

Bu aşamada bana her zaman destek olan Doğuş Üniversitesi ailesine ve özellikle Mühendislik Fakültesi'ndeki kıymetli hocalarıma teşekkür ederim.

Tez savunma sürecinde şahsıma yol gösteren ve bu çalışmanın nihai haline gelmesinde büyük önemi olan kıymetli geri bildirimlerini benimle paylaşan Sayın jüri üyelerine en içten teşekkürlerimi ve saygılarımı sunarım.

Ayrıca akademik gelişimime katkıda bulunan ve bu süreci daha anlamlı kılan tüm değerli hocalarımla desteği, bu çalışmanın ortaya çıkmasında büyük rol oynamıştır.

Son olarak, lisans eğitim döneminden itibaren benim her zaman en büyük destekçilerimden olan çok sevdiğim arkadaşım Sayın Doç. Dr. Rahmiye Zerrin YARBAY'a ve hayatımın her aşamasında olduğu gibi yüksek lisans çalışmalarım sırasında da beni sabır ve içtenlikle destekleyen sevgili annem Semra CİHAN'a en içten teşekkürlerimi sunarım.

AYŞEN CİHAN
2024

ÖZET

ELEKTRİK TÜKETİM VERİLERİNE

YAPAY ZEKÂ MODELLERİNİN UYGULANMASI

Bu çalışmada, 2016 Ocak - 2024 Haziran döneminde Türkiye'nin Bilecik ilinin Aydınlatma, Mesken, Sanayi, Tarımsal Sulama ve Ticarethane sektörlerine ait elektrik tüketim verileri incelenmiştir. Elektrik tüketiminin gelecekteki eğilimlerini tahmin etmek amacıyla, Enerji Piyasası Düzenleme Kurumu'nun (EPDK) yayımladığı Elektrik Piyasası Aylık Resmi İstatistikleri kullanılarak veriler toplanmış ve Zaman Serisi Analizi ile işlenmiştir. RNN, GRU, LSTM ve BiLSTM modelleri, sektörel bazda epoch 25, 50, 100 ve 200 değerlerinde eğitilmiş, 2016-2019 dönemi eğitim verisi, 2020-2024 Haziran dönemi test verisi olarak kullanılmıştır. Modellerin performansı MAE, RMSE, MSE ve MAPE metrikleri ile değerlendirilmiştir. Çalışmada elde edilen bulgular, Mesken ve Ticarethane sektörlerinde BiLSTM ve LSTM modellerinin yüksek doğrulukla tahmin yaptığını, Sanayi ve Tarımsal Sulama sektörlerinde ise GRU ve BiLSTM modellerinin daha başarılı olduğunu göstermiştir. RNN modeli genel olarak diğer modellere göre daha düşük performans sergilemiştir. Çalışma, derin öğrenme modellerinin elektrik tüketimi tahmininde güçlü bir öğrenme yeteneğine sahip olduğunu, ancak bazı sektörlerde daha fazla hiperparametre optimizasyonuna ihtiyaç duyulduğunu ortaya koymuştur. Sonuç olarak, bu modeller, Bilecik ilinin gelecek yıllarındaki elektrik tüketiminin sektörel bazda tahmin edilmesini sağlamış ve enerji yönetimi açısından önemli öngörüler sunmuştur. Gelecekteki çalışmalar için modellerin sektörel bazda performanslarını artırmak amacıyla daha karmaşık ve daha büyük veri kümelerinde optimizasyon yöntemleri kullanılabilir.

Anahtar Kelimeler: Yapay Zekâ, GRU, LSTM, BiLSTM, Zaman Serisi Tüketim Tahmini.

ABSTRACT

APPLICATION OF ARTIFICIAL INTELLIGENCE

MODELS TO ELECTRICITY CONSUMPTION DATA

In this study, electricity consumption data of Bilecik province of Turkey for Lighting, Residential, Industrial, Agricultural Irrigation and Commercial sectors for the period of 2016 January - 2024 June are analysed. In order to estimate the future trends of electricity consumption, data are collected using the Electricity Market Monthly Official Statistics published by the Energy Market Regulatory Authority (EMRA) and processed by Time Series Analysis. RNN, GRU, LSTM and BiLSTM models were trained at Epoch 25, 50, 100 and 200 on a sectoral basis, and the period 2016-2019 was used as training data and the period 2020-2024 June was used as test data. The performance of the models was evaluated with MAE, RMSE, MSE and MAPE metrics. The findings of the study show that BiLSTM and LSTM models predict with high accuracy in Residential and Commercial sectors, while GRU and BiLSTM models are more successful in Industrial and Agricultural Irrigation sectors. The RNN model generally performed worse than the other models. The study revealed that deep learning models have a strong learning ability in electricity consumption forecasting, but more hyperparameter optimisation is needed in some sectors. As a result, these models have enabled the prediction of electricity consumption of Bilecik province in the coming years on a sectoral basis and provided important predictions in terms of energy management. For future studies, optimisation methods can be used in more complex and larger datasets to improve the performance of the models on a sectoral basis.

Keywords: Artificial Intelligence, GRU, LSTM, BiLSTM, Time Series Consumption Forecasting.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ.....	xi
KISALTMALAR VE SİMGELER LİSTESİ	xxiii
1.GİRİŞ.....	1
1.1. Tezin Amacı	4
1.2. Hipotez.....	4
2. YAPAY ZEKÂ.....	6
2.1. Yapay Zekâ Kavramı.....	6
2.2. Makine Öğrenmesi	7
2.3. Derin Öğrenme.....	8
3. YAPAY SİNİR AĞLARI	9
3.1. Yapay Sinir Ağı Kavramı	9
3.2. Yapay Sinir Ağının Modeli.....	9
3.2.1. Tek Katmanlı Algılayıcılar (SLP) Modeli	11
3.2.2 Çok Katmanlı Algılayıcılar (MLP) Modeli.....	11
3.2.3 Konvolüsyonel Sinir Ağları (CNN) Modeli.....	12
3.2.4. Tekrarlayan Sinir Ağları (RNN) Modeli	13
3.2.5 Geçitli Tekrarlayan Birim Ağları (GRU) Modeli.....	14

3.2.6 Uzun Kısa Süreli Bellek Ağları (LSTM) Modeli	16
3.2.6.1. Sigmoid Fonksiyonu	17
3.2.6.2. Hiperbolik Tanjant Fonksiyonu	18
3.2.7 Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM) Modeli	18
4. MATERYAL VE METOD	20
4.1 Veri Seti ve Özellikleri	20
4.1.1. Veri Kaynağı	21
4.1.2. Verinin Temizlenmesi ve Hazırlanması	21
4.1.3. Zaman Serisi Özellikleri	22
4.2. Veri Hazırlama Süreci	22
4.2.1 Verinin Normalizasyonu ve Ölçeklenmesi	22
4.3.1. Model Mimarisi	25
4.3.1.1. Girdi ve Çıktı Katmanları	25
4.3.1.2 Gizli Katmanlar ve Aktivasyon Fonksiyonları	26
4.3.2. Model Eğitim Süreci	27
4.3.2.1. Hiperparametreler ve Optimizasyon	27
4.3.2.2 Modelin Eğitim ve Doğrulama Kayıplarının Takibi	27
4.4 Performans Değerlendirme Yöntemleri	28
4.4.1. Ortalama Mutlak Hata (MAE)	28
4.4.2. Ortalama Mutlak Yüzde Hatası (MAPE)	28
4.4.3. Ortalama Kare Hata (MSE)	29
4.4.4. Kök Ortalama Kare Hata (RMSE)	29
5. BULGULAR VE TARTIŞMALAR	30
5.1. Aydınlatma Sektörü	30

5.1.1. Eğitim ve Doğrulama Kayıpları (Epoch 25).....	30
5.1.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25).....	32
5.1.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25).....	34
5.1.4. Eğitim ve Doğrulama Kayıpları (Epoch 50).....	36
5.1.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50).....	38
5.1.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50).....	39
5.1.7. Eğitim ve Doğrulama Kayıpları (Epoch 100).....	41
5.1.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100).....	43
5.1.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100).....	45
5.1.10. Eğitim ve Doğrulama Kayıpları (Epoch 200).....	48
5.1.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200).....	49
5.1.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200).....	51
5.1.13. Aydınlatma Sektörü Bazında Genel Değerlendirme.....	53
5.2. Mesken Sektörü	56
5.2.1. Eğitim ve Doğrulama Kayıpları (Epoch 25).....	57
5.2.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25).....	59
5.2.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25).....	61
5.2.4. Eğitim ve Doğrulama Kayıpları (Epoch 50).....	63
5.2.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50).....	65
5.2.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50).....	67
5.2.7. Eğitim ve Doğrulama Kayıpları (Epoch 100).....	68
5.2.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100).....	71
5.2.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100).....	73
5.2.10. Eğitim ve Doğrulama Kayıpları (Epoch 200).....	75

5.2.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)	76
5.2.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)	78
5.2.13. Mesken Sektörü Bazında Genel Değerlendirme	80
5.3. Sanayi Sektörü	85
5.3.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)	85
5.3.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)	86
5.3.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)	89
5.3.4. Eğitim ve Doğrulama Kayıpları (Epoch 50)	90
5.3.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)	92
5.3.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)	94
5.3.7. Eğitim ve Doğrulama Kayıpları (Epoch 100)	96
5.3.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100)	98
5.3.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100)	99
5.3.10. Eğitim ve Doğrulama Kayıpları (Epoch 200)	101
5.3.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)	103
5.3.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)	105
5.3.13. Sanayi Sektörü Bazında Genel Değerlendirme	107
5.4. Tarımsal Sulama Sektörü	111
5.4.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)	111
5.4.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)	114
5.4.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)	116
5.4.4. Eğitim ve Doğrulama Kayıpları (Epoch 50)	117
5.4.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)	119
5.4.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)	121

5.4.7. Eğitim ve Doğrulama Kayıpları (Epoch 100).....	123
5.4.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100).....	125
5.4.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100).....	127
5.4.10. Eğitim ve Doğrulama Kayıpları (Epoch 200).....	129
5.4.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200).....	130
5.4.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200).....	132
5.4.13. Tarımsal Sulama Sektörü Bazında Genel Değerlendirme	134
5.5. Ticarethane Sektörü	137
5.5.1. Eğitim ve Doğrulama Kayıpları (Epoch 25).....	138
5.5.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25).....	140
5.5.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25).....	142
5.5.4. Modellerin Eğitim ve Doğrulama Kayıpları (Epoch 50).....	144
5.5.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50).....	146
5.5.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50).....	148
5.5.7. Eğitim ve Doğrulama Kayıpları (Epoch 100).....	149
5.5.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100).....	151
5.5.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100).....	153
5.5.10. Eğitim ve Doğrulama Kayıpları (Epoch 200).....	155
5.5.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200).....	157
5.5.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200).....	159
5.5.13. Ticarethane Sektörü Bazında Genel Değerlendirme	161
6. SONUÇ VE ÖNERİLER.....	166
KAYNAKÇA.....	169

TABLULAR LİSTESİ

	Sayfa
Tablo 4.1. Örnek Veri Seti	20
Tablo 4. 2. Python Kütüphaneleri	20
Tablo 5. 1. Aydınlatma Sektörüne Ait Hata Metrikleri	56
Tablo 5. 2. Mesken Sektörüne Ait Hata Metrikleri.....	84
Tablo 5. 3. Sanayi Sektörüne Ait Hata Metrikleri	111
Tablo 5. 4. Tarımsal Sulama Sektörüne Ait Hata Metrikleri	137
Tablo 5. 5. Ticarethane Sektörüne Ait Hata Metrikleri.....	165

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Zeki Sistemler	7
Şekil 2.2. Yapay Zekâ Sınıflandırması	8
Şekil 3.1. Sinir Hücresi Biyolojik Gösterimi	9
Şekil 3.2. Sinir Hücresi Matematiksel Gösterimi (Perseptron).....	10
Şekil 3.3. Tam Bağlısımlı Yapay Sinir Örneđi	10
Şekil 3.4. Tek Katmanlı Algılayıcı.....	11
Şekil 3.5. Çok Katmanlı Algılayıcı	11
Şekil 3.6. CNN modeli.....	12
Şekil 3.7. RNN Modeli	13
Şekil 3. 8. GRU Modeli	14
Şekil 3. 9. LSTM modeli.....	17
Şekil 3. 10. BiLSTM Modeli	18
Şekil 4. 1. Veri Setinde Tarihsel Dönüşüm ve Sıralama	21
Şekil 4. 2. Normalizasyon İşlemi	23
Şekil 4. 3. Veri Seti Oluşturma.....	23
Şekil 4. 4. Eğitim-Test Verilerinin Ayrılması	24
Şekil 4. 5. Yapay Sinir Ađı Modeli	26
Şekil 5. 1. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 25).....	30
Şekil 5. 2. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 25).....	31
Şekil 5. 3. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	31
Şekil 5. 4. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25).....	32
Şekil 5. 5. Aydınlatma – RNN Gerçek Deđerler ve Tahminler (Epoch 25)	32

Şekil 5. 6. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 25).....	33
Şekil 5. 7. Aydınlatma – LSTM Gerçek Değerler ve Tahminler (Epoch 25).....	33
Şekil 5. 8. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25).....	34
Şekil 5. 9. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 25).....	34
Şekil 5. 10. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 25).....	35
Şekil 5. 11. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 25).....	35
Şekil 5. 12. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 25).....	36
Şekil 5. 13. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)	36
Şekil 5. 14. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)	36
Şekil 5. 15. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	37
Şekil 5. 16. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	37
Şekil 5. 17. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 50).....	38
Şekil 5. 18. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 50).....	38
Şekil 5. 19. Aydınlatma – LSTM Gerçek Değerler ve Tahminler (Epoch 50).....	39
Şekil 5. 20. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50).....	39
Şekil 5. 21. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 50).....	40
Şekil 5. 22. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 50).....	40
Şekil 5. 23. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 50).....	40
Şekil 5. 24. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 50).....	41
Şekil 5. 25. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 100).....	41
Şekil 5. 26. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)	42
Şekil 5. 27. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	42
Şekil 5. 28. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	43
Şekil 5. 29. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 100).....	43

Şekil 5. 30. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 100).....	44
Şekil 5. 31. Aydınlatma –LSTM Gerçek Değerler ve Tahminler (Epoch 100).....	44
Şekil 5. 32. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100).....	45
Şekil 5. 33. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 100).....	46
Şekil 5. 34. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 100).....	46
Şekil 5. 35. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 100).....	46
Şekil 5. 36. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 100).....	47
Şekil 5. 37. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)	48
Şekil 5. 38. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)	48
Şekil 5. 39. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	49
Şekil 5. 40. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	49
Şekil 5. 41. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 200).....	50
Şekil 5. 42. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 200).....	50
Şekil 5. 43. Aydınlatma – LSTM Gerçek Değerler ve Tahminler (Epoch 200).....	50
Şekil 5. 44. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200).....	51
Şekil 5. 45. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 200).....	51
Şekil 5. 46. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 200).....	52
Şekil 5. 47. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 200).....	52
Şekil 5. 48. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 200).....	52
Şekil 5. 49. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25).....	53
Şekil 5. 50. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50).....	54
Şekil 5. 51. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100).....	55
Şekil 5. 52. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200).....	55
Şekil 5. 53. Mesken - RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)	57

Şekil 5. 54. Mesken - GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)	57
Şekil 5. 55. Mesken - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	58
Şekil 5. 56. Mesken - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	58
Şekil 5. 57. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 25).....	59
Şekil 5. 58. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 25).....	59
Şekil 5. 59. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 25).....	60
Şekil 5. 60. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25).....	60
Şekil 5. 61. Mesken Sektörü MAE Hata Metrikleri (Epoch 25).....	61
Şekil 5. 62. Mesken Sektörü MAPE Hata Metrikleri (Epoch 25).....	61
Şekil 5. 63. Mesken Sektörü MSE Hata Metrikleri (Epoch 25)	62
Şekil 5. 64. Mesken Sektörü RMSE Hata Metrikleri (Epoch 25).....	62
Şekil 5. 65. Mesken - RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)	63
Şekil 5. 66. Mesken - GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)	63
Şekil 5. 67. Mesken - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	64
Şekil 5. 68. Mesken - BiLSM Eğitim ve Doğrulama Kayıpları (Epoch 50).....	64
Şekil 5. 69. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 50).....	65
Şekil 5. 70. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 50).....	65
Şekil 5. 71. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 50).....	66
Şekil 5. 72. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50).....	66
Şekil 5. 73. Mesken Sektörü MAE Hata Metrikleri (Epoch 50).....	67
Şekil 5. 74. Mesken Sektörü MAPE Hata Metrikleri (Epoch 50).....	67
Şekil 5. 75. Mesken Sektörü MSE Hata Metrikleri (Epoch 50)	68
Şekil 5. 76. Mesken Sektörü RMSE Hata Metrikleri (Epoch 50).....	68
Şekil 5. 77. Mesken - RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)	69

Şekil 5. 78. Mesken – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100).....	69
Şekil 5. 79. Mesken - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	70
Şekil 5. 80. Mesken - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	70
Şekil 5. 81. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 100).....	71
Şekil 5. 82. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 100).....	71
Şekil 5. 83. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 100).....	72
Şekil 5. 84. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100).....	72
Şekil 5. 85. Mesken Sektörü MAE Hata Metrikleri (Epoch 100).....	73
Şekil 5. 86. Mesken Sektörü MAPE Hata Metrikleri (Epoch 100).....	74
Şekil 5. 87. Mesken Sektörü MSE Hata Metrikleri (Epoch 100)	74
Şekil 5. 88. Mesken Sektörü RMSE Hata Metrikleri (Epoch 100).....	74
Şekil 5. 89. Mesken – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200).....	75
Şekil 5. 90. Mesken – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200).....	75
Şekil 5. 91. Mesken – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	76
Şekil 5. 92. Mesken – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200).....	76
Şekil 5. 93. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 200).....	77
Şekil 5. 94. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 200).....	77
Şekil 5. 95. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 200).....	78
Şekil 5. 96. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200).....	78
Şekil 5. 97. Mesken Sektörü MAE Hata Metrikleri (Epoch 200).....	79
Şekil 5. 98. Mesken Sektörü MAPE Hata Metrikleri (Epoch 200).....	79
Şekil 5. 99. Mesken Sektörü MSE Hata Metrikleri (Epoch 200)	79
Şekil 5. 100. Mesken Sektörü RMSE Hata Metrikleri (Epoch 200).....	80
Şekil 5. 101. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)	81

Şekil 5. 102. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)	81
Şekil 5. 103. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)	82
Şekil 5. 104. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)	83
Şekil 5. 105. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)	85
Şekil 5. 106. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)	85
Şekil 5. 107. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	86
Şekil 5. 108. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	86
Şekil 5. 109. Sanayi – RNN Gerçek Değerler ve Tahminler (Epoch 25).....	87
Şekil 5. 110. Sanayi – GRU Gerçek Değerler ve Tahminler (Epoch 25).....	87
Şekil 5. 111. Sanayi – LSTM Gerçek Değerler ve Tahminler (Epoch 25).....	88
Şekil 5. 112. Sanayi – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25).....	88
Şekil 5. 113. Sanayi Sektörü MAE Değerleri (Epoch 25)	89
Şekil 5. 114. Sanayi Sektörü MAPE Değerleri (Epoch 25)	89
Şekil 5. 115. Sanayi Sektörü MSE Değerleri (Epoch 25)	90
Şekil 5. 116. Sanayi Sektörü RMSE Değerleri (Epoch 25)	90
Şekil 5. 117. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 50).....	91
Şekil 5. 118. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 50).....	91
Şekil 5. 119. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	92
Şekil 5. 120. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	92
Şekil 5. 121. Sanayi – RNN Gerçek Değerler ve Tahminler (Epoch 50).....	93
Şekil 5. 122. Sanayi – GRU Gerçek Değerler ve Tahminler (Epoch 50).....	93
Şekil 5. 123. Sanayi – LSTM Gerçek Değerler ve Tahminler (Epoch 50)	93
Şekil 5. 124. Sanayi – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50).....	94
Şekil 5. 125. Sanayi Sektörü MAE Değerleri (Epoch 50)	94

Şekil 5. 126. Sanayi Sektörü MAPE Değerleri (Epoch 50)	95
Şekil 5. 127. Sanayi Sektörü MSE Değerleri (Epoch 50).....	95
Şekil 5. 128. Sanayi Sektörü RMSE Değerleri (Epoch 50)	95
Şekil 5. 129. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)	96
Şekil 5. 130. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)	96
Şekil 5. 131. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	97
Şekil 5. 132. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	97
Şekil 5. 133. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)	98
Şekil 5. 134. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)	98
Şekil 5. 135. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	99
Şekil 5. 136. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	99
Şekil 5. 137. Sanayi Sektörü MAE Değerleri (Epoch 100)	99
Şekil 5. 138. Sanayi Sektörü MAPE Değerleri (Epoch 100).....	100
Şekil 5. 139. Sanayi Sektörü MSE Değerleri (Epoch 100).....	100
Şekil 5. 140. Sanayi Sektörü RMSE Değerleri (Epoch 100)	101
Şekil 5. 141. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)	101
Şekil 5. 142. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)	102
Şekil 5. 143. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	102
Şekil 5. 144. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	103
Şekil 5. 145. Sanayi – RNN Gerçek Değerler ve Tahminler (Epoch 200).....	103
Şekil 5. 146. Sanayi – GRU Gerçek Değerler ve Tahminler (Epoch 200).....	104
Şekil 5. 147. Sanayi – LSTM Gerçek Değerler ve Tahminler (Epoch 200)	104
Şekil 5. 148. Sanayi – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200).....	105
Şekil 5. 149. Sanayi Sektörü MAE Değerleri (Epoch 200)	105

Şekil 5. 150. Sanayi Sektörü MAPE Değerleri (Epoch 200)	105
Şekil 5. 151. Sanayi Sektörü MSE Değerleri (Epoch 200).....	106
Şekil 5. 152. Sanayi Sektörü RMSE Değerleri (Epoch 200)	106
Şekil 5. 153. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)	107
Şekil 5. 154. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)	108
Şekil 5. 155. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)	109
Şekil 5. 156. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)	109
Şekil 5. 157. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)	112
Şekil 5. 158. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)	112
Şekil 5. 159. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	113
Şekil 5. 160. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	113
Şekil 5. 161. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 25).....	114
Şekil 5. 162. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 25).....	114
Şekil 5. 163. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 25)	115
Şekil 5. 164. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25).....	115
Şekil 5. 165. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 25)	116
Şekil 5. 166. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 25).....	116
Şekil 5. 167. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 25).....	117
Şekil 5. 168. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 25)	117
Şekil 5. 169. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)	118
Şekil 5. 170. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)	118
Şekil 5. 171. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	119
Şekil 5. 172. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	119
Şekil 5. 173. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 50).....	120

Şekil 5. 174. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 50).....	120
Şekil 5. 175. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 50)	121
Şekil 5. 176. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50).....	121
Şekil 5. 177. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 50)	121
Şekil 5. 178. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 50)	122
Şekil 5. 179. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 50).....	122
Şekil 5. 180. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 50)	123
Şekil 5. 181. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)	123
Şekil 5. 182. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)	124
Şekil 5. 183. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	124
Şekil 5. 184. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	125
Şekil 5. 185. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 100).....	125
Şekil 5. 186. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 100).....	125
Şekil 5. 187. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 100)	126
Şekil 5. 188. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100).....	126
Şekil 5. 189. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 100)	127
Şekil 5. 190. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 100)	127
Şekil 5. 191. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 100).....	128
Şekil 5. 192. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 100)	128
Şekil 5. 193. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)	129
Şekil 5. 194. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)	129
Şekil 5. 195. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	130
Şekil 5. 196. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	130
Şekil 5. 197. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 200).....	131

Şekil 5. 198. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 200).....	131
Şekil 5. 199. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 200)	131
Şekil 5. 200. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200).....	132
Şekil 5. 201. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 200)	132
Şekil 5. 202. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 200)	132
Şekil 5. 203. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 200).....	133
Şekil 5. 204. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 200)	133
Şekil 5. 205. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)	134
Şekil 5. 206. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)	135
Şekil 5. 207. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)	135
Şekil 5. 208. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)	136
Şekil 5. 209. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)	138
Şekil 5. 210. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)	139
Şekil 5. 211. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	139
Şekil 5. 212. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)	139
Şekil 5. 213. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 25).....	140
Şekil 5. 214. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 25).....	140
Şekil 5. 215. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 25)	141
Şekil 5. 216. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25).....	141
Şekil 5. 217. Ticarethane Sektörü MAE Değerleri (Epoch 25)	142
Şekil 5. 218. Ticarethane Sektörü MAPE Değerleri (Epoch 25)	142
Şekil 5. 219. Ticarethane Sektörü MSE Değerleri (Epoch 25).....	143
Şekil 5. 220. Ticarethane Sektörü RMSE Değerleri (Epoch 25)	143
Şekil 5. 221. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)	144

Şekil 5. 222. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)	144
Şekil 5. 223. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	145
Şekil 5. 224. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)	145
Şekil 5. 225. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 50).....	146
Şekil 5. 226. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 50).....	146
Şekil 5. 227. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 50)	147
Şekil 5. 228. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50).....	147
Şekil 5. 229. Ticarethane Sektörü MAE Değerleri (Epoch 50)	148
Şekil 5. 230. Ticarethane Sektörü MAPE Değerleri (Epoch 50)	148
Şekil 5. 231. Ticarethane Sektörü MSE Değerleri (Epoch 50).....	148
Şekil 5. 232. Ticarethane Sektörü RMSE Değerleri (Epoch 50)	149
Şekil 5. 233. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)	150
Şekil 5. 234. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)	150
Şekil 5. 235. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	151
Şekil 5. 236. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)	151
Şekil 5. 237. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 100).....	152
Şekil 5. 238. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 100).....	152
Şekil 5. 239. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 100)	153
Şekil 5. 240. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100).....	153
Şekil 5. 241. Ticarethane Sektörü MAE Değerleri (Epoch 100)	154
Şekil 5. 242. Ticarethane Sektörü MAPE Değerleri (Epoch 100)	154
Şekil 5. 243. Ticarethane Sektörü MSE Değerleri (Epoch 100).....	154
Şekil 5. 244. Ticarethane Sektörü RMSE Değerleri (Epoch 100)	155
Şekil 5. 245. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)	155

Şekil 5. 246. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)	156
Şekil 5. 247. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	156
Şekil 5. 248. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)	157
Şekil 5. 249. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 200).....	157
Şekil 5. 250. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 200).....	158
Şekil 5. 251. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 200)	158
Şekil 5. 252. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200).....	159
Şekil 5. 253. Ticarethane Sektörü MAE Değerleri (Epoch 200)	159
Şekil 5. 254. Ticarethane Sektörü MAPE Değerleri (Epoch 200)	160
Şekil 5. 255. Ticarethane Sektörü MSE Değerleri (Epoch 200).....	160
Şekil 5. 256. Ticarethane Sektörü RMSE Değerleri (Epoch 200)	160
Şekil 5. 257. Ticarethane – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)	161
Şekil 5. 258. Ticarethane – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)	162
Şekil 5. 259. Ticarethane– Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)	163
Şekil 5. 260. Ticarethane – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)	163

KISALTMALAR VE SİMGELER LİSTESİ

AI : Artificial Intelligence (Yapay Zekâ)

ANN : Artificial Neural Network (Yapay Sinir Ağı)

ARIMA : Autoregressive Integrated Moving Average (Otomatik Regresif Entegre Hareketli Ortalama)

BiLSTM: Bidirectional Long Short-Term Memory (Çift Yönlü Uzun Kısa Süreli Bellek)

CNN : Convolutional Neural Network (Evrışimli Sinir Ağı)

EMRA : The Energy Market Regulatory Authority

EPDK : Enerji Piyasası Düzenleme Kurumu

EPIAŞ : Enerji Piyasaları İşletme A.Ş.

GRU : Gated Recurrent Unit (Geçitli Tekrarlayan Birim)

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)

ML : Machine Learning (Makine Öğrenimi)

MLP : Multi Layer Perceptron (Çok Katmanlı Algılayıcı)

MSE : Mean Squared Error (Ortalama Kare Hata)

MWh : Megawatt Saat

RMSE : Root Mean Square Error (Kök Ortalama Kare Hata)

RNN : Recurrent Neural Networks (Tekrarlayan Sinir Ağları)

SL : Supervised Learning (Denetimli Öğrenme)

SLP : Single Layer Perceptron (Tek Katmanlı Algılayıcı)

SVR : Support Vector Regression

SWT : Stationary Wavelet Transform(Sabit Dalgacık Dönüşümü)

TUIK : Türkiye İstatistik Kurumu

UL : Unsupervised Learning (Denetimsiz Öğrenme)

σ : Sigma (Sigmoid)

1.GİRİŞ

Her geçen gün gelişen sanayi, artan nüfus ve yükselen enerji talepleri, elektrik tüketimini karmaşıklaştırmaktadır. Ülkelerin enerji politikalarına yön veren bu değişkenler, tüketim tahminlerinin doğruluk payında önemli bir rol oynamaktadır. Elektrik tüketimini öngörmek ve doğru elektrik tahminlerinde bulunmak enerji kaynaklarının israf edilmeden verimli bir şekilde kullanılmasını sağlar.

Bu alanda, büyük veri analitiği, yapay zekâ ve makine öğrenimi yöntemleri ile kullanıldığında, elektrik tüketim tahminlerinde önemli bir doğruluk oranına ulaşılmasını sağlar. Uzun Kısa Süreli Bellek (LSTM) ağları, klasik yöntemlerin ötesine geçerek büyük veri setleri ve karmaşık yapılar üzerinde daha doğru tahminler sunan yapay sinir ağı modellerindedir.

Özellikle Tekrarlayan Sinir Ağları (RNN) ve onların geliştirilmiş versiyonları olan Gated Recurrent Unit (GRU), Uzun Kısa Süreli Bellek (LSTM) ve Çift Yönlü LSTM (BiLSTM) modelleri, zaman serisi verilerinde uzun vadeli bağımlılıkları öğrenmedeki başarılı performanslarıyla öne çıkmaktadır. Bu modeller, düzensiz ve karmaşık veri setlerinde, geçmiş veriler arasındaki ilişkileri öğrenerek daha doğru tahminler sağlar. Enerji sektöründe kullanıldığında, zamansal değişiklikleri ve uzun vadeli tüketim desenlerini etkili bir şekilde yakalayabilirler.

Bu doğrultuda, Ruyi Cai ve diğer çalışma arkadaşları, LSTM modelini uygulayarak geçmiş yük verileri ile elektrik fiyatlarının entegrasyonunu sağlayan kısa süreli bir yük tahmin modeli öne sürmüşlerdir. Bu yöndeki çalışmaları elektrik fiyatlarının model işleyişinde hesaba alınmasının diğer modeller ile karşılaştırıldığında LSTM modelinin istikrar ve doğruluğuna önemli bir katkı sunduğu tespit edilmiştir. Söz konusu çalışma neticesinde elde edilen bulgular, yük tahmin modellerinde bu etkeni dikkate almanın sağladığı potansiyel faydasını vurgulamaktadır. (Cai vd., 2019)

Pençe ve arkadaşları, Türkiye'deki sanayi bölgesinde elektrik tüketimini tahmin etmek için YSA modeli kullanmışlardır. Model 1970-2016 yılları arasındaki verilerle eğitilmiş ve 2017-2023 yılları için tahminler yapmıştır. Elde edilen sonuçlar TEİAŞ'ın tahminleri ile karşılaştırılmış ve paralellik göstermiştir. Enerji politikaları ve yatırım planları için doğru tahminlerin önemi vurgulanmış ve güneş enerjisi kullanımının artırılması önerilmiştir. Çalışmada ayrıca sanayi

elektrik tüketimi, ihracat ve Türkiye'nin 2023 hedefleri arasındaki ilişki incelenmiş ve farklı tahmin modellerinin performansı karşılaştırılmıştır (Pençe vd., 2019).

Yan ve arkadaşları, bireysel hanelerde enerji tüketimi tahmini için hibrit bir derin öğrenme modeli önermişlerdir. Sabit dalgacık dönüşümü (SWT) ve LSTM sinir ağlarını birleştiren model, doğruluk ve eğitim verimliliği açısından mevcut yöntemlerden daha iyi performans göstermektedir. Yaklaşımları, hane halkı enerji tüketim verilerinin düzensizliğini ve tek değişkenli doğasını ele alarak gelecekteki uygulamalar için umut verici sonuçlar sunmaktadır (Yan vd., 2019).

Wang ve arkadaşları, periyodik enerji tüketiminin gelecek yıllardaki değişimini tahmin etmek için LSTM ağlarını kullanan yeni bir yaklaşım önermiştir. Yöntemleri klasik tahmin yaklaşımlarından daha başarılı performans göstermiş ve mükemmel genelleme kabiliyeti sergileyerek doğru enerji tüketimi tahmini potansiyelini vurgulamıştır. Çalışmada ayrıca eksik girdi değişkenlerinin tahmin doğruluğu üzerindeki etkisi araştırılmış ve korelasyon analizi teknikleri tartışılmıştır. Makale ayrıca, LSTM modelini diğer algoritmalarla karşılaştırmakta ve enerji tüketimi tahmininde hibrit modellerin potansiyelini tartışmaktadır. (Wang J. Q. vd., 2020)

Sevinç ve Kaya, Diyarbakır ili için hava sıcaklığı tahmininde LSTM ve ARIMA (Otomatik Regresif Entegre Hareketli Ortalama) modellerinin kullanıldığı bir çalışmayı ele almışlardır. Tahminlerin başarılı olduğu ve hava sıcaklığı tahmininde kullanılabileceği sonucuna varılmıştır. Ayrıca derin öğrenme ve LSTM modelinin genel tahmin performansının yüksek olduğu vurgulanmıştır. LSTM tabanlı sıralama ile çok bölgeli iç ortam sıcaklık tahmini için seq2seq modeli önerilmiş ve ARIMA modellerinin genel olarak güçlü ve uygulanmasının kolay olduğu belirtilmiştir. Sonuç olarak çalışma, her iki modelin de hava sıcaklığını tahmin etmede başarılı olduğunu göstermiştir (Sevinç ve Kaya, 2021).

Bişkin ve Çiftçi, Türkiye'de tüketilen elektrik enerjisi miktarını tahmin etmek amacıyla geçmiş verileri kullanarak LSTM ve GRU modellerinin performansını bir saat ve üç saat sonrası için karşılaştırmıştır. GRU modeli, özellikle bir saat sonrası için yapılan tahminlerde LSTM'den biraz daha iyi performans göstermiştir. Çalışma, enerji yönetimi için doğru tahminin önemini vurgulamakta ve COVID-19'un Türkiye'deki elektrik tüketimi üzerindeki etkisini tartışmaktadır. Veriler, ülke için gerçek zamanlı elektrik tüketim verileri sağlayan EPIAŞ Şeffaflık Platformu'ndan alınmıştır (Bişkin & Çiftçi, 2021).

Kamber ve meslektaşları, elektrik yükü tahmini için LSTM ve ARIMA modellerinin kullanımını incelemektedir. İspanya'nın beş büyük şehrinin elektrik tüketim verileri ve saatlik hava durumu parametreleri üzerinde yapılan analizler, LSTM ve ARIMA modellerinin performanslarını karşılaştırmaktadır. Ayrıca, literatürdeki diğer çalışmaları kapsayan referanslar da verilmektedir (Kamber vd., 2021).

Çetiner, enerji tüketimi tahmini için ayrı GRU ve LSTM modellerinden daha iyi performans gösteren hibrit bir LSTM-GRU modeli geliştirmiştir. Çalışma ayrıca, çalışmada detaylandırılan özellikleri öneren ve uygulayan ilk çalışma olması nedeniyle enerji tüketimi tahminine yeni bir yaklaşım sunmaktadır. Çalışmada kullanılan veri seti, Avrupa piyasasına elektrik dağıtımını yapan Avrupa Elektrik İletim Sistemi İşleticileri Birliği Şeffaflık Platformu'ndan (ENTSO-E Transparency Platform) elde edilerek araştırmanın güvenilirliği ve uygunluğu artırılmıştır (Çetiner, 2022).

Wu ve Wu, evsel elektrik tüketimini tahmin etmek için CNN, BiLSTM ve Self-Attention (SA) mekanizmalarını bir araya getiren hibrit bir model önermişlerdir. Çalışmalarında, BiLSTM modelinin zamansal bağımlılıkları etkili bir şekilde yakaladığı ve uzun vadeli elektrik tüketimi trendlerini başarılı bir şekilde tahmin ettiği vurgulanmıştır. CNN ile verilerden çıkarılan uzamsal özellikler BiLSTM'e aktarılmış, BiLSTM ise ileri ve geri yönlü işlemlerle geçmiş ve gelecekteki veriler arasındaki ilişkileri öğrenmiştir. Ayrıca, SA mekanizması modelin önemli verilere odaklanarak tahmin doğruluğunu artırmasına katkı sağlamıştır. Yapılan deneyler, modelin mevcut yöntemlere kıyasla üstün performans sergilediğini ve evsel elektrik tüketimi tahmininde yüksek bir doğruluk sağladığını göstermiştir (Wu ve Wu, 2024)

Pavlatos ve çalışma arkadaşları (2023), elektrik yük tahmininde doğruluğu artırmak için BiLSTM sinir ağlarını kullanan bir model önermişlerdir. Bu model, enerji tüketimi verilerindeki zamansal bağımlılıkları çift yönlü olarak ele alarak hem geçmiş hem de gelecekteki bilgileri aynı anda değerlendirir. Bu yaklaşım, sıradan RNN, LSTM ve GRU modellerine kıyasla belirgin bir performans artışı sağlamıştır. Özellikle, BiLSTM modeli 24 saatlik bir zaman diliminde, RMSE ve MAE değerlerinde önemli iyileştirmeler kaydederek en yüksek tahmin doğruluğuna ulaşmıştır. Çalışma, enerji planlaması ve piyasa yönetimi süreçlerinde BiLSTM modelinin sağladığı avantajları vurgulayarak, elektrik yük tahmininde ileri düzey sinir ağı mimarilerinin önemini ortaya koymaktadır (Pavlatos vd., 2023)

Çalışmanın giriş bölümünde, elektrik tüketimi ve yapay zekâ uygulamalarının genel bir değerlendirmesi yapılmış, ardından literatürde elektrik tüketim tahmini üzerine yapılan çalışmalar özetlenmiştir. Bu bölümde ayrıca çalışmanın amacı ve hipotezi ele alınmıştır. İkinci bölümde, yapay zekânın alt dalları olan makine öğrenmesi ve derin öğrenme kavramlarına odaklanılmıştır. Üçüncü bölümde ise, yapay sinir ağlarının temel yapı taşları incelenmiş ve özellikle RNN, GRU, LSTM ve BiLSTM ağları üzerine detaylı bilgi verilmiştir. Yapay sinir ağlarının zaman serisi analizindeki uygulamaları ve performans değerlendirme yöntemleri paylaşılmıştır.

Dördüncü bölümde, tezde kullanılan veri seti, bu verilerin nasıl işlendiği ve hangi yöntemlerle temizlendiği anlatılmaktadır. Ayrıca, zaman serisi analizine uygun olarak RNN, GRU, LSTM ve BiLSTM modelleri eğitilmiş ve test edilmiştir. Beşinci bölümde, modelin performans sonuçları analiz edilmiş, tahmin verileri ile gerçek değerler karşılaştırılarak tartışılmıştır. Son olarak, altıncı bölümde, çalışmanın sonuçları özetlenmiş ve gelecekte yapılabilecek iyileştirme önerileri sunulmuştur.

1.1. Tezin Amacı

Bu çalışmanın amacı, Bilecik ilindeki sektörel bazda 2016 Ocak ayı ile 2024 Haziran ayları arasındaki zaman dilimine ait elektrik tüketim verileri kullanılarak RNN, GRU, LSTM ve BiLSTM yapay sinir ağı modelleri ile gelecekteki elektrik tüketimini tahmin etmektir. Doğru ve güvenilir elektrik tüketimi tahminleri, sürdürülebilir enerji politikalarının oluşturulması ve enerji kaynaklarının planlanması açısından önemlidir. Elektrik tüketimindeki artışın doğru bir şekilde öngörülmesi, elektrik üretimi ve dağıtımını gibi operasyonların planlanmasında kritik bir rol oynar. Bu çalışma, farklı derin öğrenme modellerinin performanslarını karşılaştırarak, en uygun tahmin modelini belirlemeyi ve enerji sektöründe tahmin doğruluğunu artırmayı hedeflemektedir.

1.2. Hipotez

Bu tez çalışmasında, Bilecik ilinin elektrik tüketiminin RNN, GRU, LSTM ve BiLSTM gibi yapay sinir ağı modelleri kullanılarak etkin bir şekilde tahmin edilebileceği hipotezi savunulmaktadır. Bu kapsamda, zaman serisi analizi yöntemi kullanılarak farklı yapay sinir ağı modelleri eğitilmiş ve çeşitli hiperparametre ayarları ile deneyimler yapılarak hipotezin doğruluğu test edilmiştir. Test verisi üzerindeki performanslar karşılaştırılırken en düşük hata metriklerine

sahip modeller seçilmiştir. Bu hipotez, yapay sinir ağı modellerinin elektrik tüketimi gibi karmaşık ve dinamik veri setlerinde etkili bir şekilde kullanılabileceğini ve enerji tahminlerinde doğruluğu artırabileceğini öne sürmektedir.

2. YAPAY ZEKÂ

2.1. Yapay Zekâ Kavramı

Günümüzde her geçen gün hayatımızın pek çok alanında etkisini ve izlerini daha fazla hissettiğimiz ve gördüğümüz yapay zekâ kavramının tarihçesi aslında uzun bir geçmişe dayanmaktadır. Bilgi isleyen ve tekrar eden işlemleri daha hızlı ve efektif bir şekilde yerine getirmek üzere icat edilmiş bilgisayarların dünyamıza girmesi ile insanoğlunun işlerini otomatikleştirme arzusu yapay zekâ kavramının gündemimize girmesine neden olmuştur.

Aslında yapay zekânın temellerinin çok uzun süre önce felsefe, matematik, psikoloji, bilgisayar mühendisliği ve dilbilim gibi çok farklı disiplinlerde atıldığını görebiliriz. Makineler düşünebilir mi? fikrinin ilk defa ortaya atan Alan Mathison Turing, 2. Dünya Savaşı sırasında kripto ihtiyaçları nedeniyle icat edilen elektromekanik araçlar ile gerek bilgisayar bilimi gerekse de yapay zekâ kavramlarının oluşum ve gelişimini büyük bir katkı sunmuştur.

Bilgisayarlar temelde insan beyni model olarak işlevselleştirilmiş ve geliştirilmiştir. Bilgisayarların temel fonksiyonu ve işleyiş sürecini verilerin uygun giriş üniteleri aracılığıyla bilgisayara aktarılması ve gereken işleme basamakları tamamlandıktan sonra çıktıları hedeflediğimiz formatta bize sunması olarak ifade edebiliriz. Bu aşamada yapay zekâ kavramı ile verilerin bu işleniş biçimi önem kazanmış ve insan gibi düşünebilen ya da davranabilen işleme metotları üretilmeye çalışılmıştır.

Russell ve Norvig bu doğrultuda zeki sistemler sınıflandırması şeklinde bir tasnife giderek, yapay zekâyâ dört ana kategoriye ayırmaktadır: Bu sınıflandırma Şekil 2.1.'de gösterilmiştir (Russel ve Norvig, 1995).

İnsan düşüncesiyle ilişkili olduğumuz faaliyetlerin otomasyonu, karar verme, problem çözme, öğrenme gibi faaliyetler... (Belman, 1978) “Düşünen bilgisayarlar yapma konusundaki heyecan verici yeni çabalar” (Haugeland, 1985)		“Hesaplama modelleri kullanarak zihinsel yeteneklerin incelenmesi” (Charniak ve McDermott, 1985) “Algılama, mantık ve hareket etmeyi mümkün kılan hesaplamaların incelenmesi” (Winston, 1992)	
	İnsan gibi düşünen sistemler	Akılcı düşünen sistemler	
	İnsan gibi davranan sistemler	Akılcı davranan sistemler	
“İnsanların daha iyi olduğu şeyleri bilgisayarların nasıl yapabileceğine dair çalışma” (Rich ve Knight, 1991) “Zeki insanlar tarafından gerçekleştirilen işlevleri yerine getiren makineler yaratma sanatı” (Kurzweil, 1990)		“Akıllı davranışın otomasyonu ile ilgili olan bilgisayar bilimi kolu” (Luger ve Stubblefield, 1993) “Hesaplamalı süreçler açısından akıllı davranışları açıklamak ve taklit etmek isteyen bir çalışma alanı” (Schalkoff, 1990)	

Şekil 2.1. Zeki Sistemler

Kaynak: (Russel ve Norvig, 1995)

2.2. Makine Öğrenmesi

Makine öğrenme süreci, verilerin işlenip değerlendirilmesinde başlayıp öncesinde karşılaştırılıp analizden geçirilen veriler vasıtasıyla karar verme safhasına kadar devam etmektedir (González García vd., 2019). Makine öğrenmesi denetim kriteri baz alınarak 3 farklı kategoride sınıflandırılmıştır (Cifuentes vd. 2020).

a) Denetimli Öğrenme (Supervised Learning):

Söz konusu bu derin öğrenme yönteminde etiketlenmiş giriş ve çıkış verilerinin fonksiyonundan araştırmacı yardımı ile öğrenme işlevi yerine getirilir. Bu yaklaşım kullanılarak, güvenilir veri modelleri oluşturulur. Fakat bu durum büyük veri setleri için aynı zamanda yüksek maliyetli etiketleme zorluğunu da yanında getirir (Saba Raouf ve Durai, 2022).

Denetimli Öğrenme metotlarının uygulandığı algoritmalara örnek vermek gerekirse Destek Vektör Makineleri (Support Vector Machines) ve Rastgele Orman (Random Forest) verilebilir. Ayrıca Regresyon analizi (Regression Analysis) ve Karar Ağaçları (Decision Trees) da denetimli öğrenmenin uygulandığı diğer algoritma çeşitlerindedir.

b) Denetimsiz Öğrenme (Unsupervised Learning):

Bu yöntemde model izlemesine ya da veri etiketlenmesi işlemlerine gereksinim duyulmaz. Kendi veri setinden veri bilgisi ve desenin keşfedilmeye odaklanıldığı bu yöntemde genellikle kümeleme işlemleri uygulanır. Giriş bilgisinin bulunmadığı bu modelde çıktı verilerinin doğruluk oranları düşük seviyede olması bir dezavantaj olsa da diğer modellere oranla daha az karmaşıklık barındırdığı için uygulanabilirliği yüksek seviyededir. (Ahmad vd., 2022).

Denetimsiz Öğrenme metotlarının uygulandığı algoritmalara ilk olarak Temel Bileşenler Analizi (Principal Component Analysis) olmak üzere k-Ortalamalar Kümelemesi (k-Means Clustering) ve Kendi kendine Organize Haritalar (Self Organizing Maps) algoritmaları örnek verilebilir.

c) Pekiştirmeli öğrenme (Reinforcement Learning): Çevreyle interaktif bir ilişkinin kurulmadığı bu öğrenme modelinde ise deneme-yanılma ve ödül-ceza kavramları uygulanarak, model en yüksek ödülü alma hedefiyle çalıştırılır. Q-Learning, Asynchronous Advantage Actor-Critic (A3C), Policy Gradient Methods, Actor-Critic Methods, algoritmaları pekiştirmeli derin öğrenmeye örnek olarak verilebilir.

2.3. Derin Öğrenme

Derin öğrenmede verilerin insan beyni tarafından ele alınıp işlenmesinden esinlenilmiştir. Derin öğrenme öncesinde, araştırmacı tarafından belirlenmesi gereken bir kural gereksinimi bulunmamaktadır. Ancak veriler arasında anlamlı bağlantılar kurulması için oldukça fazla veriye gereksinim duyulmaktadır. Bu nedenle derin öğrenmede, önceki katmanların çıktısından elde edilen verilerin kullanıldığı çeşitli algoritmik sinir ağı katmanları oluşturulur (Alzubaidi vd., 2021) Şekil 2.2.'de, derin öğrenmenin, makine öğrenmesi ve yapay zekâ ile ilişkisi gösterilmiştir.



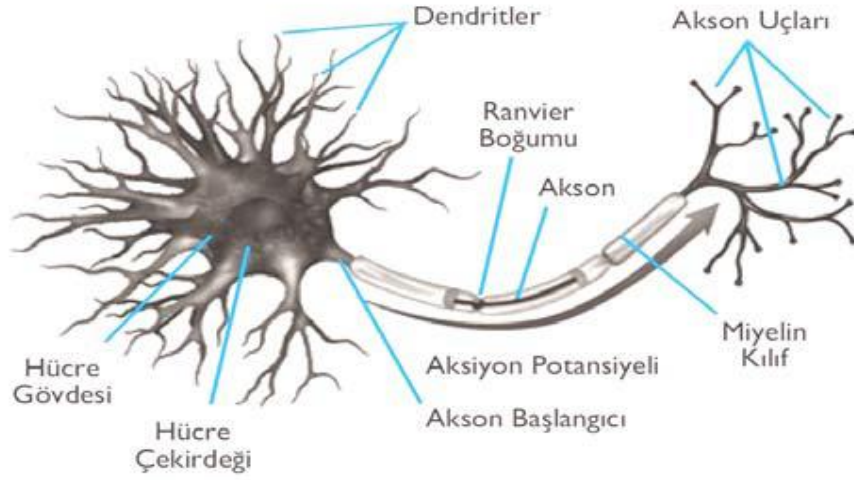
Şekil 2.2. Derin öğrenme, makine öğrenmesi ve yapay zekâ kronolojisi

Kaynak: (Tan vd., 2021)

3. YAPAY SİNİR AĞLARI

3.1. Yapay Sinir Ağı Kavramı

Biyolojik sinir sistemlerinin modellenmesi, sinir ağlarının temelini oluşturmuştur. Nöron, beynin en küçük hesaplama birimidir. Gelen sinyalleri iletmekle görevli akson nöronun çıkışını oluşturur. Nöronlar arasında gelen sinyalleri toplayıp hücre girişini oluşturan yapı dentritlerdir. Tüm nöronlar arasında sağlıklı bir haberleşmenin kurulabilmesi için dentrit ve aksonlar birbirlerine sinaps ile bağlanmışlardır. Şekil 3.1.'de yer alan biyolojik sinir hücresinin çiziminde akson, dentrit, çekirdek gibi yapılar yer almaktadır.



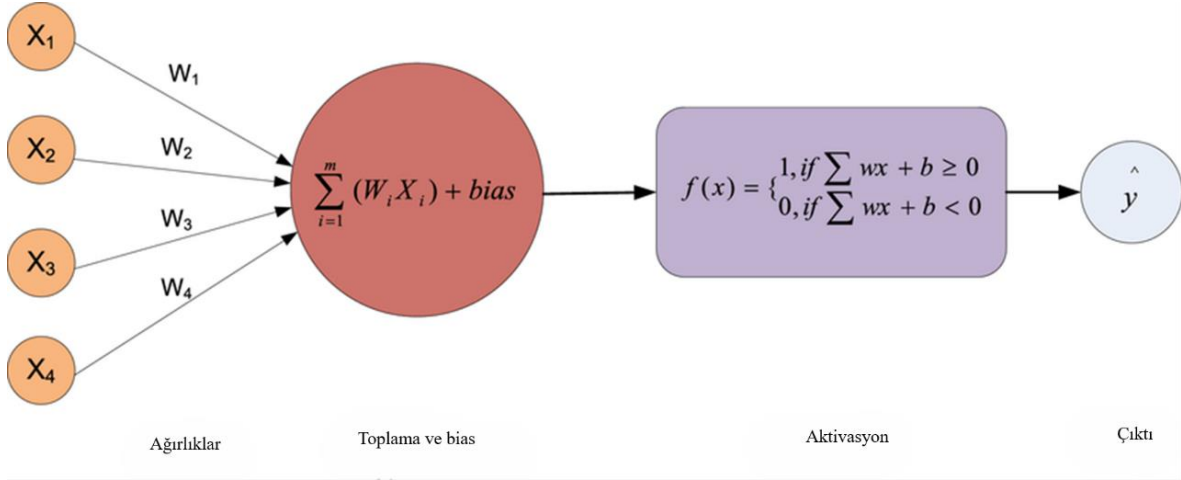
Şekil 3.1. Sinir Hücresi Biyolojik Gösterimi

Kaynak: (Mijwel, 2017)

3.2. Yapay Sinir Ağının Modeli

Yapay sinir ağlarının en küçük birimi olan perseptron, lineer bir fonksiyonla gösterilir. 1957 yılında Frank Rosenblatt tarafından perseptron tanımlanmıştır.


Perseptronlardan oluşan katmanlar yığını, yapay sinir ağları olarak bilinir. Her modül, verileri bir sonraki modüle aktarmak için farklı bir gösterime dönüştürür. Bu modüller, literatürde katmanlar olarak adlandırılır ve her bir katman çok sayıda birim veya nöron içerir. (Lucas vd., 2018). Şekil 3. 2.'de bir sinir hücresinin matematiksel gösterimi paylaşılmıştır.



Şekil 3.2. Sinir Hücresi Matematiksel Gösterimi (Perseptron)

Kaynak: (Sajja ve Rooban, 2024)

Giriş verisi X_n , ağırlık katsayısı W_n , sapma katsayısı $bias$, aktivasyon fonksiyonu $f(x)$ ile işlenerek, Y çıkışı elde edilir. Eğitim sırasında öğrenilen w ağırlık katsayısı ve b sapma katsayısı, Şekil 3.3.'de gösterilen N gizli katmandan oluşan tam bağlantımlı yapay sinir ağında yer almaktadır. Giriş birimine verilen girdilerin ağırlıklı toplamı, her katmanın çıktısıdır. Aynı katmandaki nöronlar arasında bağlantı yoktur ve diğer katmanlardaki nöronlar arasında ağırlık ve sapma katsayısı öğrenilir. Ardışık iki katman arasındaki nöronlar, birbirlerini çeşitli aktivasyon işlevleriyle etkiler. Modelin öğrenme düzeyi, bu fonksiyonların değerlerine göre belirlenir.

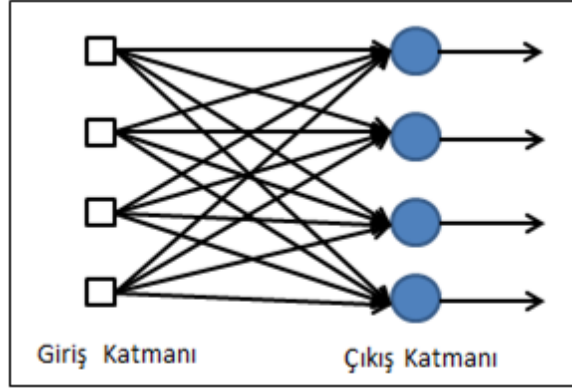


Şekil 3.3. Tam Bağlantımlı Yapay Sinir Örneği

Kaynak: (Lucas vd., 2018)

3.2.1. Tek Katmanlı Algılayıcılar (SLP) Modeli

Doğrusal sorunları çözmek amacıyla oluşturulan tek katmanlı YSA'da girdi katmanı ve çıktı katmanı kullanılmaktadır. Söz konusu bu katmanlar bir tek nöronun oluşabileceği gibi çok sayıda nöronu da içerebilir. Şekil 3.4.'de basit düzeyde oluşturulan tek katmanlı algılayıcı gösterilmektedir. (Arı & Berberler, 2017)




Şekil 3.4. Tek Katmanlı Algılayıcı

Kaynak: (Şalvarcı ve Ayten, 2019)

3.2.2 Çok Katmanlı Algılayıcılar (MLP) Modeli

MLP modeli ise ayrıştırma gerçekleştirebilen modeldir. İleri beslemeli olan bu modelde, giriş ve çıkış katmanı arasında olmak üzere çok sayıda gizli katmanlar yer almaktadır. MLP modeli Şekil 3. 5.'de gösterilmiştir.



Şekil 3.5. Çok Katmanlı Algılayıcı


Kaynak: (Şalvarcı ve Ayten, 2019)

Çok katmanlı algılayıcı modelin çalışma prensibini iki aşamadan oluşmaktadır. İlk aşamada ağa uygulanan girişler, giriş katmanından çıkış katmanına doğru ileri yönde iletim gerçekleştirilir. Diğer aşamada ise, hataların geri yayılması algoritması uygulanır. Çıkış katmanına ulaşan veriler, ile tahmin edilen çıkış verileri arasındaki fark algoritma tarafından işlenir ve ağa yeniden döndürülür. (Torres-Hernández vd., 2023)

Çok katmanlı algılayıcı modelinin doğrusal olmayan problemler üzerinde üstün bir çözme yeteneği bulunmaktadır. Yüksek sayıda girdi ile yüksek sayıda çıktı verisi üretebilen bu model özellikle doğal dil işleme, görüntü tanıma gibi farklı alanlarda oldukça tercih edilen bir yapay sinir ağı modelidir. Hesaplama maliyetinin yüksek potansiyeli ve çok katmanlı yapısı modelin negatif yönleri arasında yer almaktadır. Çok sayıda parametre içermesi nedeniyle bu parametreler uygulama öncesinde belirlenmesi gerekmektedir. Bu modelin eğitimi esnasında zaman zaman uyum problemleri yaşanabilir.

3.2.3 Konvolüsyonel Sinir Ağları (CNN) Modeli


Derin ileri beslemeli bir sinir ağı olan CNN, genellikle görüntü işleme alanında nesnelerin tanımlanması, analiz edilmesi, kategorizasyon gibi farklı alanlarda kullanılmaktadır. Gride benzer bir yapıya sahip olan bu sinir ağı modelinde matris çarpımı yerine katmanlar arasında evrişim ya da konvolüsyon olarak tanımlanan matematiksel bir işlem uygulanır. İlk katmanlarında daha basit ve temel niteliklerden meydana gelmektedir. Ancak katman sayısı ilerledikçe, derinleşen katmanlarda daha kompleks öznelikler elde edilir. Söz konusu bu kompleks öznelikler sayesinde görüntüler daha doğru ve net bir şekilde tasvir edilir. (Kızrak ve Bolat, 2018). CNN, geleneksel sinir ağlarının aksine, sayısal veriler yerine matrisler kullanır. Bu modelde insan görsel sisteminin modellenmesini örnek alınmaktadır. CNN modeli Şekil 3.6.'da gösterilmiştir.



Şekil 3.6. CNN modeli

Kaynak: (Kızrak ve Bolat, 2018)

3.2.4. Tekrarlayan Sinir Ağları (RNN) Modeli



Şekil 3.7. RNN Modeli

Kaynak: (Zaheer vd., 2023)

Giriş, gizli ve çıkış katmanları sırasıyla X, H ve Y harfleriyle gösterilir. Modelin çıktısını geliştirmek için ağ parametreleri A, B ve C kullanılır. Herhangi bir t zamanında x_t ve x_{t-1} 'deki girdiler mevcut girdiyi oluşturmak için birleştirilir. Ağ daha iyi hale getirmek için, Denklem 3.1 yardımıyla ağdan her zaman çıktı toplanır.

$$h_t = f(h_{t-1}, x_t) \quad (3.1)$$

Giriş verileri x, Şekil 3.7.'de gösterilen giriş katmanı A aracılığıyla modele aktarılır ve merkezi katman h, her biri kendi aktivasyon fonksiyonları, ağırlıkları ve önyargıları olan çoklu gizli katmanlar içerir. tanh aktivasyon fonksiyonudur. Önceki gizli durum h_{t-1} ile temsil edilir ve ağırlığı W_{ph} ile gösterilir. Denklem 3.2'de gösterildiği gibi Mevcut gizli durumun ağırlığı W_{xh} , mevcut girdi ise x_t 'dir.

$$h_t = \tanh(W_{ph} * h_{t-1} + W_{xh} * x_t) \quad (3.2)$$

Çıkış katmanı 'y', gizli katmanın çıkışını bir giriş olarak alır. Gerçek sonucu elde etmek için bazı hesaplamalar yapılır. Gerçek sonuç tahmin edilen değerdir. W_{hy} çıktının ağırlığı, h_t gizli katmanın ağırlığı ve y_t Denklem 3.3'te gösterildiği gibi t zamanındaki çıktıdır.

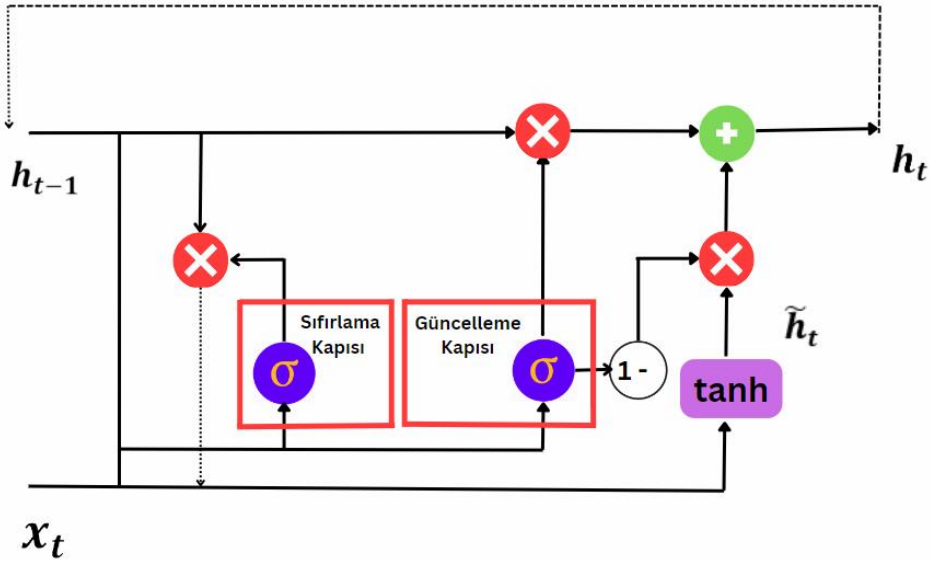
$$y_t = W_{hy} * h_t \quad (3.3)$$

3.2.5 Geçitli Tekrarlayan Birim Ağları (GRU) Modeli

Özellikle derin sinir ağlarında, her bir katmandaki ağırlıkların güncellenmesi amacıyla kullanılan gradient (türev), arka yayılım (backpropagation) yöntemi ile hesaplanır. Ancak bu süreçte, derin katmanlar arasında gradient değerleri giderek küçülür ve en alt katmanlara ulaştığında neredeyse sıfıra yaklaşabilir. Bu da daha alt katmanlardaki ağırlıkların yeterince güncellenememesine ve modelin doğru şekilde öğrenememesine neden olur. Bu duruma "vanishing gradient" problemi denir.

GRU, RNN'lerin bir türevi olup, LSTM'ye alternatif olarak geliştirilmiştir. GRU'nun amacı RNN'lerin Vanishing Gradient problemini çözmek ve uzun vadeli bağımlılıkları daha verimli bir şekilde öğrenmektir.

GRU, LSTM'ye göre daha basit bir yapıya sahip olup daha az sayıda kapı kullanır. Bu da modelin daha hızlı ve hesaplama açısından daha verimli olmasını sağlar. Sıfırlama ve Güncelleme Kapısı hücrelerin nasıl güncelleneceğini ve geçmiş bilginin ne kadarının korunacağını kontrol eder. GRU modeli Şekil 3. 8.'de gösterilmiştir.



Şekil 3. 8. GRU Modeli

Kaynak: (Zaheer vd., 2023)

Güncelleme kapısı, hücredeki bilginin ne kadarının taşınacağını ve yeni bilgi ile güncelleneceğini kontrol eder. Bilginin ne kadarının korunup ne kadarının yeni bilgi ile değiştirilmesi gerektiğine karar verir. Güncelleme kapısı, hücrenin önceki bilgisinin korunup korunmaması gerektiğini belirler. Hesaplama formülü şu şekildedir:

$$Z_t = \sigma(W_Z \cdot [h_{t-1}, X_t]) \quad (3.4)$$

Z_t : Güncelleme kapısının çıktısı

W_Z : Güncelleme kapısının ağırlık matrisi

h_{t-1} : Önceki gizli katman durumu

X_t : O anki giriş verisi

σ : Sigmoid aktivasyon fonksiyonu

Sıfırlama kapısı, önceki duruma ne kadar önem verileceğini belirler. Bu kapı, düşük bir değer aldığıında, hücre eski bilgiyi tamamen unutarak sadece yeni girdilere odaklanır. Sıfırlama Kapısı eski bilginin ne kadarının unutulacağını kontrol eder. Hesaplama formülü şu şekildedir:

$$r_t = \sigma(W_r \cdot [h_{t-1}, X_t]) \quad (3.5)$$

r_t : Sıfırlama kapısının çıktısı

W_r : Sıfırlama kapısının ağırlık matrisi

h_{t-1} : Önceki gizli katman durumu

X_t : O anki giriş verisi

Aday Durumu (Candidate Hidden State), Sıfırlama kapısının sonucuna göre, aday bir yeni hücre durumu hesaplanır. Bu durum, sıfırlama kapısı bilginin ne kadarının kullanılacağını belirlediği için önemlidir:

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \odot h_{t-1}, X_t]) \quad (3.6)$$

\tilde{h}_t : Aday hücre durumu

W_h : Aday durum için ağırlık matrisi

r_t : Sıfırlama kapısının çıktısı

h_{t-1} : Önceki gizli katman durumu

X_t : t anki giriş verisi

\odot : Eleman bazında çarpma işlemi

\tanh : Tanh aktivasyon fonksiyonu

Yeni Gizli Durum (New Hidden State), güncelleme kapısına göre eski durum ve aday durum birleştirilerek hesaplanır:

$$h_t = (1 - z_t) \odot h_{t-1} + Z_t \odot \tilde{h}_t \quad (3.7)$$

h_t : Yeni hücre durumu

Z_t : Güncelleme kapısının çıktısı

h_{t-1} : Önceki gizli katman durumu

\tilde{h}_t : Aday hücre durumu


3.2.6 Uzun Kısa Süreli Bellek Ağları (LSTM) Modeli

LSTM mimarisi içindeki geçit mekanizmaları temel olarak aşağıdaki yapılardan oluşmaktadır (Rani vd., 2022).

Forget Gate (Unutma Kapısı): Bu kapı, hücre durumundan hangi bilginin silineceğinden sorumlu olan kapıdır. Bir önceki çıktıyı (O_{t-1}) ve mevcut hücre girişini (I_t) dikkate alıp, 0 ile 1 arasında değere ulaşmak amacıyla sigmoid fonksiyonu gizli katmanların her birine uygulanır. Çıktı değeri “1” olarak alınır ise bu bilgi saklanır; diğer durumlarda ise silinir.

Update Gate (Güncelleme Kapısı): Kapı, bir önceki çıktıyı (O_{t-1}) ve mevcut hücre girişini (I_t) aynı değerlerle işleyerek sigmoid ile \tanh fonksiyonlarının uygulandığı bir aktivasyon katmanına gönderir. Bu katmanın çıkışı, her iki çıkış değerinin çarpımı sonucunda elde edilir ve r ile sonuçlanır. Son olarak, durum güncellemesi için elde edilen r değerine unutma kapısının çıkışı eklenir.

Output Gate (Çıkış Kapısı): Bu kapı, hücredeki bilginin sonrasında gelen diğer hücreye iletilip ileilmeyeceğinin belirlenmesinden sorumludur. (Cihan ve Marttin, 2023)



Şekil 3. 9. LSTM modeli

Kaynak: (Aparna, 2018)

Şekil 3.9.'da hücrede kullanılan ve aşağıda ayrıntıları verilen tüm eşitlikleri göstermektedir.

Denklemlerde σ ifadesi sigmoid fonksiyonu, b ifadesi kapılar için bias değerini, W ifadesi ise ağırlıkları ifade etmektedir.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.8)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.9)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.10)$$

$$\check{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.11)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes \check{c}_t \quad (3.12)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (3.13)$$

3.2.6.1. Sigmoid Fonksiyonu

Bu fonksiyon 0 veya 1 sonucunu verir. LSTM'de bilginin unutulması veya hatırlanması için kullanılırken, ayrıca hücreler arasında veri aktarımı için kullanılmaktadır (Sundar ve Patchaiammal, 2022: 228). Denklem 3.14'te Sigmoid fonksiyonu sunulmuştur.

$$S(x) = \frac{1}{1+e^{-x}} \quad (3.14)$$

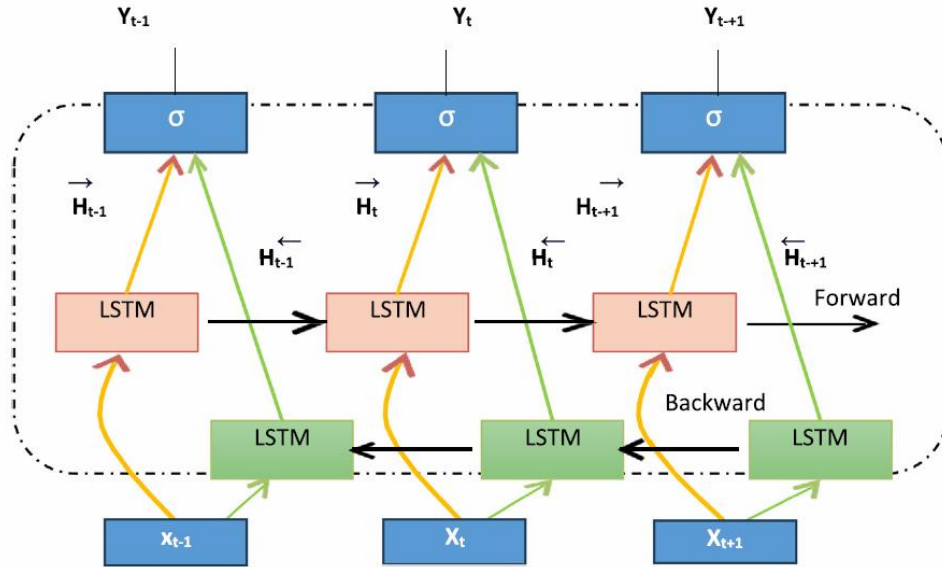
3.2.6.2. Hiperbolik Tanjant Fonksiyonu

Bu fonksiyon ise hem pozitif hem de negatif değerler üretebilir. Denklem 3.15'te hiperbolik tanjant fonksiyon verilmiştir.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.15)$$

3.2.7 Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM) Modeli

BiLSTM modelinde, LSTM'nin çalışma prensibi aynı kalmakla birlikte bu süreci çift yönlü (bidirectional) hale getirir. Tek yönlü LSTM'lerin veri akışını yalnızca geçmişten geleceğe doğru işlemesine karşın, BiLSTM, veriyi hem geçmişten geleceğe hem de gelecekte geçmişe doğru işler. Çift yönlü yapısı sayesinde, her bir zaman adımı için hem ileri hem de geri yönlü iki ayrı LSTM hücresinden oluşur. Çıktı hem geçmiş hem de gelecek bağlamıyla birlikte şekillenir. Bu özellik, özellikle dil işleme ve zaman serisi gibi sıralı veri içeren problemler için oldukça önemlidir, çünkü verinin iki yönlü bağımlılıklarını öğrenir ve daha kapsamlı bir öğrenme sağlar. BiLSTM modeli Şekil 3. 10.'da gösterilmiştir.



Şekil 3. 10. BiLSTM Modeli

Kaynak: (Wagas, 2024)

BiLSTM'ye ait formülasyon Denklem 3.16'da gösterilmiştir.

$$h_t = [\overrightarrow{h}_t, \overleftarrow{h}_t] \quad (3.16)$$

İleri Yönlü LSTM (Forward LSTM)' de Zaman adımı t için İleri yönlü LSTM'nin hesaplanması Denklem 3.17'de belirtilmiştir.

$$\overrightarrow{h}_t = LSTM_{forward}(x_t, \overrightarrow{h}_{t-1}, C_{t-1}) \quad (3.17)$$

Geri Yönlü LSTM (Backward LSTM)'de Zaman adımı t için Geri yönlü LSTM'nin hesaplanması Denklem 3.18'de belirtilmiştir.

$$\overleftarrow{h}_t = LSTM_{backward}(x_t, \overleftarrow{h}_{t+1}, C_{t+1}) \quad (3.18)$$

Temel bir LSTM'de, gizli çıktılar LSTM katmanları arasında her iki komşu LSTM hücresine aktarılır ve bir sonraki LSTM hücresi için girdi olarak kullanılır. Çift Yönlü LSTM mimarisi, bilginin ileriye ve geriye doğru akmasına izin vererek bunu geliştirir. Çift Yönlü LSTM'de, ileri akış sistem varyasyonlarını yakalarken, geri akış tahminleri yumuşatmaya yardımcı olur. İleri ve geri yollardan gelen çıktılar daha sonra birleştirilir. Çift yönlü bir LSTM için geçerli denklemler aşağıdaki gibidir (Wagas vd.,2024):

$$H_{i1} = f(U_1 * X_i + W_1 * h_{i-1}) \quad (3.19)$$

$$H_{i2} = f(U_2 * X_i + W_2 * h_{i-1}) \quad (3.20)$$

$$y_i = \sigma(V * [h_{i1} * h_{i2}]) \quad (3.21)$$

$[h_{i1} * h_{i2}]$ İleri LSTM katmanı için i zaman adımıdaki gizli durumdur.

f : Aktivasyon fonksiyonu (ReLU ya da tanh gibi)

U_1 ve U_2 İleri LSTM katmanındaki giriş-gizli bağlantılar için ağırlık matrisleridir.

W_1 ve W_2 İleri LSTM katmanındaki gizli-gizli bağlantılar için ağırlık matrisleridir.

y_i çıktısı, her iki yönden gelen sonuçların birleştirilmesiyle elde edilir.

V ağırlık matrisi, ileri ve geri LSTM katmanlarından gelen birleştirilmiş gizli durumları dönüştürmek için kullanılır.

4. MATERYAL VE METOD

4.1 Veri Seti ve Özellikleri

2016 Ocak ile 2024 Haziran ayları boyunca aylık bazda toplanmış elektrik tüketim verileri kullanılmıştır. Veriler Aydınlatma, Mesken, Sanayi, Tarımsal Sulama ve Ticarethane gibi farklı sektörlerdeki elektrik tüketimini kapsamaktadır. Tablo 4.1.'de örnek veri seti gösterilmektedir. Tablo 4.2.'de ise çalışmada kullanılan kütüphanelere dair bilgiler yer almaktadır.

Tablo 4.1. Örnek Veri Seti

TARİH	AYDINLATMA	MESKEN	SANAYİ	TARIMSAL SULAMA	TİCARETHANE
1.01.2016	2180.06	10726.27	101069.55	138.55	23142.14
2.01.2016	1335.92	9311.34	96873.92	75.53	16069.83
3.01.2016	1558.11	9575.19	105671.25	137.44	16139.92
4.01.2016	1557.04	8918.78	106239.04	83.15	15561.14
...
...
6.01.2024	1556.52	11439.94	147447.73	2298.26	13863.40

Kaynak: (EPDK, 2024)

Tablo 4. 2. Python Kütüphaneleri

KULLANILAN KÜTÜPHANELER	AÇIKLAMA	KURUCU- GELİŞTİRİCİ
PANDAS	Veri işleme ve Analizi	Wes McKinney Ursa Labs
NUMPY	Matematiksel & İstatistiksel Hesaplamalar	Travis Oliphant Open Teams
MATPLOTLIB	Verilerin 2 ya da 3 boyutlu olarak Görselleştirilmesi	John D.Hunter NumFOCUS
KERAS	Derin Öğrenme	François Chollet Google
SCIKIT-LEARN	İstatistikler Analizler Makine Öğrenmesi (Regresyon, Küme Analizi vb.)	Cournapeau David Mercari

4.1.1. Veri Kaynağı

Bu akademik çalışmada ele alınan veri seti, Türkiye'nin mevcut elektrik piyasasını yöneten EPDK'nin her ay yayımladığı Elektrik Piyasası Aylık Resmi İstatistikleri isimli raporlardan elde edilmiştir. Bilecik ilinin 2016 Ocak- 2024 Haziran ayları arasındaki dönemdeki aylık bazlı elektrik tüketimi verilerini içerir. Aydınlatma, Mesken, Sanayi, Tarımsal Sulama ve Ticaret sektörlerine ait aylık tüketim verilerinden oluşan veri seti, beş farklı tüketim davranışını temsil etmektedir. Tüketim dinamikleri ve zamana bağlı değişkenler her sektörde farklılık arz ettiğinden, bu veri çeşitliği sektörel tahmin modellerinin geliştirilmesinde önemli rol oynamaktadır.

Söz konusu veri seti, her ayın sektörel elektrik tüketim miktarlarını MWh cinsinden belirtilmiştir. 2016 yılından beri EPDK tarafından tüm sektörler için yayımlanan aylık istatistik raporlarından derlenen veri seti, Bilecik ili için geleceğe yönelik sektörel elektrik tüketim tahminlerinin geliştirilmesine ve ülke çapındaki sektörel enerji tüketim profillerinin anlaşılmasına katkı sunabilir.

4.1.2. Verinin Temizlenmesi ve Hazırlanması

Verilerin hazırlanması aşamasında gerçekleştirilen ön kontrollerde, herhangi bir kayıp ya da hatalı değerin bulunmadığı gözlemlenmiş ve muhtemel bazı anormalliklerin önemli ölçüde göz ardı edilebileceği varsayılmıştır. Fakat daha verimli bir performans ve modelin sorunsuz işleyişi açısından standart bazı ön işlemler uygulanmıştır.

Veri seti ilk aşamada Pandas kütüphanesi kullanılarak yüklenmiştir. Zaman serisi verisi olduğundan, veriler tarihsel sıralamaya göre düzenlenmiş ve analizde kullanılacak olan Tarih sütunu pd.to_datetime fonksiyonu ile datetime tipine dönüştürülmüştür. Bu işlem, modelin zaman serisi verisini doğru bir şekilde işlemesi için önemlidir. Ayrıca, yalnızca ilgili sektörlerle ait veriler seçilmiş ve gereksiz sütunlar çıkarılmıştır. Veri setinde tarihsel dönüşüm ve sıralama işlemi için kullanılan kodlar Şekil 4. 1.'de gösterilmiştir.

```
df['Tarih'] = pd.to_datetime(df['Tarih'])
df = df.sort_values(by='Tarih')
```

Şekil 4. 1. Veri Setinde Tarihsel Dönüşüm ve Sıralama

4.1.3. Zaman Serisi Özellikleri

Zaman serisi analizlerinde veri özellikleri kritik öneme sahiptir. Modelin eğitimi için kullanılan veri seti, beş farklı sektör için çeşitli örüntüler ve dalgalanmalar içerir. Tarımsal sulama sektöründe meydana gelen tüketim değişiklikleri bu duruma örnek olabilir. Özellikle yaz aylarında, tarımsal sulama sektörü aylık tüketim değerlerinde önemli bir artış göstermektedir. Bununla birlikte, sanayi sektörü tüketimi daha dengeli ve kalıcı hale getirmektedir.

Bu durum özellikle zaman seri model yaklaşımında verilerin doğru bir biçimde bölünmesini zorunlu kılmıştır. Çalışmamızda 2016-2019 dönemi arasındaki veriler eğitim verisi, 2020-2024 Haziran dönemi arasındaki veriler ise test verisi olarak tasnif edilmiştir. Bu işlem, yapay sinir ağı modelinin uygulama başında geçmiş verilerden öğrenmesini, akabinde ise bu eğitime dayanarak gelecekteki sektörel aylık tüketim miktarlarını daha doğru ve güvenilir bir şekilde tahmin etmesini sağlamaktadır.

4.2. Veri Hazırlama Süreci

4.2.1 Verinin Normalizasyonu ve Ölçeklenmesi

Zaman serisi verisi, belirli bir zaman dilimine göre sıralı olarak elde edilen verilerden oluşur. Bu çalışmada elektrik tüketim verileri, her sektör için aylık olarak düzenlenmiştir. Makine öğrenimi süreçlerinde modellerin verimini arttırmak amacıyla sıklıkla kullanılan normalizasyon tekniği, çalışmadaki modellerinin hızlı yanıt vermesine önemli bir katkı sağlamıştır. (Sagheer ve Kotb, 2019).

Bu doğrultuda zaman serisi verilerinin işlenmesi için, her sektörün elektrik tüketim verisi MinMaxScaler ile 0-1 aralığında normalize edilmiştir. Bu işlem, modelin eğitim sürecinde daha hızlı ve dengeli bir öğrenme süreci geçirmesini sağlar. Bu normalizasyon işlemi ile her sektörün verisi aynı ölçek seviyesine getirilerek, farklı büyüklüklerdeki verilerle çalışmak daha kolay hale getirilmiştir. Veri seti, yapay sinir ağlarının veriyi daha verimli bir şekilde işlemesi için normalize edilmiştir. Normalizasyon işlemi için kullanılan kodlar Şekil 4. 2.'de gösterilmiştir.

```
scalers = {}
for column in columns:
    scaler = MinMaxScaler(feature_range=(0, 1))
    df[column] = scaler.fit_transform(df[[column]])
    scalers[column] = scaler
```

Şekil 4. 2. Normalizasyon İşlemi

4.2.2. Zaman Serisi Veri Seti Oluşturma

Yapay sinir ağları genellikle geçmiş verilere dayanarak geleceği tahmin etmek için kullanılır. Bu nedenle, zaman serisi veri seti oluşturulurken girdi-çıkı kavramına özel bir vurgu yapılır. Her bir veri noktası, bir önceki zaman adımı ile ilişkilendirilerek eğitim verisi oluşturulur. Bu işlemde girdi verileri modelin tahmin yapması için gerekli geçmiş bilgiyi sağlarken, çıktı verileri modelin tahmin etmeye çalıştığı değerleri ifade eder.

Zaman serisi oluşturulurken, her bir veri noktası hem kendisi hem de bir önceki zaman adımıyla ilişkilendirilmiştir. Paylaşılan kodda bu işlem, create_dataset fonksiyonu ile yapılmıştır. Burada:

- X1: Modelin şu anki zaman adımıdaki girdisi,
- X2: Bir önceki zaman adımıdaki girdi,
- Y: Şu anki zaman adımıdaki tahmin edilmesi gereken değer (çıkı) olarak tanımlanmıştır.

Veri seti oluşturma işlemi için kullanılan kodlar Şekil 4. 3.'de gösterilmiştir.

```
def create_dataset(data, time_step=12):
    X1, X2, Y = [], [], []
    for i in range(time_step, len(data)):
        X1.append(data[i])
        X2.append(data[i - 1])
        Y.append(data[i])
    return np.array(X1), np.array(X2), np.array(Y)
```

Şekil 4. 3. Veri Seti Oluşturma

Bu fonksiyon ile model, bir önceki veri noktasını referans alarak şu anki durumu tahmin eder. Yapay sinir ağlarında, geçmiş bilgiler bu şekilde işlenerek gelecekteki değerlerin tahmin edilmesi sağlanır.

Veri seti, zaman serisi modellemeye uygun hale getirilirken 12 zaman adımı (time steps) kullanılarak geçmiş verilerin gelecekteki veriyi tahmin edebilmesi amacıyla yeniden yapılandırılmıştır. Her bir zaman adımı, bir önceki 12 ayın verisini kullanarak bir tahmin yapılmasını sağlamaktadır.

4.2.3. Verinin Eğitim ve Test Setlerine Ayrılması

Uygulama esnasında, zaman serisi verilerinin eğitim ve test setlerine bölünmesi aşamasında zamansal bağımlılığın muhafaza edilmesi büyük önem taşımaktadır. Modelin öğrenme süreci için eğitim seti kullanılırken, gelecek tahminlerinin doğruluğunu ve güvenilirliğini analiz edebilmek için test veri setinden faydalanılmaktadır. Eğitim setine 2016 ile 2019 arasındaki zaman dilimi dahil edilirken, test veri setine 2020 Ocak ayı ile 2024 Haziran ayı arasındaki zaman dilimi dahil edilmektedir. Bu sınırlama, modelin zaman içinde öğrenip öğrenemeyeceğini, tahmin aşamasında genelleme yapıp yapamayacağını belirlemek için çok kritik önem arz etmektedir. Eğitim ve test verilerinin ayrılması işleminde kullanılan kodlar Şekil 4.4.'de gösterilmiştir.

```
train_mask = (dates >= np.datetime64('2016-01-01')) & (dates <= np.datetime64('2019-12-31'))  
test_mask = (dates >= np.datetime64('2020-01-01')) & (dates <= np.datetime64('2024-06-30'))
```

Şekil 4. 4. Eğitim-Test Verilerinin Ayrılması

Bu maskelerle, modelin eğitim ve test veri setleri ayrılmış ve daha sonra modelin doğruluğunu test etmek için kullanılmıştır. Uygulama esnasında, zaman serisi verilerinin eğitim ve test setlerine bölünmesi aşamasında zamansal bağımlılığın muhafaza edilmesi büyük önem taşımaktadır. Modelin öğrenme süreci için eğitim seti kullanılırken, gelecek tahminlerinin doğruluğunu ve güvenilirliğini analiz edebilmek için test veri setinden faydalanılmaktadır. Bu sınırlama, modelin zaman içinde öğrenip öğrenemeyeceğini, tahmin aşamasında genelleme yapıp yapamayacağını belirlemek için kritik önem arz etmektedir.

RNN, GRU, LSTM ve BiLSTM modelleri eğitilirken hiper parametrelerinde bir dizi konfigürasyonlar gerçekleştirilmiştir ve ardından doğrulama sırasında ne kadar iyi performans

gösterdiği gözlenmektedir. Aşırı uyumdan kaçınmak amacıyla, eğitim esnasında Dropout oranını yüzde otuz olarak atanmıştır.

Eğitim sırasında hata sapmalarını tespit ve analiz edebilmek için MAE, RMSE, MSE ve MAPE gibi performans metrikleri takip edilmiştir. Model her sektör için metrik değerlerine binaen kısmen özelleştirilmiş ve ayrı ayrı eğitimlerden geçirilmiştir. Modelin etkinliğini bir bütün olarak değerlendirmek için her epoch dönemin sonunda meydana gelen kayıplardaki değişim analiz edilmiştir.

4.3. Modelin Yapısı ve Eğitim Süreci

Bu kısımda, elektrik tüketimi tahminlerinde kullanılan dört farklı yapay sinir ağı modelinin RNN, LSTM, GRU ve BiLSTM tasarımı, eğitim prosedürü ve hiperparametrelerin optimizasyonu hakkında kapsamlı bir açıklama sunulacaktır.

4.3.1. Model Mimarisi


Veri girdilerini işlemek ve çıktılar üretmek için yapay sinir ağı modelleri, aktivasyon fonksiyonları aracılığıyla çeşitli katmanlar oluşturur ve bu katmanlar arasında öğrenmeyi sağlar. Bu araştırmada dört farklı model (RNN, LSTM, GRU ve BiLSTM) kullanılmıştır. Her model, bir zaman serisi verisi üzerinde tahmin işlemi gerçekleştirmiş olup mimari özellikleri aşağıda gösterilmektedir.

4.3.1.1. Girdi ve Çıktı Katmanları

Her bir modelin girdisi ve çıktısı zaman serisi verisi üzerinden şekillendirilmiştir. Girdi katmanı, zaman adımlarına bölünmüş elektrik tüketim verisini alırken, çıktı katmanı bir tahmin değeri üretmektedir. Modellerin genel yapısı şu şekildedir:

Girdi Katmanı: Her model, 12 zaman adımından oluşan giriş dizisini alır. Bu diziler geçmiş tüketim verilerini içerir ve gelecekteki bir zaman adımı için tahmin yapılmasına olanak tanır. Girdi katmanında, her bir zaman adımı bir dizi şeklinde modele sunulmaktadır.

Çıktı Katmanı: Modellerin çıktı katmanı, ilgili zaman dilimi için tahmin edilen elektrik tüketim değerini üretir. Şekil 4.5.'de çalışmada kullanılan yapay sinir ağı modeli gösterilmiştir.



Şekil 4. 5. Yapay Sinir Ağı Modeli

Zaman adımı 12 olarak belirlenen bu modelde,

- X1: Modelin şu anki zaman adımıdaki girdisi,
- X2: Bir önceki zaman adımıdaki girdi,
- Y: Şu anki zaman adımıdaki tahmin edilmesi gereken değer (çıktı) olarak tanımlanmıştır.

4.3.1.2 Gizli Katmanlar ve Aktivasyon Fonksiyonları

Gizli katmanlar, modellerin öğrenme sürecinde veriler arasındaki ilişkiyi kavrayıp tahminlerde bulunmalarını sağlar. Bu kısımda, her bir modelin gizli katmanları ve kullanılan aktivasyon fonksiyonları açıklanmaktadır.

İki Tekrarlayan Katman: Her modelde iki adet tekrarlayan (RNN, GRU, LSTM ve BiLSTM) katman bulunur, her birinde 128 birim kullanılır.

Dropout: Aşırı öğrenmeyi önlemek amacıyla her tekrarlayan katmandan sonra %30 oranında dropout uygulanır.

Dense Katmanlar: Sonrasında 64 nöronlu bir Dense katman (ReLU aktivasyonu) ve tek nöronlu çıkış katmanı bulunur.

Bu yapı sayesinde, modeller temel olarak benzer derinlik ve düzenlemeye sahipken, farklı tekrarlayan katman türleri sayesinde zaman serisi verilerindeki çeşitli desenleri ve bağımlılıkları yakalayabilirler.

4.3.2. Model Eğitim Süreci

Modelin öğrenme sürecini kapsayan eğitim aşaması, verilerin modele sunulması ve modelin çıktılarıyla geri bildirim alarak parametrelerini optimize etme sürecini içerir. Bu kısımda, modellerin eğitim sürecinde kullanılan hiperparametreler, optimizasyon yöntemleri ve eğitim sırasında model performansının nasıl takip edildiği detaylandırılmaktadır.

4.3.2.1. Hiperparametreler ve Optimizasyon

Model eğitiminin başarısı, doğru hiperparametrelerin seçilmesine bağlıdır. Bu çalışmada, tüm modeller için benzer hiperparametre ayarları kullanılmıştır. Hiperparametreler aşağıda listelenmiştir:

Öğrenme Hızı (learning rate): Tüm modellerde 0.0001 olarak belirlenmiştir. Bu düşük öğrenme hızı, modelin küçük adımlarla öğrenmesini sağlayarak daha iyi sonuçlar elde etmeyi hedeflemiştir.

Epoch Sayısı: Modellerin her biri, her bir sektörde 25, 50, 100 ve 200 olmak üzere farklı epoch değerlerinin kullanıldığı bir eğitim sürecine tabi tutulmuştur. Bu süreçte, model her bir epoch'ta verileri tekrar gözden geçirip hatalarını azaltmaya çalışmıştır.

Batch Size: Her bir modelin eğitiminde 1 batch size kullanılmıştır. Bu, her bir veri örneğinin model tarafından tek tek öğrenilmesini sağlamıştır.

Dropout Oranı: Modellerde %30 dropout oranı kullanılmıştır. Bu oran, aşırı öğrenmenin önüne geçmek için seçilmiştir.

Model eğitim sürecinde, Adam optimizasyon algoritması kullanılmış ve bu algoritma ile model parametrelerinin güncellenmesi sağlanmıştır.

4.3.2.2 Modelin Eğitim ve Doğrulama Kayıplarının Takibi

Modelin performansını izlemek için eğitim ve doğrulama kayıpları her epoch'ta hesaplanmış ve kayıt altına alınmıştır. MSE metriği, modellerin eğitim ve doğrulama kayıplarını ölçmek için kullanılmıştır.

Eğitim süresince, eğitim kaybı ve doğrulama kaybının nasıl değiştiği grafiklerle takip edilmiştir. Her bir modelin eğitim süreci boyunca elde edilen kayıplar şu şekilde gözlenmektedir:

- Eğitim Kaybı (loss): Modelin eğitim verileri üzerindeki hataları ifade eder.

- Doğrulama Kaybı (val_loss): Modelin eğitim süreci boyunca test verileri üzerindeki performansını ifade eder.

Her bir model için eğitim ve doğrulama kayıplarının takip edilmesi sayesinde, modelin ne zaman aşırı öğrenmeye uğradığı belirlenebilmiştir. Modellerin başarı düzeyleri, kayıplar arasındaki farklara bakılarak değerlendirilmiştir.

4.4 Performans Değerlendirme Yöntemleri

Bu kısımda, RNN, GRU, LSTM ve BiLSTM modellerinin performansını değerlendirmek için kullanılan metrikler ve bu metriklerin nasıl hesaplandığı detaylı olarak açıklanacaktır. Model performansını değerlendirmek için yaygın olarak kullanılan Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hatası (MAPE), Ortalama Kare Hata (MSE) ve Kök Ortalama Kare Hata (RMSE) metrikleri üzerinde durulacaktır.

Zaman serisi modellerinde tahmin edilen değerlerin gerçek değerlerle ne kadar uyumlu olduğunu değerlendirmek için farklı hata metrikleri kullanılmaktadır. Bu metrikler, modelin genel doğruluğunu ve performansını anlamak için önemli ölçütlerdir. Çalışmada kullanılan performans metrikleri, modellerin hata oranlarını minimize etmek amacıyla hesaplanmıştır.

4.4.1. Ortalama Mutlak Hata (MAE)

MAE, karşılık gelen veri noktası çiftleri arasındaki farkların mutlak büyüklüğünü değerlendirerek, verilen bağlamda tahmin edilen değerler ile gerçek gözlemler arasında doğrudan bir karşılaştırma yapılmasını sağlar (Chou ve Pham, 2013), MAE'nin hesaplanması Denklem 4.1'de ayrıntılı olarak açıklanmıştır.

$$MAE = \frac{1}{m} \sum_{i=1}^m |P_i - T_i| \quad (4.1)$$

P_i : Tahmin Değerleri

T_i : Gerçek Değerler

4.4.2. Ortalama Mutlak Yüzde Hatası (MAPE)

Zaman serisi tahminlerinde sıkça kullanılan MAPE fonksiyonu, MAE yapısına benzer şekilde mutlak hatanın yüzdesini alarak hata durumunu hesaplar. Model tarafından tahmin edilen

değerlerin hatalarının ne kadar büyük olduğunu yüzdesel olarak hesapladığı için anlaşılması daha kolay bir metriktir. (Chicco vd., 2020). MAPE'nin formülasyonu Denklem 4.2'de verilmiştir.

$$MAPE = \frac{100}{m} \sum_{i=1}^m \left| \frac{P_i - T_i}{P_i} \right| \quad (4.2)$$

P_i : Tahmin Değerleri

T_i : Gerçek Değerler

4.4.3. Ortalama Kare Hata (MSE)

MSE, tahmin edilen değerler ile gözlemlenen veri noktaları arasındaki karesel farkların ortalamasını ölçer (Feng vd., 2020). MSE'nin formülasyonu Denklem 4.3'te verilmiştir.

$$MSE = \frac{1}{m} \sum_{i=1}^m (P_i - T_i)^2 \quad (4.3)$$

P_i : Tahmin Değerleri

T_i : Gerçek Değerler

4.4.4. Kök Ortalama Kare Hata (RMSE)

RMSE, tahmin hatalarının (artıkların) standart sapmasının bir ölçüsü olarak hizmet eder ve veri noktalarının optimum uydurma çizgisi etrafında ne kadar yakın kümелendiğinin bir göstergesini sağlar (Reddy ve Naqash, 2019). RMSE'nin formülasyonu Denklem 4.4 ile tanımlanmıştır.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (P_i - T_i)^2} \quad (4.4)$$

P_i : Tahmin Değerleri

T_i : Gerçek Değerler

5. BULGULAR VE TARTIŞMALAR


Bu bölüm, tahminlerin sonuçlarını sektörel olarak incelemek ve RNN, GRU, LSTM ve BiLSTM modellerinin performansının bir analizini sunmaktadır. Çalışmanın sonuçları, modellerle ilgili avantaj ve dezavantajlarını gözler önüne sererken, sektörel analizlere de imkân sağlamaktadır. Ayrıca, gelecekte yürütülebilecek araştırma projeleri için de çeşitli fikirler sunulmuştur.

5.1. Aydınlatma Sektörü

Bu kısımda Aydınlatma sektörüne ait 25-50-100 ve 200 epoch değerleri için modellerin eğitim ve doğrulama kaybı ile modellerin tahmin sonuçlarının gerçek verilerle karşılaştırılması ve performans metrikleri sırasıyla sunulmuştur.

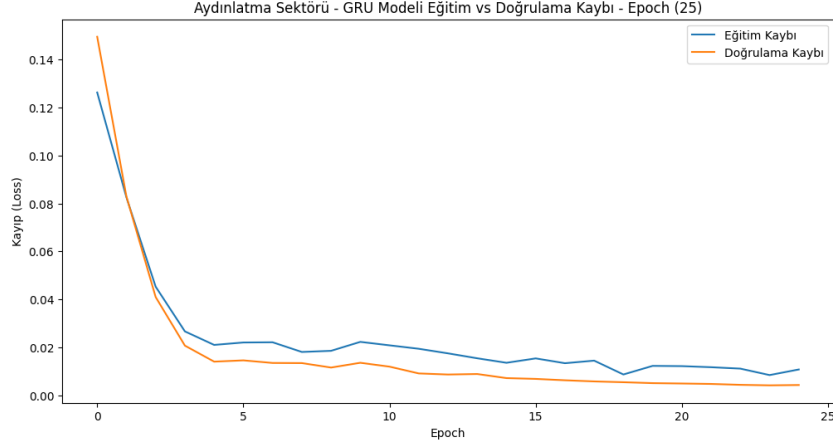
5.1.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)

Aydınlatma sektöründe epoch 25 değerinde tüm modellerin eğitim ve doğrulama kayıpları incelendiğinde, eğitimin başlangıcında hızlı bir düşüş yaşanmıştır. Ancak belirli bir epoch değerinden sonra kayıplar dengeli bir seviyeye ulaşmıştır.




Şekil 5. 1. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5.1.'de diğer modellere kıyasla en düşük doğrulama kaybına sahip olan RNN modeli, başlangıçtaki hızlı düşüşten sonra 10. epoch'tan itibaren eğitim ve doğrulama kayıplarını neredeyse eşit seviyede tutmayı başarmıştır. Bu durum, modelin daha az aşırı öğrenme eğilimi gösterdiğini işaret etmektedir.



Şekil 5. 2. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)

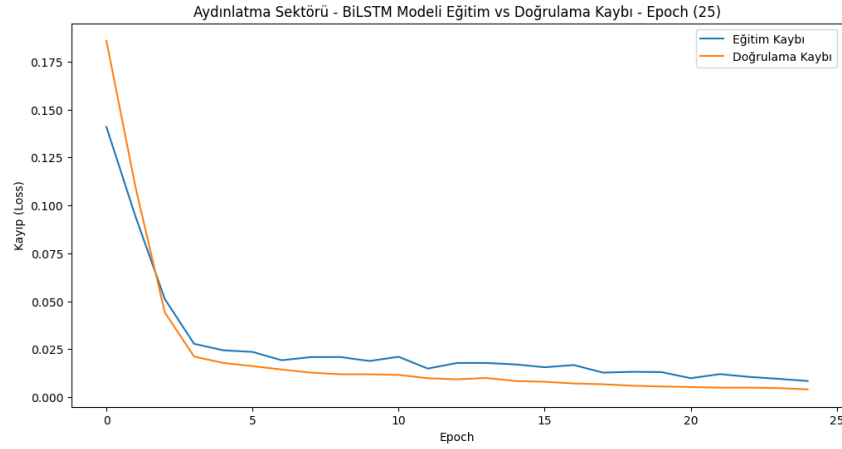
Şekil 5.2.'de GRU modelinde eğitim ve doğrulama kayıplarının birbirine oldukça yakın olduğu görülmektedir. 3. epoch'tan sonra GRU modeli de oldukça düşük kayıplarla dengeli hale gelmiştir.



Şekil 5. 3. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5.3.'de Başlangıçta diğer modellere kıyasla daha yüksek doğrulama kaybı gösteren LSTM, hızlı bir şekilde düşüş göstererek 5. epoch'tan sonra kayıpları azaltmış ve eğitim ve doğrulama kayıpları arasındaki fark en aza inmiştir.


Şekil 5.4.'de BiLSTM modelinde hem eğitim hem de doğrulama kayıpları, başlangıçta oldukça yüksektir ve kısa sürede hızlı bir düşüş yaşanarak 5. epoch'tan itibaren dengeli bir duruma gelmiştir. Eğitim kaybı doğrulama kaybıyla benzer seviyede hareket etmiş ve belirgin bir aşırı öğrenme durumu gözlenmemiştir.



Şekil 5. 4. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

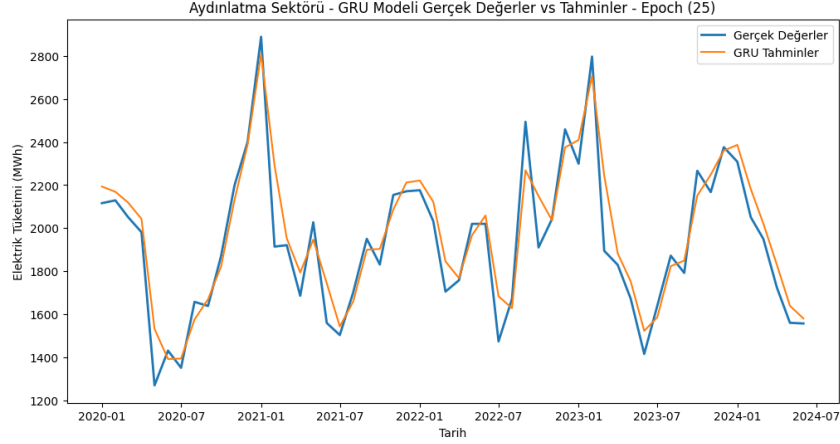
5.1.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)

Modellerin tahmin sonuçları ile gerçek veriler karşılaştırıldığında, tüm modellerin Aydınlatma sektörü için 2020-2024 yılları arasındaki tahminlerinde genel eğilimleri doğru bir şekilde yakaladıkları gözlenmektedir. Ancak bazı modeller, gerçek verilere daha yakın sonuçlar vermiştir.



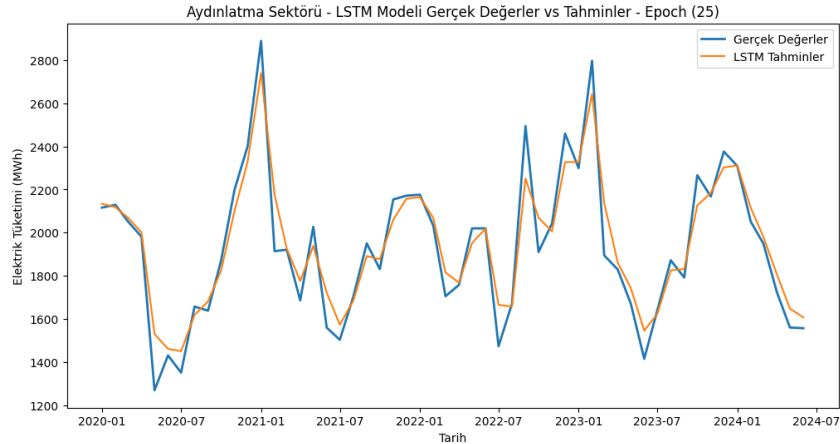
Şekil 5. 5. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5.5.'de RNN modeli, diğer modellere göre daha yüksek bir doğruluk göstermiştir. Özellikle ani tüketim değişikliklerinde gerçek verilerle paralel sonuçlar vermesi, modelin avantajlarından biridir. 2022 yılı sonrası dalgalanmalarda gerçek değerler ile örtüşme oranı oldukça yüksektir.



Şekil 5. 6. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 25)

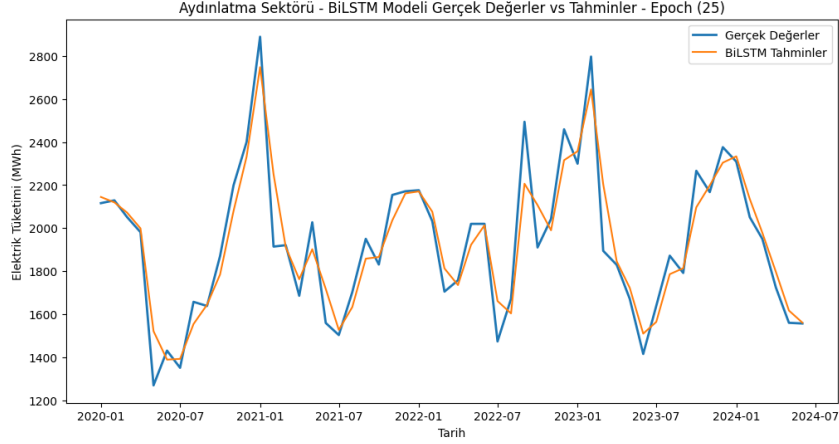
Şekil 5.6.'da GRU modeli, tahminlerde yüksek doğruluk oranı sunmuş, fakat özellikle 2022 yılında oluşan dalgalanmalarda gerçek verilerin altına düşen tahminler yapmıştır. Ancak genel eğilimi başarılı bir şekilde yakalamıştır.



Şekil 5. 7. Aydınlatma – LSTM Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5.7.'de LSTM modeli, tahmin edilen verilerin gerçek verilere oldukça yakın olduğu bir modeldir. Özellikle tüketim zirvelerinde diğer modellere göre daha iyi sonuçlar vermiştir. Ancak bazı küçük sapmalar gözlenmiştir.

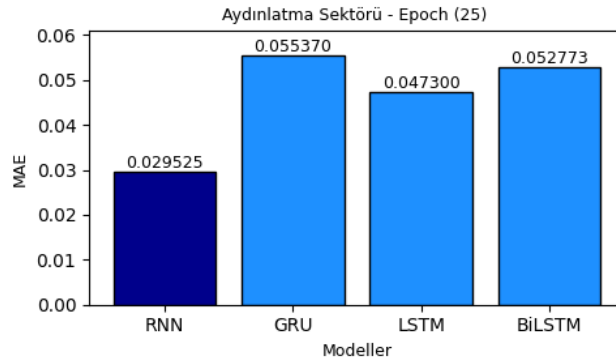
Şekil 5.8.'de BiLSTM modelinde tahmin edilen değerler genel olarak gerçek verilere yakın olsa da bazı tepe değerlerde (özellikle 2021 ve 2022 yılları arasında) sapmalar gözlenmektedir. Tüketim artışlarını ve ani düşüşleri yakalama konusunda modelin hata yaptığı görülmektedir.



Şekil 5. 8. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25)

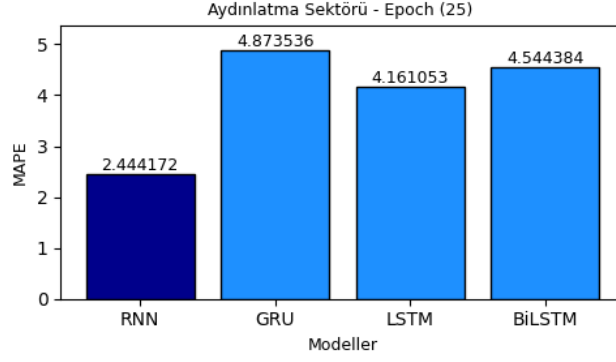
5.1.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)

Aydınlatma sektöründe epoch 25'teki değerlendirmeye göre, en iyi performans gösteren model RNN olmuştur. Bu model hem eğitim/doğrulama kayıplarında hem de hata metriklerinde diğer modellere kıyasla daha düşük hatalar göstermiştir. GRU ve BiLSTM modelleri ise genel performans açısından daha geride kalmış olup, özellikle yüksek tüketim zamanlarında daha büyük hatalar yapmıştır. LSTM modeli ise bazı zaman dilimlerinde başarılı sonuçlar verse de genel hata oranlarında RNN'in gerisinde kalmıştır. Bu analizde, RNN modelinin Aydınlatma sektöründeki verileri daha iyi öğrendiği ve tahmin başarısının daha yüksek olduğu sonucuna varılmıştır.




Şekil 5. 9. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 25)

Şekil 5.9.' da görüldüğü üzere RNN modeli en düşük MAE değeri olan 0.029 ile diğer modellere göre daha başarılı sonuçlar vermiştir. GRU (0.055370), BiLSTM (0.052773) ve LSTM (0.047300) modelleri RNN modeline kıyasla daha yüksek hata değerlerine sahiptir.



Şekil 5. 10. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 25)

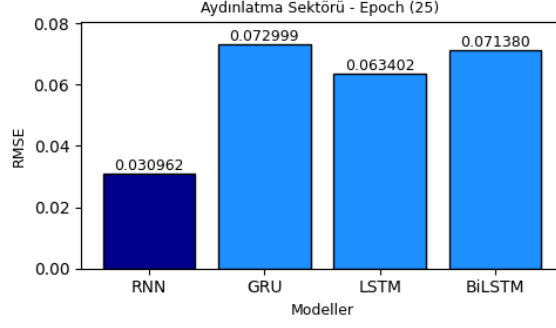
Şekil 5.10.' da görüldüğü üzere RNN modeli (%2.444172) ile en düşük MAPE değerine sahiptir. Bu durum modelin, diğer modellere göre daha düşük oransal hata yaptığını gösterir. GRU, BiLSTM ve LSTM modelleri sırasıyla (%4.873536), (%4.544384) ve (%4.161053) oranında hata yapmıştır.



Şekil 5. 11. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 25)

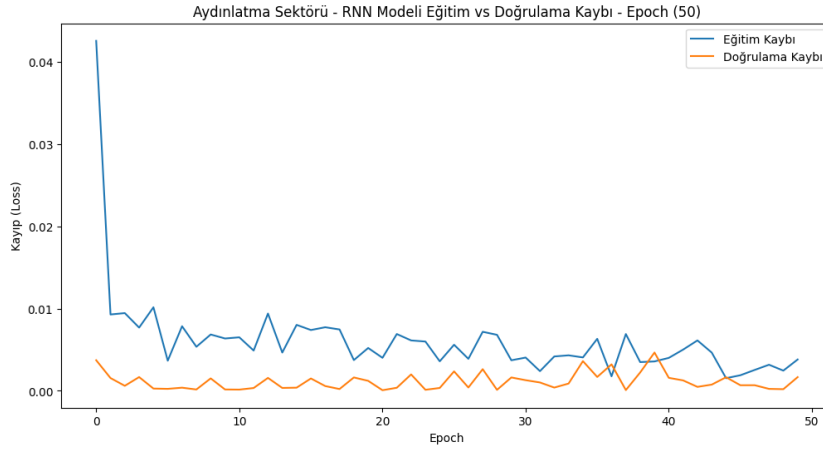
Şekil 5.11.' de görüldüğü üzere RNN, MSE açısından da en düşük hata (0.000959) ile en iyi performansı göstermiştir. Diğer modellerin MSE değerleri daha yüksek olup sırasıyla GRU (0.005329), BiLSTM (0.005095) ve LSTM (0.004020) olarak sıralanmıştır.

Şekil 5.12.'de görüldüğü üzere RNN, RMSE açısından da en düşük hata oranına (0.030962) sahiptir. Bu metrik, modelin büyük sapmalarında ne kadar başarılı olduğunu gösterir. GRU (0.072999), BiLSTM (0.071380) ve LSTM (0.063402) modelleri RNN modeline kıyasla daha yüksek sapma oranlarına sahiptir.



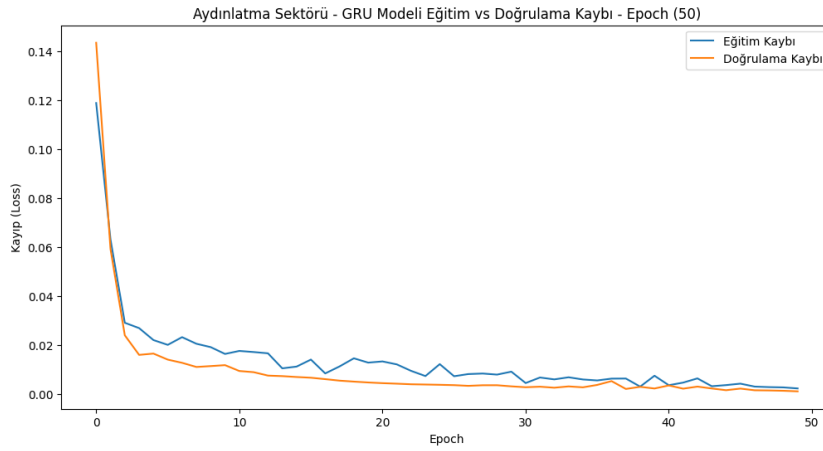
Şekil 5. 12. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 25)

5.1.4. Eğitim ve Doğrulama Kayıpları (Epoch 50)



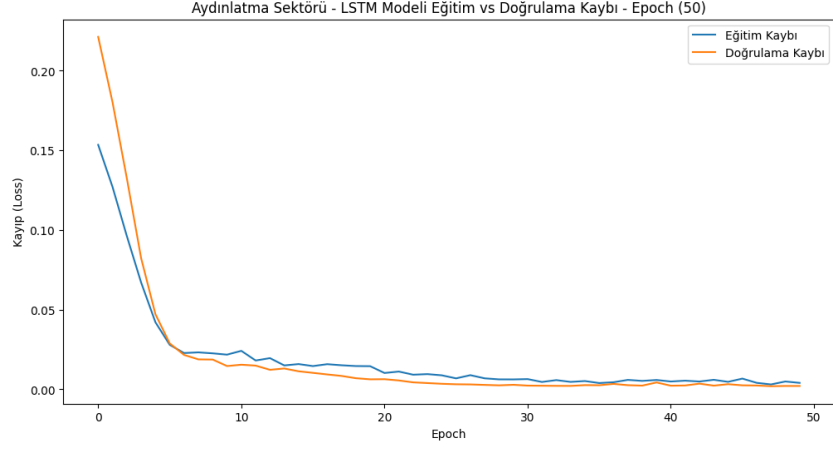
Şekil 5. 13. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.13.'de RNN doğrulama kayıplarının dalgalı bir seyir izlediği görülmüştür. RNN modelinde doğrulama kayıpları, eğitim kayıplarına kıyasla biraz daha yüksek seyretmiştir.



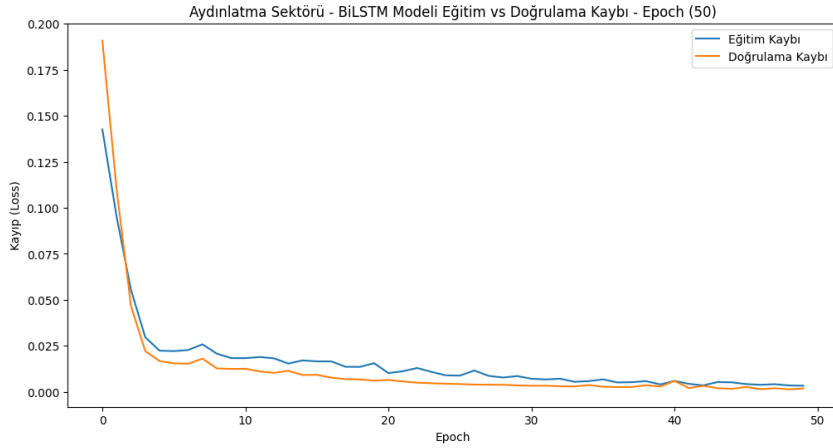
Şekil 5. 14. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)

GRU modeli de benzer bir eğilim ortaya koymuştur. Şekil 5.14.'de Eğitim kayıpları doğrulama kayıplarına çok yakın bir seyir izleyerek aşırı öğrenme riskinin düşük olduğunu göstermiştir.



Şekil 5. 15. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

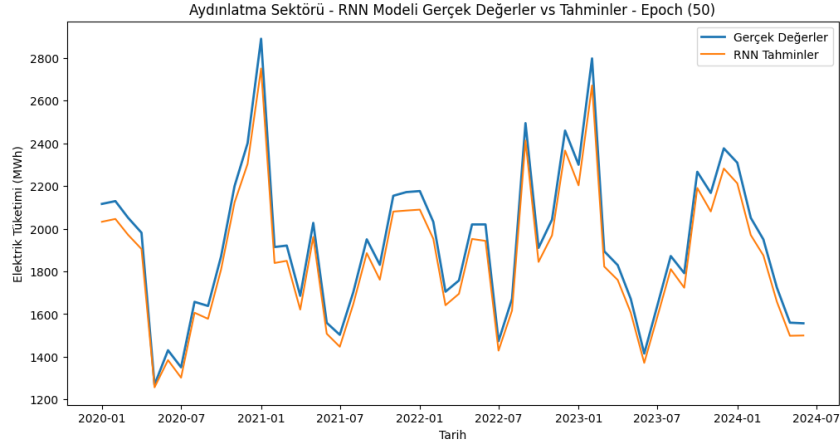
Şekil 5.15.'de LSTM modelinde eğitim ve doğrulama kayıpları hızla düşmüş ve özellikle 20. epoch'tan sonra dengeli bir hale gelmiştir. LSTM'nin doğrulama kayıpları, eğitim kayıplarına yakın seyretmiş ve benzer şekilde modelin aşırı öğrenmeye maruz kalmadığını göstermektedir.



Şekil 5. 16. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

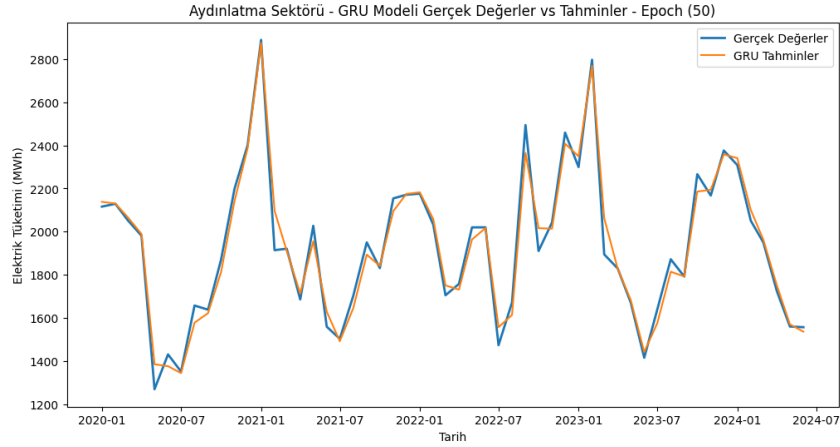
Şekil 5.16.'da görüldüğü üzere BiLSTM modelinde, eğitim ve doğrulama kayıpları başlangıçta hızlı bir şekilde azalmış ve yaklaşık 10. epoch'tan sonra dengelenmiştir. Eğitim ve doğrulama kayıpları oldukça düşük seviyelere inmiştir ve bu, modelin iyi bir şekilde öğrenme eğiliminde olduğunu göstermektedir.

5.1.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)



Şekil 5. 17. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 50)

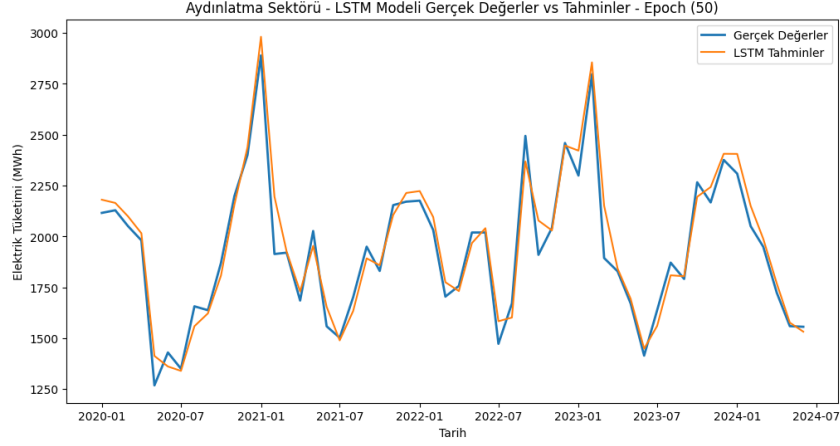
Şekil 5.17.'de RNN modeli ise diğer modellere kıyasla daha dalgalı bir tahmin performansı göstermiştir. RNN'nin gerçek verilerle olan uyumsuzluğu zaman zaman fark edilir derecede fazla olmuştur.



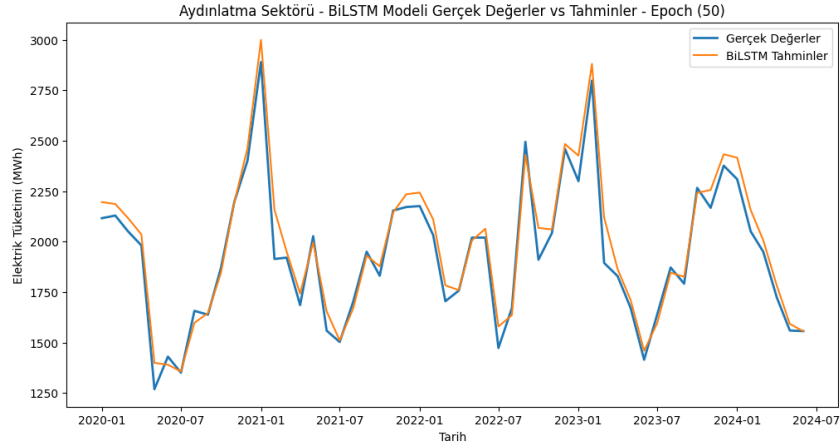
Şekil 5. 18. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 50)

GRU modeli, Şekil 5.18.'de özellikle tahmin değerleri ile gerçek değerler arasında daha az sapma göstermiş ve enerji tüketimi tahminlerinde daha yüksek doğruluk sağlamıştır.

BiLSTM, GRU ve LSTM modelleri genel olarak gerçek verilerle uyumlu tahminler yapmışlardır. Şekil 5.19. ve Şekil 5.20. incelendiğinde tahmin ve gerçek değerler arasındaki farklar minimal düzeydedir ve büyük dalgalanmalar gözlenmemiştir.



Şekil 5. 19. Aydınlatma – LSTM Gerçek Değerler ve Tahminler (Epoch 50)

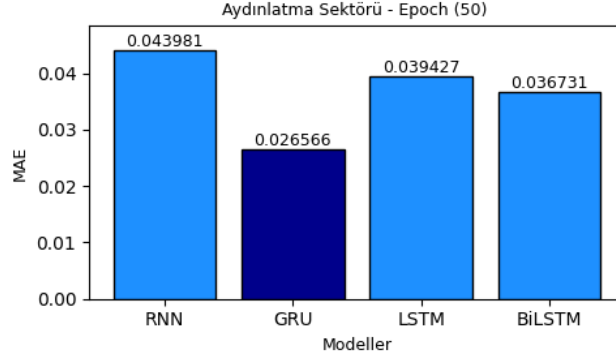


Şekil 5. 20. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50)


5.1.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)

GRU modeli, Aydınlatma sektöründe epoch 50 değeri için en iyi performansı sergilemiştir. Hem hata metriklerinde düşük değerlere sahip olması hem de eğitim ve doğrulama kayıplarındaki uyumu GRU'nun avantajlı olduğunu göstermektedir. RNN modeli ise diğer modellere göre daha düşük bir performans göstermiştir.

Şekil 5.21.'ye göre GRU modeli, en düşük MAE (0.026566) değerine sahip olup, en iyi performansı sergilemiştir. BiLSTM ve LSTM modelleri birbirine yakın değerlerle ikinci ve üçüncü sırada yer almıştır. RNN modeli ise en yüksek MAE değeri ile en zayıf performansı göstermiştir.




Şekil 5. 21. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 50)




Şekil 5. 22. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 50)

Şekil 5.22.'ye göre GRU modeli MAPE metriklerinde de diğer modellere göre daha iyi performans göstermiştir (%2.326799), bu da modelin gerçek değerlere olan yakınlığını göstermektedir. RNN modelinde ise MAPE (%3.636948) gibi daha yüksek bir değerde gerçekleşmiştir.



Şekil 5. 23. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 50)


Şekil 5.23.'de GRU modeli MSE metriklerinde (0.001308) değeri ile en düşük hata oranını sağlamıştır. RNN, BiLSTM ve LSTM ise daha yüksek MSE değerleri sergilemiştir.



Şekil 5. 24. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 50)


Şekil 5.24.'de GRU modeli en düşük RMSE (0.036169) ile diğer modellerden daha başarılı bir performans sergilemiştir. Diğer modellerde ise RMSE değerleri sırasıyla LSTM (0.051574), BiLSTM (0.047696) ve RNN (0.045645) olarak gerçekleşmiştir.

5.1.7. Eğitim ve Doğrulama Kayıpları (Epoch 100)




Şekil 5. 25. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.25.'de RNN modeli ile ilgili sonuçlar incelendiğinde, eğitim kayıplarının diğer modellere göre daha dalgalı bir seyir izlediği gözlenmektedir. Bu dalgalanmalar, eğitim süreci boyunca RNN modelinin daha kararsız bir performans sergilediğine işaret edebilir. Doğrulama kayıpları ise daha düşük ve sabit seviyelerde kalmaktadır. RNN modelinin karmaşık veriler üzerindeki sınırlı öğrenme kapasitesi, modelin genelleme kabiliyetini etkileyebilecek bir faktör olarak değerlendirilmektedir.



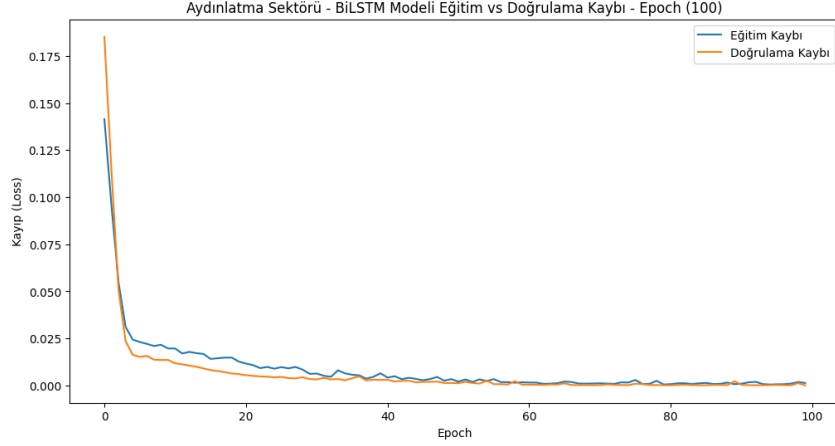
Şekil 5. 26. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.26.'da görüldüğü üzere GRU modeli ile ilgili grafik, eğitim ve doğrulama kayıplarının 20. epoch'a kadar belirgin bir şekilde azaldığını ve bu noktadan itibaren durağanlaştığını ortaya koymaktadır. Şekil 5.26 genel olarak BiLSTM ile benzer bir eğilim göstermektedir. Bununla birlikte, GRU modelinde kayıplarda görülen küçük dalgalanmaların daha fazla olduğu gözlenmektedir.



Şekil 5. 27. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.27.'de LSTM modeli, başlangıçta yüksek kayıplar sergilemekte olup, bu kayıplar hızla azalarak 20. epoch'tan sonra dengeli bir seviyeye ulaşmaktadır. LSTM modelinin başlangıç kayıpları, BiLSTM ve GRU modellerine kıyasla daha yüksek olmakla birlikte, eğitim ve doğrulama kayıplarının zamanla birbirine yakın seyretmesi, modelin aşırı öğrenmeden uzak olduğunu göstermektedir. Kayıpların düşük seviyelere inmiş olması, modelin genel başarısına işaret etmektedir.




Şekil 5. 28. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.28.'de BiLSTM modelinde eğitim ve doğrulama kayıplarının hızla azaldığı ve yaklaşık 20. epoch'tan sonra dengeli hale geldiği görülmektedir. Eğitim ve doğrulama kayıplarının birbirine yakın seyretmesi, modelin aşırı öğrenme eğiliminde olmadığını düşündürmektedir.


Epoch 100 için eğitim ve doğrulama kayıplarına baktığımızda tüm modellerde belirgin bir düşüş gözlemlenmektedir. Modellerin eğitim kayıpları doğrulama kayıplarına oldukça yakın seyretmekte, bu da modellerin aşırı öğrenme yapmadığını göstermektedir. BiLSTM ve GRU modelleri doğrulama ve eğitim kaybı açısından en iyi performansı göstermektedir. Eğitim ve doğrulama kayıpları neredeyse sıfıra çok yakın değerlerde seyretmektedir. LSTM ve RNN modellerinde ise doğrulama kayıpları diğer modellere göre daha fazladır, özellikle RNN modelinde bu fark belirgindir.

5.1.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100)




Şekil 5. 29. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5.29.'da RNN modeli incelendiğinde, tahmin edilen değerlerin genel olarak gerçek değerlerle uyumlu olduğu ancak diğer modellere kıyasla daha fazla sapma gösterdiği gözlemlenmektedir. Özellikle büyük dalgalanmaların yaşandığı zaman dilimlerinde RNN modelinin tahminlerde zaman zaman geride kaldığı anlaşılmaktadır.



Şekil 5. 30. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 100)


Şekil 5.30'da GRU modeli tahminler açısından gerçek değerlerle güçlü bir uyum göstermektedir. Grafik incelendiğinde, özellikle tüketim verilerinde görülen artış ve düşüşlerin GRU tarafından etkin bir şekilde yakalandığı görülmektedir. Bazı noktalar dışında, tahminlerin gerçek değerlere oldukça yakın olduğu ve modelin zaman serisi verilerini başarılı bir şekilde öğrendiği anlaşılmaktadır.



Şekil 5. 31. Aydınlatma –LSTM Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5.31.'de LSTM modeli de benzer bir doğruluk sergilemektedir. Sonuçlar, modelin büyük oranda gerçek değerleri takip ettiğini göstermektedir. Özellikle elektrik tüketimindeki ani

değişiklikler LSTM modeli tarafından başarılı bir şekilde tahmin edilmiştir. Ancak, bazı dönemlerde tahminlerdeki sapmaların daha belirgin olduğu gözlenmektedir. Bu durum, modelin belirli dönemlerdeki verilerde biraz daha düşük performans gösterdiğini düşündürülebilir.




Şekil 5. 32. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5.32.'de BiLSTM modelinin gerçek değerler ile tahmin edilen değerler arasında oldukça yakın bir ilişki kurduğu gözlenmektedir. Modelin tahmin performansı, tüketim eğilimlerini doğru bir şekilde yakaladığını ve gerçek değerlere paralel bir şekilde ilerlediğini ortaya koymaktadır. Özellikle tüketimdeki ani artış ve düşüşler başarıyla tahmin edilmiştir, ancak bazı uç noktalarda tahmin hatalarının olabileceği ihtimali mevcuttur.


Tahmin grafiklerine bakıldığında, BiLSTM ve GRU modellerinin gerçek verilerle çok yakın sonuçlar verdiği görülmektedir. BiLSTM özellikle yüksek doğrulukta tahmin yaparak verilerin hemen hemen tamamını yakalamaktadır. GRU modeli de benzer şekilde iyi sonuçlar verse de BiLSTM kadar tutarlı değildir. LSTM modeli tahmin sonuçlarında orta seviyede bir başarı gösterirken, RNN modeli ise epoch 100 değerinde en düşük performansı ortaya koymuştur.

5.1.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100)

Şekil 5.33.'de RNN modeli en yüksek hata değeri olan (0.068339) ile en düşük performansı sergilemiştir. Buna karşılık, BiLSTM modeli (0.004289) gibi oldukça düşük bir hata ile en başarılı model olarak öne çıkmaktadır. GRU ve LSTM modelleri ise sırasıyla (0.010327) ve (0.038712) hata değerleri ile orta düzey performans göstermektedir. Bu durum, BiLSTM modelinin diğer modellere kıyasla daha yüksek bir doğruluk sunduğunu göstermektedir.




Şekil 5. 33. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 100)




Şekil 5. 34. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 100)

Şekil 5.34.'de RNN modelinin MAPE (%5.504418) hata oranı ile en yüksek sapmayı sergilediği gözlenmektedir. BiLSTM modeli MAPE (%0.393337) değeri ile en düşük hata oranına sahip model olarak ön plana çıkmıştır. GRU ve LSTM modelleri ise bu iki model arasında yer almak birlikte BiLSTM modeline kıyasla daha yüksek hata oranlarına sahiptir. BiLSTM modelinin bu grafikteki düşük hata oranı, diğer modellere göre oldukça başarılı olduğunu vurgulamaktadır.



Şekil 5. 35. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 100)

Şekil 5.35.'de MSE değerlerine göre, RNN modelinin (0.005455) hata değeri ile en yüksek hata oranına sahip olduğu görülmektedir. BiLSTM modeli ise (0.000035) ile en düşük hata oranını sunmaktadır. GRU ve LSTM modelleri sırasıyla (0.000193) ve (0.002568) hata değerleri ile sıralanmıştır.




Şekil 5. 36. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 100)

Şekil 5.36.'da MSE değerlerine göre, RNN modelinin (0.005455) hata değeri ile en yüksek hata oranına sahip olduğu görülmektedir. BiLSTM modeli ise (0.000035) ile en düşük hata oranını sunmaktadır. GRU ve LSTM modelleri sırasıyla (0.000193) ve (0.002568) hata değerleri ile sıralanmıştır.

Bu doğrultuda performans metrikleri açısından baktığımızda, BiLSTM modeli en düşük hata oranlarını sunmaktadır. GRU modeli de oldukça düşük hata oranlarına sahip ve başarılı bir performans sergilemektedir. LSTM modelinde ise hata oranları GRU'ya göre daha yüksek ve BiLSTM'nin gerisinde kalmaktadır. Tüm metriklerde diğer modellere kıyasla daha yüksek hata oranlarına sahip olan RNN modeli, epoch 100 değerinde en zayıf performansı ortaya koymuştur.


Bu analizler doğrultusunda, epoch 100 değerinde Aydınlatma sektörü için en iyi performansı BiLSTM modeli göstermektedir. GRU modeli de başarılı bir alternatif olarak öne çıkmaktadır. RNN ise hem tahmin sonuçları hem de hata metrikleri açısından en zayıf model olarak değerlendirilmektedir.

5.1.10. Eğitim ve Doğrulama Kayıpları (Epoch 200)



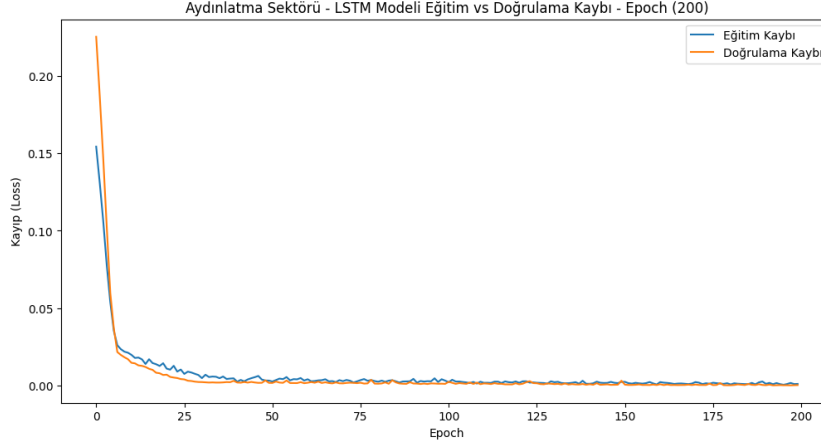
Şekil 5. 37. Aydınlatma - RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekil 5.37.'de görüldüğü üzere RNN modelindeki eğitim kaybı, doğrulama kaybına göre biraz daha fazla dalgalanmaktadır ve genel olarak diğer modellere kıyasla daha yüksek seviyede seyretmektedir. RNN modelinin diğer modellere göre daha fazla kayıplara sahip olduğu açıkça görülmektedir.




Şekil 5. 38. Aydınlatma - GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekil 5.38.'de paylaşılan GRU modelinde eğitim ve doğrulama kayıpları yine hızlı bir azalma eğilimi göstermekte ve 50. epoch'tan sonra oldukça düşük seviyelerde seyretmektedir. Eğitim kaybı doğrulama kaybına göre çok az bir dalgalanma göstermiştir, genel olarak başarılı bir performans sergilemektedir.



Şekil 5. 39. Aydınlatma - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekil 5.39.'da belirtilen LSTM modelinde ise eğitim ve doğrulama kayıpları 50. epoch'tan sonra dengeli seviyede ilerlemiştir. Kayıplar arasında belirgin bir fark bulunmamaktadır, modelin tutarlı bir performans gösterdiği anlaşılmaktadır.




Şekil 5. 40. Aydınlatma - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)


BiLSTM eğitim ve doğrulama kayıpları, Şekil 5.40.'da birbirine çok yakın ilerlemektedir. Bu modelde kayıpların hızlı bir şekilde azaldığı ve 100. epoch sonrasında daha dengede kaldığı gözlemlenmektedir. Eğitim ve doğrulama hatalarının düşük ve dengeli olduğu görülmektedir.

5.1.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)

Şekil 5.41. incelendiğinde RNN modelinin tahminleri, diğer modellere göre gerçek verilere en az yakın olan modeldir. 2023 ve sonrası tahminlerinde belirgin sapmalar ve dalgalanmalar gözlenmektedir.




Şekil 5. 41. Aydınlatma – RNN Gerçek Değerler ve Tahminler (Epoch 200)




Şekil 5. 42. Aydınlatma – GRU Gerçek Değerler ve Tahminler (Epoch 200)

Şekil 5.42.'ye göre GRU modeli, tahminlerin gerçek verilerle neredeyse örtüştüğü bir performans sergilemiştir. Dönemsel dalgalanmalar ve ani artışlar, modelin gerçeğe oldukça yakın tahminler sunduğunu göstermektedir.



Şekil 5. 43. Aydınlatma – LSTM Gerçek Değerler ve Tahminler (Epoch 200)


LSTM modelinin tahmin performansı Şekil 5.43.'de genel olarak başarılıdır. Ancak bazı dönemlerde, özellikle ani düşüşlerde, gerçek verilerden biraz sapmalar gözlenmektedir. Yine de genel eğilimi doğru yakalamaktadır.



Şekil 5. 44. Aydınlatma – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200)


Şekil 5.44.'ye göre BiLSTM modelinin tahmin sonuçları gerçek verilerle oldukça yakın bir seyir izlemekte, özellikle dönemsel artış ve azalışlarda büyük ölçüde uyum göstermektedir. 2022-2024 döneminde modelin performansının oldukça başarılı olduğu gözlenmektedir.

5.1.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)




Şekil 5. 45. Aydınlatma Sektörü MAE Hata Metrikleri (Epoch 200)

Şekil 5.45.'de belirtildiği üzere en düşük MAE değeri GRU modelinde (0.008195) gözlenmektedir. RNN modeli ise MAE (0.031771) ile en zayıf performansı sergilemiştir.




Şekil 5. 46. Aydınlatma Sektörü MAPE Hata Metrikleri (Epoch 200)

Şekil 5.46.'da MAPE açısından da GRU modeli (%0.682848) en iyi performansı sergilemiştir. En kötü sonuç ise RNN modeline aittir (%2.522316).



Şekil 5. 47. Aydınlatma Sektörü MSE Hata Metrikleri (Epoch 200)

Şekil 5.47.'de belirtildiği üzere MSE değerlendirmesinde de GRU (0.000086) en iyi performansı göstermiştir. RNN modeli ise en yüksek MSE (0.001271) ile zayıf bir performans sergilemiştir.




Şekil 5. 48. Aydınlatma Sektörü RMSE Hata Metrikleri (Epoch 200)

Şekil 5.48.'ye göre RMSE açısından da GRU modeli (0.009289) en başarılı sonuçları verirken, RNN modeli en yüksek hata (0.035657) ile en düşük performansı göstermiştir.

Bu analiz sonucunda, GRU modeli epoch 200 değerinde Aydınlatma Sektörü için en iyi performansı gösteren model olmuştur. Hem tahminlerin gerçek verilerle uyumu hem de hata metrikleri açısından diğer modellerin önüne geçmiştir. RNN modeli ise genel olarak en zayıf performansı göstermiştir.


5.1.13. Aydınlatma Sektörü Bazında Genel Değerlendirme



Şekil 5. 49. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)

Şekil 5.49.'da Aydınlatma sektörü için RNN, GRU, LSTM ve BiLSTM modellerinin epoch 25, 50, 100 ve 200 değerlerindeki performansları detaylıca incelendiğinde, modeller arasında belirgin performans farklılıkları olduğu açıkça görülmektedir. Her epoch değerinde, modellerin eğitim ve doğrulama kayıpları, tahmin sonuçlarının gerçek verilerle karşılaştırılması ve performans metrikleri üzerinde yapılan değerlendirmeler, modellerin farklı özellikleri ve üstünlüklerini ortaya koymuştur.

Epoch 25 değerinde yapılan tahminlere göre, RNN modeli diğer modellere göre nispeten daha iyi bir performans sergilemiştir. Hem eğitim hem de doğrulama kayıplarında düşük değerler elde etmiş ve aşırı öğrenme belirtileri gözlemlenmemiştir. Ancak tahmin sonuçları açısından LSTM ve GRU modelleri de dikkate değer sonuçlar vermiştir. BiLSTM modeli ise daha yavaş bir öğrenme eğilimi göstererek epoch 25'te diğer modellerin gerisinde kalmıştır. Bu erken dönemde, RNN modelinin hızlı öğrenme kabiliyeti sayesinde öne çıktığı görülmektedir.



Şekil 5. 50. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)


Şekil 5.50.'de belirtildiği üzere epoch 50 değerinde, GRU modeli en başarılı performansı sergilemiş, en düşük eğitim ve doğrulama kayıplarına sahip olmuştur. Tahmin sonuçlarının gerçek verilerle uyumu ve hata metrikleri açısından GRU modeli dikkat çekici bir doğruluk sağlamıştır.

LSTM ve BiLSTM modelleri de genel olarak başarılı sonuçlar verirken, RNN modeli bu aşamada daha fazla dalgalanmalar göstermiş ve diğer modellere göre daha zayıf bir performans sergilemiştir. Özellikle GRU'nun dengeli öğrenme kapasitesi ve düşük kayıpları, epoch 50'de en iyi model olarak öne çıkmasına neden olmuştur.

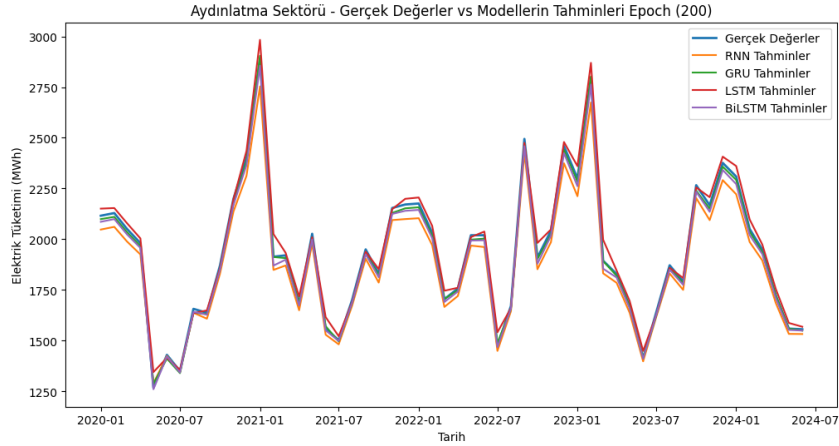
Epoch 100 değerinde yapılan tahminlere gelindiğinde ise, Şekil 5.51.'de BiLSTM modelinin diğer modellere göre daha iyi sonuçlar vermeye başladığı gözlemlenmektedir. Eğitim ve doğrulama kayıpları oldukça düşük seviyelerde seyretmiş ve tahmin sonuçları gerçek verilerle neredeyse birebir örtüşmüştür.

GRU modeli ise BiLSTM'yi yakından takip etmiş ve benzer şekilde düşük kayıp oranları sunmuştur. LSTM modeli genel olarak başarılı olsa da BiLSTM ve GRU'nun gerisinde kalmıştır.

RNN modeli ise epoch 100 değerinde, diğer modellere kıyasla daha yüksek kayıplara sahip olmuş ve tahmin sonuçlarında sapmalar göstermiştir. Bu sonuçlar, epoch 100 değerinde BiLSTM ve GRU'nun verimli bir öğrenme süreci geçirdiğini ve RNN modelinin performansının düştüğünü göstermektedir.



Şekil 5. 51. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)



Şekil 5. 52. Aydınlatma – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)

Epoch 200 değerinde Şekil 5. 52.'de de görüleceği üzere, GRU modelinin tahmin doğruluğu ve düşük hata metrikleri ile diğer modellere kıyasla en iyi performansı sergilediği görülmektedir. Eğitim ve doğrulama kayıpları oldukça düşük seviyelerde dengede kalmış ve modelin aşırı öğrenme yapmadığı görülmüştür. BiLSTM modeli de GRU'ya oldukça yakın bir performans göstermiştir. LSTM modeli de genel olarak başarılı bir performans sergilese de GRU ve BiLSTM'nin gerisinde kalmıştır. RNN modeli ise bu aşamada daha zayıf performans göstermiş ve yüksek kayıp oranları ile tahminlerdeki sapmalar modelin başarısını sınırlamıştır.

Yapılan tüm değerlendirmeler sonucunda, Aydınlatma sektörü için en iyi performansı epoch 50 ve epoch 200 değerlerinde GRU modeli sergilemiştir. GRU modeli, özellikle düşük hata oranları ve tahmin doğruluğu ile öne çıkmıştır. BiLSTM modeli de genel olarak yüksek performans sunarak GRU'ya iyi bir alternatif olmuştur. LSTM modeli de başarılı bir performans göstermesine rağmen

BiLSTM ve GRU'nun gerisinde kalmıştır. Özellikle epoch 100 ve 200 değerlerinde artan kayıplar ve sapmalarla karşılaşan RNN modeli en zayıf performansı sergilemiştir.

Bu sonuçlar, Aydınlatma sektörü için GRU ve BiLSTM modellerinin en uygun modeller olduğunu ve yüksek tahmin doğruluğu sunduklarını göstermektedir. Aydınlatma sektörüne ait tüm hata metrikleri Tablo 5.1.'de belirtilmiştir.

Tablo 5. 1. Aydınlatma Sektörüne Ait Hata Metrikleri

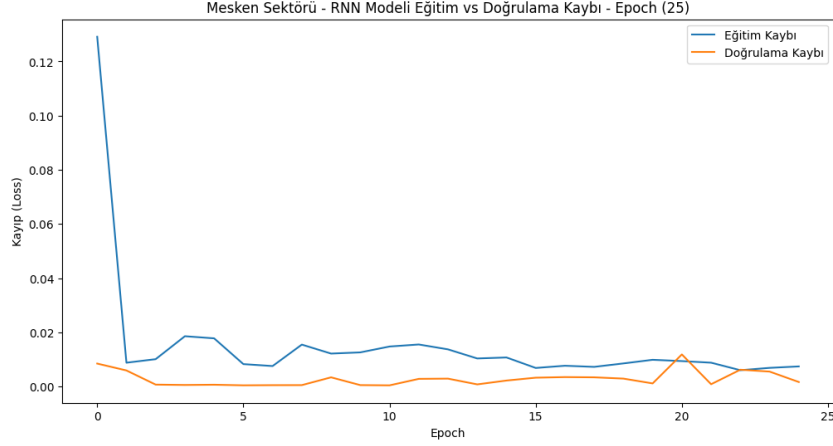
Sektör	AYDINLATMA SEKTÖRÜ			
Metrik Türü	MAE	RMSE	MSE	MAPE
Epoch Değeri	EPOCH - 25			
RNN	0.029525	0.030962	0.000959	2.444172
GRU	0.055370	0.072999	0.005329	4.873536
LSTM	0.047300	0.063402	0.004020	4.161053
BILSTM	0.052773	0.071380	0.005095	4.544384
Epoch Değeri	EPOCH - 50			
RNN	0.043981	0.045645	0.002083	3.636948
GRU	0.026566	0.036169	0.001308	2.326799
LSTM	0.039427	0.051574	0.002660	3.393723
BILSTM	0.036731	0.047696	0.002275	3.122514
Epoch Değeri	EPOCH - 100			
RNN	0.068339	0.073856	0.005455	5.504418
GRU	0.010327	0.013888	0.000193	0.931068
LSTM	0.038712	0.050677	0.002568	3.223586
BILSTM	0.004289	0.005896	0.000035	0.393337
Epoch Değeri	EPOCH - 200			
RNN	0.031771	0.035657	0.001271	2.522316
GRU	0.008195	0.009289	0.000086	0.682848
LSTM	0.019165	0.024683	0.000609	1.635450
BILSTM	0.013762	0.015305	0.000234	1.099844

5.2. Mesken Sektörü

Bu kısımda Mesken sektörüne ait 25-50-100 ve 200 epoch değerleri için modellerin eğitim ve doğrulama kaybı ile modellerin tahmin sonuçlarının gerçek verilerle karşılaştırılması ve performans metrikleri sırasıyla sunulmuştur.


5.2.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)

Mesken sektörü için epoch 25 değerinde RNN, GRU, LSTM ve BiLSTM modellerinin eğitim ve doğrulama kayıplarına baktığımızda, her modelin başlangıçta yüksek bir kayıp değeriyle başladığı, ancak hızlı bir şekilde kayıpların azaldığı gözlemlenmektedir. Eğitim kayıpları genellikle doğrulama kayıplarına oldukça yakın seyretmiştir, bu da modellerin genel anlamda iyi bir şekilde öğrendiğini göstermektedir.




Şekil 5. 53. Mesken - RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5.53. incelendiğinde RNN modelinde kayıpların dalgalandığı, özellikle 5. epoch'a kadar ani düşüşler gösterdiği, ancak sonrasında kayıpların çok düşük seviyelerde dengede olduğu görülmüştür. Bu model, eğitim ve doğrulama kayıplarının birbirine yakın seyretmesi nedeniyle aşırı öğrenme belirtisi göstermemiştir.




Şekil 5. 54. Mesken - GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5.54.'de GRU modelinde eğitim ve doğrulama kayıpları 5. epoch'a kadar hızlı bir düşüş yaşamış, ardından dengeli bir seviyede ilerlemiştir. Ancak BiLSTM ve LSTM ile karşılaştırıldığında GRU'nun doğrulama kayıpları eğitim kayıplarına göre daha yüksek kalmıştır, bu da modelin doğrulama verileri üzerinde biraz daha zorlandığını göstermektedir.



Şekil 5. 55. Mesken - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

LSTM modeli, Şekil 5.55.'de başlangıçta yüksek doğrulama kayıpları ile başlamış ancak epoch 5 civarında hem eğitim hem de doğrulama kayıplarının sıfıra yakın değerlere düşmesi dikkat çekicidir. Bu model, eğitim ve doğrulama sürecinde en dengeli kayıp grafiğine sahip modellerden biridir.




Şekil 5. 56. Mesken - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

BiLSTM modeli ise Şekil 5.56.'da diğer modellere kıyasla daha hızlı bir şekilde kayıpları azaltmış ve 5. epoch itibarıyla doğrulama kayıplarını oldukça düşük seviyelerde tutmayı başarmıştır.


5.2.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)

Mesken sektörü için tahmin sonuçlarının gerçek elektrik tüketim verileri ile karşılaştırılması yapıldığında, modellerin genel anlamda benzer bir performans sergilediği görülmektedir. Ancak, bazı modellerin tahmin performansı dönemsel dalgalanmalarda farklılık göstermektedir.



Şekil 5. 57. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 25)


RNN modeli, Şekil 5.57.'de özellikle kısa vadeli dalgalanmalarda gerçek verilere oldukça yakın tahminler yapmıştır. Ancak, genel eğilimde bazı küçük sapmalar gözlenmektedir. Yine de modelin genel eğilimleri yakalamada oldukça başarılı olduğu söylenebilir.



Şekil 5. 58. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 25)


Şekil 5.58.'ye göre GRU modeli, gerçek verilerle karşılaştırıldığında genel eğilimleri yakalamada güçlü performans sergilemiş, ancak bazı dönemsel tepe noktalarında ve diplerde

gerçek değerlerden daha fazla sapma göstermiştir. Bu da modelin ani değişimlere karşı daha az hassas olduğunu gösterir.



Şekil 5. 59. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 25)

LSTM modelinin Şekil 5.59.’da belirtilen tahmin sonuçları gerçek değerlerle oldukça iyi örtüşmektedir. Bu model, özellikle 2022 sonlarından itibaren elektrik tüketimindeki artış ve azalışları iyi bir şekilde tahmin edebilmiştir. Ancak, bazı zirve noktalarında küçük sapmalar yaşanmıştır.




Şekil 5. 60. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25)

BiLSTM modeli ise Şekil 5.60.’da belirtilen uzun vadeli tahminlerde oldukça başarılı olup, kısa vadeli dalgalanmaları diğer modellere göre daha iyi yakalamıştır. Gerçek verilerle karşılaştırıldığında, tahminlerin en iyi örtüştüğü modelin BiLSTM olduğu söylenebilir.


5.2.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)

Performans metriklerine bakıldığında, Mesken sektörü için epoch 25 değerinde modellerin MAE, MSE, RMSE ve MAPE değerleri arasında belirgin farklılıklar vardır.




Şekil 5. 61. Mesken Sektörü MAE Hata Metrikleri (Epoch 25)

Şekil 5. 61.'deki deki deki hata metrik değerleri incelendiğinde RNN modeli MAE değeri (0.078032) olarak en düşük seviyededir. GRU modeli ise MAE değeri (0.138504) ile en yüksek hata seviyesine sahiptir. LSTM modeli, MAE değerinde (0.120690) ve MAPE değerinde (%4.386253) ile ortalama bir performans göstermiştir. Bu sonuçlar, LSTM'nin genel eğilimleri iyi yakaladığını ancak belirli dönemlerde küçük sapmalar yapabileceğini göstermektedir.



Şekil 5. 62. Mesken Sektörü MAPE Hata Metrikleri (Epoch 25)


Benzer şekilde, Şekil 5. 62.'deki hata metrik değerleri kıyaslandığında (%5.045347) MAPE değeri ile en kötü performansı sergileyen GRU modelinin diğer modellere kıyasla daha fazla hata yaptığı açıkça görülmektedir.



Şekil 5. 63. Mesken Sektörü MSE Hata Metrikleri (Epoch 25)

RNN modeli ise, Şekil 5. 63. ve Şekil 5. 64.’deki hata metriklerinde de görüleceği üzere diğer hata metriklerinde olduğu gibi MSE ve RMSE metriklerinde de diğer modellere kıyasla daha iyi sonuçları vermiştir. Bu sonuçlar, RNN’nin kısa vadeli tahminlerde diğer modellere göre daha az hata yaptığını göstermektedir. Ayrıca epoch 25 değerinde GRU’nun Mesken sektörü için uygun bir model olmadığı görülmektedir.

BiLSTM modeli ise MAE (0.087213) ve MAPE (%3.265493) değerlerinde RNN’ye yakın bir performans sergilemiştir. Özellikle MSE değeri (0.011142) de düşük seviyelerde olup, bu modelin epoch 25 değerinde Mesken sektörü için oldukça güçlü bir tahmin yeteneğine sahip olduğunu göstermektedir.

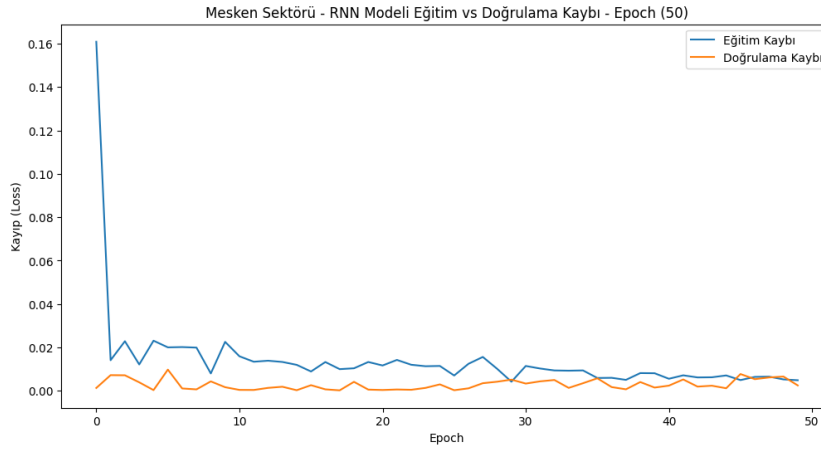


Şekil 5. 64. Mesken Sektörü RMSE Hata Metrikleri (Epoch 25)

Genel değerlendirmede, epoch 25 değerinde Mesken sektörü için en iyi performansın RNN modelinde olduğunu söylemek mümkündür. RNN, en düşük MAE ve MAPE değerlerini elde ederek kısa vadeli dalgalanmalarda en az hata ile tahmin yapmıştır. BiLSTM modeli ise genel anlamda iyi bir performans sergilemiş ve özellikle daha uzun vadeli tahminlerde güçlü sonuçlar vermiştir. Bu model, RNN’den sonra en iyi tahmin yeteneğine sahip model olarak öne çıkmıştır.


LSTM modeli de kabul edilebilir bir performans sergilemiştir ancak hem kısa vadeli hem uzun vadeli tahminlerde RNN ve BiLSTM kadar güçlü bir performans göstermemiştir. GRU modeli ise diğer modellere kıyasla daha zayıf bir performans sergilemiş, özellikle kısa vadeli tahminlerde daha fazla hata yapmıştır. Bu nedenle, epoch 25 değerinde GRU modelinin Mesken sektörü için uygun bir model olmadığı söylenebilir. Sonuç olarak, Mesken sektörü için epoch 25 değerinde en iyi performansı gösteren modeller sırasıyla RNN, BiLSTM, LSTM ve GRU olarak belirlenmiştir.

5.2.4. Eğitim ve Doğrulama Kayıpları (Epoch 50)



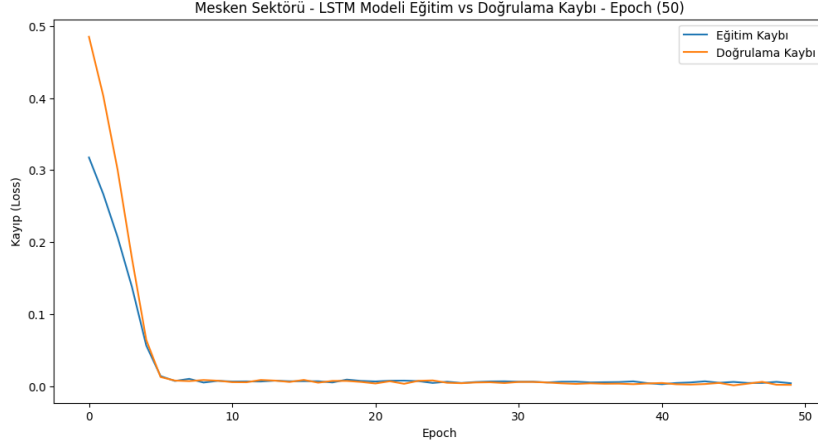
Şekil 5. 65. Mesken - RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5. 65’deki değerler incelendiğinde RNN modelinde eğitim ve doğrulama kayıplarının düzensiz bir seyir izlediği ve yüksek seyrettiği görülmektedir.



Şekil 5. 66. Mesken - GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5. 66. ve Şekil 5. 67’de ise hem GRU hem de LSTM modellerinde oldukça dengeli bir eğitim sürecinin işlediği ve dengeli bir öğrenme sürecinin gerçekleştiği gözlemlenmektedir.




Şekil 5. 67. Mesken - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

BiLSTM modelinin Şekil 5. 68.’deki performansı ele alındığında eğitim ve doğrulama kayıplarının dengeli seviyede ilerlediği değerlendirilmektedir.


Genel olarak değerlendirildiğinde Mesken sektörü epoch 50 değerinde BiLSTM başta olmak üzere LSTM ve GRU modellerinde eğitim ve doğrulama kayıpları daha kararlı bir şekilde düşmekte olup, özellikle 20. epoch sonrası hem eğitim hem de doğrulama kayıpları asgari düzeyde devam etmektedir.

Özetle, eğitim ve doğrulama kayıpları açısından BiLSTM ve LSTM modelleri daha dengeli ve başarılı bir sonuç verirken, RNN modeli daha fazla hata göstermektedir.




Şekil 5. 68. Mesken - BiLSM Eğitim ve Doğrulama Kayıpları (Epoch 50)

5.2.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)



Şekil 5. 69. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5. 69.’daki tahmin sonuçları incelendiğinde RNN modelinin gerçek verilerle benzer bir eğilim izlediği ancak diğer modellere kıyasla daha fazla sapma gösterdiği gözlenmiştir. Özellikle yüksek tüketim değerlerinin tahmin edilmesinde bazı zorluklar yaşandığı, modelin bu verilerdeki değişiklikleri yakalama kapasitesinin sınırlı olabileceği anlaşılmaktadır.




Şekil 5. 70. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5. 70.’de GRU modelinin genel eğilimleri yakalama kabiliyeti yüksek olmakla birlikte, bazı küçük sapmalar nedeniyle BiLSTM ve LSTM’nin gerisinde kaldığı görülmektedir.


Şekil 5. 71.’de LSTM modeli de tahminler açısından gerçek değerlere yakın bir performans sergilemektedir. Modelin performansı, modelin özellikle tüketimdeki büyük değişiklikleri iyi bir

şekilde yakaladığını, ancak bazı noktalarda tahmin edilen değerlerin gerçek verilerden hafif sapmalar gösterebildiğini ortaya koymaktadır.



Şekil 5. 71. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5. 72.'de ise BiLSTM modelinin tahmin ettiği değerler genel olarak gerçek değerlerle paralellik göstermektedir. Sonuçlar, modelin dalgalanmaları ve elektrik tüketimindeki değişiklikleri başarılı bir şekilde yakaladığını ortaya koymaktadır. Özellikle tüketim verilerindeki büyük artış ve azalışlar model tarafından başarılı bir şekilde tahmin edilmiştir. Ancak, bazı dönemlerde tahminlerin gerçek verilerden bir miktar sapma gösterdiği gözlemlenmektedir. Bu sapmalar modelin doğruluğu üzerinde hafif bir etkide bulunmaktadır.




Şekil 5. 72. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50)

Genel bir değerlendirme yapmak gerekir ise tüm modellerin genel eğilimleri takip edebildiği görülmektedir. Ancak, RNN modeli, zaman zaman tahminlerde sapmalar gösterirken, BiLSTM ve LSTM modellerinin gerçek verilere daha yakın sonuçlar verdiği net bir şekilde fark

edilmektedir. Özellikle LSTM ve BiLSTM modelleri, elektrik tüketimi dalgalanmalarını doğru bir şekilde yakalamakta ve tahmin hataları minimum seviyede kalmaktadır.


GRU modeli de nispeten iyi bir performans sergilese de BiLSTM ve LSTM modellerine kıyasla bazı aylarda tahminlerde sapmalar gözlemlenmektedir. Genelde tahmin eğrisi, gerçek eğrinin bir miktar altında veya üstünde seyretmektedir.

5.2.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)




Şekil 5. 73. Mesken Sektörü MAE Hata Metrikleri (Epoch 50)

Şekil 5. 73.'de görüldüğü üzere MAE açısından en düşük hata BiLSTM modeline aittir, onu LSTM ve GRU modelleri takip etmektedir. RNN modeli en yüksek hata oranına sahiptir.




Şekil 5. 74. Mesken Sektörü MAPE Hata Metrikleri (Epoch 50)

Şekil 5. 74.'de belirtilen MAPE sonuçlarında da BiLSTM modeli en iyi performansı göstermekte, onu LSTM takip etmektedir. RNN modeli ise diğer modellere göre daha fazla hata oranına sahiptir.



Şekil 5. 75. Mesken Sektörü MSE Hata Metrikleri (Epoch 50)

Şekil 5. 75.'de görüldüğü üzere RNN ve GRU modellerine ait MSE değerleri arasında çok fazla fark yoktur. BiLSTM ve LSTM modelleri diğerlerinden daha iyi sonuçlar vermektedir.



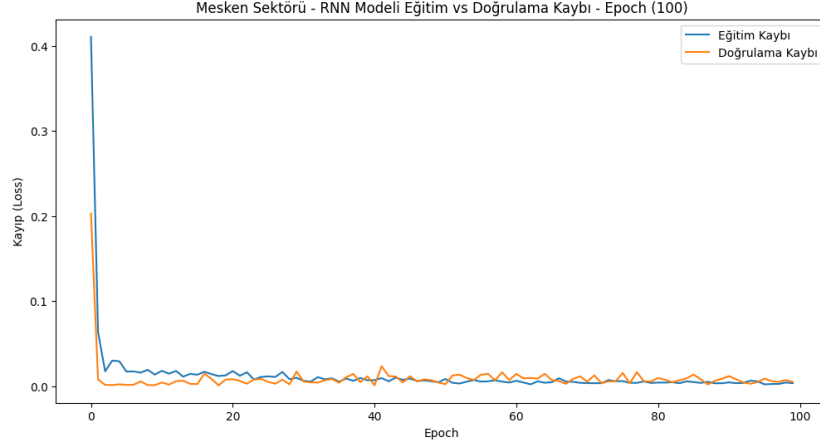
Şekil 5. 76. Mesken Sektörü RMSE Hata Metrikleri (Epoch 50)

Şekil 5. 76.'da belirtildiği üzere RMSE'de de BiLSTM modeli en düşük hatayı vermekte, LSTM ikinci sırada yer almaktadır. RNN ve GRU modelleri ise daha yüksek hatalara sahiptir.

Özetle epoch 50 değerinde Mesken sektörü için en başarılı model BiLSTM olmuştur. Tüm metriklerde en düşük hata oranlarını sağlamış ve tahmin eğrisi, gerçek verilere en yakın sonuçları vermiştir. LSTM modeli de BiLSTM'ye yakın sonuçlar vermekte olup, RNN ve GRU modellerine kıyasla daha iyi performans sergilemiştir. RNN modeli ise en düşük performansı göstermiştir.

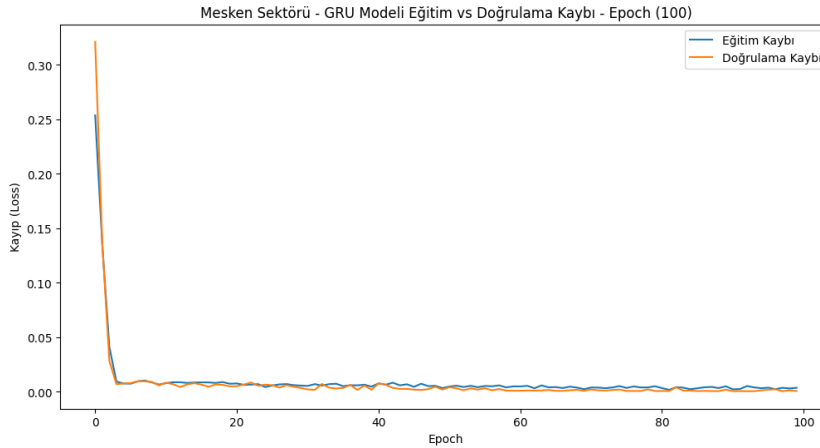
5.2.7. Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5. 77.'de RNN modelinin eğitim kayıpları başlangıçta diğer modellere göre daha fazla dalgalanma yaşadığı görülmektedir. Bu dalgalanmalar modelin öğrenme sürecinde kararsızlık yaşadığını düşündürülebilir.



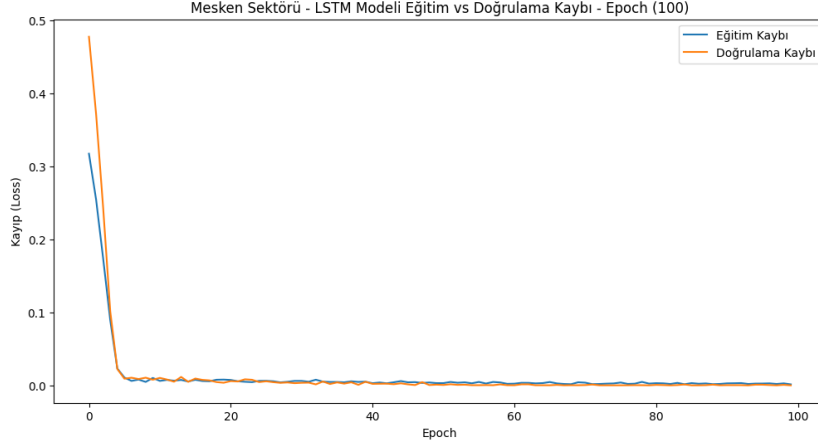
Şekil 5. 77. Mesken - RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)

Ancak doğrulama kayıpları daha sabit bir seyir izlemektedir. Eğitim ve doğrulama kayıplarının genel olarak düşük seviyelere ulaşmış olması olumlu bir performansa işaret ederken, eğitim kayıplarındaki dalgalanmalar modelin daha basit yapısından kaynaklanıyor olabilir ve modelin daha karmaşık desenleri öğrenme kabiliyetinde sınırlamalar olabileceğini düşündürmektedir.



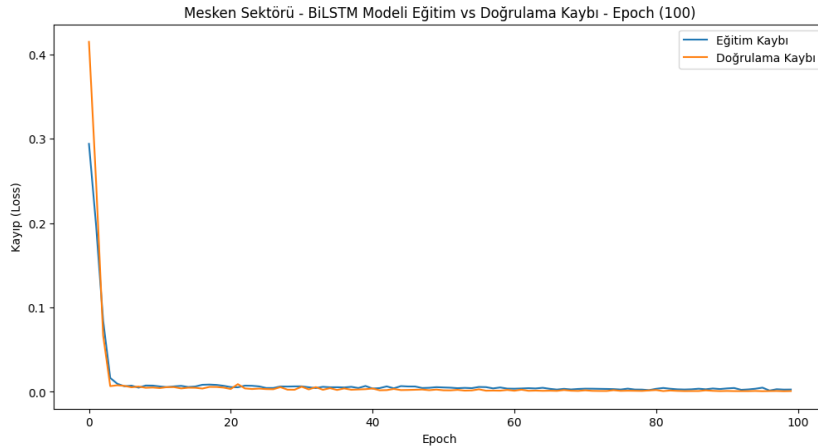
Şekil 5. 78. Mesken – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5. 78.'de GRU modelinde de benzer bir kayıp eğrisi gözlenmektedir. Eğitim ve doğrulama kayıpları başlangıçta hızla azalmış ve 20. epoch'tan itibaren sabitlemiştir. Kayıpların birbirine yakın seyretmesi, modelin doğrulama verileri üzerinde de eğitim verilerine yakın bir başarı sergilediğini göstermektedir. Bu, modelin aşırı öğrenme riskinden kaçındığını ve genelleme yeteneğinin iyi olduğunu işaret etmektedir.



Şekil 5. 79. Mesken - LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5. 79.'da LSTM modelinde, eğitim ve doğrulama kayıpları yaklaşık 5. epoch'tan sonra sabit bir noktaya ulaşmaktadır. Eğitim ve doğrulama kayıplarının birbirine yakın seviyelerde ilerlemesi, modelin dengeli bir öğrenme süreci geçirdiği yönünde değerlendirilmektedir. Kayıpların oldukça düşük seviyelere inmesi, LSTM modelinin iyi bir performans sergilediğini göstermektedir.




Şekil 5. 80. Mesken - BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5. 80.'de BiLSTM modelinin performans incelendiğinde hem eğitim hem de doğrulama kayıplarının neredeyse aynı seviyelerde olması, modelin genelleme kabiliyetinin iyi olduğunu ve aşırı öğrenmenin önüne geçildiğini göstermektedir.

Epoch 100 değerinde RNN, GRU, LSTM ve BiLSTM modellerinin eğitim ve doğrulama kayıpları incelendiğinde, modellerin genel olarak doğrulama kaybı ile eğitim kaybı arasında benzer bir seyir izlediği görülmektedir. RNN modelinde doğrulama kaybı başlarda daha yüksek


seviyelerde olup, ilerleyen epoch'larda daha düşük seviyelere inmiştir, ancak genel eğilimi diğer modellere göre daha kararsız ve dalgalı bir seyir izlemektedir. GRU, LSTM ve BiLSTM modellerinde ise doğrulama ve eğitim kayıpları başlangıçta hızlı bir şekilde düşüş göstermekte, sonrasında dengeli bir hale gelmektedir. Bu modellerin kayıp değerleri genel olarak birbirine çok yakın olup, istikrarlı bir performans sergilemektedir. Özellikle LSTM ve BiLSTM modellerinin kayıp eğrileri neredeyse paralel bir şekilde ilerlemektedir, bu da daha kararlı bir model yapısına işaret etmektedir.

5.2.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100)




Şekil 5. 81. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5. 81.'de RNN modelinin tahmin performansı diğer modellere kıyasla daha fazla sapma göstermektedir. Özellikle tüketimdeki yüksek artış ve düşüşlerin tahmin edilmesinde modelin zorluk yaşadığı gözlenmektedir.




Şekil 5. 82. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5. 82.'de GRU modeli de genel tüketim eğilimini başarılı bir şekilde tahmin edebilmiştir. Model, elektrik tüketimindeki dalgalanmaları büyük oranda doğru şekilde yakalamış, gerçek veriler ile uyumlu sonuçlar üretmiştir. Bununla birlikte, bazı dönemlerde tahmin edilen verilerde küçük sapmalar olduğu dikkat çekmektedir. Bu sapmalar, modelin performansında küçük bir fark yaratmakla birlikte, genel doğruluk açısından önemli bir problem oluşturmamaktadır.



Şekil 5. 83. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5. 83.'de LSTM modeli de tüketim verilerini büyük ölçüde doğru bir şekilde tahmin etmeyi başarmıştır. Sonuçlar, modelin elektrik tüketimindeki önemli değişiklikleri yakaladığını, ancak belirli dönemlerde tahmin edilen değerlerin gerçek verilerden hafif sapmalar gösterdiğini ortaya koymaktadır. Özellikle bazı zirve noktalarında tahminlerdeki sapmalar, modelin karmaşık desenlerde kısmen zayıfladığını düşündürülebilir. Buna rağmen model, genel eğilimleri iyi bir şekilde takip etmektedir.




Şekil 5. 84. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5. 84.'de BiLSTM modelinin özellikle tüketimdeki büyük değişimleri başarıyla yakaladığını göstermektedir. Tahmin edilen değerlerin, gerçek değerlere paralel bir şekilde ilerlemesi modelin zaman serisi verilerini doğru bir şekilde öğrendiğini göstermektedir. Ancak bazı tepe noktalarında tahminler ile gerçek değerler arasında hafif sapmalar olduğu gözlenmektedir.

Epoch 100 değerinde, modellerin gerçek tüketim değerleri ile tahmin edilen değerler karşılaştırıldığında, en iyi tahmin doğruluğunun LSTM ve GRU modellerinde olduğu görülmektedir. BiLSTM modeli de oldukça başarılı bir performans sergilemekte, ancak LSTM modeline kıyasla hafif bir sapma gözlenmektedir. RNN modeli ise tahmin sonuçlarında daha büyük sapmalara yol açmıştır, özellikle dalgalı ve ani artış/azalış gösteren dönemlerde RNN modelinin sapmaları oldukça belirgindir. LSTM ve BiLSTM modelleri ise tahminlerinde genel olarak gerçek değerlerle uyumlu bir şekilde ilerlemiştir ve ani değişimlerde daha az sapma göstermiştir. Tahmin doğruluğunun genel anlamda GRU ve LSTM modelleri arasında dengeli olduğu ve bu modellerin gerçek verilerle en iyi uyumu sağladığı söylenebilir.


5.2.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100)




Şekil 5. 85. Mesken Sektörü MAE Hata Metrikleri (Epoch 100)

Şekil 5.85. değerlendirildiğinde, LSTM modeli en düşük MAE (0.043494) değerine sahiptir onu GRU ve BiLSTM modelleri izlemektedir. RNN modeli ise en yüksek MAE (0.141881) değerine sahiptir. Bu da RNN'nin diğer modellere kıyasla tahminlerinde daha fazla hata yaptığını göstermektedir.

Şekil 5.86.'da ise LSTM modeli yine en düşük MAPE (%1.640595) değerine sahiptir, onu GRU (%1.777689) ve BiLSTM (%1.889744) takip etmektedir. RNN modeli burada da en yüksek MAPE (%5.283064) değerine sahiptir.




Şekil 5. 86. Mesken Sektörü MAPE Hata Metrikleri (Epoch 100)



Şekil 5. 87. Mesken Sektörü MSE Hata Metrikleri (Epoch 100)

Şekil 5.87.'de belirtildiği üzere LSTM yine en düşük MSE (0.002617) değerine sahipken, GRU (0.003342) ve BiLSTM (0.003735) modelleri birbirine yakın sonuçlar vermiştir.

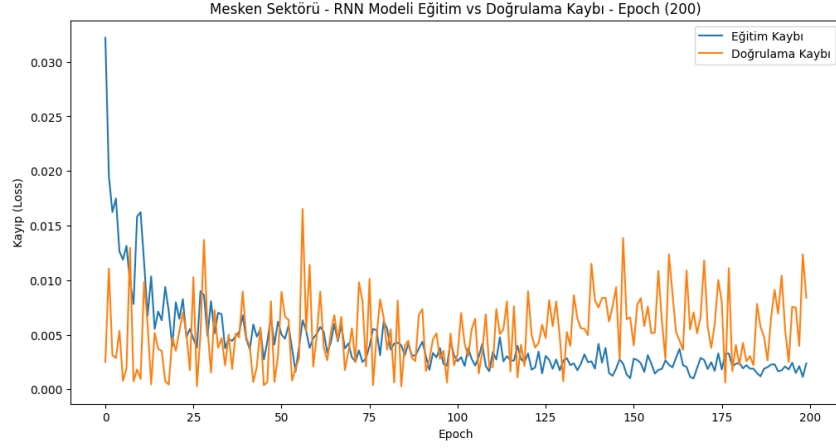


Şekil 5. 88. Mesken Sektörü RMSE Hata Metrikleri (Epoch 100)

Şekil 5.88.'de de LSTM modeli en düşük RMSE (0.051154) değerine sahiptir. LSTM modelini GRU (0.057809) ve BiLSTM (0.061117) modelleri takip etmektedir. RNN modeli ise diğer modellere kıyasla çok daha yüksek bir hata oranına (0.144824) sahiptir.


Sonuç olarak, epoch 100 değerinde en başarılı tahmin performansını sergileyen model LSTM olmuştur. LSTM modelini GRU ve BiLSTM takip etmektedir. RNN modeli ise performans açısından en geride kalmıştır. Özellikle ani değişimlerin olduğu dönemlerde önemli sapmalar görülmüştür.

5.2.10. Eğitim ve Doğrulama Kayıpları (Epoch 200)




Şekil 5. 89. Mesken – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)

Epoch 200 değerinde Mesken Sektörü için RNN, GRU, LSTM ve BiLSTM modellerinin eğitim ve doğrulama kayıplarını kıyasladığımızda, Şekil 5.89.'da RNN modelinin eğitim kaybının ve doğrulama kaybının diğer modellere kıyasla çok daha fazla dalgalanma gösterdiği görülmektedir. Bu, modelin eğitim sırasında dengesiz bir öğrenme süreci yaşadığını ve doğrulama verilerinde önemli bir hata artışıyla karşılaştığını gösterir.




Şekil 5. 90. Mesken – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)



Şekil 5. 91. Mesken – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)

Buna karşın, Şekil 5.90., Şekil 5.91. ve Şekil 5.92. analiz edildiğinde BiLSTM, GRU ve LSTM modelleri çok daha dengeli bir eğitim ve doğrulama süreci sergilemişlerdir. BiLSTM modelinde, eğitim ve doğrulama kayıpları neredeyse birbirine paralel gitmekte ve sıfıra yakın bir kayıp değeri sunmaktadır. Bu, modelin yüksek bir öğrenme kapasitesine sahip olduğunu ve aşırı öğrenme yapmadığını işaret eder.

GRU ve LSTM modellerinde de benzer şekilde dengeli bir düşüş gözlene de BiLSTM modeline göre doğrulama kayıpları bir miktar daha yüksektir.




Şekil 5. 92. Mesken – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)


5.2.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)

Şekil 5. 93.'de görüleceği üzere RNN modeli genel eğilimleri yakalamakta başarılı olsa da diğer modellere göre daha az hassas sonuçlar üretmiştir. Tahminler daha dengesiz ve sapma oranı

daha yüksektir. Özellikle dönem sonlarında, 2023'ün ikinci yarısından itibaren RNN'nin tahminleri belirgin bir şekilde gerçek verilerden uzaklaşmaktadır.




Şekil 5. 93. Mesken – RNN Gerçek Değerler ve Tahminler (Epoch 200)



Şekil 5. 94. Mesken – GRU Gerçek Değerler ve Tahminler (Epoch 200)


Şekil 5. 94.'de GRU modeli elektrik tüketimindeki dalgalanmaları büyük oranda doğru şekilde yakalamış, gerçek veriler ile uyumlu sonuçlar üretmiştir. Bununla birlikte, bazı dönemlerde tahmin edilen verilerde küçük sapmalar olduğu dikkat çekmektedir. Özellikle 2023'ün bazı dönemlerinde tahminlerin gerçek değerlerden sapma eğiliminde olduğu görülmektedir.

Şekil 5. 95.'de ise LSTM modelinde genel tahminler gerçek verilerle yakın uyumluluk göstermektedir. Ancak bazı dönemlerde hafif sapmalar gözlenmektedir. Model, tepe noktaları iyi yakalasa da bazı düşüşlerde BiLSTM kadar başarılı bir performans ortaya koyamamıştır.



Şekil 5. 95. Mesken – LSTM Gerçek Değerler ve Tahminler (Epoch 200)

Şekil 5. 96.'da BiLSTM'nin performansı incelendiğinde ise modelin tahminlerinin, gerçek değerleri yakından takip ettiği, özellikle tepe ve dip noktaları doğru şekilde yansıttığı görülmektedir. Özellikle, 2022 ve 2023 yıllarında yapılan tahminler oldukça başarı yakalamıştır.




Şekil 5. 96. Mesken – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200)

Özetle, Mesken sektöründe epoch 200 değerinde RNN, GRU, LSTM ve BiLSTM modellerinin tahmin sonuçlarını gerçek verilerle karşılaştırdığımızda, BiLSTM, gerçek verilerle tahmin sonuçları arasında en iyi uyumu sağlayan modeldir.


5.2.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)

Epoch 200 değerinde Mesken Sektörü için MAE, MAPE, MSE ve RMSE gibi hata metriklerinde, BiLSTM modelinin açık ara en iyi performansı sergilediği görülmektedir.




Şekil 5. 97. Mesken Sektörü MAE Hata Metrikleri (Epoch 200)

Şekil 5.97’de BiLSTM modelinin MAE (0.006562) değeri, diğer modellere kıyasla çok daha düşüktür. En yüksek MAE değeri ise RNN modelinde (0.185955) görülmüştür. Bu, RNN tahminlerinin düşük doğrulukta olduğunu göstermektedir.




Şekil 5. 98. Mesken Sektörü MAPE Hata Metrikleri (Epoch 200)

Şekil 5.98.’de ise BiLSTM modelinde MAPE değeri oldukça düşüktür (%0.248450), bu da modelin çok yüksek bir doğruluk sunduğunu göstermektedir. Buna karşılık RNN modelinin yüksek MAPE (%6.922474) değeri, bu modelin düşük performansını doğrulamaktadır.



Şekil 5. 99. Mesken Sektörü MSE Hata Metrikleri (Epoch 200)

Şekil 5.99’da görüldüğü üzere BiLSTM (0.000070) ve LSTM (0.002528) ile en düşük MSE değerlerine sahipken, RNN modeli (0.036030) en yüksek değere sahip model olmuştur.



Şekil 5. 100. Mesken Sektörü RMSE Hata Metrikleri (Epoch 200)

Şekil 5.100. analiz edildiğinde RNN modelinde ise RMSE (0.189816) değeri oldukça yüksektir. Diğer modellerle kıyaslandığında BiLSTM (0.008343) modelinin çok daha düşük değere sahip olduğu görülmektedir.


Epoch 200 değerinde, BiLSTM modeli Mesken sektöründe en başarılı model olarak karşımıza çıkmaktadır. Hem eğitim ve doğrulama kayıplarındaki istikrarı, hem de tahmin sonuçlarındaki doğruluğu diğer modellerden çok daha üstündür.

BiLSTM'nin gerisinde kalsa da LSTM ve GRU modelleri de bir önceki epoch değerine göre daha iyi performans göstermiştir. Ancak LSTM'nin GRU'ya göre bir adım önde olduğunu söylemek mümkündür.

RNN ise hem doğrulama kayıplarındaki dengesizlikler hem de yüksek hata metrikleri nedeniyle Mesken sektöründe başarısız bir model olarak değerlendirilebilir.

5.2.13. Mesken Sektörü Bazında Genel Değerlendirme


Mesken sektörü için Epoch 25, Epoch 50, Epoch 100 ve Epoch 200 değerlerindeki modellerin performanslarını genel olarak değerlendirdiğimizde, modellerin gelişim süreçlerinde önemli farklılıklar görülmüştür. Özellikle RNN, GRU, LSTM ve BiLSTM modelleri arasındaki performans farkları, epoch sayısının artmasıyla daha belirgin hale gelmiştir. Her bir epoch değeri için yapılan analizler, modellerin zamanla nasıl evrildiğini ve hangi modellerin hangi koşullarda daha etkili olduğunu açıkça göstermektedir.



Şekil 5. 101. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)

Şekil 5. 101.'de epoch 25 değerinde yapılan analizler, modellerin başlangıç seviyesinde olduğunu ve özellikle BiLSTM ve RNN'nin bu aşamada öne çıktığını göstermektedir. RNN, kısa vadeli tahminlerde başarılı bir performans sergilemiş, özellikle MAE ve MAPE değerlerinde düşük hata oranları elde etmiştir. Bu da epoch 25 seviyesinde RNN'nin kısa dönem tahminlerinde daha başarılı olduğunu göstermiştir. Ancak, GRU modeli epoch 25 değerindeki tahminlerde zayıf bir performans sergilemiştir. Hem eğitim hem doğrulama kayıplarındaki tutarsızlıklar, modelin daha fazla epoch'a ihtiyaç duyduğunu göstermiştir. GRU, epoch 25 değerinde yüksek hata oranlarıyla dikkat çekmiş ve tahmin sonuçlarında belirgin sapmalar göstermiştir.

BiLSTM modeli ise uzun vadeli tahminlerde güçlü bir performans sergilemiş ve epoch 25 değerinde dengeli bir şekilde öğrenme sürecini devam ettirmiştir. Bu da BiLSTM'nin uzun vadeli öğrenme kapasitelerinin daha yüksek olduğunu göstermektedir.




Şekil 5. 102. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)

Epoch 50 seviyesine gelindiğinde, Şekil 5.102.'de modellerin performansları arasında belirgin farklılıklar görülmüştür. Özellikle BiLSTM ve LSTM modelleri bu noktada çok daha başarılı sonuçlar vermeye başlamış, eğitim ve doğrulama kayıplarındaki dengeli düşüşler bu modellerin daha iyi bir öğrenme sürecine girdiğini göstermiştir.

RNN modelinde ise kayıpların düzensiz seyretmesi ve tahmin sonuçlarındaki sapmalar, epoch 50 değerinde modelin düşük performansını devam ettirdiğini göstermektedir. RNN, özellikle kısa vadeli tahminlerde iyi bir performans sergilese de uzun vadeli eğilimleri yakalamada yetersiz kalmıştır.

GRU ise epoch 25 değerindeki tahminlerine kıyasla daha iyi bir performans sergilemiş, ancak BiLSTM ve LSTM modellerine göre hala daha düşük bir doğruluk seviyesine sahiptir. Bu, modelin öğrenme sürecinin hızlandığını, ancak yeterince optimize olmadığını göstermektedir.




Şekil 5. 103. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)

Epoch 100 seviyesinde, Şekil 5. 103.'de modellerin performansları arasında LSTM'nin öne çıktığı gözlenmiştir. LSTM hem eğitim hem doğrulama kayıplarında dengeli bir öğrenme süreci izlerken, tahmin sonuçlarında da gerçek verilere en yakın sonuçları vermiştir. Özellikle MAPE, MAE ve MSE gibi performans metriklerinde LSTM modelinin üstünlüğü görülmektedir.

GRU modeli de epoch 100 seviyesinde başarılı bir performans sergilemiş, BiLSTM'ye kıyasla daha düşük hata oranları elde etmiştir. Ancak, LSTM'nin performansına yaklaşıp da zirve noktalarında küçük sapmalar yaşanmıştır.

RNN modeli ise epoch 100 değerinde tahmin performansındaki dengesizlikleri devam ettirmiştir. Özellikle dönemsel dalgalanmalarda tahmin hatalarının arttığı gözlenmiştir. Bu durum

modelin daha düşük bir doğruluk sunduğunu göstermektedir. RNN'nin özellikle ani değişimlerdeki yetersiz performansı, modelin Mesken sektörü için uygun olmadığını ortaya koymaktadır.



Şekil 5. 104. Mesken – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)

Epoch 200 değerine ulaşıldığında, Şekil 5. 104.'de BiLSTM modelinin açık ara en başarılı model olduğu netleşmiştir. Eğitim ve doğrulama kayıplarındaki istikrar, modelin aşırı öğrenme yapmadan dengeli bir öğrenme süreci izlediğini göstermektedir. Tahmin sonuçları, gerçek verilerle neredeyse tamamen örtüşmekte ve hata metriklerinde en düşük değerlere sahip olmaktadır. Bu, BiLSTM'nin Mesken sektörü için en uygun model olduğunu kesin bir şekilde ortaya koymaktadır.

LSTM ve GRU modelleri de epoch 200 değerinde iyi bir performans göstermiştir, ancak BiLSTM'ye kıyasla geride kalmışlardır. LSTM, özellikle daha uzun vadeli tahminlerde daha iyi sonuçlar vermiştir. GRU ise epoch 200 seviyesinde daha dengeli bir seviyeye kavuşmuş, ancak LSTM ve BiLSTM kadar güçlü bir performans sergileyememiştir.

RNN modeli ise epoch 200 değerinde hala dengesiz bir tahmin süreci sergilemiştir. Eğitim ve doğrulama kayıplarındaki dalgalanmalar, modelin dengeli bir seviyeye ulaşamadığını ve yüksek hata oranlarına sahip olduğunu göstermektedir. RNN'nin tahmin sonuçları, özellikle 2023 yılındaki dalgalanmalarda gerçek verilerden ciddi sapmalar göstermiştir.

Epoch değerleri arttıkça, BiLSTM modelinin Mesken sektörü için en uygun model olduğu açıkça ortaya çıkmıştır. Özellikle uzun vadeli tahminlerde ve dalgalanmalarda gösterdiği istikrarlı performans, bu modelin en düşük hata oranlarına sahip olmasını sağlamıştır.

LSTM modeli, BiLSTM'yi yakından takip etmiş, ancak özellikle zirve ve dip noktalarındaki küçük sapsmalar nedeniyle bir adım geride kalmıştır. Yine de LSTM, genel olarak güçlü bir tahmin performansı sergilemiştir.

GRU modeli, epoch sayısı arttıkça iyileşme göstermiş, ancak BiLSTM ve LSTM'nin gerisinde kalmıştır. Özellikle kısa vadeli tahminlerde daha fazla hata yapmış, uzun vadede ise kabul edilebilir sonuçlar vermiştir.

RNN modeli ise en düşük performansı sergilemiş, özellikle ani değişimlerin olduğu dönemlerde tahmin hataları ciddi şekilde artmıştır. Bu nedenle, epoch 200 de dahil olmak üzere, RNN modelinin Mesken sektörü için uygun bir model olmadığı söylenebilir.

Sonuç olarak, Mesken sektöründe epoch değerleri arttıkça BiLSTM ve LSTM modelleri öne çıkmakta, GRU ise daha geride kalmaktadır. RNN ise en düşük performansa sahip model olarak karşımıza çıkmaktadır. Mesken sektörüne ait tüm hata metrikleri Tablo 5.2.'de belirtilmiştir.


Tablo 5. 2. Mesken Sektörüne Ait Hata Metrikleri

Sektör	MESKEN SEKTÖRÜ			
Metrik Türü	MAE	RMSE	MSE	MAPE
Epoch Değeri	EPOCH - 25			
RNN	0.078032	0.084019	0.007059	2.858328
GRU	0.138504	0.161727	0.026156	5.045347
LSTM	0.120690	0.143315	0.020539	4.386253
BILSTM	0.087213	0.105557	0.011142	3.265493
Epoch Değeri	EPOCH - 50			
RNN	0.098977	0.103890	0.010793	3.651552
GRU	0.086331	0.104168	0.010851	3.181154
LSTM	0.074452	0.089851	0.008073	2.738719
BILSTM	0.071527	0.085257	0.007269	2.687013
Epoch Değeri	EPOCH - 100			
RNN	0.141881	0.144824	0.020974	5.283064
GRU	0.047419	0.057809	0.003342	1.777689
LSTM	0.043494	0.051154	0.002617	1.640595
BILSTM	0.050396	0.061117	0.003735	1.889744
Epoch Değeri	EPOCH - 200			
RNN	0.185955	0.189816	0.036030	6.922474
GRU	0.065317	0.067140	0.004508	2.443062
LSTM	0.041029	0.050282	0.002528	1.538481
BILSTM	0.006562	0.008343	0.000070	0.248450

5.3. Sanayi Sektörü


Bu kısımda Sanayi sektörüne ait 25-50-100 ve 200 epoch değerleri için modellerin eğitim ve doğrulama kaybı ile modellerin tahmin sonuçlarının gerçek verilerle karşılaştırılması ve performans metrikleri sırasıyla sunulmuştur.

5.3.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)



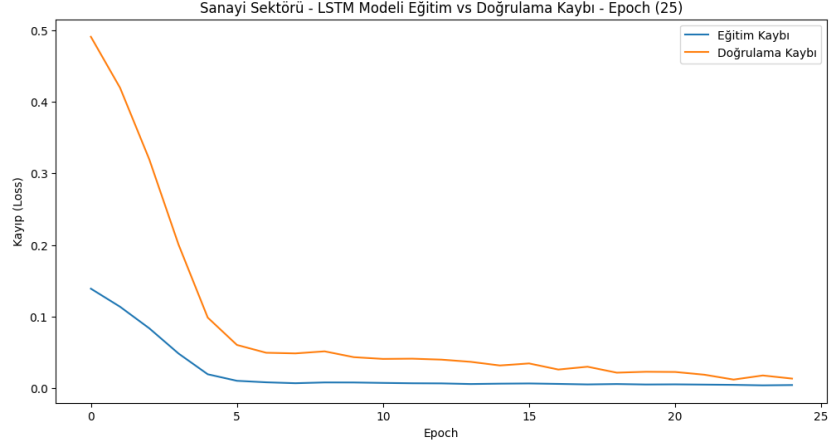
Şekil 5. 105. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5. 105.'de RNN modelinin performansı incelendiğinde eğitim kayıpları oldukça düşük seviyede olmasına rağmen doğrulama kayıplarındaki dalgalanma dikkat çekmektedir. Bu dalgalanma, modelin doğrulama setinde tutarsız performans gösterdiğini işaret etmektedir.



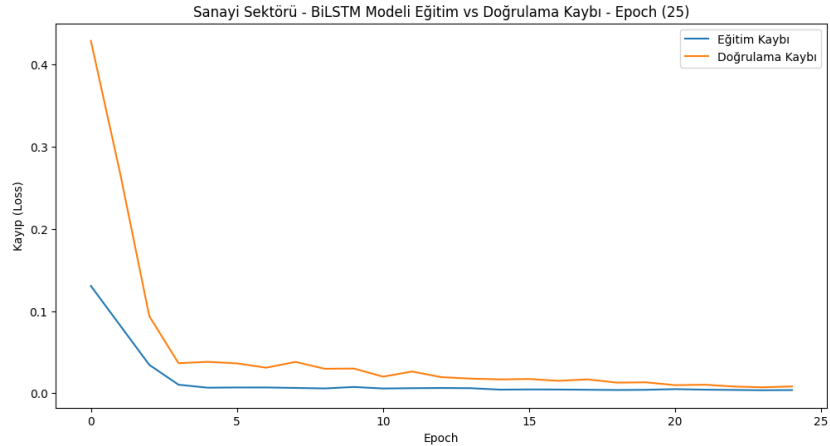
Şekil 5. 106. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5. 106.'da ise GRU modeli daha hızlı bir şekilde doğrulama kaybını azaltarak, eğitim kayıpları ile doğrulama kayıplarının daha yakın seviyelere gelmesini sağlamıştır.



Şekil 5. 107. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5. 107. ve Şekil 5.108. değerlendirildiğinde, BiLSTM ve LSTM modellerinde doğrulama kaybı başlangıçta yüksek olup, eğitimin ilerleyen safhalarında belirgin bir düşüş göstermiştir. Ancak doğrulama kayıpları eğitim kayıplarına göre daha yüksek seyretmektedir.




Şekil 5. 108. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

Sanayi sektörü için epoch 25 değerinde dört modelin eğitim ve doğrulama kayıplarını karşılaştıran grafikleri incelediğimizde, genel olarak, GRU ve BiLSTM modellerinin eğitim ve doğrulama kayıplarının daha dengeli olduğunu, RNN modelinin ise doğrulama kayıplarında dalgalanmalar gözlenmiştir.


5.3.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)

RNN modelinin tahminleri gerçek verilerle uyumlu olmakla beraber, daha küçük dalgalanmalarda belirli sapmalar göstermiştir. Tahminlerdeki sapmalar, modelin doğrusal olmayan

dinamiklerle başa çıkmakta zorlandığını göstermektedir. RNN modelinin tahmin sonuçları Şekil 5. 109.'da gösterilmiştir.




Şekil 5. 109. Sanayi – RNN Gerçek Değerler ve Tahminler (Epoch 25)




Şekil 5. 110. Sanayi – GRU Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5. 110. ve Şekil 5. 111.'de ise LSTM ve GRU modelinin tahmin sonuçlarının gerçek veriler ile karşılaştırılması paylaşılmıştır. LSTM modeli belirli dönemlerde büyük sapmalar göstermiştir. LSTM'nin tahmin eğrisi, özellikle 2020 yılının ikinci yarısında belirgin sapmalar yaşarken, GRU ve BiLSTM modelleri daha dengeli tahminler üretmiştir.



Şekil 5. 111. Sanayi – LSTM Gerçek Değerler ve Tahminler (Epoch 25)




Şekil 5. 112. Sanayi – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5. 112.'de ise BiLSTM'nin tahmin performansı sergilenmiştir. Bu doğrultuda modellerin tahmin sonuçları ile gerçek veriler karşılaştırıldığında, her modelin genel eğilimleri yakalayabilmesine rağmen bazı modellerin zaman zaman büyük sapmalar gösterdiği görülmektedir.

Özellikle BiLSTM ve GRU modelleri, tahmin edilen elektrik tüketim değerlerini gerçek verilere daha yakın tutarken, RNN modelinin ise sanayi sektörü için nispeten iyi tahminler sunduğu, ancak kısa süreli dalgalanmalarda gerçek verilerden sapma eğiliminde olduğu görülmüştür.

Özetle, GRU ve BiLSTM modelleri genel eğilimlere daha uygun tahminler sunarken, LSTM modelinde sapmaların daha belirgin olduğu gözlenmiştir.

5.3.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)




Şekil 5. 113. Sanayi Sektörü MAE Değerleri (Epoch 25)

Şekil 5.113. ve Şekil 5.114. incelendiğinde Sanayi sektörü epoch 25 değerinde performans metriklerine baktığımızda, en düşük MAE ve MAPE değerlerini RNN modeli elde etmiştir. Bu, RNN modelinin sanayi sektörü verisinde daha iyi bir tahmin doğruluğu sunduğunu göstermektedir.

Özellikle LSTM modelinde, MAE (0.122743) ve MAPE (%5.691974) değerlerinin diğer modellere göre daha yüksek olduğu ve bu modelin sanayi sektörü verisine yeterli uyum sağlayamadığı görülmektedir.


GRU ve BiLSTM modelleri ise birbirine yakın performans göstermiş ve LSTM modeline kıyasla daha iyi sonuçlar üretmiştir.



Şekil 5. 114. Sanayi Sektörü MAPE Değerleri (Epoch 25)


Şekil 5.115. ile Şekil 5.116.' da gösterilen MSE ve RMSE değerlerinde de benzer bir tablo gözlenmektedir. RNN modelinde MSE (0.006380) ve RMSE (0.079876) değerleri en düşük seviyede iken, LSTM modelinde bu değerler sırasıyla (0.019192) ve (0.138536) olarak hesaplanmıştır.

BiLSTM ve GRU modelleri ise orta seviyede bir performans göstermiştir. Bu analiz sonuçlarıyla birlikte, epoch sayısının artırılmasıyla diğer modellerin daha iyi performans gösterebileceği ve LSTM modelinin performansının da bu yönde iyileşeceği beklenebilir.



Şekil 5. 115. Sanayi Sektörü MSE Değerleri (Epoch 25)


Sonuç olarak, epoch 25 için yapılan analizlerde en iyi performansı RNN modeli gösterirken, LSTM modelinin daha fazla iyileştirilmesi gerektiği, GRU ve BiLSTM modellerinin ise kabul edilebilir doğrulukta sonuçlar sunduğu ortaya çıkmıştır.



Şekil 5. 116. Sanayi Sektörü RMSE Değerleri (Epoch 25)


5.3.4. Eğitim ve Doğrulama Kayıpları (Epoch 50)

Epoch 50 için eğitim ve doğrulama kayıplarına baktığımızda, BiLSTM, GRU ve LSTM modelleri benzer performanslar sergilemiştir. Ancak, Şekil 5. 117.'de RNN modelinin doğrulama kayıplarında diğer modellere kıyasla önemli dalgalanmalar olduğu görülmektedir.




Şekil 5. 117. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)

RNN modeli diğer modellere göre doğrulama kaybında sürekli dalgalanmalar sergilemiş ve eğitim kayıpları ile uyumsuz bir grafik çizmiştir. Bu durum, RNN modelinin daha fazla aşırı öğrenmeye maruz kalmış olabileceğine işaret eder.




Şekil 5. 118. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)

GRU ve LSTM modelleri ise Şekil 5. 118. ve Şekil 5. 119.'da doğrulama kayıplarında 20. epoch'tan itibaren oldukça düşük ve sabit kalmıştır. Bu durum bu modellerin de veri setine iyi uyum sağladığını göstermektedir.



Şekil 5. 119. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)


Şekil 5. 120.’deki BiLSTM modeli 50 epoch boyunca doğrulama kaybında oldukça kararlı bir düşüş yaşarken, eğitim kaybı da düşük seviyelerde kalmıştır. Bu durum, BiLSTM'nin veri setine iyi bir şekilde uyum sağladığını göstermektedir.




Şekil 5. 120. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

5.3.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)

Şekil 5.121.’de paylaşılan RNN modeli ise tahminlerde belirgin sapmalar göstermektedir. Özellikle dönemsel artış ve azalışlara yeterince uyum sağlayamamış ve gerçek verilerden daha fazla farklılık göstermiştir.




Şekil 5. 121. Sanayi – RNN Gerçek Değerler ve Tahminler (Epoch 50)




Şekil 5. 122. Sanayi – GRU Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5.123.'de ise LSTM modeli, genel olarak iyi performans göstermesine rağmen bazı noktalarda gerçek değerlerden sapma göstermiştir. Ani yükseliş ve düşüşlerde performansı biraz daha zayıf kalmıştır.




Şekil 5. 123. Sanayi – LSTM Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5.122.'de ve Şekil 5.124.'te gösterilen GRU ve BiLSTM modelleri, 2020-2024 yılları arasında oldukça başarılı tahminler üretmiştir. Gerçek verilerle neredeyse paralel gitmiş ve ani değişimlere dahi uyum sağlamıştır.




Şekil 5. 124. Sanayi – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50)

5.3.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)




Şekil 5. 125. Sanayi Sektörü MAE Değerleri (Epoch 50)

Şekil 5.1265.'ye göre MAE açısından, GRU modeli en düşük hata değerine sahiptir (0.054846), ardından BiLSTM (0.055195) gelmektedir. LSTM ise bu iki modelden daha yüksek bir MAE değeri üretmiştir. RNN modelinin MAE değeri ise çok daha yüksektir (0.136986), bu da modelin sapmalarının daha büyük olduğunu gösterir.




Şekil 5. 127. Sanayi Sektörü MAPE Değerleri (Epoch 50)

Şekil 5.1286.'ya göre MAPE açısından da yine BiLSTM (%2.714602) ve GRU (%2.714748) modelleri en düşük MAPE değerine sahiptir. RNN modelinde ise bu değer çok daha yüksektir (%6.350618), bu da RNN'nin genel tahmin doğruluğunun düşük olduğunu gösterir.



Şekil 5. 129. Sanayi Sektörü MSE Değerleri (Epoch 50)


Şekil 5.1307.'ye göre MSE açısından baktığımızda, BiLSTM (0.005114) ve GRU modeli (0.005203) en iyi sonuçları vermektedir. RNN modeli bu metriğe göre de diğerlerinden belirgin bir şekilde daha fazla hata yapmaktadır.



Şekil 5. 131. Sanayi Sektörü RMSE Değerleri (Epoch 50)


Şekil 5.1328.'ye göre RMSE açısından ise BiLSTM (0.071509) ve GRU (0.072130) modelleri en düşük değerlere sahipken, RNN (0.142002) yine en yüksek hata oranına sahiptir. Sonuç olarak, epoch 50 değerinde yapılan analizlerde GRU ve BiLSTM modelleri tahmin doğruluğu ve hata metrikleri açısından en başarılı modeller olarak karşımıza çıkmaktadır. RNN modeli ise her metrikte daha yüksek hata oranlarına sahiptir, bu da modelin diğer modellere göre daha düşük performans gösterdiğini ortaya koymaktadır.

5.3.7. Eğitim ve Doğrulama Kayıpları (Epoch 100)




Şekil 5. 133. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.129.'da belirtilen RNN modelinde eğitim ve doğrulama kayıplarının dalgalı bir seyir izlediği görülmektedir. Bu durum modelin doğrulama performansındaki tutarsızlıkları ön plana çıkarmaktadır.




Şekil 5. 134. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5. 130. ve Şekil 5. 131.'de GRU ve LSTM modelleri, doğrulama kayıplarında daha sabit ve istikrarlı bir azalma göstermiştir. Eğitim kayıpları da düşük seviyelerde dengelenmiştir. GRU modeli LSTM'ye göre daha düşük bir doğrulama kaybı ile daha istikrarlı bir performans sergilemiştir.



Şekil 5. 135. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)




Şekil 5. 136. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5. 132.'deki BiLSTM modelinde ise eğitim kaybı çok düşük seviyelere inmiş ve doğrulama kaybı da benzer şekilde sabitlenmiştir. Bu durum, modelin hem eğitimde hem doğrulamada oldukça dengeli olduğunu göstermektedir. Bu model, en düşük doğrulama kaybına sahip model olarak öne çıkmıştır.


5.3.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100)

Şekil 5.133.'de RNN modelinin tahmin sonuçları, gerçek verilerle kıyaslandığında belirli dönemlerde daha fazla sapmalar göstermektedir. Özellikle elektrik tüketimi dalgalandığında tahminlerdeki uyumsuzluk dikkat çekmektedir.




Şekil 5. 137. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)


Şekil 5.134. ve Şekil 5.135.'teki GRU ve LSTM modellerinin tahmin performansları incelendiğinde, modellerin gerçek verilerle daha uyumlu tahminler yaptığı görülmüştür. Söz konusu modeller genellikle tüketim artış ve azalışlarını doğru tahmin edebilmiştir. LSTM, bazı küçük dönemsel sapmalara rağmen genel olarak daha tutarlı tahminler sunmuştur.



Şekil 5. 138. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)




Şekil 5. 139. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)



Şekil 5. 140. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)


Şekil 5. 136.'daki BiLSTM modelinde, tahminler gerçek değerlere en yakın olacak şekilde ilerlemiştir. Özellikle eğilimleri ve dalgalanmaları yakalamada daha başarılıdır.

5.3.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100)




Şekil 5. 141. Sanayi Sektörü MAE Değerleri (Epoch 100)

Şekil 5. 137.'de paylaşılan MAE değerlendirmesinde BiLSTM modelinin (0.025720) ile en düşük hata değerine sahip olduğu görülmüştür. GRU ve LSTM modelleri de sırasıyla (0.030406) ve (0.038538) hata ile takip etmektedir. RNN modeli ise (0.052961) ile en yüksek MAE'yi sergilemiştir.




Şekil 5. 142. Sanayi Sektörü MAPE Değerleri (Epoch 100)

Şekil 5.138.'de BiLSTM yine en düşük MAPE değeri (%1.250701) ile en iyi performansı göstermektedir. GRU modeli de (%1.487445) ile benzer bir performans sergilemiştir. RNN modeli, (%2.446567) ile en yüksek MAPE değerine sahiptir.



Şekil 5. 143. Sanayi Sektörü MSE Değerleri (Epoch 100)

Şekil 5.139.'da MSE açısından, BiLSTM modeli (0.001077) ile en iyi sonuçları vermektedir. GRU (0.001440) ile yakın bir performans gösterirken, LSTM ve RNN modelleri daha yüksek MSE değerleri sırasıyla (0.002451) ve (0.003099) sergilemiştir.




Şekil 5. 144. Sanayi Sektörü RMSE Değerleri (Epoch 100)

Şekil 5.140.'da paylaşılan RMSE değerlendirmesinde BiLSTM (0.032819) ile en düşük değeri yakalamıştır. GRU modeli (0.037954) ile ikinci sırada yer alırken, RNN ve LSTM daha yüksek RMSE değerleri sergilemiştir.

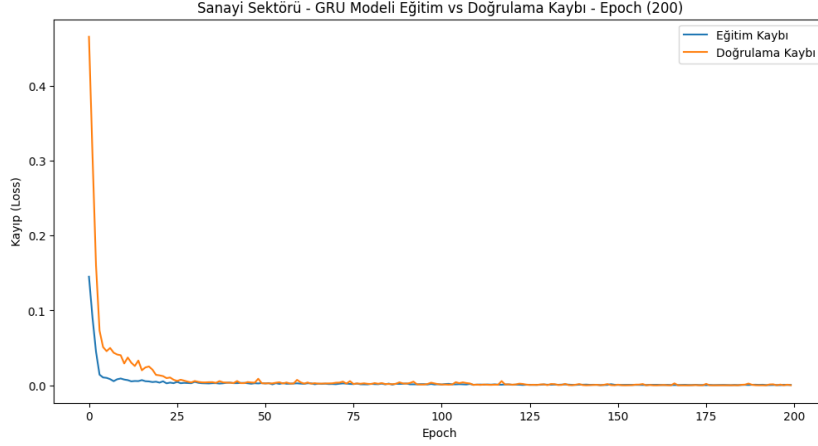
Sonuç olarak, epoch 100 sonuçları incelendiğinde, BiLSTM modelinin hem eğitim ve doğrulama süreçlerinde hem de performans metriklerinde en başarılı sonuçları verdiği görülmüştür. GRU modeli de yakın bir performans sergilemekle birlikte, özellikle doğrulama kayıplarında ve tahmin sonuçlarında BiLSTM'nin gerisinde kalmıştır.

5.3.10. Eğitim ve Doğrulama Kayıpları (Epoch 200)




Şekil 5. 145. Sanayi – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekil 5.141.'de gösterilen RNN modelinde doğrulama kayıpları belirgin şekilde dalgalı bir seyir izlemektedir. Bu, modelin öğrenme sürecinde daha kararsız olduğunu ve aşırı öğrenme yapabileceğini göstermektedir.



Şekil 5. 146. Sanayi – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)

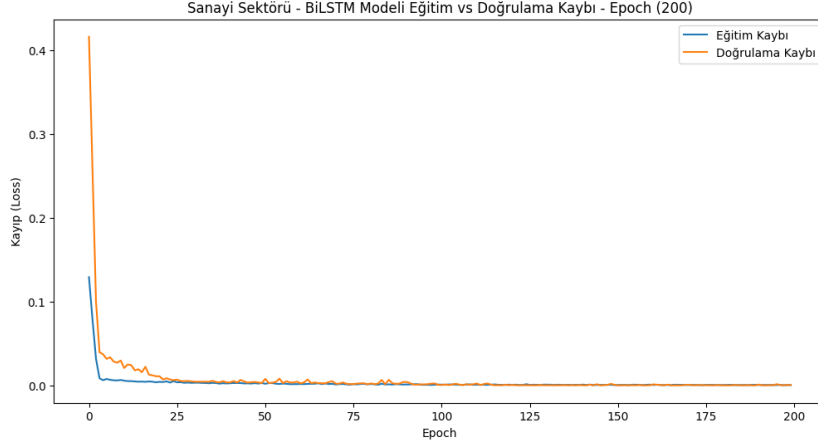
Şekil 5.142.'de gösterilen GRU modelinin de eğitim ve doğrulama kayıpları benzer şekilde düşük seviyelerde ve kararlı hale gelmiştir. Özellikle GRU, BiLSTM ile birlikte daha düşük eğitim kaybı ve doğrulama kaybına sahiptir.



Şekil 5. 147. Sanayi – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)


Şekil 5.143.'de gösterilen LSTM modelinde kayıplar diğer modellere göre biraz daha yüksektir, ancak eğitim ve doğrulama kayıplarındaki azalma modeli yeterli performans gösterdiğini ifade eder. Yine de BiLSTM ve GRU'ya göre daha fazla kayıp yaşanmaktadır.

Şekil 5.144.'de gösterilen BiLSTM modelinin hem eğitim hem de doğrulama kayıpları oldukça düşük seviyelere inmiş ve eğitim ile doğrulama hatası arasında tutarlı bir seyir gözlenmektedir. Bu, modelin aşırı öğrenme yapmadan yüksek doğrulukla eğitildiğini göstermektedir.



Şekil 5. 148. Sanayi – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)


5.3.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)




Şekil 5. 149. Sanayi – RNN Gerçek Değerler ve Tahminler (Epoch 200)

Şekil 5.145.'ye göre RNN modelinin tahmin sonuçları, diğer modellere kıyasla daha düşük bir doğruluğa sahiptir. Özellikle dalgalı ve ani değişimlerin olduğu zaman dilimlerinde tahmin performansı düşüktür.

Şekil 5.146.'ya göre GRU modelinin tahmin sonuçları da oldukça başarılıdır. Gerçek verilerle modelin tahminleri arasında küçük sapmalar olsa da genel olarak oldukça yakın sonuçlar üretilmiştir. Bu, GRU modelinin de tahmin kabiliyetinin yüksek olduğunu göstermektedir.




Şekil 5. 150. Sanayi – GRU Gerçek Değerler ve Tahminler (Epoch 200)



Şekil 5. 151. Sanayi – LSTM Gerçek Değerler ve Tahminler (Epoch 200)


Şekil 5.147.'ye göre ise LSTM modeli, GRU ve BiLSTM kadar başarılı olmasa da gerçek verilerle tahminler arasında nispeten iyi bir uyum göstermektedir. Ancak bazı noktalarda modelin sapma eğilimi gösterdiği görülmektedir.

Şekil 5.148.'de belirtilen BiLSTM modeli, gerçek tüketim verileri ile neredeyse birebir örtüşmektedir. Özellikle 2020-2023 dönemi boyunca gerçekleşen değerlerle oldukça uyumlu tahminler yapmıştır. Bu durum, BiLSTM modelinin sanayi sektöründeki elektrik tüketimi tahminlerinde en başarılı model olduğunu ortaya koymaktadır.




Şekil 5. 152. Sanayi – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200)

5.3.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)




Şekil 5. 153. Sanayi Sektörü MAE Değerleri (Epoch 200)

Şekil 5.149.'da GRU modelinin en düşük MAE (0.015726) değerine sahip olduğu gözlenmiştir. BiLSTM ise (0.023247) ile ikinci en düşük MAE'yi üretmektedir. RNN ise en yüksek MAE (0.062345) değerine sahiptir.




Şekil 5. 154. Sanayi Sektörü MAPE Değerleri (Epoch 200)

Şekil 5.150.'de MAPE açısından GRU modeli (%0.711240) değeri ile yine en düşük hatayı vermektedir. BiLSTM modeli ise (%1.079549) değeri ile ikinci sıradadır. RNN modeli ise en yüksek MAPE değerine sahiptir (%2.867105).



Şekil 5. 155. Sanayi Sektörü MSE Değerleri (Epoch 200)

Şekil 5.151.'de MSE açısından da GRU modeli (0.000355) ile en iyi performansı sergilemektedir. BiLSTM ise (0.000591) ile ikinci sıradadır. RNN modelinin MSE (0.004353) değeri ise en yüksektir.




Şekil 5. 156. Sanayi Sektörü RMSE Değerleri (Epoch 200)

Şekil 5.152.'de RMSE değerlerinde de GRU modeli en düşük hata ile liderdir (0.018840), ardından BiLSTM modeli (0.024315) ile gelmektedir. RNN modeli ise en yüksek RMSE'ye (0.065976) sahiptir.

Epoch 200 değeri için modellerin performans metriklerine göre genel bir değerlendirme yapıldığında elde edilen sonuçlara göre, GRU modeli sanayi sektöründe en düşük hata oranlarına sahip modeldir. BiLSTM ise GRU modelini yakından takip etmektedir ve çok düşük hatalar üretmiştir. LSTM modeli tatmin edici sonuçlar verse de GRU ve BiLSTM kadar iyi performans

gösterememiştir. RNN modeli ise tüm performans metriklerinde en düşük sonuçları vermiştir ve sanayi sektörü tahminleri için uygun bir model olmadığını göstermektedir. Bu analiz, epoch 200 değerindeki GRU ve BiLSTM modellerinin sanayi sektöründe elektrik tüketimi tahminlerinde oldukça başarılı olduklarını ortaya koymaktadır.

5.3.13. Sanayi Sektörü Bazında Genel Değerlendirme




Şekil 5. 157. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)

Sanayi sektöründe dört farklı modelin epoch 25, 50, 100 ve 200 değerlerindeki performanslarını karşılaştırarak genel bir değerlendirme yapacak olursak, modellerin performanslarının epoch sayısına göre belirgin şekilde değiştiği gözlenmiştir. Genel olarak, BiLSTM ve GRU modelleri daha iyi sonuçlar verirken, RNN modelinin her epoch sayısında daha düşük performans sergilediği görülmektedir. LSTM modeli ise ortalama bir performans sergilemekle birlikte, BiLSTM ve GRU modellerinin gerisinde kalmıştır.

Epoch 25 seviyesinde, Şekil 5.153.'de modellerin öğrenme kapasiteleri düşük olup, modelin eğitimi henüz tam oturmuş durumda değildir. Bu aşamada RNN modeli, performans metriklerinde (MAE, MAPE, MSE) en düşük hata oranlarını vermiştir. Ancak bu, RNN'nin model doğruluğunda dengeli bir performans sunduğu anlamına gelmemektedir. Çünkü eğitim ve doğrulama kayıplarında ciddi dalgalanmalar meydana gelmiştir. BiLSTM ve GRU modelleri, epoch 25 seviyesinde dengeli doğrulama kaybı ile dikkat çekse de hata oranlarında RNN'nin gerisinde kalmıştır. Ancak, bu durum geçici bir başarı olarak değerlendirilebilir; zira epoch sayısı arttıkça, RNN modelinde performans kaybı gözlenmiştir. LSTM modeli ise bu epoch değerinde daha zayıf bir performans sergilemiş ve en yüksek hata oranlarını vermiştir.

Sonuç olarak, epoch 25 değerinde RNN modelinin öne çıktığı, BiLSTM ve GRU'nun dengeli performans sergilediği, ancak genel performanslarının yüksek epoch sayılarında daha iyi hale geleceği öngörülmüştür.



Şekil 5. 158. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)

Epoch 50 seviyesine ulaşıldığında, Şekil 5.154.'de modellerin doğrulama kayıpları önemli ölçüde azalmış ve eğitim süreci daha dengeli hale gelmiştir. BiLSTM ve GRU modelleri hem tahmin sonuçları açısından hem de performans metriklerinde oldukça başarılı sonuçlar vermiştir.

Bu modellerin eğitim ve doğrulama kayıpları dengeli bir seyir izlerken, tahmin sonuçları gerçek verilere oldukça yakın olmuştur. Özellikle GRU modeli, daha düşük MAE ve MAPE değerleri ile dikkat çekmiştir.


LSTM modeli, epoch 25 seviyesindeki performansına kıyasla daha iyi bir performans sergilemiş olsa da GRU ve BiLSTM modelleri kadar başarılı olamamıştır.

RNN modeli ise Epoch 50'de dalgalı doğrulama kayıpları ve yüksek hata oranları ile en zayıf performansı sergilemeye başlamıştır. RNN modelinin tahmin sonuçlarındaki büyük sapmalar, modelin doğrusal olmayan sanayi verileri ile başa çıkmada zorlandığını göstermiştir.

Bu noktada, epoch 50 değerinde GRU ve BiLSTM modellerinin başarılı sonuçlar verdiği, RNN modelinin ise performans kaybetmeye başladığı görülmektedir.

Şekil 5. 155.'de epoch 100 değerinin modellerin sanayi sektörü verilerine en iyi uyum sağladıkları aşama olduğu görülmektedir. BiLSTM modeli hem eğitim hem de doğrulama kayıplarında oldukça dengeli hale gelmiş ve performans metriklerinde en düşük hata oranlarını


sağlamıştır. Gerçek verilerle tahmin sonuçları neredeyse birebir örtüşmüş ve bu model, sanayi sektöründeki eğilim ve dalgalanmaları en doğru şekilde yakalayabilmiştir.



Şekil 5. 159. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)

GRU modeli, BiLSTM'ye benzer şekilde başarılı sonuçlar vermiş, ancak hata oranlarında BiLSTM'nin bir adım gerisinde kalmıştır. LSTM modeli de epoch 100 seviyesinde iyi sonuçlar vermiş, ancak GRU ve BiLSTM kadar düşük hata oranları sağlamamıştır. RNN modeli ise eğitim ve doğrulama kayıplarında ciddi dalgalanmalar sergilemeye devam etmiş ve genel tahmin doğruluğu açısından düşük performans göstermiştir.

Sonuç olarak, epoch 100 değerinde BiLSTM modeli en başarılı model olarak öne çıkarken, GRU modeli de oldukça yakın bir performans sergilemiştir. RNN modeli ise sanayi sektöründe başarılı tahminler yapmada başarısız kalmıştır.



Şekil 5. 160. Sanayi – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)

Şekil 5.156. incelendiğinde ise epoch 200 seviyesi, modellerin sanayi sektörü verisine uyum sağlama kapasitesinin en üst seviyeye çıktığı aşama olmuştur. Bu aşamada, GRU modeli en düşük hata oranları ile en iyi performansı sergilemiştir.

BiLSTM modeli, GRU'nun hemen arkasında yer almış ve düşük MAE, MAPE ve MSE değerleri ile dikkat çekmiştir. Eğitim ve doğrulama kayıpları açısından BiLSTM ve GRU modelleri oldukça dengeli hale gelmiştir.

LSTM modeli, epoch 100 değerindeki performansını biraz daha iyileştirmiş olsa da GRU ve BiLSTM modellerinin gerisinde kalmaya devam etmiştir. RNN modeli ise epoch 200 seviyesinde en düşük performansı sergileyerek eğitim sürecinde ciddi dalgalanmalar göstermiş ve tahmin sonuçlarında yüksek sapmalar vermiştir.

Epoch 200 sonuçları, GRU ve BiLSTM modellerinin sanayi sektöründeki elektrik tüketimi tahminlerinde oldukça başarılı olduğunu ve düşük hata oranları ile dengeli sonuçlar verdiğini ortaya koymuştur.

RNN modelinin sanayi sektörü için uygun bir tahmin aracı olmadığı bir kez daha görülmüş, LSTM modelinin ise yeterli performans sağladığı ancak GRU ve BiLSTM'nin gerisinde kaldığı anlaşılmıştır.

Sanayi sektörü analizlerinde dört farklı modelin epoch 25, 50, 100 ve 200 değerleri incelendiğinde, BiLSTM ve GRU modelleri en başarılı sonuçları vermiştir. Bu modeller, düşük hata oranları ve yüksek tahmin doğruluğu ile sanayi sektöründeki elektrik tüketimini başarılı bir şekilde tahmin edebilmiştir.

LSTM modeli, makul bir performans sergilemekle birlikte, BiLSTM ve GRU kadar etkili olamamıştır. RNN modeli ise epoch 25 değerinden sonra epoch değerleri yükseldikçe en düşük performansı göstermiş ve sanayi sektörü gibi karmaşık verilerle başa çıkmakta yetersiz kalmıştır.

Sonuç olarak, sanayi sektöründe BiLSTM ve GRU modellerinin tercih edilmesi, en düşük hata oranları ve en yüksek tahmin doğruluğu ile en iyi sonuçları verecektir. RNN modeli ise daha basit veri yapılarında kullanılsa da sanayi sektörü gibi dinamik ve doğrusal olmayan verilerde etkili bir tahmin aracı değildir. Sanayi sektörüne ait tüm hata metrikleri Tablo 5.3.'de belirtilmiştir.

Tablo 5. 3. Sanayi Sektörüne Ait Hata Metrikleri

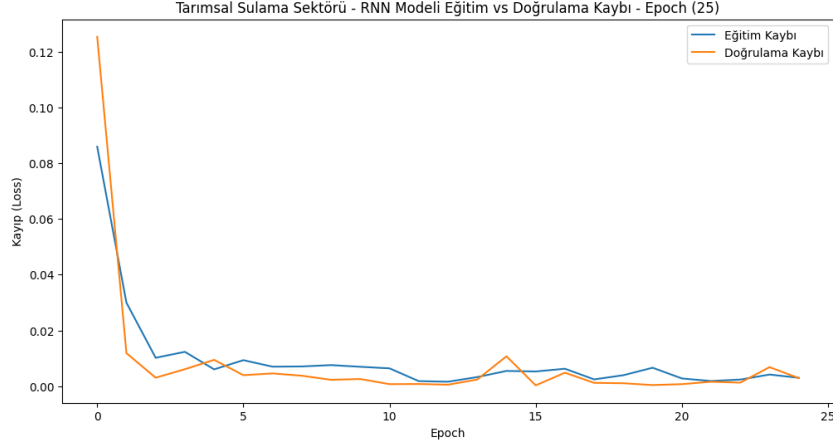
Sektör	SANAYİ SEKTÖRÜ			
Metrik Türü	MAE	RMSE	MSE	MAPE
Epoch Değeri	EPOCH - 25			
RNN	0.074829	0.079876	0.006380	3.434705
GRU	0.092950	0.108422	0.011755	4.371237
LSTM	0.122743	0.138536	0.019192	5.691974
BILSTM	0.091634	0.108728	0.011822	4.342436
Epoch Değeri	EPOCH - 50			
RNN	0.136986	0.142002	0.020165	6.350618
GRU	0.054846	0.072130	0.005203	2.714748
LSTM	0.064923	0.078600	0.006178	3.124691
BILSTM	0.055195	0.071509	0.005114	2.714602
Epoch Değeri	EPOCH - 100			
RNN	0.052961	0.055672	0.003099	2.446567
GRU	0.030406	0.037954	0.001440	1.487445
LSTM	0.038538	0.049507	0.002451	1.885567
BILSTM	0.025720	0.032819	0.001077	1.250701
Epoch Değeri	EPOCH - 200			
RNN	0.062345	0.065976	0.004353	2.867105
GRU	0.015726	0.018840	0.000355	0.711240
LSTM	0.035313	0.044000	0.001936	1.702816
BILSTM	0.023247	0.024315	0.000591	1.079549

5.4. Tarımsal Sulama Sektörü

Bu kısımda Tarımsal Sulama sektörüne ait 25-50-100 ve 200 epoch değerleri için modellerin eğitim ve doğrulama kaybı ile modellerin tahmin sonuçlarının gerçek verilerle karşılaştırılması ve performans metrikleri sırasıyla sunulmuştur.


5.4.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)

Eğitim ve doğrulama kayıpları karşılaştırıldığında, modellerin genel olarak başarılı bir öğrenme süreci gösterdiği gözlenmektedir. Her dört modelde de epoch sayısı ilerledikçe kayıplar ciddi oranda azalmış, doğrulama kayıpları ise eğitim kayıpları ile uyumlu bir şekilde düşüş göstermiştir.



Şekil 5. 161. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)

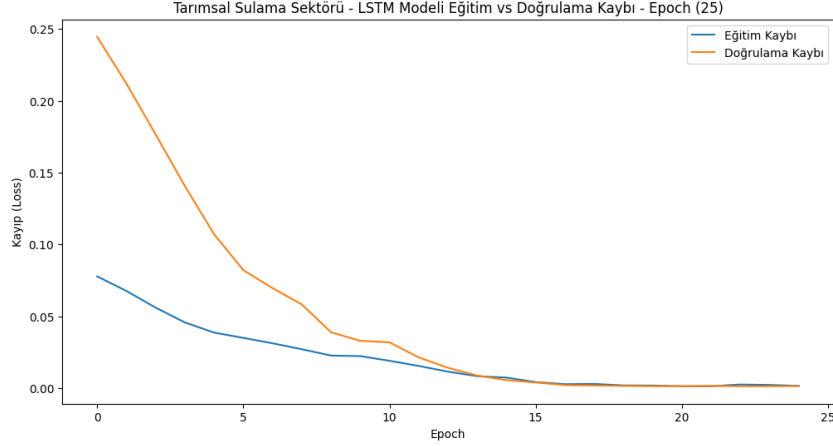
Bu doğrultuda Şekil 5.157.’de RNN modeli başlangıçta yüksek bir doğrulama kaybı ile başlamış ve daha düzensiz bir azalma göstermiştir. Ancak doğrulama kaybının eğitim kaybı ile zaman zaman kesişmesi modelin bu epoch sayısında dengeli öğrenme süreci yaşamadığını göstermektedir.



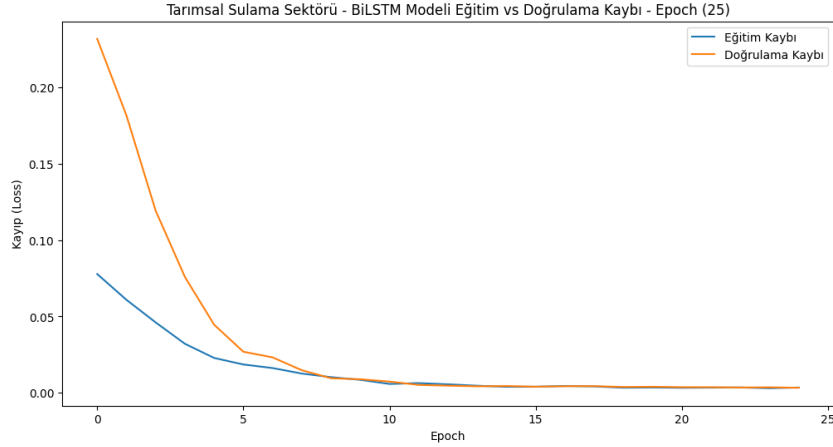
Şekil 5. 162. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5.158.’ye göre GRU modeli, doğrulama kaybının eğitim kaybı ile oldukça uyumlu bir şekilde azaldığı bir yapı sunmaktadır. Özellikle 5. epoch’tan sonra modelin performansında daha dengeli bir azalma görülmektedir. Bu, GRU’nun daha kararlı bir öğrenme kapasitesine sahip olduğunu işaret etmektedir.

Şekil 5.159.'ya göre LSTM modeli hem eğitim hem de doğrulama kayıplarının en hızlı ve dengeli bir şekilde azaldığı model olarak dikkat çekmektedir. Eğitim kaybı ile doğrulama kaybı arasındaki fark oldukça küçüktür, bu da modelin aşırı öğrenme yaşamadığını ve iyi bir öğrenme süreci izlediğini gösterir.



Şekil 5. 163. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)




Şekil 5. 164. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)

Şekil 5.160.'ya göre BiLSTM modeli, eğitim ve doğrulama kayıplarında benzer bir azalma eğrisi gösterirken, diğer modellere kıyasla biraz daha yüksek kayıplar sergilediği gözlenmektedir. Özellikle epoch ilerledikçe eğitim-doğrulama kaybı dengelenmiş, ancak LSTM kadar hızlı öğrenme sağlamamıştır.


5.4.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)

Modellerin tahmin sonuçları gerçek verilerle karşılaştırıldığında genel olarak dört modelin de tahmin performanslarının birbirine yakın olduğu görülmektedir. Ancak daha detaylı incelemede bazı farklılıklar öne çıkmaktadır.



Şekil 5. 165. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 25)


Şekil 5.161.'de gösterilen RNN modelinin tahmin grafiği incelendiğinde, modelin bazı ani dalgalanmalar ve yüksek tüketim değerlerinde sapmalar yaşadığı görülmektedir. Özellikle elektrik tüketiminin ani arttığı dönemlerde modelin gerçek veriden saptığı dikkat çekmiştir.



Şekil 5. 166. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 25)


Şekil 5.162.'ye göre GRU modeli, genel olarak tahminlerinde daha istikrarlı bir performans göstermiştir. Yüksek elektrik tüketim dönemlerinde bile model, gerçek verilere oldukça yakın

tahminlerde bulunmuştur. Özellikle yaz aylarında (2022-2023) elektrik tüketimindeki artış dönemlerinde GRU'nun başarılı tahminlerde bulunduğu gözlenmektedir.



Şekil 5. 167. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5.163.'de belirtilen LSTM modeli, gerçek verilerle neredeyse mükemmel bir uyum sağlamıştır. Model, özellikle ani yükseliş ve düşüşlerdeki sapmaları minimize edebilmiştir. Elektrik tüketimindeki zirvelerde bile tahmin doğruluğu yüksek kalmıştır.




Şekil 5. 168. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25)


Şekil 5.164.'de belirtilen BiLSTM, LSTM'ye benzer bir performans sergilese de tahmin sonuçları gerçek verilere kıyasla hafif bir sapma göstermiştir. Yüksek elektrik tüketimi dönemlerinde LSTM kadar iyi performans göstermemiştir, ancak yine de RNN göre daha doğru tahminlerde bulunmuştur.

5.4.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)

Hata metriklerine baktığımızda, modeller arasında belirgin farklılıklar olduğu görülmektedir. Şekil 5.165.'ye göre LSTM modeli en düşük hata değerine sahiptir. Bu da modelin hem kısa hem de uzun vadeli tahminlerde daha başarılı olduğunu göstermektedir. MAE (0.041596), MAPE (%5.290006), MSE (0.003309) ve RMSE (0.05752) değerleri ile LSTM, Tarımsal Sulama Sektörü için en iyi performansı sergilemiştir.




Şekil 5. 169. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 25)




Şekil 5. 170. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 25)

Şekil 5.166.'ya göre LSTM en düşük MAPE (%5.290006) değerine sahiptir. GRU, MAPE (%6.624227) ve MAE (%0.053856) değerleri ile LSTM'den sonra en iyi performansı gösteren modeldir. GRU, özellikle uzun vadeli tahminlerde istikrar göstermektedir.

Şekil 5.167. ve Şekil 5.168. incelendiğinde BiLSTM, LSTM ve GRU'ya kıyasla biraz daha yüksek hata oranlarına sahiptir. RMSE (0.084156) ve MAE (0.059965) değerleri bu farkı açıkça göstermektedir. Ancak modelin genel performansı kabul edilebilir düzeydedir.



Şekil 5. 171. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 25)




Şekil 5. 172. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 25)

RNN modeli ise hata metriklerinde en yüksek değerlere sahip olan modeldir. MAPE (%10.618295) ve MAE (0.077126) gibi yüksek değerlerle, modelin diğer modellere kıyasla daha düşük performans sergilediği ve sektördeki elektrik tüketimi tahminlerinde beklenen doğruluğu sağlayamadığı anlaşılmaktadır.

Tarımsal Sulama Sektörü için epoch 25 analizlerinde LSTM modeli açık ara en iyi performansı göstermiştir. Bunu sırasıyla GRU, BiLSTM ve RNN modelleri takip etmektedir. Hata metrikleri, tahmin sonuçlarının gerçek verilerle uyumu ve eğitim/doğrulama kayıplarına göre LSTM, epoch 25 değerindeki ve bu sektördeki elektrik tüketim tahmini için en uygun model olarak öne çıkmaktadır.

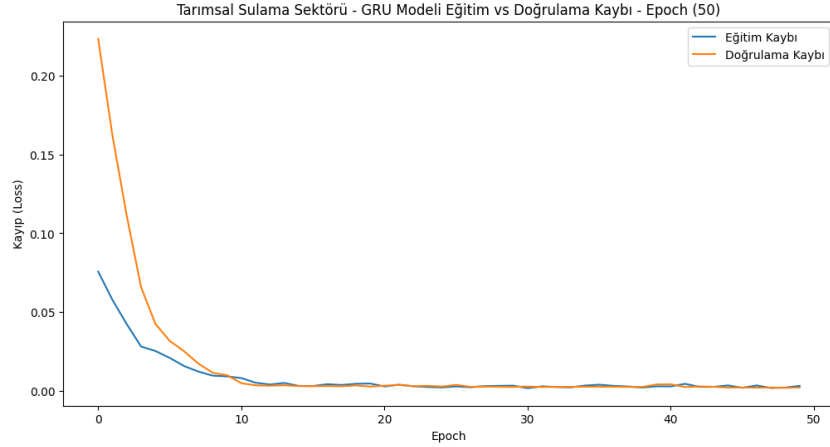
5.4.4. Eğitim ve Doğrulama Kayıpları (Epoch 50)

Modellerin eğitim ve doğrulama kayıpları incelendiğinde, epoch 50 değerindeki sonuçlar epoch 25 değerindeki sonuçlara kıyasla daha dengeli bir öğrenme süreci sunmaktadır. Her dört model de belirli bir noktada doğrulama ve eğitim kayıplarını minimum seviyeye indirmiştir.



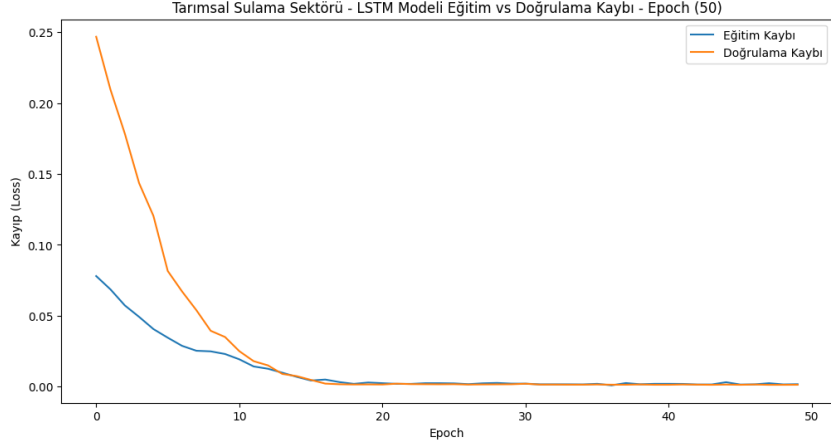
Şekil 5. 173. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.169.'da belirtilen RNN modeli, başlangıçta oldukça yüksek bir doğrulama kaybına sahip olup daha sonra yavaşça düşüş göstermiştir. Ancak epoch ilerledikçe eğitim ve doğrulama kaybı arasındaki farkın genişlemesi, modelin aşırı öğrenme yaşadığını ve daha fazla epoch'ta dengeli kalamadığını göstermektedir.



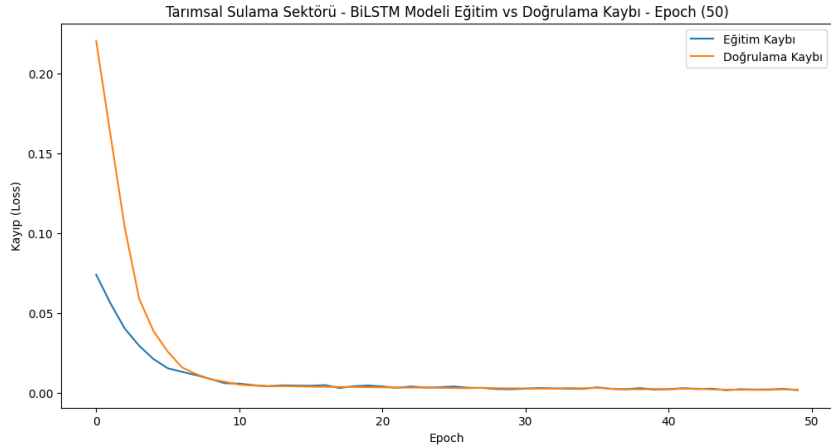
Şekil 5. 174. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.170.'ye göre GRU'nun doğrulama kaybı, eğitim kaybı ile oldukça paralel bir düşüş göstermektedir. Doğrulama kaybı, yaklaşık 10. epoch'tan itibaren dengeli bir hale gelmiş ve daha fazla dalgalanma göstermemiştir. GRU, özellikle uzun epoch süreçlerinde istikrarlı bir model olarak öne çıkmıştır.



Şekil 5. 175. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.171.'de paylaşılan LSTM modeli epoch 50'deki en düşük eğitim ve doğrulama kayıplarına sahip olan modeldir. LSTM'nin öğrenme süreci oldukça dengeli bir şekilde ilerlemiş ve doğrulama kaybı eğitim kaybı ile çok yakın seviyelere kadar düşmüştür.




Şekil 5. 176. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.172.'de paylaşılan BiLSTM modeli, LSTM'ye göre bir miktar daha yüksek eğitim ve doğrulama kayıpları sergilemiştir. Ancak genel olarak eğitim ve doğrulama kayıplarının benzer bir hızda azaldığı ve dengeli bir noktaya geldiği görülmektedir.


5.4.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)

Modellerin tahmin sonuçları epoch 50 seviyesinde gerçek verilerle karşılaştırıldığında daha yüksek doğruluk oranları sergilenmiştir. Özellikle LSTM ve GRU modelleri, tahminlerinde gerçek verilerle oldukça yakın sonuçlar sunmuştur.



Şekil 5. 177. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 50)


Şekil 5.173.’de belirtilen RNN modeli, epoch 25 değerinde olduğu gibi epoch 50 değerinde de tahmin performansında diğer modellere kıyasla daha düşük bir doğruluk sergilemektedir. Elektrik tüketiminin yüksek olduğu dönemlerde sapmalar daha belirgin hale gelmiştir.




Şekil 5. 178. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5.174.’de belirtilen GRU modeli, özellikle yaz aylarındaki elektrik tüketimindeki ani artışları ve düşüşleri başarılı bir şekilde tahmin edebilmiştir. Genel olarak tahmin performansı oldukça dengeli ve gerçek verilerle uyumludur.

Şekil 5.175.’de belirtilen LSTM modeli, tahmin sonuçları açısından en başarılı model olarak öne çıkmıştır. Gerçek verilerle neredeyse birebir örtüşen tahminler üretebilmiştir. Özellikle mevsimsel değişimlerde tahmin sonuçları yüksek doğruluğa sahiptir.




Şekil 5. 179. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 50)



Şekil 5. 180. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50)


Şekil 5.176.'da belirtilen BiLSTM, LSTM ve GRU modellerine benzer bir performans sergilemiş ancak özellikle elektrik tüketimindeki en yüksek değerlerde hafif sapmalar göstermiştir.

5.4.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)



Şekil 5. 181. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 50)


Epoch 50 deęerindeki hata metriklerinin paylařıldıęı Őekil 5.177. incelendięinde, LSTM modelinin aık ara en dŐk hata oranlarına sahip olduęu grlmektedir. Dięer modellerle kıyaslandıęında LSTM hem kısa hem de uzun vadeli tahminlerde daha bařarılıdır. Hata metriklerinde LSTM, en dŐk MAE (0.035963), MAPE (%4.516377), MSE (0.002718) ve RMSE (0.052131) deęerlerine sahiptir.




Őekil 5. 182. Tarımsal Sulama Sektr MAPE Deęerleri (Epoch 50)

Őekil 5.178.'de GRU, hata metriklerinde LSTM'den sonra en iyi performansı sergileyen modeldir. MAE (0.051443) ve MAPE (%6.670659) deęerleri ile uzun dnem tahminlerde olduka bařarılı sonular vermektedir. BiLSTM, GRU'dan biraz daha dŐk performans sergilese de genel olarak kabul edilebilir hata metriklerine sahiptir. MAE (0.044943) ve MSE (0.003974) deęerleri ile GRU'ya yakın sonular elde etmiřtir.

Őekil 5.179.'da RNN, epoch 50 deęerinde de en yksek hata oranlarına sahip modeldir. MAPE (%14.376441), MAE (0.109088) ve MSE (0.012996) gibi deęerlerle, dięer modellere kıyasla daha dŐk performans sergilemiřtir. Elektrik tkretimindeki deęiřkenlikleri yeterince iyi tahmin edememiřtir.




Őekil 5. 183. Tarımsal Sulama Sektr MSE Deęerleri (Epoch 50)



Şekil 5. 184. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 50)

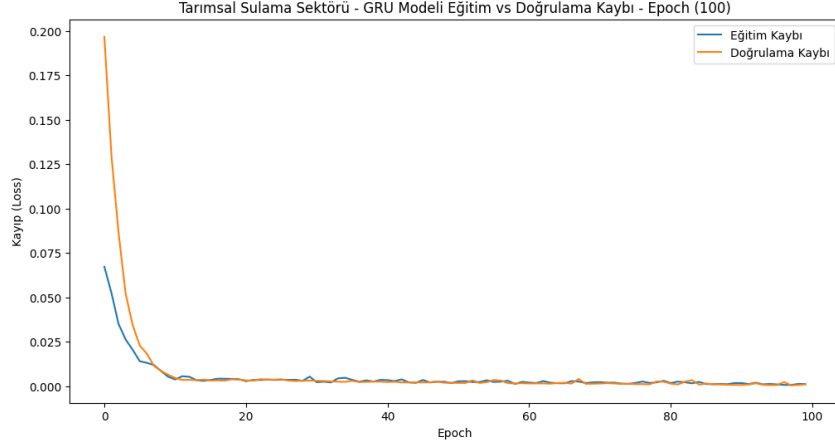
Şekil 5.180.'de görüleceği üzere LSTM modeli epoch 50 analizlerinde en başarılı tahmin sonuçlarını vermiştir. GRU ve BiLSTM modelleri LSTM'yi takip ederken, RNN modeli tahmin performansı açısından diğer modellere kıyasla zayıf kalmıştır. LSTM'nin düşük hata oranları ve gerçek verilerle yüksek uyumu, bu modelin elektrik tüketim tahminlerinde en doğru model olduğunu göstermektedir.

5.4.7. Eğitim ve Doğrulama Kayıpları (Epoch 100)




Şekil 5. 185. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.181.- Şekil 5.184.'ye göre RNN, GRU, LSTM ve BiLSTM modelleri arasında epoch 100 değerinde eğitim ve doğrulama kayıpları açısından gözlemlenen farklar dikkat çekicidir. Tüm modellerde eğitim ve doğrulama kayıpları epoch'lar ilerledikçe hızla azalmış, belli bir noktadan sonra minimum seviyeye yaklaşmıştır.



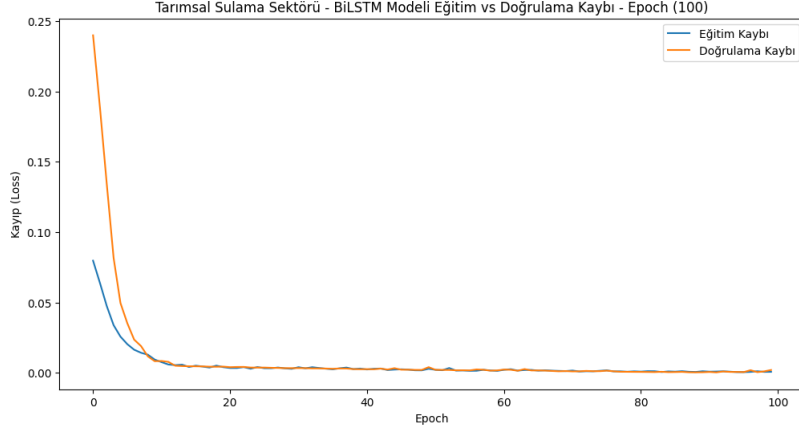
Şekil 5. 186. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 100)

BiLSTM ve LSTM modelleri, özellikle doğrulama kayıpları açısından diğer modellere göre daha iyi performans sergilemişlerdir. Grafiklerde de gözlemlendiği gibi, bu iki modelde eğitim ve doğrulama kayıpları arasındaki fark oldukça küçüktür, bu da modellerin genel olarak dengeli ve iyi bir şekilde öğrendiklerini göstermektedir.




Şekil 5. 187. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

RNN modelinde ise doğrulama kaybı eğitim kaybına göre dalgalanmalar göstermiş ve dengeli bir öğrenme eğrisi elde edilememiştir. Bu dalgalanma, modelin zamanla aşırı uyum yaşadığına işaret edebilir. Benzer şekilde GRU modeli de iyi bir doğrulama kaybı sergilemiş olsa da BiLSTM ve LSTM'nin performansına kıyasla biraz daha yüksek bir doğrulama kaybına sahiptir.




Şekil 5. 188. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

5.4.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100)




Şekil 5. 189. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5.185.'de ve Şekil 5.186.'de RNN ve GRU modellerine ait tahminler paylaşılmıştır.




Şekil 5. 190. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 100)

Modellerin tahmin sonuçlarını gerçek elektrik tüketim verileriyle kıyasladığımızda, tüm modellerin eğilimleri yakalamakta başarılı olduklarını söyleyebiliriz. Ancak RNN modeli, kısa dönemli dalgalanmalarda diğer modellere göre daha az başarılı olmuş ve tahminlerinde daha fazla sapma gözlenmektedir. Şekil 5.187.'de ve Şekil 5.188.'de LSTM ve BiLSTM modellerine ait tahminler paylaşılmıştır.



Şekil 5. 191. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 100)

Özellikle tepe noktaların tahmininde GRU, LSTM ve BiLSTM daha iyi sonuçlar elde etmişlerdir. BiLSTM modeli, tepe tüketim noktalarını oldukça isabetli bir şekilde tahmin etmiş, bu da modelin kompleks zaman serilerini daha iyi kavrayabildiğini göstermektedir.




Şekil 5. 192. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100)

LSTM ve GRU modelleri de yüksek tahmin başarısı göstermiştir ancak LSTM, GRU'ya göre daha dengeli ve genel eğilimi daha iyi takip etmiştir. RNN modelinin tahminlerinde ise

özellikle tepe noktalarında ciddi sapmalar gözlemlenmiş, bu da modelin karmaşık zaman serilerinde yeterli performansı gösteremediğini ortaya koymaktadır.

5.4.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100)


Performans metriklerine baktığımızda, epoch 100 seviyesindeki hata metrik değerlerine göre RNN, GRU, LSTM ve BiLSTM modellerinin karşılaştırmalı performansı ortaya çıkmaktadır.



Şekil 5. 193. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 100)


Şekil 5.189.'de incelendiğinde RNN modeli en düşük MAE'yi vermiş, yani mutlak hata açısından en başarılı model olmuştur. Bu durum, modelin genel eğilimi yakalamada zayıf olmasına rağmen kısa dönemli tahminlerde düşük hata üretmiş olmasından kaynaklanmakta olduğu değerlendirilmektedir.

Şekil 5.190.'ya göre RNN modeli yine en düşük MAPE'yi üretmiştir, yani tahmin edilen değerlerin gerçek değerlerden yüzdesel sapması en düşük olan modeldir. BiLSTM modeli ise en yüksek MAPE'ye sahiptir, bu da BiLSTM'nin özellikle bazı dönemlerde yüksek sapmalar yaşadığını göstermektedir.




Şekil 5. 194. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 100)

Şekil 5.191.'de belirtilen MSE açısından da RNN modeli en düşük hata değerini sağlamış, LSTM ve GRU modelleri de yakın performans göstermiştir. BiLSTM, diğer modellere kıyasla en yüksek MSE değerine sahiptir.



Şekil 5. 195. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 100)

Şekil 5.192.'de paylaşılan RMSE metriğine göre de RNN en düşük değere sahip olup, BiLSTM en yüksek RMSE değerini üretmiştir. Yüksek RMSE, modelin büyük sapmalarla hata yaptığı dönemlerin varlığını ortaya koymaktadır.




Şekil 5. 196. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 100)

Sonuç olarak, her bir modelin güçlü ve zayıf yönleri farklı metriklerde ortaya çıkmıştır. Genel olarak, LSTM modeli tüm metriklerde dengeli bir performans sergileyerek tahmin başarısında öne çıkmıştır.

RNN modelinin düşük hata oranlarına rağmen genel tahmin başarısının sınırlı olduğu değerlendirilebilir. BiLSTM modelinin ise güçlü olduğu bazı noktalar olmasına rağmen, özellikle epoch 100 değerinde tahmin performansında genel olarak daha yüksek sapmalar yaşadığı söylenebilir. GRU modeli ise LSTM'ye yakın bir performans göstererek başarılı sonuçlar vermiştir.


Bu analiz sonuçları, farklı modellerin performansını değerlendirmek için epoch 100 gibi daha ileri dönemlerde daha derin bir öğrenmenin gerçekleştiğini ve bu modellerin elektrik tüketimi gibi karmaşık zaman serisi verilerini tahmin etmekte genel olarak başarılı olduklarını göstermektedir.

5.4.10. Eğitim ve Doğrulama Kayıpları (Epoch 200)



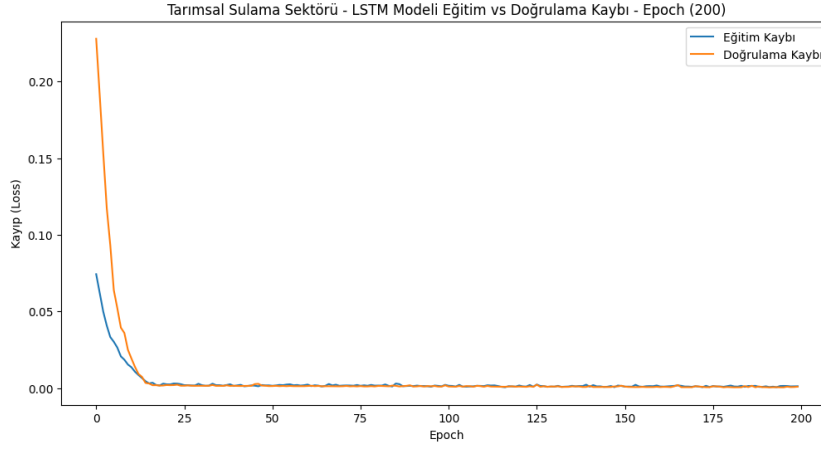
Şekil 5. 197. Tarımsal Sulama – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekillere bakıldığında, tüm modellerin doğrulama ve eğitim kayıplarının genellikle düşük olduğu ve hızla sabitlendiği gözlemlenmektedir. Şekil 5. 193.'de RNN modelinde, doğrulama kaybının zaman zaman eğitim kaybından daha yüksek olduğu ve dalgalanmalar görüldüğü için RNN'in istikrarsız bir öğrenme eğrisine sahip olduğu söylenebilir.




Şekil 5. 198. Tarımsal Sulama – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekil 5. 194. Ve Şekil 5. 195. incelendiğinde özellikle, LSTM ve GRU modelleri düşük kayıplarla daha tutarlı bir performans sergilemiştir.



Şekil 5. 199. Tarımsal Sulama – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)

LSTM ve GRU modelleri arasında ise kayıp değerleri benzer olup, Şekil 5. 196.'da BiLSTM modelinin doğrulama kaybı daha düşük seyretmektedir, bu da daha iyi bir genel performansın işaretidir.

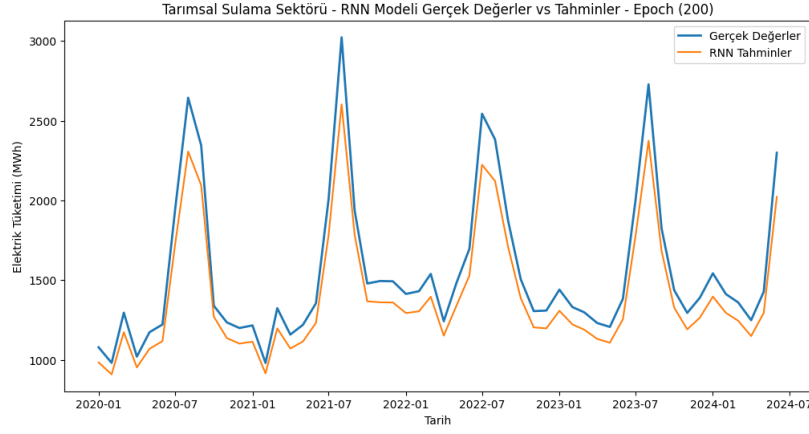


Şekil 5. 200. Tarımsal Sulama – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)


5.4.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)

Modellerin tahmin sonuçları gerçek elektrik tüketim verileriyle karşılaştırıldığında, tüm modellerin genel eğilimleri yakaladığı görülmektedir. Şekil 5.197.'ye göre RNN modeli bazı dönemlerde gerçek değerlerden önemli sapmalar göstermektedir. Şekil 5.200.'de gösterilen


BiLSTM modelinin gerçek değerlere oldukça yakın tahminler yaptığı, sırasıyla Şekil 5.198. ve Şekil 5.199.'da gösterilen GRU ve LSTM modelleri de benzer performans sergilemektedir.




Şekil 5. 201. Tarımsal Sulama – RNN Gerçek Değerler ve Tahminler (Epoch 200)



Şekil 5. 202. Tarımsal Sulama – GRU Gerçek Değerler ve Tahminler (Epoch 200)




Şekil 5. 203. Tarımsal Sulama – LSTM Gerçek Değerler ve Tahminler (Epoch 200)




Şekil 5. 204. Tarımsal Sulama – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200)

5.4.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)




Şekil 5. 205. Tarımsal Sulama Sektörü MAE Değerleri (Epoch 200)




Şekil 5. 206. Tarımsal Sulama Sektörü MAPE Değerleri (Epoch 200)

Performans metriklerine baktığımızda, BiLSTM modelinin en düşük hata oranlarına sahip olduğu görülmektedir. Şekil 5.201. ve Şekil 5.202.'de görüldüğü üzere RNN modeli en yüksek hata

oranları ile dikkat çekmektedir. Özellikle MAPE metriğinde (%9.017430) değerinde bir hata göstermiştir.



Şekil 5. 207. Tarımsal Sulama Sektörü MSE Değerleri (Epoch 200)




Şekil 5. 208. Tarımsal Sulama Sektörü RMSE Değerleri (Epoch 200)

GRU ve LSTM modelleri arasında ise benzer hata oranları görülmektedir. Ancak GRU modeli genellikle LSTM'den biraz daha düşük hata metriklerine sahiptir. Şekil 5.203. ve Şekil 5.204.'de görüldüğü üzere BiLSTM modelinin en düşük MSE (0.000499) ve RMSE (0.022334) değerlerine sahip olması, genel olarak en iyi performans gösteren model olduğunu ortaya koymaktadır.

RNN modelinin ise diğer modellere kıyasla önemli ölçüde daha kötü performans gösterdiği MSE ve RMSE metriklerinde belirgindir. Bu analiz sonuçları, Tarımsal Sulama sektörü için yapılan tahminlerde epoch 200 değerinde BiLSTM modelinin en iyi performansı sergilediğini, RNN modelinin ise diğer modellere kıyasla düşük bir performans gösterdiğini ortaya koymaktadır. GRU ve LSTM modelleri de kabul edilebilir hata oranları ile BiLSTM modeline yakın sonuçlar elde etmiştir.


5.4.13. Tarımsal Sulama Sektörü Bazında Genel Değerlendirme



Şekil 5. 209. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)


Tarımsal Sulama sektöründe RNN, GRU, LSTM ve BiLSTM modellerinin farklı epoch sayılarındaki performansları incelendiğinde, her modelin belirgin güçlü ve zayıf yönlerinin olduğu, bu yönlerin epoch sayısına göre değişkenlik gösterdiği tespit edilmiştir. Genel olarak, epoch sayısı arttıkça modellerin hata oranlarının düştüğü ve daha dengeli öğrenme eğrileri sergilediği gözlenmektedir. Ancak, modellerin elektrik tüketimi tahmin performansları eğitim ve doğrulama kayıpları, tahminlerin gerçek verilerle uyumu ve performans metrikleri açısından farklılık göstermektedir.

Epoch 25 seviyesinde, Şekil 5. 205.'de LSTM ve GRU modelleri tahmin doğruluğu ve hata oranları açısından öne çıkarken, RNN modeli daha yüksek hata oranları ile diğer modellerin gerisinde kalmıştır. RNN modelinin özellikle elektrik tüketimindeki ani artış ve düşüş dönemlerinde büyük sapmalar yaşadığı, eğitim ve doğrulama kayıplarının dengeli bir şekilde azalmadığı görülmüştür. Bu, modelin karmaşık veriler karşısında yeterli performans gösteremediğini ortaya koymaktadır. Buna karşılık, LSTM modeli düşük eğitim ve doğrulama kayıpları ile en dikkat çeken model olmuş ve gerçek verilerle tahminleri arasındaki uyum oldukça yüksek bulunmuştur. BiLSTM modeli ise LSTM'ye yakın bir performans sergilemesine rağmen, yüksek elektrik tüketimi dönemlerinde hafif sapmalar gözlenmektedir. GRU ise istikrarlı bir öğrenme süreci sunarak, özellikle mevsimsel değişimlerde başarılı tahmin sonuçları üretmiştir.



Şekil 5. 210. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)


Epoch 50 seviyesine gelindiğinde, modellerin performansları genel olarak iyileşmiştir. Şekil 5. 206.'da LSTM, GRU ve BiLSTM modelleri arasında eğitim ve doğrulama kayıpları açısından daha dengeli bir öğrenme süreci gözlenmiştir. LSTM modeli, en düşük hata metrikleri ile öne çıkmış ve gerçek verilerle neredeyse birebir uyum sağlamıştır. GRU modeli de benzer şekilde dengeli bir tahmin yapısı sunmuş, özellikle mevsimsel değişimlerde başarılı sonuçlar elde etmiştir. RNN modelinin tahmin doğruluğu ise düşük kalmış, sapmalar epoch 25'e kıyasla daha azalmış olsa da diğer modellerle kıyaslandığında daha yüksek hata oranlarına sahip olduğu görülmüştür.



Şekil 5. 211. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)

Epoch 100 seviyesine gelindiğinde, Şekil 5.207.'de modeller arasında belirgin farklar ortaya çıkmıştır. RNN modeli hata metriklerinde düşük değerler elde etmiş olsa da, bu durum modelin genel tahmin başarısını yansıtmamaktadır. RNN, kısa vadeli tahminlerde daha düşük hata

üretmiş, ancak genel eğilimleri ve mevsimsel değişiklikleri yakalamada başarısız kalmıştır. Özellikle tepe noktaların tahmininde ciddi sapmalar yaşamış, uzun vadeli bağımlılıkları öğrenmekte zorlanmıştır. Bu durum, RNN'in düşük hata metriklerine rağmen genel performans açısından diğer modellere kıyasla zayıf kalmasına yol açmıştır. LSTM ve BiLSTM modelleri, daha dengeli bir öğrenme süreci sergilemiş ve özellikle uzun vadeli tahminlerde yüksek doğruluk oranlarına ulaşmışlardır. BiLSTM, özellikle karmaşık zaman serilerinde başarılı olmuş ve daha düşük hata oranları ile dikkat çekmiştir. GRU modeli, LSTM'ye yakın bir performans gösterse de bazı dönemlerde LSTM'ye göre daha yüksek sapmalar yaşamıştır.



Şekil 5. 212. Tarımsal Sulama – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)

Epoch 200 seviyesine gelindiğinde, Şekil 5.208.'de modeller arasındaki farklar daha da netleşmiştir. BiLSTM modeli, tüm metriklerde en düşük hata oranlarına ulaşarak en başarılı model olarak öne çıkmıştır. Bu model, özellikle mevsimsel değişiklikleri doğru tahmin etmede başarılı olmuş ve karmaşık zaman serisi verilerini etkin bir şekilde öğrenmiştir. GRU ve LSTM modelleri, benzer hata oranlarına sahip olup dengeli bir performans sergilemişlerdir. Ancak, RNN modeli, en yüksek hata oranlarına sahip olup özellikle yüksek elektrik tüketim dönemlerinde büyük sapmalar göstermiştir. Bu durum, RNN'in daha uzun vadeli bağımlılıkları öğrenme konusunda sınırlı kaldığını ve karmaşık veri setleri ile başa çıkmada yetersiz olduğunu ortaya koymaktadır.

Sonuç olarak, Tarımsal Sulama sektörü için yapılan bu analizlerde, her epoch seviyesinde en başarılı modellerin LSTM ve BiLSTM olduğu, GRU modelinin ise bu modellere yakın bir performans sergilediği anlaşılmaktadır. RNN modeli ise diğer modellere kıyasla düşük performans sergilemiştir. LSTM ve BiLSTM modelleri, özellikle uzun dönemli tahminlerde daha dengeli sonuçlar vermiş ve düşük hata oranları ile öne çıkmıştır. Bu durum, bu iki modelin tarımsal sulama

sektöründe elektrik tüketimi tahmini için en uygun modeller olduğunu göstermektedir. Epoch sayısının artırılması, modellerin doğruluk oranını yükseltirken, aynı zamanda öğrenme süreçlerinin daha dengeli hale gelmesini sağlamıştır. Bu sonuçlar, daha fazla epoch ile eğitim verilen modellerin, elektrik tüketimi gibi karmaşık zaman serisi verilerini daha başarılı bir şekilde tahmin edebildiğini ortaya koymaktadır. Tarımsal Sulama sektörüne ait tüm hata metrikleri Tablo 5.4.'de belirtilmiştir.

Tablo 5. 4. Tarımsal Sulama Sektörüne Ait Hata Metrikleri

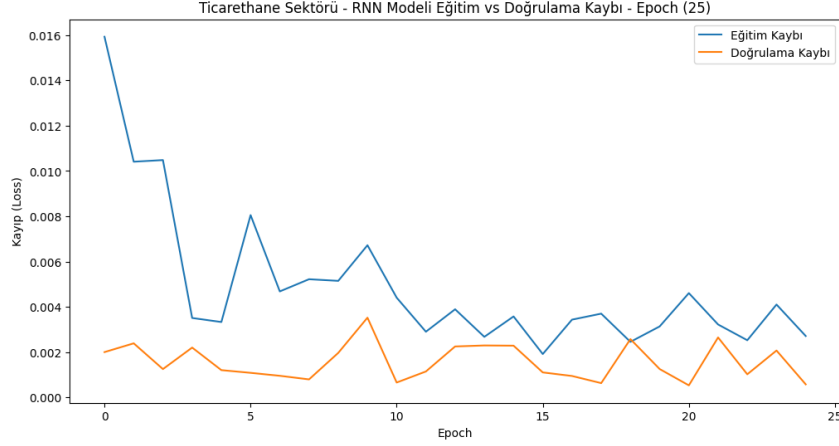
Sektör	TARIMSAL SULAMA SEKTÖRÜ			
Metrik Türü	MAE	RMSE	MSE	MAPE
Epoch Değeri	EPOCH - 25			
RNN	0.077126	0.078134	0.006105	10.618295
GRU	0.053856	0.073990	0.005474	6.624227
LSTM	0.041596	0.057520	0.003309	5.290006
BILSTM	0.059965	0.084156	0.007082	7.152631
Epoch Değeri	EPOCH - 50			
RNN	0.109088	0.114001	0.012996	14.376441
GRU	0.051443	0.066706	0.004450	6.670659
LSTM	0.035963	0.052131	0.002718	4.516377
BILSTM	0.044943	0.063042	0.003974	5.324616
Epoch Değeri	EPOCH - 100			
RNN	0.028927	0.034266	0.001174	3.535169
GRU	0.037178	0.047247	0.002232	4.566523
LSTM	0.034300	0.046445	0.002157	4.374798
BILSTM	0.061505	0.064567	0.004169	8.565574
Epoch Değeri	EPOCH - 200			
RNN	0.071718	0.080826	0.006533	9.017430
GRU	0.026173	0.026478	0.000701	3.607647
LSTM	0.032857	0.043261	0.001872	4.498932
BILSTM	0.021460	0.022334	0.000499	2.893882

5.5. Ticarethane Sektörü

Bu kısımda Ticarethane sektörüne ait 25-50-100 ve 200 epoch değerleri için modellerin eğitim ve doğrulama kaybı ile modellerin tahmin sonuçlarının gerçek verilerle karşılaştırılması ve performans metrikleri sırasıyla sunulmuştur.

5.5.1. Eğitim ve Doğrulama Kayıpları (Epoch 25)

Modellerin eğitim ve doğrulama kayıpları incelendiğinde, tüm modellerde benzer bir öğrenme eğilimi gözlenmiştir. GRU, LSTM ve BiLSTM modelleri için eğitim kayıpları başlangıçta yüksekken, zamanla doğrulama kayıplarına yaklaşıp düşmüştür ve epoch 25'e yaklaştıkça nispeten sabitlenmiştir. Bu, modellerin eğitim sürecinde veriyle uyum sağladığını ve öğrenme sürecinde başarı elde ettiklerini göstermektedir.

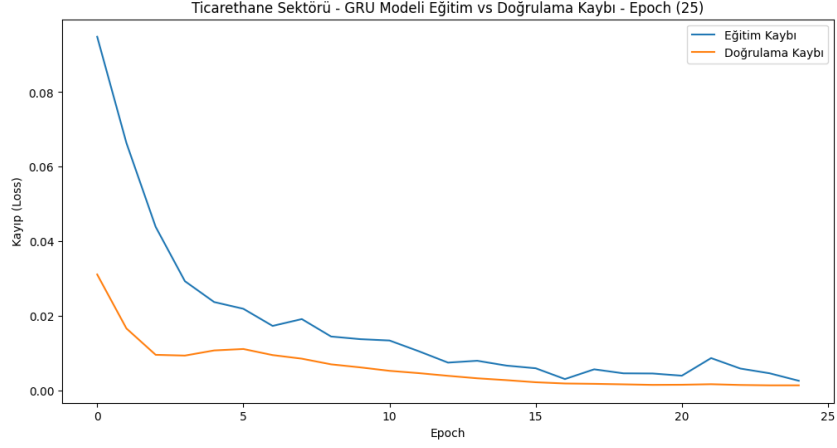


Şekil 5. 213. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 25)

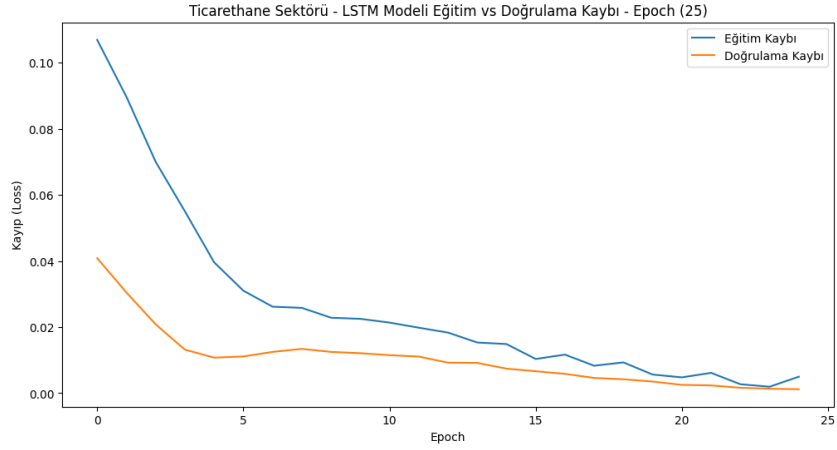
Şekil 5.209.'da görüldüğü üzere RNN modelinde eğitim ve doğrulama kayıplarındaki dalgalanmalar daha belirgindir. RNN, zaman serilerinde kısa dönem bağımlılıkları öğrenmede başarılı olmasına rağmen, eğitim sürecinde veriyle istikrarlı bir şekilde uyum sağlamada zorlanmıştır.

Eğitim kaybındaki bu dalgalanma, RNN'nin model optimizasyonu sırasında dengeli bir öğrenme sağlayamadığını, bunun yerine her epoch'ta değişken sonuçlar verdiğini ortaya koymaktadır. Doğrulama kaybı, eğitim kaybına kıyasla daha istikrarlıdır, ancak genel olarak RNN modeli veriyle tutarlı bir öğrenme gerçekleştirememiştir.

Şekil 5.210. ve Şekil 5.211. de GRU ve LSTM modellerine ait Eğitim ve Doğrulama Kayıpları belirtilmiştir.




Şekil 5. 214. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 25)



Şekil 5. 215. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)


BiLSTM modeline ait Eğitim ve Doğrulama Kayıpları Şekil 5.212.'de paylaşılmıştır.



Şekil 5. 216. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 25)


Şekil 5.209. ile Şekil 5.212. arasındaki tüm şekiller analiz edildiğinde, ileriye dönük olarak, dengeli ve az dalgalanan kayıplara sahip modellerin tercih edilmesi gerektiğini ve BiLSTM ve LSTM gibi daha gelişmiş modellerin uzun vadeli öğrenme açısından daha avantajlı olduğunu göstermektedir.

5.5.2. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 25)




Şekil 5. 217. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5.213.'de paylaşılan RNN modeli diğer modellere kıyasla tahmin sonuçlarında daha yüksek sapmalar göstermektedir. Bu model kısa vadeli verileri iyi takip etse de özellikle ani değişiklikler karşısında başarılı sonuçlar üretememektedir. RNN modelinin tahmin eğrisi, büyük değişimlerde (özellikle 2023'teki ani düşüşler) gerçek veri eğrisinden sapmaktadır. Bu durum, modelin zaman serilerinde uzun dönem bağımlılıkları yeterince iyi öğrenemediğini ve dolayısıyla daha düşük bir tahmin performansı sergilediğini ortaya koymaktadır.




Şekil 5. 218. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 25)

GRU ve LSTM modelleri de genel eğilimleri yakalayabilmektedir. GRU modelinde tahminler daha düzgün ve dengeli görünse de ani yükseliş ve düşüşlerde gerçek değerlere tam anlamıyla uyum sağlamakta zorlanmaktadır. GRU Modeline ait Gerçek Değerler ve Tahminler Şekil 5.214.'de gösterilmiştir.



Şekil 5. 219. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5.215. incelendiğinde LSTM'nin de uzun dönem bağımlılıkları yakalamada güçlü olduğu gözlenmektedir ancak yine de tepe noktalarında hata payı oluşmaktadır.




Şekil 5. 220. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 25)

Şekil 5.216.'da paylaşılan BiLSTM modeli, genel olarak gerçek verilerle iyi bir örtüşme sağlamış olsa da özellikle büyük tepe noktalarında ve ani düşüşlerde sapmalar yaşamaktadır. Örneğin, 2022 ve 2023 yıllarındaki büyük artış ve düşüşler sırasında BiLSTM tahminleri, gerçek değerlerden biraz uzaklaşmıştır. Ancak, tahminlerinin doğruluğu normal seviyelerde oldukça başarılıdır, bu da modelin ani değişimlere uyum sağlama konusunda zayıf kaldığını göstermektedir.

Şekillerde genel olarak tahminlerin gerçek verilerle uyumlu görünmesi yanıltıcı olabilir. Ancak daha büyük sapmaların olduğu noktalarda modelin başarısızlığı açıkça ortaya çıkmaktadır. Tahmin sonuçları ile gerçek verilerin örtüşmesinde dalgalanma noktalarına odaklanmak, modelin performansını doğru analiz etmek için önemlidir.


5.5.3. Performans Metriklerinin Değerlendirilmesi (Epoch 25)



Şekil 5. 221. Ticarethane Sektörü MAE Değerleri (Epoch 25)

Performans metriklerine baktığımızda Şekil 5.217.'de belirtildiği üzere MAE açısından, en düşük hata oranına RNN modeli sahiptir (0.022306). Bu, modelin kısa vadeli tahminlerde genel olarak iyi bir performans sergilediğini ve ortalama sapmanın düşük olduğunu göstermektedir. Ancak, MAE metriği büyük sapmaların etkisini yeterince yansıtmadığı için grafiklerde gözlemlenen ani değişikliklerin hatası MAE'de düşük çıkmış olabilir.


BiLSTM modeli ise en yüksek MAE'ye sahiptir (0.032597), bu da modelin tahminlerinde diğer modellere kıyasla daha fazla hata yaptığını göstermektedir.



Şekil 5. 222. Ticarethane Sektörü MAPE Değerleri (Epoch 25)


Şekil 5.218.'de MAPE değerlerine göre, RNN modeli yine en iyi performansı sergilemiştir (%3.074126). Yüzdesele olarak daha küçük sapmalar yapmıştır. BiLSTM modeli ise (%4.897460) ile en yüksek MAPE değerine sahip modeldir.

RNN'nin başarılı görünmesinin sebebi, tahminlerin genel olarak gerçek değerlerle kısa vadeli uyum göstermesi olabilir. Ancak uzun vadeli eğilimlerde sapma yapması nedeniyle genel başarı sınırlı kalmaktadır.



Şekil 5. 223. Ticarethane Sektörü MSE Değerleri (Epoch 25)

Bu metriklerin RNN modelinde daha düşük çıkmasının bir nedeni, büyük hataların MSE ve RMSE tarafından daha ağır cezalandırılmasıdır. RNN'nin daha pürüzsüz ve kısa vadeli tahminlerde iyi olması, bu metriklerde daha düşük hata oranları elde etmesine neden olmuştur.




Şekil 5. 224. Ticarethane Sektörü RMSE Değerleri (Epoch 25)

Şekil 5.219. ve Şekil 5.220. analiz edildiğinde MSE ve RMSE açısından en iyi performans RNN modeline aittir. BiLSTM, RMSE değeri (0.059899) ve MSE değeri (0.003588) ile en yüksek hata oranına sahiptir.


Sonuç olarak, epoch 25 değerinde RNN modeli kısa vadeli tahminlerde diğer modellere göre daha iyi sonuçlar vermiş olsa da uzun vadeli bağımlılıkları öğrenme ve ani değişiklikleri yakalama konusunda zayıf kalmıştır. BiLSTM ve LSTM gibi daha gelişmiş modeller, uzun dönem verilerde daha dengeli ve güvenilir tahminler sunabilir, ancak daha yüksek hata oranlarına sahip olabilirler. Bu nedenle, daha büyük veri setlerinde ve daha uzun epoch sayılarında bu gelişmiş modellerin daha iyi performans göstermesi beklenebilir.

5.5.4. Modellerin Eğitim ve Doğrulama Kayıpları (Epoch 50)




Şekil 5. 225. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 50)

Epoch 50'de tüm modeller için eğitim ve doğrulama kayıplarını incelediğimizde, Şekil 5.221.'de paylaşılan RNN modeli yine dalgalı bir öğrenme eğrisi göstermesine rağmen, eğitim ve doğrulama kayıpları diğer modellere kıyasla daha düşük seviyelerde seyretmiştir. RNN modeli, genel olarak doğrulama kayıplarını minimize etmede başarılı görünmektedir.




Şekil 5. 226. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 50)

GRU modelinin eğitim sürecinde kayıplarında hafif dalgalanmalar gözlenmiştir. Bu, modelin belirli dönemlerde öğrenme sürecinde zorlandığını işaret etmektedir. Şekil 5.222.'de Ticarethane Sektöründe GRU modeline ait Eğitim ve Doğrulama Kayıpları paylaşılmıştır.



Şekil 5. 227. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.223.'de Ticarethane Sektöründe LSTM modeline ait Eğitim ve Doğrulama Kayıpları paylaşılmıştır.




Şekil 5. 228. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 50)

Şekil 5.224.'de Ticarethane Sektöründe BiLSTM modeline ait Eğitim ve Doğrulama Kayıpları paylaşılmıştır.

LSTM, GRU ve BiLSTM modellerinde kayıplar azalma eğiliminde olup, özellikle BiLSTM ve LSTM modelleri doğrulama kayıplarını oldukça düşük seviyelere çekebilmiştir.


Bu durumda, RNN modeli özellikle eğitim ve doğrulama kayıplarında daha tutarlı bir performans sergilemiş, GRU ise eğitim sürecinde bazı sapmalar göstermiştir. BiLSTM ve LSTM modelleri ise dengeli ve düşük kayıplar elde ederek, özellikle doğrulama kayıplarını oldukça başarılı bir şekilde azaltmıştır.

5.5.5. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 50)




Şekil 5. 229. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5.225. analiz edildiğinde RNN modeli, diğer modellere kıyasla en düşük sapmayı gösteren modeldir. Ancak, bu modelin büyük tepe ve düşüş dönemlerinde zayıf kaldığı ve genel eğilimlerde diğer modellere kıyasla daha fazla hata yaptığı gözlenmektedir. Yani, RNN modeli daha düşük hata oranlarıyla çalışsa da ani değişimlerin olduğu dönemlerde tahminlerdeki sapmalar dikkat çekmektedir.




Şekil 5. 230. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 50)

Şekil 5.226.'da belirtilen GRU modeli, genel eğilimi yakalayabilse de tahmin sonuçlarının büyük artış ve düşüşlerde gerçek verilerle arasında daha belirgin sapmalar olduğu görülmektedir. Bu, modelin özellikle ani değişimlere tam anlamıyla uyum sağlayamadığını göstermektedir.



Şekil 5. 231. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 50)


Gerçek verilerle tahminlerin karşılaştırıldığı Şekil 5.227. ve Şekil 5.228.'de LSTM ve BiLSTM modelleri, büyük artış ve düşüş noktalarında tahminlerini gerçek verilere oldukça yakın bir şekilde yapabilmıştır.



Şekil 5. 232. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 50)


Ancak, büyük değere sahip dönemlerde, tahmin sonuçlarının gerçek değerlerden sapma gösterdiği bazı noktalar mevcuttur. Özellikle 2022 ve 2023 yıllarındaki ani artış ve düşüşlerde BiLSTM modeli diğer modellere göre biraz daha başarılıdır.

5.5.6. Performans Metriklerinin Değerlendirilmesi (Epoch 50)




Şekil 5. 233. Ticarethane Sektörü MAE Değerleri (Epoch 50)

Şekil 5.229.'ya göre MAE açısından en iyi performansı yine RNN modeli göstermiştir (0.016943). GRU modeli ise en yüksek MAE değerine (0.035691) sahip olup, tahminlerinde diğer modellere kıyasla daha fazla hata yapmıştır. LSTM ve BiLSTM modelleri ise benzer ve düşük MAE değerleriyle, RNN'den sonra iyi performans sergilemiştir.




Şekil 5. 234. Ticarethane Sektörü MAPE Değerleri (Epoch 50)



Şekil 5. 235. Ticarethane Sektörü MSE Değerleri (Epoch 50)

RNN modeli Şekil 5.230’da en düşük MAPE değeri ile (%2.389103) öne çıkmaktadır. Bu, RNN modelinin genel olarak daha tutarlı ve düşük sapma gösteren tahminler ürettiğini göstermektedir. GRU modeli ise (%5.127861) gibi yüksek bir MAPE değeri ile en fazla sapmayı gösteren modeldir. Şekil 5.231’de RNN modeli en düşük MSE (0.000395) değerine sahiptir.



Şekil 5. 236. Ticarethane Sektörü RMSE Değerleri (Epoch 50)


Şekil 5.232.’de RMSE metriklerinde de RNN modeli en düşük hata oranı göstermiştir (0.019880). LSTM ve BiLSTM modelleri ise bu metriklerde birbirine yakın değerlerle başarılı sonuçlar elde etmiştir. GRU modeli ise en yüksek RMSE (0.050488) değerine sahiptir.

Sonuç olarak, RNN modeli, epoch 50’de daha düşük hata oranlarına sahip olmasına rağmen ani değişikliklere adaptasyonda zayıf kalmıştır. Ancak genel anlamda, BiLSTM ve LSTM modelleri büyük değişikliklerde daha doğru tahminler üretirken, GRU modeli performans olarak en zayıf model olarak gözükmektedir.


5.5.7. Eğitim ve Doğrulama Kayıpları (Epoch 100)

Epoch 100 seviyesinde eğitim ve doğrulama kayıplarına baktığımızda, tüm modellerin performanslarının iyileştiği görülmektedir.

Şekil 5.233.’de RNN modelinde ise eğitim kaybında belirgin dalgalanmalar gözlenmiştir. Ancak, doğrulama kaybı sabit ve düşük seviyede kalmıştır, bu da modelin aşırı öğrenmeden kaçındığını, fakat eğitim verisinde dengeli bir performans yakalayamadığını göstermektedir.




Şekil 5. 237. Ticarethane – RNN Eğitim ve Doğrulama Kayırları (Epoch 100)




Şekil 5. 238. Ticarethane – GRU Eğitim ve Doğrulama Kayırları (Epoch 100)

Şekil 5.234.'de GRU modelinde de benzer bir eğilim gözlenmektedir. GRU modelinin eğitim ve doğrulama kayırları hızlı bir şekilde azalmış ve neredeyse sıfıra yakın bir seviyede sabitlenmiştir. Ancak, eğitim kayırları küçük dalgalanmalar göstermiştir.

Şekil 5.235.'e göre LSTM modeli doğrulama kayırları açısından en dengeli modellerden biridir. Eğitim kaybında ise dalgalanmalar olsa da genel olarak başarılı bir performans sergilemiştir. Bu, uzun dönemli bağımlılıkları iyi yakaladığını gösterir.



Şekil 5. 239. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)




Şekil 5. 240. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 100)

Şekil 5.236.'da BiLSTM modelinde eğitim ve doğrulama kayıplarının zaman içinde çok düşük seviyelere indiği ve neredeyse sabit bir seviyede devam ettiği gözlenmektedir. Bu modelin erken dönemlerde hızlı bir düşüş gösterip daha sonra dengeli bir performans sergilemesi, modelin yüksek öğrenme kapasitesini yansıtmaktadır.

Sonuç olarak, Epoch 100'de modellerin genel olarak başarılı öğrenme süreçleri gösterdiği ve özellikle BiLSTM, GRU ve LSTM modellerinin doğrulama kayıplarında istikrar yakaladığı görülmektedir.


5.5.8. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 100)

Modellerin tahmin sonuçlarının gerçek verilerle karşılaştırılması sonucunda, modellerin genel eğilimi iyi yakaladığı görülmektedir.



Şekil 5. 241. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 100)


Şekil 5.237.’de RNN modelinde ise ani değişiklikler sırasında daha belirgin sapmalar gözlenmektedir. Model, genel eğilimi yakalasa da özellikle tepe noktalarda diğer modellere kıyasla daha fazla hata yapmıştır.




Şekil 5. 242. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 100)

Şekil 5.238.’de GRU modeli de benzer şekilde, genel eğilimi yakalayabilmiş, ancak ani değişikliklerde BiLSTM’e göre daha fazla sapma göstermiştir. Bu sapmalar özellikle keskin tepe noktalarında daha belirgindir.

Şekil 5.239.’da LSTM modeli, uzun dönem bağımlılıkları iyi yakalayarak, ani değişimlerde bile nispeten dengeli tahminler yapmıştır. Tepe noktalarında BiLSTM kadar olmasa da GRU modeline kıyasla daha iyi bir performans sergilemiştir.



Şekil 5. 243. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 100)

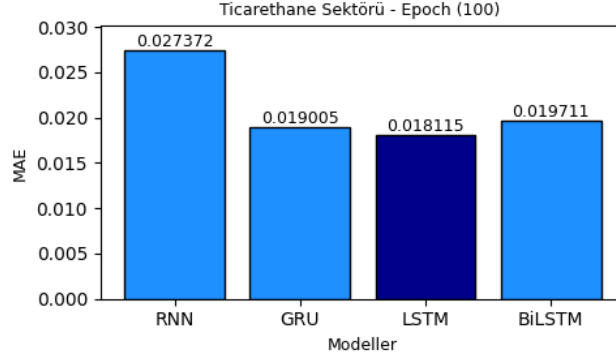


Şekil 5. 244. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 100)


Şekil 5.240.'da görüldüğü üzere BiLSTM modeli, tepe noktaları ve ani düşüşleri oldukça başarılı bir şekilde tahmin edebilmiştir. Özellikle büyük artış ve düşüşlerde gerçek verilerle oldukça yakın tahminler üretmiştir. Bu sonuçlar, BiLSTM ve LSTM modellerinin ticarethane sektörü için en uygun modeller olduğunu ve özellikle büyük veri dalgalanmalarını daha başarılı şekilde tahmin ettiklerini göstermektedir.

5.5.9. Performans Metriklerinin Değerlendirilmesi (Epoch 100)

Performans metrikleri açısından, epoch 100 seviyesinde farklı modellerin sonuçları değerlendirildiğinde Şekil 5.241.'de LSTM modeli, (0.018115) ile en düşük MAE değerine sahip olup, en iyi performansı sergilemiştir. Bunu sırasıyla GRU (0.019005) ve BiLSTM (0.019711) izlemektedir. RNN modeli ise (0.027372) ile en yüksek MAE değerine sahip modeldir.




Şekil 5. 245. Ticarethane Sektörü MAE Değerleri (Epoch 100)




Şekil 5. 246. Ticarethane Sektörü MAPE Değerleri (Epoch 100)

LSTM modeli Şekil 5.242.'de (%2.737798) ile en düşük MAPE değerine sahiptir ve en doğru tahminleri gerçekleştirmiştir. BiLSTM (%2.867038) ve GRU (%2.897374) modelleri de yakın değerler sergilemiştir. RNN modeli ise (%3.865079) ile en yüksek MAPE değerine sahip olmuştur.



Şekil 5. 247. Ticarethane Sektörü MSE Değerleri (Epoch 100)


LSTM modeli Şekil 5.243.'de (0.001019) MSE değeri ile en iyi performansı sergilemiştir. BiLSTM (0.001009) ve RNN (0.001045) modelleri de benzer sonuçlar vermiştir. GRU modeli ise (0.001166) MSE ile en yüksek hata değerine sahiptir.



Şekil 5. 248. Ticarethane Sektörü RMSE Değerleri (Epoch 100)

BiLSTM modeli, Şekil 5.244.'de (0.031772) ile en düşük RMSE değerine sahip olup, genel hata performansında en başarılı model olmuştur. LSTM (0.031924) ve RNN (0.032319) modelleri de başarılı sonuçlar elde etmiştir. GRU modeli (0.034148) ile en yüksek RMSE değerine sahip olmuştur. Sonuç olarak, Epoch 100 seviyesinde LSTM ve BiLSTM modelleri, en düşük hata oranları ile en başarılı modeller olarak öne çıkmaktadır. GRU modeli ise bazı metriklerde diğer modellere göre daha zayıf bir performans göstermiştir. RNN modeli ise özellikle MAE ve MAPE değerlerinde daha yüksek hatalar sergilemiştir, bu da modelin ticarethane sektörü için yeterince uygun olmadığını göstermektedir.


5.5.10. Eğitim ve Doğrulama Kayıpları (Epoch 200)



Şekil 5. 249. Ticarethane – RNN Eğitim ve Doğrulama Kayıpları (Epoch 200)


Ticarethane Sektöründe Epoch 200 için RNN, GRU, LSTM ve BiLSTM modelleri eğitim ve doğrulama süreçlerinde farklı kayıplar sergilemiştir. Modellerin kayıp grafiklerine bakıldığında, tüm modellerin hem eğitim hem de doğrulama kayıplarının hızlı bir şekilde azaldığı ve epoch sayısı arttıkça dengeli hale geldiği görülmektedir.

RNN modeli, Şekil 5.245.'de eğitim ve doğrulama kayıpları açısından diğer modellere kıyasla biraz daha dalgalanma göstermiştir. Erken epoch'larda yüksek bir kayıp yaşasa da epoch ilerledikçe kayıpları düşmeye başlamıştır. Ancak, belirli bir noktadan sonra doğrulama kayıpları eğitim kayıplarından hafif daha yüksek bir seviyede kalmıştır.



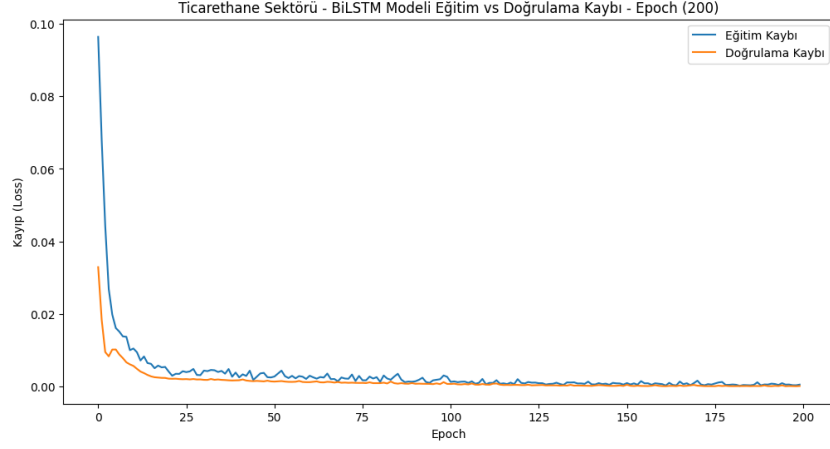
Şekil 5. 250. Ticarethane – GRU Eğitim ve Doğrulama Kayıpları (Epoch 200)

GRU modeli ise Şekil 5.246.'da daha tutarlı bir eğitim ve doğrulama kaybı süreci sergilemiştir. Eğitim kayıpları diğer modellere kıyasla daha erken dengeli hale gelmiş ve doğrulama kayıplarıyla arasındaki fark minimal düzeyde kalmıştır.



Şekil 5. 251. Ticarethane – LSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)

Şekil 5.247.'de LSTM modelinde, eğitim kayıpları hızla azalmış olsa da, doğrulama kayıplarında dönemsel dalgalanmalar yaşanmıştır. Bu modelin daha karmaşık yapısından kaynaklanan doğrulama süreci, diğer modellere göre biraz daha uzun sürmüştür.




Şekil 5. 252. Ticarethane – BiLSTM Eğitim ve Doğrulama Kayıpları (Epoch 200)

BiLSTM modeli, Şekil 5.248.'de en düşük eğitim ve doğrulama kaybını göstermiştir. Özellikle doğrulama kayıplarındaki hızlı düşüş ve kararlılık, BiLSTM'in epoch 200'de daha başarılı bir model olduğunu göstermektedir.


5.5.11. Tahmin Sonuçlarının Gerçek Verilerle Karşılaştırılması (Epoch 200)

Tahmin sonuçları ve gerçek değerler arasındaki karşılaştırma grafikleri, her modelin performansını görsel olarak gözlemlememizi sağlar.




Şekil 5. 253. Ticarethane – RNN Gerçek Değerler ve Tahminler (Epoch 200)

Şekil 5.249.'da RNN modeli, tahminlerinde belirli dönemlerde ciddi sapmalar göstermiştir. Ancak genel eğilimde gerçek değerlere yakın bir performans sergilemiştir. Özellikle ani yükselişlerde modelin tahminleri gerçek değerlerin biraz altında kalmıştır.




Şekil 5. 254. Ticarethane – GRU Gerçek Değerler ve Tahminler (Epoch 200)

Şekil 5.250.'de GRU modeli, gerçek verilerle oldukça uyumlu tahminler üretmiştir. Özellikle dönemsel değişimlerin olduğu bölgelerde tahmin performansı daha iyidir. Ancak bazı ani artış ve azalışlarda modelin tahminlerinin hafif gecikmeli olduğu görülmektedir.



Şekil 5. 255. Ticarethane – LSTM Gerçek Değerler ve Tahminler (Epoch 200)

Şekil 5.251.'de görüleceği üzere LSTM modelinin tahmin performansı, gerçek verilere oldukça yakındır. Özellikle ani değişimlerde bu modelin performansı oldukça yüksektir. Ancak mevsimsel geçişlerde modelin tahminleri gerçek değerlerden biraz farklılaşmıştır.




Şekil 5. 256. Ticarethane – BiLSTM Gerçek Değerler ve Tahminler (Epoch 200)

BiLSTM modeli ise Şekil 5.252.'de en yüksek tahmin doğruluğunu sağlayan model olmuştur. Gerçek verilerle BiLSTM tahminleri neredeyse birebir örtüşmektedir. Bu durum, özellikle mevsimsel değişimlerin ve ani yükselişlerin olduğu dönemlerde BiLSTM'in daha iyi genelleme yapabildiğini göstermektedir.


5.5.12. Performans Metriklerinin Değerlendirilmesi (Epoch 200)

Modellerin performans metriklerine bakıldığında, BiLSTM modelinin diğer modellere kıyasla üstün performans gösterdiği açıkça görülmektedir. Aşağıda her bir modelin metrikleri detaylı olarak değerlendirilmiştir.




Şekil 5. 257. Ticarethane Sektörü MAE Değerleri (Epoch 200)

Şekil 5.253.'de Ticarethane sektöründe kullanılan tüm modellere ait MAE değerleri paylaşılmıştır.




Şekil 5. 258. Ticarethane Sektörü MAPE Değerleri (Epoch 200)

Şekil 5.254.'de Ticarethane sektöründe kullanılan tüm modellere ait MAPE değerleri paylaşılmıştır.



Şekil 5. 259. Ticarethane Sektörü MSE Değerleri (Epoch 200)

Şekil 5.255.'de Ticarethane sektöründe kullanılan tüm modellere ait MSE değerleri paylaşılmıştır.



Şekil 5. 260. Ticarethane Sektörü RMSE Değerleri (Epoch 200)

Şekil 5.256.'da Ticarethane sektöründe kullanılan tüm modellere ait RMSE değerleri paylaşılmıştır.

RNN modeli, MAE, MAPE, MSE ve RMSE metriklerinde diğer modellere kıyasla biraz daha yüksek hata oranlarına sahiptir. Özellikle RMSE ve MAPE metriklerinde RNN modelinin diğer modellere kıyasla daha az başarılı olduğunu söyleyebiliriz.


GRU modeli, RNN modeline göre daha düşük hata oranlarına sahiptir. Özellikle MSE ve MAE metriklerinde daha düşük değerler elde edilmiştir. GRU, ani değişimlerin olduğu dönemlerde biraz sapma yaşasa da genel performansı oldukça iyidir.

LSTM modeli, GRU'ya benzer bir hata metrik profili sergilemiştir ancak RMSE ve MSE metriklerinde GRU'dan biraz daha yüksek hata değerleri göstermiştir. Bu da LSTM'in özellikle büyük değişimlerde hafif sapma yaşadığını göstermektedir.

BiLSTM modeli, en düşük hata oranlarına sahiptir. MAE, MAPE, MSE ve RMSE metriklerinde tüm modeller arasında en iyi sonuçlar bu modelle elde edilmiştir. Özellikle mevsimsel değişimlerin yoğun olduğu dönemlerdeki başarılı performansı, BiLSTM'i öne çıkarmaktadır.

Sonuç olarak, Ticarethane sektöründe Epoch 200'de BiLSTM modeli, hem eğitim/doğrulama kayıpları hem de tahmin doğruluğu ve hata metrikleri açısından diğer modellere göre daha üstün bir performans sergilemiştir. Bu model, özellikle ani değişimlerin ve mevsimsel dalgalanmaların yoğun olduğu veri setlerinde daha iyi sonuçlar vermektedir.

5.5.13. Ticarethane Sektörü Bazında Genel Değerlendirme




Şekil 5. 261. Ticarethane – Gerçek Değerler ve Modellerin Tahminleri (Epoch 25)

Ticarethane Sektörü için gerçekleştirdiğimiz analizler doğrultusunda dört farklı epoch değerindeki (25, 50, 100, 200) performansları dikkate alarak model tercihlerini yönlendirecek genel bir karşılaştırma yapmak istersek epoch 25'te RNN modelinin, kısa dönem bağımlılıkları iyi bir şekilde öğrenmesine rağmen, uzun dönemli verilerle başa çıkmakta zorlandığını söyleyebiliriz.

Şekil 5.257.'ye göre Eğitim ve doğrulama kayıplarında belirgin dalgalanmalar ve tahmin sonuçlarında ani değişiklikler karşısında yüksek sapmalar göstermiştir. MAE ve MAPE değerleri, kısa vadede iyi sonuçlar verse de genel performans açısından diğer modellere kıyasla daha düşük kalmıştır. Bu epoch seviyesinde BiLSTM ve LSTM modelleri, doğrulama kayıplarını daha iyi yönetmiş, uzun dönem bağımlılıkları daha doğru bir şekilde öğrenmişlerdir.

Özellikle BiLSTM, ani artış ve düşüşlerde gerçek veriye daha yakın tahminler sunmuştur. GRU modeli ise ani değişikliklere adaptasyonda LSTM ve BiLSTM kadar başarılı olmamış, eğitim sürecinde daha fazla dalgalanma yaşamıştır.




Şekil 5. 262. Ticarethane – Gerçek Değerler ve Modellerin Tahminleri (Epoch 50)

Şekil 5.258.'de epoch 50'ye gelindiğinde, modellerin öğrenme süreçleri iyileşmiş ve daha dengeli hale gelmiştir. RNN modeli, eğitim kayıplarında hala dalgalanma gösterse de doğrulama kayıplarını minimize etmede başarılı olmuştur. Ancak, ani değişikliklerde ve büyük yükselişlerde, diğer modellere kıyasla daha fazla sapma göstermiştir.


LSTM ve BiLSTM, doğrulama kayıplarını düşük seviyelerde tutmuş ve tahmin sonuçlarında büyük artış ve düşüşlerde gerçek veriye oldukça yakın sonuçlar üretmiştir. BiLSTM modeli, özellikle mevsimsel değişikliklerde öne çıkmış ve tahmin doğruluğunu korumayı

başarmıştır. GRU ise bu epoch seviyesinde eğitim sürecinde zaman zaman sapmalar yaşamış ve tahmin performansı açısından en düşük başarıyı göstermiştir.



Şekil 5. 263. Ticarethane– Gerçek Değerler ve Modellerin Tahminleri (Epoch 100)

Şekil 5.259.'da görüldüğü üzere epoch 100 seviyesinde modellerin performansı iyileşmeye devam etmiştir. BiLSTM, LSTM ve GRU modelleri doğrulama kayıplarını minimum seviyelere çekmiş, öğrenme süreçleri kararlı hale gelmiştir. BiLSTM modeli, tahminlerinde gerçek verilere en yakın sonuçları üretmiş ve ani değişimlerde dahi başarılı bir performans sergilemiştir. LSTM, uzun dönem bağımlılıklarını iyi bir şekilde öğrenmiş, ancak bazı tepe noktalarında BiLSTM kadar başarılı olamamıştır. RNN modeli ise yine tahmin sonuçlarında diğer modellere göre daha yüksek sapmalar göstermiştir. Performans metrikleri açısından bakıldığında, MAE ve MAPE değerlerinde LSTM ve BiLSTM en iyi sonuçları vermiştir. Bu epoch seviyesinde RNN, büyük veri dalgalanmalarına adaptasyonda zayıf kalmış ve daha düşük bir performans sergilemiştir.



Şekil 5. 264. Ticarethane – Gerçek Değerler ve Modellerin Tahminleri (Epoch 200)

Şekil 5.260. analiz edildiğinde epoch 200, tüm modellerin en yüksek performansı sergilediği seviyedir. BiLSTM modeli hem eğitim ve doğrulama kayıplarında hem de tahmin doğruluğunda en başarılı model olmuştur.

Gerçek verilerle yapılan karşılaştırmalarda BiLSTM, mevsimsel değişiklikler ve ani tepe noktalarında dahi başarılı tahminler üretmiştir. MAPE, MAE, MSE ve RMSE metriklerinde en düşük hata oranlarına sahip olan bu model, Ticarethane sektöründe en uygun model olarak öne çıkmıştır.

LSTM ve GRU modelleri de benzer şekilde başarılı sonuçlar üretmiş, ancak BiLSTM kadar düşük hata oranlarına ulaşamamıştır. RNN modeli ise diğer modellere kıyasla daha yüksek hata oranlarına sahip olmuş ve ani değişikliklerde en yüksek sapmayı göstermiştir.

Tüm epoch seviyeleri göz önünde bulundurulduğunda, BiLSTM modeli en yüksek başarıyı göstermiştir. Bu model, uzun dönem bağımlılıkları öğrenmede ve ani değişimlere adaptasyonda diğer modellere göre daha başarılı olmuştur.

LSTM modeli de genel olarak iyi sonuçlar verse de büyük veri değişimlerinde BiLSTM kadar etkili olamamıştır. GRU modeli ise özellikle Epoch 50'de düşük performans sergilemiş, ancak genel eğilimleri iyi takip edebilmiştir.

RNN modeli ise kısa vadeli tahminlerde başarılı olmasına rağmen, uzun dönemli öğrenme ve ani değişikliklere adaptasyonda en düşük performansı sergileyen model olarak öne çıkmıştır.

Sonuç olarak, Ticarethane sektöründe verimli ve doğru tahminler için BiLSTM ve LSTM modelleri tercih edilmelidir. Özellikle büyük veri setlerinde ve mevsimsel değişikliklerin olduğu sektörlerde BiLSTM'in üstün performansı dikkat çekmektedir. Ticarethane sektörüne ait tüm hata metrikleri Tablo 5.5.'de belirtilmiştir.

Tablo 5. 5. Ticarethane Sektörüne Ait Hata Metrikleri

Sektör	TİCARETHANE SEKTÖRÜ			
Metrik Türü	MAE	RMSE	MSE	MAPE
Epoch Değeri	EPOCH - 25			
RNN	0.022306	0.032237	0.001039	3.074126
GRU	0.029691	0.051378	0.002640	4.267303
LSTM	0.029243	0.046175	0.002132	4.476584
BILSTM	0.032597	0.059899	0.003588	4.897460
Epoch Değeri	EPOCH - 50			
RNN	0.016943	0.019880	0.000395	2.389103
GRU	0.035691	0.050488	0.002549	5.127861
LSTM	0.028522	0.039786	0.001583	4.107932
BILSTM	0.026175	0.046926	0.002202	3.860317
Epoch Değeri	EPOCH - 100			
RNN	0.027372	0.032319	0.001045	3.865079
GRU	0.019005	0.034148	0.001166	2.897374
LSTM	0.018115	0.031924	0.001019	2.737798
BILSTM	0.019711	0.031772	0.001009	2.867038
Epoch Değeri	EPOCH - 200			
RNN	0.017171	0.024446	0.000598	2.353368
GRU	0.013781	0.021328	0.000455	2.146730
LSTM	0.016782	0.027189	0.000739	2.464031
BILSTM	0.009236	0.012878	0.000166	1.428154

6. SONUÇ VE ÖNERİLER

Çalışmanın temel amacı, Zaman Serisi Analizi yöntemi kullanılarak Aydınlatma, Mesken, Sanayi, Tarımsal Sulama ve Ticarethane sektörlerinde geleceğe yönelik elektrik tüketim tahminleri yaparak, enerji yönetimi ve kaynak planlamasında önemli öngörüler sağlamaktır.

Bu çalışmada, Bilecik iline ait 2016-2024 yılları arasındaki elektrik tüketim verileri kullanılarak sektörel bazda tüketim tahminleri yapmak için RNN, GRU, LSTM ve BiLSTM yapay sinir ağı modelleri eğitilmiş ve tahmin performansları 25, 50, 100 ve 200 epoch değerlerine göre değerlendirilmiştir. Elde edilen bulgular ışığında, modellerin sektörel bazda performansları ve genel tahmin başarıları ortaya konmuş ve sonuçlar analiz edilerek modelin güçlü ve zayıf yönleri tartışılmıştır.

Aydınlatma sektöründe GRU ve BiLSTM modelleri en yüksek performansı göstermiştir. Epoch 50 ve 200 değerlerinde GRU modeli, düşük hata oranları ve yüksek tahmin doğruluğu ile öne çıkmıştır.

Mesken sektöründe epoch sayısının artmasıyla birlikte BiLSTM ve LSTM modelleri üstünlük sağlamıştır. Özellikle Epoch 200'de BiLSTM modeli en düşük hata oranlarına ulaşmış ve uzun dönemli tahminlerde yüksek doğruluk sağlamıştır.

Sanayi sektöründe BiLSTM ve GRU modelleri en başarılı sonuçları vermiştir. Epoch 100 ve 200 değerlerinde bu modeller düşük hata oranları ile dikkat çekmiştir.

Tarımsal Sulama sektöründe LSTM ve BiLSTM modelleri en yüksek tahmin doğruluğuna ulaşmıştır. Özellikle Epoch 200'de BiLSTM modeli mevsimsel değişiklikleri ve ani tüketim artışlarını başarılı bir şekilde tahmin etmiştir.

Ticarethane sektöründe BiLSTM modeli tüm epoch değerlerinde en yüksek performansı göstermiştir. Büyük veri setleri ve mevsimsel değişikliklerin yoğun olduğu bu sektörde BiLSTM modeli düşük hata oranları ve yüksek tahmin doğruluğu ile öne çıkmıştır.

RNN modeli, kısa vadeli bağımlılıkları öğrenmede başarılı olmasına rağmen, uzun dönemli ve karmaşık veri yapılarını yakalamada yetersiz kalmıştır. Özellikle epoch sayısının artmasıyla birlikte performans düşüşü gözlemlenmiş, eğitim ve doğrulama kayıplarında dalgalanmalar meydana gelmiştir. RNN modeli, ani değişimlerin ve yüksek dalgalanmaların yoğun olduğu sektörlerde yüksek hata oranları sergilemiştir.

GRU modeli, genel olarak dengeli bir öğrenme süreci göstermiş ve düşük hata oranları ile başarılı tahminler üretmiştir. Epoch değerlerinin artırılmasıyla birlikte performansı belirgin şekilde iyileşen GRU modeli, özellikle Aydınlatma ve Sanayi sektörlerinde yüksek doğruluk sağlamıştır. Ancak bazı sektörlerde LSTM ve BiLSTM modelinin gerisinde kalmıştır.

LSTM modeli, uzun dönemli bağımlılıkları ve karmaşık veri yapılarını etkili bir şekilde öğrenebilmiştir. Eğitim ve doğrulama kayıplarında istikrarlı bir düşüş sergileyen LSTM modeli, Mesken ve Tarımsal Sulama sektörlerinde başarılı sonuçlar elde etmiştir. Epoch sayısının artmasıyla performansı artan LSTM modeli, bazı sektörlerde BiLSTM modelinin gerisinde kalsa da genel olarak yüksek tahmin doğruluğuna ulaşmıştır.

BiLSTM modeli, ileri ve geri yönde öğrenme kabiliyeti sayesinde en düşük hata oranlarını ve en yüksek tahmin doğruluğunu sağlamıştır. Özellikle epoch sayısının artırılmasıyla birlikte performansı belirgin şekilde iyileşen BiLSTM modeli, Mesken, Tarımsal Sulama ve Ticarethane sektörlerinde en başarılı model olmuştur. Karmaşık zaman serisi verilerinde ve yüksek dalgalanmaların yoğun olduğu dönemlerde üstün performans sergilemiştir.

Bu çalışmanın sonuçlarına dayanarak gelecekte yapılabilecek iyileştirme ve genişletme çalışmaları için bazı önerilerde bulunulabilir:

Elektrik tüketimi tahminlerinde, özellikle karmaşık ve uzun dönemli bağımlılıkların bulunduğu sektörlerde BiLSTM ve LSTM modellerinin kullanılması önerilir. Bu modeller, ileri ve geri yönde öğrenme kabiliyetleri sayesinde daha düşük hata oranları ve yüksek tahmin doğruluğu sağlamaktadır.

Modellerin performansını iyileştirmek amacıyla, literatürde önerilen bazı yöntemler bu çalışmada da uygulanabilir. Özellikle hiperparametre optimizasyonu ve zaman adımı (time step) gibi parametrelerin optimize edilmesi, modellerin daha iyi sonuçlar vermesini sağlayabilir (Bergstra ve Bengio, 2012). Dropout oranı ve öğrenme oranı gibi hiper parametrelerin optimize edilmesi, aşırı öğrenmenin önlenmesi açısından önemlidir. Ayrıca modellerin performansını artırmak için epoch sayısının dikkatli bir şekilde belirlenmesi önemlidir. Epoch sayısının artırılması genellikle modelin öğrenme kapasitesini artırır da aşırı öğrenmeyi önlemek için erken durdurma tekniklerinin kullanılması faydalı olabilir. Özellikle RNN modellerinde hiperparametre ayarları performansı önemli ölçüde etkileyebilir.

Farklı modellerin güçlü yönlerini birleştiren hibrit modellerin geliştirilmesi ile tahmin performansı artırabilir. Örneğin, BiLSTM ve GRU modellerinin birleşimiyle oluşturulacak bir model hem uzun dönemli bağımlılıkları hem de kısa dönemli değişimleri daha iyi yakalayabilir.

KAYNAKÇA

- Ahmad, R., Wazirali, R., & Abu-Ain, T.** (2022). Machine learning for wireless sensor networks security: An overview of challenges and issues. *Sensors*, 22(13), 4730.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M.A., Al-Amidie, M., Farhan, L.** (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8, 1-74.
- Aparna, S.** (2018). Long short term memory and rolling window technique for modeling power demand prediction. In *2018 Second international conference on intelligent computing and control systems (ICICCS)* (pp. 1675-1678). IEEE.
- Arı, A., & Berberler, M. E.** (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 1(2), 55-73.
- Bergstra, J., & Bengio, Y.** (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(2), 281-305.
- Bişkin, O. T., & Çifçi, A.** (2021). Forecasting of Turkey's Electrical Energy Consumption using LSTM and GRU Networks. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 8(2), 656-667.
- Cai, R., Li, S., Tian, J., & Ren, L.** (2019). Short-term load forecasting based on electricity price in lstm in power grid. In *IOP Conference Series: Materials Science and Engineering*, 569(4).
- Chicco, D., Warrens, M. J., & Jurman, G.** (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peerj computer science*, 7, e623.
- Chou, J. S., & Pham, A. D.** (2013). Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. *Construction and Building Materials*, 49, 554-563.
- Cifuentes, J., Marulanda, G., Bello, A., & Reneses, J.** (2020). Air temperature forecasting using machine learning techniques: a review. *Energies*, 13(16), 4215.

Cihan A., Marttin V. (2023). Advancements in Deep Learning for Electrical Consumption Forecasting: A Review of 2019-2023 Studies for LSTM, Academic Research And Reviews In Engineering Sciences, Prof.Birol KILIÇ Ph.D, (Ed.), Platanus Publishing, Ankara, s.273-290.

Çetiner, H. (2022). Recurrent Neural Network Based Model Development for Energy Consumption Forecasting. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(3), 759-769.

Enerji Piyasası Denetleme Kurumu, (2024). Elektrik Piyasası Resmi İstatistikleri Listesi, Aylık Resmi İstatistikler. [Erişim: 25.05.2022, <https://www.epdk.gov.tr/Detay/Icerik/3-0-167/resmi-istatistikler/>]

Feng, D. C., Liu, Z. T., Wang, X. D., Chen, Y., Chang, J. Q., Wei, D. F., & Jiang, Z. M. (2020). Machine learning-based compressive strength prediction for concrete: An adaptive boosting approach. *Construction and Building Materials*, 230, 117000.

González García, C., Núñez Valdéz, E. R., García Díaz, V., Pelayo García-Bustelo, B. C., & Cueva Lovelle, J. M. (2019). A review of artificial intelligence in the internet of things. *International Journal Of Interactive Multimedia And Artificial Intelligence*, 5.

Kamber, E., Körpüz, S., Can, M., Aydoğmuş, H. Y., & Gümüş, M. (2021). Yapay Sinir Ağlarına Dayali Kisa Dönemli Elektrik Yüku Tahmini. *Endüstri Mühendisliği*, 32(2), 364-379.

Kızrak, M. A., & Bolat, B. (2018). Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.

Lucas, A., Iliadis, M., Molina, R., & Katsaggelos, A. K. (2018). Using deep neural networks for inverse problems in imaging: beyond analytical methods. *IEEE Signal Processing Magazine*, 35(1), 20-36.

Mijwel, M. M. (2017). *Yapay Sinir Ağlar Yapısı ve Fonksiyonu*, [Erişim: 04.02.2024 <https://www.researchgate.net/publication/323073864>]

Pavlatos, C., Makris, E., Fotis, G., Vita, V., & Mladenov, V. (2023). Enhancing electrical load prediction using a bidirectional LSTM neural network. *Electronics*, 12(22), 4652.

Pençe, İ., Kalkan, A., & Çeşmeli, M. Ş. (2019). Türkiye sanayi elektrik enerjisi tüketiminin 2017-2023 dönemi için yapay sinir ağları ile tahmini. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 3(2), 206-228.

Rani, S., Maheswar, R., Kanagachidambaresan, G. R., Ahuja, S., & Gupta, D. (Eds.). (2022). *Machine Learning Paradigm for Internet of Things Applications*. John Wiley & Sons.

Reddy, P. N., & Naqash, J. A. (2019). Strength prediction of high early strength concrete by artificial intelligence. *Int. J. Eng. Adv. Technol*, 8(3), 330-334.

Russel, S.J., Norvig, P., (1995), “*Artificial Intelligence A Modern Approach*”, Contributing writers: John F. Canny, Jitendra M. Malik, Douglas D. Edwards, Prentice Hall, Englewood Cliffs, New Jersey 07632, ISBN 0-13-103805-2, [Eriřim: 04.05.2024, https://people.engr.tamu.edu/guni/csce421/files/AI_Russell_Norvig.pdf]

Saba Raoof, S., & Durai, M. S. (2022). A comprehensive review on smart health care: applications, paradigms, and challenges with case studies. *Contrast Media & Molecular Imaging*, 2022(1), 4822235.

Sajja, A., & Rooban, S. (2024). FPGA implementation of automatic seizure detection in EEG signals using machine learning algorithm. *Discover Applied Sciences*, 6(8), 383.

Sagheer, A.E., & Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323, 203-213.

Sundar, G., & Patchaiammal, P. (2022). Comprehensive Deep Recurrent Artificial Neural Network (CDRANN): Evolutionary Model for Future Prediction. In *International Conference on Computing, Communication, Electrical and Biomedical Systems* (pp. 217-234). Cham: Springer International Publishing.

Sevinç, A., & Kaya, B. (2021). Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneđi. *Computer Science*, (Special), 217-225.

Şalvarcı, Ü. B., & Ayten, U. E. (2019). Yapay sinir ađları ile görüntü işlemeye dayalı uzaktan bağımsız ağırlık tahmin sistemi: yumurta ve portakal örnekleri. *Jeodezi ve Jeoinformasyon Dergisi*, 6(1), 26-46.

Tan, F. G., Yüksel, A. S., Aydemir, E., Ersoy, M. (2021). Derin Öğrenme Teknikleri ile Nesne Tespiti ve Takibi Üzerine Bir İnceleme. *Avrupa Bilim ve Teknoloji Dergisi* (25), 159-171.

Torres-Hernández, M. A., Escobedo-Barajas, M. H., Guerrero-Osuna, H. A., Ibarra-Pérez, T., Solís-Sánchez, L. O., & Martínez-Blanco, M. D. R. (2023). Performance Analysis of

Embedded Multilayer Perceptron Artificial Neural Networks on Smart Cyber-Physical Systems for IoT Environments. *Sensors*, 23(15), 6935.

Ubal, C., Di-Giorgi, G., Contreras-Reyes, J. E., & Salas, R. (2023). Predicting the long-term dependencies in time series using recurrent artificial neural networks. *Machine Learning and Knowledge Extraction*, 5(4), 1340-1358.

Waqas, M., & Humphries, U. W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. *MethodsX*, 102946.

Wang, J. Q., Du, Y., & Wang, J. (2020). LSTM based long-term energy consumption prediction with periodicity. *energy*, 197, 117197.

Wu, M.-P., & Wu, F. (2024). Predicting residential electricity consumption using CNN-BiLSTM-SA neural networks. *IEEE Access*, 12, 71555-71565.

Yan, K., Li, W., Ji, Z., Qi, M., & Du, Y. (2019). A hybrid LSTM neural network for energy consumption forecasting of individual households. *Ieee Access*, 7, 157633-157642.

Zaheer, S., Anjum, N., Hussain, S., Algarni, A. D., Iqbal, J., Bourouis, S., & Ullah, S. S. (2023). A multi parameter forecasting for stock time series data using LSTM and deep learning model. *Mathematics*, 11(3), 590.