

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**FARKLI MAKİNE ÖĞRENMESİ YÖNTEMLERİ
İLE ENERJİ PİYASASINDA YEREL MARJİNAL
FİYAT TAHMİNİ**

Başak ERSÖZ YILDIRIM

YÜKSEK LİSANS TEZİ
Elektrik Mühendisliği Anabilim Dalı
Elektrik Tesisleri Programı

Danışman
Prof. Dr. Ozan ERDİNÇ

Temmuz, 2023

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FARKLI MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE
ENERJİ PİYASASINDA YEREL MARJİNAL FİYAT
TAHMİNİ

Başak ERSÖZ YILDIRIM tarafından hazırlanan tez çalışması 13.07.2023 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı Elektrik Tesisleri Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Ozan ERDİNÇ
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Ozan ERDİNÇ, Danışman
Yıldız Teknik Üniversitesi

Dr. Altuğ BOZKURT, Üye
Yıldız Teknik Üniversitesi

Dr. Ayşe Kübra ERENOĞLU, Üye
Fatih Sultan Mehmet Vakıf Üniversitesi

Danışmanım Prof. Dr. Ozan ERDİNÇ sorumluluğunda tarafımda hazırlanan "Farklı Makine Öğrenmesi Yöntemleri ile Enerji Piyasasında Yerel Marjinal Fiyat Tahmini" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Başak ERSÖZ YILDIRIM

İmza

Tüm güzel kalplilere



TEŞEKKÜR

Bu yüksek lisans tezi çalışmam için beni teşvik eden, görüşleri ile beni yönlendiren, yayın konusunda ve çalışmamın her aşamasında benden desteğini esirgemeyen danışman hocam Sayın Prof. Dr. Ozan Erdinç'e ve Dr. Ali Rıfat Boynueğri'ye teşekkürlerimi sunarım.

Çalışmayı zenginleştirebilmek için katkıda bulunan Şevval YILDIZ'a tüm emeği için teşekkür ederim. Derin öğrenme konusundaki anlayışımın gelişmesinde büyük katkıları olan Dr. Andrew NG'ye ve ekibine sağladığı eğitimler ve detaylı anlatımları için teşekkür ederim.

Hayatıma girdiği günden beri sevgisi ve desteği ile her zaman yanımda olan hayat arkadaşım, değerli eşim İhsan Ozan YILDIRIM'a ve destekleri için ailemin diğer üyelerine teşekkür ederim.

Son olarak bu ülkenin gençliğine ve kadınlarına sonsuz güveni, özverisi ve yarattığı vizyon için Mustafa Kemal ATATÜRK'e teşekkürlerimi sunarım.

Başak ERSÖZ YILDIRIM

İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	xiii
HARİTA LİSTESİ	xv
ÖZET	xvi
ABSTRACT	xviii
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	3
2 ELEKTRİK ENERJİ PİYASA SİSTEMLERİ	5
2.1 Enerji Tüketimi Genel Değerlendirmesi	5
2.2 Piyasa Tipleri ve Detayları	6
3 YAPAY ZEKA METODOLOJİLERİ	16
3.1 Yapay Zekanın Elektrik Enerji Piyasalarındaki Konumu	16
3.2 Yapay Zeka Metodolojilerinin Genel Adımları	17
3.3 Yaygın Metodlar	18
3.4 Kontrol Metodları	20
3.5 Zaman Serileri	21
4 TASARIM SÜRECİ	22
4.1 MISO Enerji Piyasası Veri Setlerini Oluşturma	22
4.2 PJM Enerji Piyasası Veri Setlerini Oluşturma	24
4.3 MISO, PJM ve New England Enerji Piyasası Veri Setlerini Oluşturma	30
5 TAHMİNLEME SÜRECİ	33

5.1	MISO Enerji Piyasası Verileriyle Tahminleme	33
5.2	PJM Enerji Piyasası Verileriyle Tahminleme	38
5.3	MISO, PJM ve New England Enerji Piyasası Bir Yıllık Veri Setiyle Tahminleme	58
6	SONUÇLARIN DEĞERLENDİRİLMESİ	69
6.1	MISO Enerji Piyasası Verilerinin Sonuçları	69
6.2	PJM Enerji Piyasası Verileriyle Tahminleme Sonuçları	71
6.3	MISO, PJM ve New England Enerji Piyasası Bir Yıllık Veri Setiyle Tahminleme Sonuçları	75
6.4	Gelecek Çalışmalar	76
	KAYNAKÇA	78
	TEZDEN ÜRETİLMİŞ YAYINLAR	84

SİMGE LİSTESİ

R^2	Determinasyon Kat Sayısı (R-Squared)
$\bar{y}$	Gerçek Değerlerin Ortalaması
y_i	Gerçek Değer
MC^{PG}	Güç Üretiminin Marjinal Maliyeti
C^{TC}	İletim Tıkanıklık Maliyeti
MC^{Loss}	Kayıpların Marjinal Maliyeti
$\hat{y}_i$	Tahmin Edilen Değer
n	Tahmin Edilen ve Gerçek Değerlerin Toplam Sayısı

KISALTMA LİSTESİ

ABD	Amerika Birleşik Devletleri
ARIMA	Otoregresif Entegre Hareketli Ortalama
CNN	Evrişimli Sinir Ağı
DNN	Deep Neural Network
EIA	Enerji Bilgi İdaresi
EPİAŞ	Enerji Piyasası İşletme AŞ
EEX	European Energy Exchange
GA	Genetik Algoritma
GRU	Kapılı Tekrarlayan Birim
HEnEx	Hellenic Energy Exchange
HUPX	Hungarian Power Exchange
IBEX	Independent Bulgarian Energy Exchange
ISO	Bağımsız Sistem Operatörü
IPEX	Italian Power Exchange
LMP	Locational Marginal Pricing
MAE	Ortalama Mutlak Hata
MISO	Midcontinent Independent System Operator
PJM	Pennsylvania-New Jersey-Maryland Interconnection
RMSE	Kök Ortalama Kare Hata
TGE	Polish Power Exchange
YMF	Yerel Marjinal Fiyat

ŞEKİL LİSTESİ

Şekil 3.1	Yapay zeka kullanarak tahmin etme için izlenecek yol	17
Şekil 4.1	LSTM tahmin modelinin genel akış şeması	22
Şekil 4.2	k=5 kümeleme neticesinde kümelerin 3 boyutlu dağılımı (Rasgele seçilmiş dört adet üçlü kombinasyon örneği gösterilmiştir.)	27
Şekil 4.3	k=5 kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş birinci ikili kombinasyon)	29
Şekil 4.4	k=5 kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş ikinci ikili kombinasyon)	29
Şekil 4.5	k=5 kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş üçüncü ikili kombinasyon)	29
Şekil 4.6	k=5 kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş dördüncü ikili kombinasyon)	30
Şekil 5.1	MISO LSTM 2018/19 için 24 saat ilerisi için tahminlerin grafikleri	33
Şekil 5.2	MISO LSTM 2020 için 24 saat ilerisi için tahminlerin grafikleri	34
Şekil 5.3	MISO LSTM 2021 için 24 saat ilerisi için tahminlerin grafikleri	34
Şekil 5.4	MISO LSTM 2018/19, 2020 ve 2021 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.	35
Şekil 5.5	MISO LSTM 2018/19, ve 2020 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.	35
Şekil 5.6	MISO LSTM 2018/19, ve 2021 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.	36
Şekil 5.7	MISO LSTM 2020 ve 2021 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.	36
Şekil 5.8	MISO LSTM 2018/19 yılları için 24 saat ilerisi tahminlerinin grafiksel karşılaştırması çok değişkenli 2018/19 vs. tek değişkenli 2018/19*.	37
Şekil 5.9	MISO LSTM 2020 yılı için 24 saat ilerisi tahminlerinin grafiksel karşılaştırması çok değişkenli 2020 vs. tek değişkenli 2020*.	37
Şekil 5.10	MISO LSTM 2021 yılı için 24 saat ilerisi tahminlerinin grafiksel karşılaştırması çok değişkenli 2021 vs. tek değişkenli 2021*.	38
Şekil 5.11	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, tüm test seti	39

Şekil 5.12	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti	39
Şekil 5.13	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti	40
Şekil 5.14	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti	40
Şekil 5.15	Tüm veri seti ile LSTM modeli eğitimi boyunca eğitim ve doğrulama kayıplarının değişimi	42
Şekil 5.16	k=5 kümeleme neticesinde en büyük küme ile oluşturulan veri seti ile LSTM modeli eğitimi boyunca eğitim ve doğrulama kayıplarının değişimi	42
Şekil 5.17	k=5 kümeleme neticesinde en büyük küme dışında kalan kümelerden oluşturulan veri seti ile LSTM modeli eğitimi boyunca eğitim ve doğrulama kayıplarının değişimi	43
Şekil 5.18	PJM 2022/2023 Haziran k=5 Tüm Veri Seti Küme Tahmin Grafikleri	44
Şekil 5.19	PJM 2022/2023 Haziran k=5 Diğer Kümeler Küme Tahmin Grafikleri	44
Şekil 5.20	PJM 2022/2023 Haziran k=5 En Büyük Küme Tahmin Grafikleri	45
Şekil 5.21	PJM 2022/2023 Haziran k=5 Tüm veri seti 5 günlük test seti	45
Şekil 5.22	PJM 2022/2023 Haziran k=5 Diğer Kümeler 5 günlük test seti	46
Şekil 5.23	PJM 2022/2023 Haziran k=5 En Büyük Küme Tahmin Grafikleri 5 günlük test seti	46
Şekil 5.24	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği	47
Şekil 5.25	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği, 30 Günlük	47
Şekil 5.26	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği, 5 Günlük	48
Şekil 5.27	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği, 1 Günlük	48
Şekil 5.28	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği	49
Şekil 5.29	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği, 30 Günlük	49

Şekil 5.30	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği, 5 Günlük	49
Şekil 5.31	PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği, 1 Günlük	50
Şekil 5.32	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, tüm test seti	51
Şekil 5.33	PJM Market LSTM için optimize edilmiş parametrelerle GRU 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti . . .	51
Şekil 5.34	PJM Market LSTM için optimize edilmiş parametrelerle GRU 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti . . .	51
Şekil 5.35	PJM Market LSTM için optimize edilmiş parametrelerle GRU 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti . . .	52
Şekil 5.36	PJM Market optimize GRUs* 2022/2023 24 saat ilerisi için tahmin grafikleri, tüm test seti	53
Şekil 5.37	PJM Market optimize GRUs* 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti	53
Şekil 5.38	PJM Market optimize GRUs* 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti	54
Şekil 5.39	PJM Market optimize GRUs* 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti	54
Şekil 5.40	PJM Market optimize LSTM (üstte) ve GRUs (altta) 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti	55
Şekil 5.41	PJM Market optimize LSTM (üstte) ve GRUs (altta) 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti	56
Şekil 5.42	PJM Market optimize LSTM (üstte) ve GRUs (altta) 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti	57
Şekil 5.43	MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti	59
Şekil 5.44	MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti	59
Şekil 5.45	MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti	60
Şekil 5.46	MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti	60
Şekil 5.47	MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti	61

Şekil 5.48	MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti	61
Şekil 5.49	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti	62
Şekil 5.50	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti	63
Şekil 5.51	PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti	63
Şekil 5.52	PJM Market optimize GRUs 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti	64
Şekil 5.53	PJM Market optimize GRUs 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti	64
Şekil 5.54	PJM Market optimize GRUs 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti	65
Şekil 5.55	MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti	66
Şekil 5.56	MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti	66
Şekil 5.57	MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti	67
Şekil 5.58	MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti	67
Şekil 5.59	MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti	68
Şekil 5.60	MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti	68

TABLO LİSTESİ

Tablo 2.1	Gün öncesi ve gün içi piyasası karşılaştırması	9
Tablo 2.2	Dengeleme piyasası avantaj ve dezavantajları	9
Tablo 2.3	Avrupa kıtasındaki elektrik piyasasında kullanılan farklı toptan satış piyasa isimleri	10
Tablo 2.4	ABD elektrik piyasa kuruluşları ve hizmet şirketleri	12
Tablo 4.1	MISO Enerji Piyasası Veri Seti Örnek Kesiti	23
Tablo 4.2	Optimizasyon için çoklu ve tek değişkenli veri setlerinin tahminlenmesinde kullanılan parametre değerleri	24
Tablo 4.3	PJM Enerji Piyasası Veri Seti Kesiti	25
Tablo 4.4	Optimizasyon için mimarideki LSTM ve GRU parametreleri . . .	25
Tablo 4.5	Veri setine kümeleme yapılması sonucu küme-örnek dağılımları (k=2 ile k=6 aralığı)	26
Tablo 4.6	Veri setine kümeleme yapılması sonucu küme-örnek dağılımları (k=7 ile k=15 aralığı)	26
Tablo 4.7	Veri setine kümeleme yapılması sonucu küme-örnek dağılımları (k=16 ile k=24 aralığı)	28
Tablo 4.8	MISO 2022-2023 Haziran optimizasyon için mimarideki LSTM ve GRU parametreler	31
Tablo 4.9	PJM 2022-2023 Haziran optimizasyon için mimarideki LSTM ve GRU parametreler	31
Tablo 4.10	New England 2022-2023 Haziran optimizasyon için mimarideki LSTM ve GRU parametreler	32
Tablo 5.1	MISO performans metriklerinin değerlendirilmesi	33
Tablo 5.2	PJM LSTM Performans metriklerinin değerlendirilmesi	38
Tablo 5.3	PJM K-Means kümelemede baz alınan performans değerleri . . .	41
Tablo 5.4	Tüm veri seti ve k=5 ile oluşturulan küme seti ile eğitilmiş LSTM modellerinin performans metrikleri	43
Tablo 5.5	LSTM için optimize edilmiş LSTM ve GRU parametreleri	50
Tablo 5.6	LSTM için optimize edilmiş LSTM ve GRU tahmin değerleri . .	50
Tablo 5.7	k=5 k-Ortalamlar yöntemi ile LSTM'in ilk ve son değerleri . . .	52
Tablo 5.8	Optimize edilmiş GRUs* parametreleri	52
Tablo 5.9	Optimize edilmiş GRUs* tahmin değerleri	52

Tablo 5.10	LSTM için optimize edilmiş LSTM ve GRUs* tahmin değerleri .	55
Tablo 5.11	Elde edilmiş GRUs ve GRUs* tahmin değerleri	58
Tablo 5.12	MISO performans metriklerinin değerlendirilmesi	58
Tablo 5.13	PJM performans metriklerinin değerlendirilmesi	62
Tablo 5.14	New England performans metriklerinin değerlendirilmesi	65



HARİTA LİSTESİ

Harita 2.1	MISO pazarının sınırlarını ve 18 Nisan 2023 tarihinde örnekleme yapılan renkli gerçek zamanlı toplam yük değerlerini gösteren harita [58].	14
Harita 2.2	PJM pazarının sınırlarını ve 17 Haziran 2023 tarihinde örnekleme yapılan renkli gerçek zamanlı LMP değerlerini gösteren harita. [59].	15
Harita 2.3	New England pazarının yerel kontrol sınırlarını gösteren harita. [60].	15

Farklı Makine Öğrenmesi Yöntemleri ile Enerji Piyasasında Yerel Marjinal Fiyat Tahmini

Başak ERSÖZ YILDIRIM

Elektrik Mühendisliği Anabilim Dalı
Elektrik Tesisleri Programı
Yüksek Lisans Tezi

Danışman: Prof. Dr. Ozan ERDİNÇ

Bu yüksek lisans tezi çalışması, Amerika Birleşik Devletleri (ABD) elektrik piyasası sistemine yönelik yerel marjinal fiyat (YMF) tahmini için derin öğrenme ve makine öğrenme yaklaşımının geliştirilmesini ve uygulanmasını amaçlamaktadır. YMF, şebeke içinde belirli konumlardaki elektrik fiyatını ifade eder ve piyasa operasyonları ve karar verme süreçlerinde kritik bir rol oynar. Tez, MISO (Midcontinent Independent System Operator), New England ve PJM (Pennsylvania-New Jersey-Maryland Interconnection) bölgelerinden YMF değerleri de dahil olmak üzere tarihsel verilerin toplanması ve işlenmesini içerir. Tekrarlayan sinir ağları (RNN'ler), Uzun Kısa Dönem Bellek (LSTM), Kapalı Tekrarlayan Birim (GRU) gibi derin öğrenme teknikleri ve makine öğrenme tekniği olan k-ortalamlar (k-Means) kümeleme, tahmin modelini eğitmek için kullanılır. Model, tarihsel veri setinden karmaşık ilişkileri öğrenerek gelecekteki YMF değerlerini tahmin etmektedir. Modelin performansı ve doğruluğunu ölçmek için değerlendirmeler ve kontroller yapılır. Tahmin edilen YMF değerleri ile gerçek piyasa verileri arasında karşılaştırmalar yapılır ve değerlendirme metrikleri kullanılır. Sonuçlar ve bulgular, derin öğrenme yaklaşımının YMF tahmininde etkinliğini göstermektedir. LMP değerlerinin doğru tahminleri, elektrik fiyatı eğilimleri ve dalgalanmaları hakkında değerli bilgiler sağlayarak, enerji şirketlerine, bu konudaki karar vericilere ve düzenleyicilere bilinçli kararlar vermelerinde yardımcı olmaktadır. Araştırmanın etkileri, elektrik piyasasında fiyatlandırma stratejileri, üretim planlaması, talep tepkisi programları ve kaynak tahsisi gibi

alanlara uzanmaktadır. Bu çalışma, yapay zeka tabanlı elektrik fiyatı tahmininde derin öğrenme tekniklerinin anlaşılması ve uygulanmasına önemli bir katkı yapmakta olup, MISO, New England ve PJM bölgelerine odaklanmaktadır. Araştırma sonuçları pratik sonuçlara sahiptir ve yapay zeka tabanlı elektrik fiyatı analizinde daha ileri gelişmeler için kapılar açmaktadır.

Anahtar Kelimeler: derin öğrenme, makine öğrenmesi, elektrik fiyat tahminlemesi, yerel marjinal fiyat, lokasyonel marjinal fiyat.



ABSTRACT

Local Marginal Price Forecasting Using Different Machine Learning Approaches

Başak ERSÖZ YILDIRIM

Department of Electrical Engineering
Master of Science Thesis

Supervisor: Prof. Dr. Ozan ERDİNÇ

This master's thesis study aims to develop and implement a deep learning and machine learning approach for locational marginal price (LMP) forecasting in the U.S. electricity market system. LMP refers to the electricity price at specific locations within the grid, playing a crucial role in market operations and decision-making. The thesis involves collecting and processing historical data, including LMP values, from the MISO (Midcontinent Independent System Operator), New England ve PJM (Pennsylvania-New Jersey-Maryland Interconnection) regions. Deep learning techniques, such as recurrent neural networks (RNNs), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and machine learning technique k-means clustering, are utilized to train the forecasting model. The model learns complex relationships from the historical dataset to predict future LMP values. Assessments are conducted to measure the model's performance and accuracy. Evaluation metrics are used, and comparisons are made between the forecasted LMP values and actual market data. Statistical techniques may be employed for validation. The results and findings demonstrate the effectiveness of the deep Learning approach in LMP forecasting. Accurate predictions of LMP values provide valuable insights into electricity price trends and fluctuations, aiding utilities, energy traders, and regulators in making informed decisions. The implications of the research extend to pricing strategies, generation planning, demand response programs, and resource allocation in the electricity market. The work contributes to the field of artificial intelligence based electricity price forecasting and has practical implications for grid stability and optimization

of power flows. Overall, the master's thesis makes a significant contribution to the understanding and application of machine learning techniques in LMP forecasting within the U.S. electricity market system, with a focus on the MISO, New England and PJM regions. The research outcomes have practical implications and open avenues for further advancements in artificial intelligence based electricity price analysis.

Keywords: Deep learning, machine learning, electricity price forecasting, locational marginal price.



1.1 Literatür Özeti

Son yıllarda, endüstri ve ekonomide önemli dönüşümler nedeniyle küresel enerji tüketimi hızla artmıştır. Karar vericilerin; risk azaltmayı, ekonomik büyümeyi ve toplumsal gelişmeleri kapsayan optimal stratejiler geliştirebilmeleri için doğru talep tahminlerine sahip olmaları son derece önemlidir [1].

Elektrik fiyatlandırması, enerji sektöründeki reformları takiben güç piyasası işlemlerinde önemli bir rol oynar. Yüksek fiyatlar, satıcıları elektrik arzını havuz piyasasına sağlamaya teşvik eder veya alıcıları kendi üretim tesislerini kullanmaya yönlendirir. Karlarını maksimize etmek ve finansal risklerden korunmak için hem satıcılar hem de alıcılar elektrik fiyat tahminlerine bağımlıdır. Güç piyasalarında elektrik fiyatlarını tahmin etmek için talep, arz, hava durumu ve yakıt piyasası değişkenleri gibi birçok faktör dikkate alınmalıdır. Elektrik fiyatlarının volatilitesi ve diğer piyasalara tahmin tekniklerinin uygulanmasından kaynaklanan önemli hatalar da göz önünde bulundurulmalıdır. Yerel marjinal fiyat (YMF), farklı enerji piyasalarında alınan ve satılan enerjinin fiyatını belirlemek için kullanılır ve sistem enerji fiyatlarını, iletim sıkışıklığı maliyetlerini ve marjinal kayıp maliyetlerini içerir [2–4].

YMF, elektrik sektöründe belirli bir konuma elektrik sağlama maliyetini belirlemek için kullanılan bir yöntemdir ve elektrik üretim maliyetini ve iletim sistemi kısıtlamalarını dikkate alır. Büyük ölçekli enerji şebekelerinde sıkışıklığı yönetmek için ABD Federal Enerji Düzenleme Komisyonu (The US Federal Energy Regulatory Commission) bu yaklaşımı önermiştir. YMF'nin benimsenmesiyle, elektrik piyasaları hem kısa hem de uzun vadede daha verimli hale gelebilir. YMF tabanlı fiyatlandırma; PJM, MISO ve New England gibi birçok elektrik piyasasında uygulanmış ve Bağımsız Sistem İşletmecileri (Independent System Operators - ISO) tarafından yönetilmiştir. Böylece sıkışıklık dönemlerinde etkili iletim sistemi kullanımı sağlanmaktadır. YMF, adil elektrik fiyatlarının korunmasına ve kesinti

veya gerilim dalgalanmalarının olasılığını azaltmaya katkıda bulunur [4, 5].

Literatür incelendiğinde, elektrik fiyatlandırması ve yerel marjinal fiyat ile ilgili birçok farklı alanda çok sayıda çalışma olduğu görülmektedir.

Crozier vd. [6] (2022), elektrik fiyatlarında meydana gelen yerel farklılıklarla, ucuz enerji açığı olan bölgelere enerji taşındığında ek gelir akışları oluşturabileceğini ve tıkanıklık giderme gibi değerli şebeke hizmetleri sağlayabileceğini belirtmiştir. Bölgeler arasındaki fiyatların belirgin şekilde farklılaştığı ve yüksek olasılıkla tahmin edilebildiği durumlarda bir elektrikli aracın şarj, deşarj ve seyahatini optimize ederek geliri en üst düzeye çıkaran deterministik ve tek aşamalı stokastik optimizasyon ile önemli gelir elde edildiğini belirtmiştir. Zhang vd. [7] (2022), güncel üretim teklifi bilgilerine erişme zorlukları nedeniyle, pazar katılımcılarının bakış açısından önceki fiyat tahminleri kullanılarak, üretim teklifi bilgisi kullanılmadan sadece tarihsel fiyat ve yük verileri arasındaki lokasyon ve zaman ilişkilerini öğrenmeye odaklanmıştır. Sivasankari vd. [8] (2022) YMF'nin kullanılmasıyla yük ve fiyat tahmini yapmanın önemini vurgulanmış ve tahmin hatalarının cezalandırma kavramıyla belirlenerek enerji tüketiminin etkin yönetimi ve gelir artışının sağlanması amaçlanmıştır.

Bir diğer çalışmalarında Zhang vd. [9] (2020), toptan elektrik piyasalarında gerçek zamanlı yerel marjinal fiyatları tahmin etmek için bir modelden bağımsız, denetimsiz öğrenme yaklaşımı önermektedir. Yadav vd. [10] (2023), yerel marjinal fiyatları tahmin etmek için otoregresif entegre hareketli ortalama (Autoregressive Integrated Moving Average-ARIMA) kullanarak bir örnek göstermiştir. Li vd. [11] (2022) bu makalede, elektrik piyasalarında sanal teklif vermek için hem risk kısıtlamalarını hem de fiyat hassasiyetini dikkate alan bir makine öğrenmesi tabanlı portföy optimizasyon çerçevesinde tekrarlayan sinir ağı temelli YMF yayımlı tahmin modeli geliştirmiştir. Hong vd. [3] (2020) konvolüsyonel sinir ağı (Convolutional Neural Network-CNN) görsel tanıma ve sınıflandırmada yaygın olarak kullanılmakla birlikte, CNN'in lokasyon ve zaman verilerinden özellik çıkarabilen bir öngörücü olarak da kullanılabileceği sonucunu çıkartmıştır. CNN'i evrimsel bir algoritma ile entegre eden ve hem yerel hem zamansal verileri kullanan 24 saat sonrası için elektrik fiyatı tahmin yöntemi önerilmektedir. İleriye dönük yerel marjinal fiyat tahmini CNN ağı ile birlikte, genetik algoritma (GA) kombinasyonu kullanılarak elde edilmiştir. Atabay vd. [12] (2022) Houston, Teksas, ABD'deki iki katlı bir evin elektrik tüketimi tarihsel verileri üzerinde geleneksel ARIMAX ve SARIMAX (Seasonal Autoregressive Integrated Moving Average) tahmin modelleri ile tekrarlayan sinir ağları (Recurrent Neural Networks-RNN) tabanlı derin öğrenme modellerinin kullanıldığı, günlük ortalama

elektrik tüketiminin tahmin edilmesi için bir çalışma geliştirmiş, enerji tüketimi tahmini yapmanın önemi ve farklı modeller arasındaki performansı karşılaştırmıştır. Javed vd. [13] (2022) PJM bölgesindeki 35 düğümün gerçek zamanlı fiyatlarını, yük değişimleri, hava durumu ve geçmiş fiyatlar gibi girdileri kullanarak düşük yanlılık ve yüksek varyansa sahip makine öğrenme modellerinin artımlı öğrenmeye dayalı bir modeli önermişlerdir. Kumar vd. [14] (2021) , yenilenebilir enerji geliştirme senaryosunun dünya çapında kapasite artışı ve şebeke bağlantısı açısından hızla değiştiği bir ortamda, rüzgar enerjisinin elektrik fiyatı üzerindeki etkisini belirlemek ve değişkenliği dikkate alarak fiyatı tahmin etmek için güç sistem planlamacıları için önemli bir görev olan Avusturya Elektrik Piyasası'nda Destek Vektör Regresyonu (Support Vector Regression-SVR) ve Derin Sinir Ağı (Deep Neural Network-DNN) kullanılarak yapılan araştırma ile katkı sunmuştur.

Wang vd. [15] (2022) yenilenebilir enerji üretim çıktılarındaki belirsizliklerle başa çıkabilmek için sistem operatörlerinin, geleneksel generatörleri daha sık devreye alıp kapatmak zorunda kaldıklarına dikkat çekerek YMF'ye ek olarak gelişmiş e-YMF (e-LMP) önermiştir. Yang [16] (2022) makalesinde oluşturduğu model gelecek birkaç yılın elektrik fiyatı değişim trendini, rüzgar enerjisi üzerine çizelgeye alınan fiyatı ve enerji şirketlerinin satın alma ve satış farkını daha iyi tahmin edebildiğini gösteren bir çalışma önermektedir. Angaphiwatchawal vd. [17] (2022) bu makalede, rüzgar enerjisi üretiminin güç spot piyasasında büyük ölçekte yer alması durumunda, volatilitesi nedeniyle finansal risk ve kısıtlama sorunu ile karşılaşıldığını vurgulamıştır. Güç spot piyasasında bir rüzgar çiftliği GENCO için enerji depolama sistemlerinin optimal planlaması için bir süreç önerilmektedir. Park vd. [18] (2021) dağıtım yerel marjinal fiyatlarının talep yanıtı stratejilerinde kullanılması ve güç sistemlerine yenilenebilir enerji kaynaklarının entegrasyonunda sağlam ve optimal talep yanıtı stratejilerinin geliştirilmesini amaçlanmıştır. Kumar vd. [19] (2022) bu makalede, YMF tabanlı elektrik piyasalarında yenilenebilir enerji kaynaklarının entegrasyonu ile ilgili ortaya çıkan yeni zorluklara odaklanan literatüre bir genel bakışı sunmaktadır.

1.2 Tezin Amacı

Bu yüksek lisans tezi, ABD elektrik piyasası sisteminde YMF tahminlemesi için derin öğrenme ve klasik makine öğrenmesi yaklaşımının geliştirilmesini ve uygulanmasını amaçlamaktadır. YMF değerlerinin doğru tahminleri, enerji şirketleri, enerji ticaretçileri ve düzenleyicilerin bilinçli kararlar almasına yardımcı olarak elektrik fiyatı trendlerine ve dalgalanmalara ilişkin değerli bilgiler sunmaktadır. Araştırmanın sonuçları, elektrik piyasasında fiyatlandırma stratejileri,

retim planlaması, talep tepki programları ve kaynak tahsisi gibi konulara ilişkin nemli uygulamaları iermektedir. alıřma, yapay zeka tabanlı elektrik fiyat tahminlemesi alanına katkıda bulunmakta ve enerji aęının kararlılıęı ve g akıřının optimize edilmesi konularında pratik sonular saęlamaktadır. Genel olarak, bu alıřma, MISO, New England ve PJM blgelerine odaklanarak, ABD elektrik piyasası sistemi iinde derin ęrenme ve makine ęrenmesi tekniklerinin YMF tahminlemesi konusuna katkı saęlamaktadır ve kontrol metotlarıyla sonuları deęerlendirmektedir. Arařtırma sonuları, yapay zeka tabanlı elektrik fiyat analizinde ilerlemeler iin yeni olanaklar sunmaktadır.



2 ELEKTRİK ENERJİ PİYASA SİSTEMLERİ

2.1 Enerji Tüketimi Genel Değerlendirmesi

Sanayi sektörü ve genel ekonomi içindeki karar vericiler ve politika yapıcılar için, küresel enerji tüketimindeki büyük artış, doğru talep tahminlerinin kritik önemini vurgulamıştır. 1950’den 2019 yılına kadar hemen hemen her sektörde artarak yükselen enerji talebi 2020’de hayatımıza pandemi gerçeğinin girmesiyle değişti. Bu konuyla ilgili EIA (U.S. Energy Information Administration)’nın ABD içinde bağımsız olarak araştırıp yayınladığı rapora göre birçok alanda çarpıcı örnekler mevcuttur [20]. Örneğin, EIA’nın raporuna göre; 2020 yılında, ABD endüstri sektöründe enerji tüketimi %5 oranında düştü. Elektrik şebekesinin güvenli işleyişi için elektrik arzı ile talebini dengelemek önemlidir. Talepteki dalgalanmaları anlamak ve doğru bir şekilde tahmin etmek, özellikle şebeke operatörleri için önemlidir.

Bizim için beklenmedik bir olay olan COVID-19 salgını ve sosyal kısıtlamalar, seyahat yasakları ve uzaktan çalışma politikaları gibi beraberinde getirdiği kapanma önlemleri, işletmelerin faaliyetlerine önemli bir etki yapmış ve elektrik talebinde düşüşe neden olmuştur.

Bu sırasında, beklenmedik bir şekilde, konutlardan gelen elektrik talebi önemli ölçüde artarken, işletmelerden ve endüstriden gelen talep azalmıştır. Bu yılın ardından, birçok insan politika ve yaşam tarzlarını değiştirmiştir ve bu da dikkate alınması gereken bir durumdur.

Bu nedenle, politika yapıcılar ve karar vericilerin doğru tahmin modellerine ve stratejilere ihtiyaçları vardır. Bu modeller ve stratejiler, gelecekteki salgınlar veya beklenmedik olaylar karşısında istikrarlı ve sürdürülebilir bir enerji arzını sağlamak için bu değişen enerji tüketimi değişimlerini dikkate almalıdır.

2020 yılında Amerika Birleşik Devletleri’nde birçok seyahat kısıtlaması uygulandı ve bazı kısıtlamalar hafifletildikten sonra bile petrol talebi önceki seviyelerin altında

kaldı. 2020 yılı Şükran Günü haftasında ABD’de kullanılan jet yakıtı hacmi, 2019 yılı hacminin yaklaşık yarısı kadardı. Genel olarak, ABD’deki ulaşım sektörü tarafından kullanılan jet yakıtı %38, motor benzin %13 ve dizel yakıt (distilasyonlu yakıt yağı) %7 oranında azaldı.

Kapalı ofisler ve işletmeler, evden çalışma uygulamaları ve nispeten daha sıcak geçirilen kış hava şartları, ticari enerji tüketiminin azalmasına da katkıda bulundu. ABD’de ticari doğal gaz tüketimi %11 oranında düştü ve ticari sektörde elektrik perakende satışları %6 oranında azaldı.

Yine 2020 yılında ABD’nin birçok ürüne olan talebinin azalmasıyla birlikte, enerji yoğun sanayi sektörü daha az ham petrol ve doğal gaz üretti ve bu nedenle bu ürünleri üretmek, rafine etmek ve işlemek için daha az enerji tüketti. ABD endüstrisinin her bir enerji kaynağında tüketim düştü: kömür kullanımı %16, petrol kullanımı %4 ve doğal gaz kullanımı %2 oranında azaldı. Elektriğin sanayiye perakende satışı %8 oranında düştü. Bu rapor konut alanında ise yine şaşırtıcı bir tabloyu önümüze koymaktadır. 2020 yılında çeşitli evde kalma emirleri nedeniyle insanlar evlerinde daha fazla zaman geçirdi ve bu da elektrik satışlarının ABD konut sektöründe %2 oranında artmasına neden oldu. Ancak 2020 yılı nispeten sıcak bir yıl olduğu için ev ısıtması için daha az enerji tüketildi. ABD’nin konutlarda enerji tüketimi biyokütle (çoğunlukla odun) %16, petrol %11 ve doğal gaz %7 oranında azaldı [20].

AEO2023 [21] raporuna göre ise gelecek yıllar için yapılan öngörülerde, ABD’de tüketilen elektriğin payı, evlerin soğutma talebinin artması ve elektrikli araçların daha büyük bir pazar payına sahip olmasıyla en çok konut ve taşımacılık sektörlerinde artacak gibi gözükmemektedir. Geleceğe yönelik yapılan tüm senaryolarda, konutlarda satın alınan elektriğin tüketiminin, 2022 ile 2050 arasında yaklaşık %14 ila %22 arasında artış göstereceği düşünülüyor. 2022’de elektrikli araçlar, ABD araç pazarının yaklaşık %6-%7’sini oluşturdu. Elektrikli araçların benimsenmesinin artmasıyla, 2022’de satın alınan elektriğin miktarı olan 0.1 quaddan 2050’de 0.6 quad ile 1.3 quad arasında değişen bir artış gözlenmesi bekleniyor, bu da tüm gelecek senaryolarında yaklaşık %900 ile %2000’lik bir artış anlamına gelmektedir [22].

2.2 Piyasa Tipleri ve Detayları

Elektrik fiyat tahminlemesi, hem satıcıların hem de alıcıların kârlarını optimize etmek ve finansal risklerden korunmak için gereklidir. Bununla birlikte, elektrik fiyatlarını tahmin etmek, talep, arz, hava durumu, sıcaklık, konum, düzenleyici

politikalar, teknolojik ilerlemeler ve piyasa trendleri gibi birçok faktörü dikkate almayı gerektirir.

Elektrik piyasası fiyatlandırmasında çeşitli farklı pazar türleri bulunmaktadır ve her biri genel elektrik piyasası sisteminde belirli bir amaca hizmet etmektedir. Bazı yaygın pazar türleri şunları içerir [19, 23–26].

2.2.1 Toptan Satış Piyasası

Toptan pazarın literatürdeki ismini “wholesale market” olarak görmek mümkündür. Toptan pazar, elektriğin üreticiler ve hizmet şirketleri gibi büyük ölçekli tüketiciler arasında alım satımının yapıldığı ana pazardır. Toptan pazar genellikle bağımsız bir sistem işleticisi (ISO - independent system operator) veya bölgesel iletim örgütü (RTO - regional transmission organization) tarafından yönetilir ve elektrik fiyatları, hizmetin sağlanma maliyetini yansıtan bir teklif üzerinden gerçekleşir.

2.2.2 Perakende Satış Piyasası

Perakende piyasanın literatürdeki ismini “retail market” olarak görmek mümkündür. Perakende pazar, elektriğin evler ve küçük işletmeler gibi son kullanıcı müşterilere satıldığı pazardır. Perakende pazar genellikle düzenlenmesizdir, yani müşteriler elektrik tedarikçilerini seçebilir ve elektrik sözleşmesinin şartlarını müzakere edebilir.

2.2.3 Dengeleme Piyasası

Dengeleme piyasaının literatürdeki ismini “balancing market” olarak görmek mümkündür. Dengeleme pazarı, elektrik arzını ve talebini gerçek zamanlı olarak dengeleyerek elektrik şebekesinin güvenilirliğini ve istikrarını sağlamak için kullanılan bir pazar türüdür.

2.2.4 Marjinal Maliyet Fiyatlandırması

Marjinal maliyet fiyatlandırması literatürdeki ismini “marginal cost pricing” olarak görmek mümkündür. Marjinal maliyet fiyatlandırması; piyasa katılımcılarını, elektriği mümkün olan en düşük maliyetle üretip satmaya teşvik eder.

Marjinal maliyet fiyatlandırması genellikle rekabetçi piyasalarla ilişkilidir. Burada firmalar rekabet avantajı elde etmek için ürünlerini en düşük maliyetle sunmaya çalışırlar. Bu yaklaşım, şirketlere üretim süreçlerini geliştirmek, israfı azaltmak

ve üretkenliği artırmak için teşvik sağlar ve nihayetinde tüketicilere daha düşük fiyatlarla fayda sağlar.

2.2.5 Yerel Marjinal Fiyat

YMF veya diğer adıyla lokasyonel marjinal fiyatın literatürdeki ismini “locational marginal price” olarak görmek mümkündür. Elektrik sektöründe belirli bir konuma enerji sağlama maliyetini belirlemek için kullanılan bir yöntemdir.

YMF, enerji piyasalarında alınan ve satılan enerjinin fiyatını belirlemek için kullanılır ve sistem enerji fiyatları, iletim sıkışıklık maliyetleri ve marjinal kayıp maliyetlerini içerir.

YMF aşağıdaki gibi hesaplanabilir:

$$YMF = MC^{PG} + C^{TC} + MC^{Loss} \quad (2.1)$$

MC^{PG} güç üretiminin marjinal maliyetini, C^{TC} iletim tıkanıklık maliyetini ve MC^{Loss} kayıpların marjinal maliyetini temsil etmektedir.

2.2.6 Açık Arttırma Tabanlı Fiyatlandırma

Açık arttırma tabanlı fiyatlandırmanın literatürdeki ismini “Auction-based pricing” olarak görmek mümkündür. Elektrik alım satımı için piyasa katılımcılarının teklif ve tekliflerini sunduğu rekabetçi bir açık artırma sürecidir.

2.2.7 Gün Öncesi Piyasası

Gün öncesi piyasası (GÖP), piyasa katılımcılarının önceden elektrik ticareti yapmasına olanak tanıyan, enerji riskini yönetmeye ve operasyonları optimize etmeye yardımcı olan bir piyasa türüdür. GÖP vadeli işlem esasına göre çalışır, yani piyasa katılımcılarının bir sonraki gün teslim edilmek üzere elektrik ticareti yapmasına olanak tanır.

2.2.8 Gün İçi Piyasası

Piyasa katılımcılarının değişen piyasa koşullarına gerçek zamanlı olarak tepki vermelerini sağlayan bir piyasa türüdür. Spot esasına göre çalışır. Yani piyasa katılımcılarının hemen teslim için elektrik ticareti yapmasına izin verir. Gün içi piyasa genellikle elektrik şebekesindeki kısa vadeli dengesizlikleri yönetmek için kullanılır.

2.2.9 Market Tiplerinin Karşılaştırılması

Gün içi ve gün öncesi piyasaları avantajları ve dezavantajları yönüyle değerlendirilebilir. Bu konuyla ilgili detaylı bilgiye Tablo 2.1’de yer verilmiştir. Aynı şekilde dengeleme piyasasının da avantaj ve dezavantajları vurgulanarak Tablo 2.2 oluşturulmuştur [19, 24–26].

Tablo 2.1 Gün öncesi ve gün içi piyasası karşılaştırması

	Gün Öncesi Piyasası	Gün İçi Piyasası
Avantajlar	- İleri tarihli ticaret imkanı	- Esneklik sağlar
	- Enerji riskinin yönetiminde istikrar, şeffaflık sağlar	- Anlık talep ve arz durumlarına tepki verme imkanı
	- Operasyonların planlanmasına yardımcı olur	- Anlık fiyatlar üzerinden işlem yapma imkanı
Dezavantajlar	- Talep ve arz tahminlerinde belirsizlik olabilir	- Daha yüksek fiyat değişimi
	- Daha sınırlı esneklik	- Planlama ve yönetim daha zor olabilir

Tablo 2.2 Dengeleme piyasası avantaj ve dezavantajları

Avantajlar	Dezavantajlar
Elektrik şebekesinin güvenilirliğini sağlar	Daha yüksek işlem maliyetleri
Enerji arzı ve talebini gerçek zamanlı olarak dengeler	Daha karmaşık ve sofistike sistemlere ihtiyaç duyabilir
Hızlı tepki verme yeteneği sağlar	Karmaşık ve hızlı işleyiş zorlukları
Şebeke güvenliği için hızlı karar alma süreçleri	Küçük ölçekli üreticiler ve tüketiciler için erişilebilirlik
Rekabeti teşvik eder ve fiyatların adil olmasını sağlar	Ani değişikliklerin dengelemeyi zorlaştırması

2.2.10 Ülkelere Göre Piyasa Tipleri, Yapısı ve İsimleri

Bu bölümde dünyanın farklı noktalarından birçok elektrik toptan sağlayıcısı şirketin bilgilerine yer verilmiştir [27–44]. Tablo 2.3’te Avrupa kıtasındaki elektrik piyasasında kullanılan farklı toptan pazarlara ait detaylara yer verilirken Tablo 2.4’te ABD elektrik piyasa kuruluşları ve hizmet şirketleri yer almaktadır.

2.2.11 Elektrik Piyasalarını Doğrudan ve Dolaylı Etkileyen Etmenler

Elektrik enerji piyasası, birçok faktörün etkileşimiyle şekillenen karmaşık bir yapıya sahiptir. Bu faktörler, elektrik enerjisi piyasasını doğrudan veya dolaylı

Tablo 2.3 Avrupa kıtasındaki elektrik piyasasında kullanılan farklı toptan satış piyasa isimleri

Ülke	Toptan Pazar
Türkiye	Enerji Piyasası İşletme AŞ (EPIAŞ) [36]
Danimarka	Nordpool Spot [27]
Finlandiya	Nordpool Spot [27]
İsveç	Nordpool Spot [27]
Norveç	Nordpool Spot [27]
Almanya	European Energy Exchange (EEX) [37]
İngiltere	N2EX [38]
Fransa	EPEX SPOT [39]
İtalya	Italian Power Exchange (IPEX) [40]
İspanya	OMIE [41]
Hollanda	APX Group [42]
Belçika	Belpex [43]
İsviçre	Swissix [44]
Avusturya	EXAA [28]
Polonya	Polish Power Exchange (TGE) [29]
Çek Cumhuriyeti	Power Exchange Central Europe (PXE) [30]
Slovakya	Power Exchange Central Europe (PXE) [30]
Macaristan	Hungarian Power Exchange (HUPX) [31]
Romanya	OPCOM [32]
Bulgaristan	Independent Bulgarian Energy Exchange (IBEX) [33]
Yunanistan	Hellenic Energy Exchange (HEX) [34]
Portekiz	OMIP [35]

olarak etkileyebilir. Yeni kapasite yatırımları, elektrik arzını artırmak veya güncellemek amacıyla yapılan projelerdir ve piyasa koşullarını değiştirebilir. Aynı şekilde, elektrik enerjisi politikaları ve piyasa yapısı da piyasa dinamiklerini belirleyen önemli unsurlardır [45].

Yenilenebilir enerji kaynaklarının hacmi ve üretim dengesizlikleri de elektrik piyasasını etkileyen faktörler arasındadır. Rüzgar, güneş, hidroelektrik gibi yenilenebilir kaynakların değişken doğası, arz-talep dengesini etkileyebilir ve fiyatları dalgalanmalara yol açabilir. Ayrıca, yakıt veya kaynak fiyatları ile işletme maliyetleri de elektrik enerjisi piyasasının belirleyicilerindendir.

Piyasa oyuncularının fiyat stratejileri ve işletme maliyetleri, elektrik fiyatlarını doğrudan etkileyen faktörlerdir. Rekabetçi bir piyasada, piyasa katılımcıları fiyatları optimize etmek ve rekabet avantajı elde etmek için çeşitli stratejiler izlerler. Hava şartları, yük tahminleri, arz-talep dengesi ve ekonomi, nüfus, sanayileşme trendleri gibi faktörler de elektrik fiyatlarını etkileyebilir. Ayrıca, sistemdeki planlı veya plansız onarımlar, sezonsallık ve zaman dilimleri gibi faktörler de fiyatları

etkileyen unsurlardır.

Geçmiş elektrik fiyat arşivi, piyasada oluşan fiyatların analiz edilmesine ve gelecekteki fiyat hareketlerinin tahmin edilmesine yardımcı olabilir. Elektrik enerji piyasasında bu kadar çok etmenin bir araya gelmesi, fiyatların sürekli olarak değişkenlik gösterdiği ve karmaşık bir yapıya sahip olduğu anlamına gelir. Bu nedenle, piyasa katılımcıları ve regülatörler, bu faktörleri dikkate alarak stratejilerini ve politikalarını belirlerler.

2.2.12 Amerika Elektrik Piyasası

Amerika'daki elektrik piyasası sistemi, devlet düzenlemesi ve düzenlemesizlik (deregülasyon) karışımı olarak tanımlanabilir ve eyaletten eyalete farklılık gösterebilir [46–57]. Bunun anlaşılması için ana bileşenleri olan üretim ve dağıtımı ele alalım.

Üretim: Elektrik üretimi sektörü, kömür, doğal gaz, nükleer enerji, yenilenebilir enerji (güneş, rüzgar, hidro) ve diğer kaynaklardan elektrik üretimini içerir. Geçmişte, çoğu eyalette tek bir hizmet sağlayıcısının üretim ve dağıtımı ele aldığı düzenlenmiş monopoliler bulunuyordu. Ancak bazı eyaletler rekabetçi veya yeniden yapılandırılmış piyasalara geçiş yapmıştır.

Dağıtım: Dağıtım sektörü, elektriğin santrallerden tüketiciye ulaşmasını sağlayan iletim hatları ve dağıtım sistemleri üzerinden gerçekleşir. Bu elektrik piyasasının bir yönü genellikle düzenlenmiştir ve hizmet sağlayıcılar, altyapıyı sürdürmekte ve müşterilere güvenilir bir şekilde teslimat yapmaktan sorumludur.

Deregülasyon, geleneksel olarak düzenlenen sektörlerle rekabetin girmesi sürecini ifade eden önemli bir adımdır. Elektrik piyasası bağlamında, birden fazla şirketin üretim ve elektrik satışına katılabildiği rekabeti teşvik etmek amacıyla eyaletler politikalar benimsemiştir. Deregülasyon, daha rekabetçi bir piyasa yaratmayı ve potansiyel olarak düşük fiyatları ve artan yenilikçilik tutumunu sağlamayı, sürekli hale getirmeyi hedefler.

Deregüle eyaletlerde piyasa genellikle üç ana bileşene ayrılmıştır:

Üretim: Elektrik üretimi rekabete açıktır ve birden fazla şirketin santral inşa etmesine ve işletmesine izin verilir. Bu şirketler elektriği toptan fiyatlardan piyasaya satarlar.

İletim: Elektrik iletimi düzenlenmeye devam eder ve ISO'lar veya RTO'lar iletim ağını denetler. tüm piyasa katılımcılarına adil iletim hattı erişimi sağlar.

Perakende: Perakende rekabet, tüketicilerin elektrik tedarikçilerini çeşitli perakende şirketleri arasından seçebilmelerine olanak tanır. Perakende tedarikçileri elektriği toptan piyasadan satın alır ve farklı fiyatlandırma planları ve hizmet seçenekleri sunarak tüketiciye satarlar.

Tüm eyaletlerin elektrik piyasalarını tamamen deregüle etmediklerini belirtmek önemlidir. Bazı eyaletler, belirli yönlerin deregüle olduğu hibrit bir yaklaşım benimsemiştir, diğerleri ise daha geleneksel düzenlenmiş modelleri sürdürmektedir.

Genel olarak, deregülasyon derecesi ve belirli piyasa yapısı eyaletlere göre farklılık gösterir, bazı eyaletler tam rekabetçi piyasalara sahipken, diğerleri daha geleneksel düzenlenmiş modelleri sürdürmektedir [46–57].

Tablo 2.4 ABD elektrik piyasa kuruluşları ve hizmet şirketleri

Kısaltma	Açıklama
PJM-RTO [46]	PJM Interconnection Bölgesel İletim Kuruluşu, Amerika Birleşik Devletleri'ndeki en büyük elektrik şebeke operatörlerinden biridir ve Orta Atlantik ve Ortabatı bölgelerinde birden fazla eyalete hizmet vermektedir.
MID-ATL/APS [50]	Mid-Atlantic Power Supply Association, Orta Atlantik bölgesinde rekabetçi enerji tedarikçilerini temsil eden bir kuruluştur.
AECO	Alberta Elektrik Sistemi İşletmecisi, Kanada'nın Alberta eyaletinde elektrik şebekesini işletme ve bakımından sorumlu olan kuruluştur.
BGE [51]	Baltimore Gas and Electric Company, merkezi Maryland'de elektrik ve doğal gaz hizmetleri sunan bir hizmet şirketidir.
DPL [52]	Delmarva Power, Delaware ve Maryland'de elektrik hizmetleri sunan bir hizmet şirketidir.
JCPL	Jersey Central Power and Light, New Jersey'nin bazı bölgelerinde elektrik hizmetleri sunan bir hizmet şirketidir.
METED	Metropolitan Edison, Pennsylvania'nın bazı bölgelerinde elektrik hizmetleri sunan bir hizmet şirketidir.
PECO [53]	Philadelphia Electric Company, Philadelphia bölgesinde elektrik hizmetleri sunan bir hizmet şirketidir.
PEPCO [54]	Potomac Electric Power Company, Washington, D.C. ve Maryland'ın bazı bölgelerinde elektrik hizmetleri sunan bir hizmet şirketidir.


Tablo 2.4 ABD elektrik piyasa kuruluşları ve hizmet şirketleri - devamı

Kısaltma	Açıklama
PPL [55]	Pennsylvania Power and Light, Pennsylvania’da elektrik hizmetleri sunan bir hizmet şirkettir.
PENELEC	Pennsylvania Electric Company, Pennsylvania’nın bazı bölgelerinde elektrik hizmetleri sunan bir hizmet şirkettir.
PSEG	Public Service Enterprise Group, New Jersey’de faaliyet gösteren ve elektrik ve doğal gaz hizmetleri sunan bir enerji şirkettir.
RECO	Rockland Electric Company, New Jersey’nin bazı bölgelerinde elektrik hizmetleri sunan bir hizmet şirkettir.
APS [56]	Arizona Public Service, Arizona’da elektrik hizmetleri sunan bir hizmet şirkettir.
AEP [57]	American Electric Power, Amerika Birleşik Devletleri’ndeki en büyük elektrik hizmeti sağlayıcılarından biridir ve birden fazla eyalette faaliyet göstermektedir.
COMED [47]	Commonwealth Edison, Kuzey Illinois’te elektrik hizmetleri sunan bir hizmet şirkettir.
DAY	Dayton Power and Light, Batı Ohio’da elektrik hizmetleri sunan bir hizmet şirkettir.
DOM	Dominion Energy, Virginia ve bazı diğer bölgelerde elektrik ve doğal gaz hizmetleri sunan bir enerji şirkettir.
DUQ [48]	Duquesne Light Company, Pittsburgh bölgesinde elektrik hizmetleri sunan bir hizmet şirkettir.
ATSI	American Transmission Systems Incorporated, Amerika Birleşik Devletleri’nde iletim hatları işleten bir kuruluştur.
DEOK	Dayton Power and Light - Ohio/Kentucky, Ohio ve Kentucky’de elektrik hizmetleri sunan bir hizmet şirkettir.
EKPC	East Kentucky Power Cooperative, Kentucky’de kooperatif bir elektrik enerjisi sağlayıcısıdır.
OVEC	Ohio Valley Electric Corporation, Ohio Vadisi bölgesinde elektrik üreten bir şirkettir.


Bu tezde MISO, PJM ve New England şirketlerinden sağlanan YMF veri setlerinden faydalandığı için bu iki şirket hakkında detaylı bilgi vermek doğru olacaktır.

YMF temelli fiyatlandırma, PJM, MISO ve New England gibi birkaç Amerikan

elektrik piyasasında uygulanmıştır ve bağımsız sistem işletmecileri tarafından yönetilmektedir. Bu sayede, tıkanıklık durumunda etkili iletim sistemi kullanımı sağlanmaktadır. Harita 2.1’de, harita MISO pazarının sınırlarını göstermektedir. Harita 2.3’de ise harita, PJM pazarının sınırlarını göstermektedir [58, 59].




Harita 2.1 MISO pazarının sınırlarını ve 18 Nisan 2023 tarihinde örnekleme yapılan renkli gerçek zamanlı toplam yük değerlerini gösteren harita [58].



Harita 2.2 PJM pazarının sınırlarını ve 17 Haziran 2023 tarihinde örnekleme yapılan renkli gerçek zamanlı LMP değerlerini gösteren harita. [59].

New England's Six LCCs



Harita 2.3 New England pazarının yerel kontrol sınırlarını gösteren harita. [60].

3

YAPAY ZEKA METODOLOJİLERİ

3.1 Yapay Zekanın Elektrik Enerji Piyasalarındaki Konumu

Son yirmi yılda fiyat tahmini için istatistiksel ve yapay zeka teknikleri gibi çeşitli yöntemler kullanılmıştır. Burada, çok değişkenli zaman serisi veya literatürdeki imi ile "multivariate time series" tahminiyle uğraşıyoruz. YMF uzay-zamansal veri serilerini kullanmak, birbiriyle ilişkili çoklu değişkenlerin zaman içinde gelecekteki değerlerini tahmin etmeyi gerektirir [61].

Makine öğrenimi, verileri analiz etmek ve bu verilere dayalı olarak tahminlerde bulunmak veya kararlar almak için algoritmaların kullanıldığı yapay zeka türüdür. Makine öğrenimi yöntemleri genellikle Avrupa elektrik piyasasında talep tahmini yapmak, enerji santrallerinin işletmesini optimize etmek ve yenilenebilir enerji kaynaklarının kullanılabilirliğini öngörmek için kullanılır.


Sinir ağları, insan beyninin yapısı ve işleyişinden esinlenerek geliştirilen bir makine öğrenimi algoritma türüdür. Sinir ağları genellikle Avrupa, Amerika, Avustralya elektrik piyasasında fiyat tahmini yapmak, şebeke işletmesini optimize etmek ve yenilenebilir enerji kaynaklarının kullanılabilirliğini öngörmek için kullanılır.

Karar ağaçları, bir dizi kurala dayalı olarak kararlar veya tahminler yapmak için ağaç benzeri bir modelin kullanıldığı bir makine öğrenimi algoritma türüdür. Karar ağaçları genellikle Avrupa elektrik piyasasında enerji üretimi ve iletiminin zamanlamasını optimize etmek için kullanılır.

Genetik algoritmalar, doğal seçim prensiplerinden esinlenerek geliştirilen bir optimizasyon algoritması türüdür. Genetik algoritmalar genellikle Avrupa, Amerika elektrik piyasasında enerji santrallerinin ve iletim sistemlerinin işletmesini optimize etmek için kullanılır [3, 62, 63].

3.2 Yapay Zeka Metodolojilerinin Genel Adımları

Yapay zeka veya literatürdeki kullanımı ile "artificial intelligence" yöntemlerini kullanarak elektrik piyasası fiyatlarını tahmin etme konusunda dikkate alınması gereken birkaç şey bulunmaktadır.



Şekil 3.1 Yapay zeka kullanarak tahmin etme için izlenecek yol

Veri kalitesi ve miktarı: Yüksek kaliteli iyi seçilmiş verilere sahip olmak önemlidir. Doğru kaynaktan, yeterli sayıda veriyi sağlamak yüksek doğruluklu tahmin yapmanın ilk ve en önemli adımıdır.

Model seçimi: Makine öğrenimi algoritmaları, sinir ağları, karar ağaçları ve genetik algoritmalar gibi birçok farklı yapay zeka modeli bulunmaktadır. Her model türünün güçlü yanlarını ve sınırlamalarını dikkatlice değerlendirmek ve özel tahmin ihtiyaçlarınıza en uygun olanı seçmek önemlidir.

Model eğitimi ve doğrulaması: Verilerinizi bir eğitim seti ve bir test setine bölmek, eğitim setini modele uydurmak ve test setini performansını değerlendirmek için kullanmak önemlidir.

Model yorumlama ve kullanıma alma: Yapay zeka modelinizi eğittikten ve doğruladıktan sonra sonuçları dikkatlice yorumlamak ve modelin uygulamada nasıl kullanılacağını düşünmek önemlidir. Bu, modeli mevcut tahmin sistemlerine entegre etmeyi veya tahminlerini dahil etmek için yeni süreçler geliştirmeyi

gerektirebilir.

Veri ön işleme: Verilerinizi modele uygun bir formatta olduğundan emin olmak için ön işleme yapmak gereklidir. Bu, verileri hataları veya tutarsızlıkları gidermek için temizlemeyi, tüm değişkenlerin aynı ölçekte olduğundan emin olmak için verileri normalize etmeyi ve kategorik değişkenleri sayısal değerlere dönüştürmeyi içerebilir.

Öznitelik (feature) seçimi: Birçok yapay zeka modeli, tahminler yapmak için bir dizi girdi değişkenine veya öz niteliğe dayanır. Modeliniz için en ilgili ve bilgilendirici öz nitelikleri dikkatlice seçmek önemlidir, çünkü çok fazla veya çok az öz nitelik kullanmak performansa olumsuz etki edebilir.

Model performansının değerlendirilmesi: Yapay zeka modelinizin performansını düzenli olarak değerlendirmek, hâlâ doğru ve uygun olduğundan emin olmak önemlidir. Bunun için modelin tahminlerini gerçek piyasa fiyatlarıyla karşılaştırmak ve doğruluk, hassasiyet ve hatırlama gibi temel performans göstergelerini izlemek gerekebilir.

Model güncelleme ve bakım: Modelin düzgün çalışmaya devam etmesi için düzenli olarak güncellenmesi ve bakımı yapmak önemlidir. Bu, yeni verilerle modeli yeniden eğitmeyi veya mimarisini ve parametrelerini değiştirmeyi içerebilir [62, 64].

3.3 Yaygın Metodlar

Aşağıdaki bölümde yaygın olarak kullanılan bazı makine öğrenmesi ve derin öğrenme yöntemleri kısaca açıklanmıştır. Bu yöntemlerin mimari yapısında sıkça kullanılan bazı terimleri için kısa açıklamalar yapılabilir.

Katman (layer), yapay sinir ağındaki bölümler olarak açıklanabilir. Veriye uygulanan işlemleri temsil eder. **Grup boyutu (batch size),** bir grupta bulunan örneklerin sayısını belirtir. Örneğin, bu değeri 64 olarak seçersek, her bir adımda 64 eğitim örneği aynı anda işlenir. **Grup boyutu,** eğitim süresini ve bellek kullanımını etkiler. Veri setini birden fazla parçaya bölmek ve her bir parçayı bir batch olarak adlandırmak, eğitim sürecini daha verimli hale getirir diyebiliriz. **Öğrenme oranı (learning rate)** ise, kullandığınız modelde denklemdeki ağırlıkların güncellenme hızını kontrol eden bir hiperparametredir. Eğitim sırasında, öğrenme oranı ağırlıkların her adımda ne kadar değiştirileceğini belirler. Büyük seçmek ise performansı negatif etkiler. **Epoch sayısı,** eğitim sürecinde veri setinin kaç kez

tamamen model tarafından işlendiğini ifade eder. Örneğin, bir modelin eğitimi sırasında 300 epoch kullanıldığında, veri seti 300 kez tamamen model tarafından geçilir ve ağırlık güncellemeleri yapılır [65].

Tahmin (forecast), geçmiş verilerin analizine dayanarak gelecekteki bir zaman adımıdaki değeri tahmin etmek için kullanılır. Geriye bakış (lookback), var olan zaman adımıdan geriye doğru kaç adımlık geçmiş veriye bakılması gerektiğini belirtir. Özellikler (feature), tahmin yapmak için kullanılan girdi verileridir [66].

Tekrarlayan Sinir Ağları: Tekrarlayan sinir ağları (Recurrent Neural Networks-RNN) tabanlı derin öğrenme, sıralı verileri işlemek için tasarlanmış bir sinir ağı mimarisidir. Özellikle zaman serisi tahmini ve doğal dil işleme gibi görevlerde kullanılır, çünkü verilerin sıralaması ve bağımlılıkları önemlidir. RNN'ler önceki zaman adımlarından bilgiyi korumalarını sağlayan geri besleme bağlantılarına sahiptir, bu da zaman içindeki bağlantıları yakalamak için uygundur [63, 67–69].

Uzun Kısa Dönem Bellek: Uzun Kısa Dönem Bellek (Long Short-Term Memory-LSTM), kaybolan gradyan sorununu çözmek için bir hafıza hücresi ve farklı kapılardan (giriş, unutma ve çıkış kapıları) oluşan bir RNN türüdür. Hafıza hücresi, LSTM'nin uzun süreli bağımlılıkları seçici olarak korumasına veya unutmasına olanak tanır, bu da uzun vadeli bağımlılıkları yakalamak için daha yetenekli hale getirir. LSTM, konuşma tanıma, dil çevirisi gibi uzun mesafeli bağımlılıkları içeren görevlerde yaygın olarak kullanılmaktadır [70, 71].

Kapılı Tekrarlayan Birimler: Kapılı Tekrarlayan Birimler (Gated Recurrent Units-GRUs), LSTM ile benzer olan, ancak basitleştirilmiş bir mimariye sahip başka bir RNN türüdür. GRU'lar da bilginin akışını kontrol etmek ve seçici olarak güncellemek veya unutmak için kapılar kullanır. Bununla birlikte, GRU'ların daha az kapıya sahip basitleştirilmiş bir yapıya sahip olmaları, hesaplama açısından daha verimli olmalarını sağlar. GRU'lar, bellek verimliliğinin önemli olduğu senaryolarda yaygın olarak kullanılır [70, 72, 73].

K-Ortalamalar: K-Ortalamalar (K-Means), benzer veri noktalarını önceden belirlenmiş bir sayıda kümeye gruplayan popüler bir kümeleme algoritmasıdır. Çalışma prensibi, veri noktalarını en yakın küme merkezine atamak ve atanan noktaların ortalamasına dayanarak merkezleri güncellemektir. K-Ortalamalar, müşteri segmentasyonu, görüntü sıkıştırma ve anormallik tespiti gibi çeşitli uygulamalarda yaygın olarak kullanılır [74–77].

XGBoost: XGBoost, gradyan artırma çerçevesiyle bilinen güçlü bir makine

öğrenmesi algoritmasıdır. Çeşitli veri türleriyle başa çıkmak üzere tasarlanmıştır ve birçok makine öğrenmesi yarışmasında başarılı olmuştur. XGBoost, zayıf tahmin modellerini (karar ağaçları) birleştirir ve bir kayıp fonksiyonunu en aza indirgeyerek performanslarını aşamalı olarak iyileştirir. Değişkenlerin birbirine bağımlılığı, sınıflandırma ve sıralama gibi görevlerde yaygın olarak kullanılır [78].

K En Yakın Komşu: K en yakın komşu (K Nearest Neighbors-KNN) olarak da bilinen bir makine öğrenmesi algoritmasıdır. Bu algoritma, yeni bir veri noktasını tahmin etmek için etrafındaki en yakın komşuların etiketlerine dayanır. KNN, basit bir mantığa sahiptir: bir veri noktasının sınıfını belirlemek için o noktanın en yakın komşularının sınıflarına bakar. Komşuluk ilişkisi genellikle Euclidean veya Manhattan mesafesi gibi bir uzaklık ölçütü kullanılarak belirlenir. KNN, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan basit ama etkili bir algoritmadır [78, 79].

Diğer: Açıkça belirtilmeyen diğer makine öğrenmesi algoritmaları ve derin öğrenme teknikleri anlamına gelir. Bu, destek vektör makineleri (Support Vector Machine-SVM), doğrusal regresyon gibi geniş bir yöntem yelpazesini içerebilir [77]. Bu algoritmaların seçimi, görevin özel gereksinimlerine ve verilerin özelliklerine bağlıdır.

3.4 Kontrol Metodları

Aşağıdaki denklemler tahminlemeler için kayıp fonksiyonlar olarak açıklanabilir. Burada n tahmin edilen ve gerçek değerlerin toplam sayısı, y_i gerçek değer, $\hat{y}_i$ tahmin edilen değer ve $\hat{y}$ gerçek değerlerin ortalamasıdır. Kayıp fonksiyonu değeri daha küçük olduğunda, model daha iyi performans gösterir, bu da tahmin edilen değerlerin gerçek değerlere daha yakın olduğunu gösterir [67].

3.4.1 Ortak Mutlak Hata

Ortak Mutlak Hata (Mean Absolute Error-MAE), tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasını ifade eden bir hata metriğidir. Bu hata ölçütü, tahmin modelinin doğruluğunu değerlendirmek ve hata miktarını anlamak için kullanılabilir [80].

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

3.4.2 Kök Ortalama Kare Hata

Kök Ortalama Kare Hata (Root Mean Square Error-RMSE), bir tahmin modelinin gerçek değerlerle uyumluluğunu değerlendirmek için sıkça kullanılan bir hata metriğidir, özellikle regresyon problemlerinde tercih edilir. RMSE, hataların karelerinin kullanılmasıyla pozitif ve negatif hataların dengelenmesini sağlar [80].

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

3.4.3 Determinasyon Katsayısı

Determinasyon katsayısı (Coefficient of Determination, R-Squared), bir regresyon modelinin veriye ne kadar iyi uyarlandığını ölçen istatistiksel bir ölçüdür [81].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.3)$$

3.5 Zaman Serileri

3.5.1 Çok Değişkenli ve Tek Değişkenli Zaman Serileri

Çok değişkenli ve tek değişkenli zaman serileri, zamanla değişen verilerin istatistiksel analizidir. Bu analiz, geçmiş verilere dayanarak gelecekteki değerleri tahmin etmeyi amaçlar.

Tek değişkenli zaman serileri, yalnızca bir değişkenin zaman içinde; çok değişkenli zaman serileri ise birden fazla değişkenin zaman içindeki değerlerinin incelendiği analizlerdir. Bu değişkenler arasında birbirleriyle ilişkili olan veya birbiri üzerinde etkisi bulunan değişkenler yer alabilir [82].


4 TASARIM SÜRECİ

4.1 MISO Enerji Piyasası Veri Setlerini Oluşturma

4.1.1 İleriye Dönük 24 Saat Tahminlemesi Veri Seti

YMF veya LMP verileri, MISO'nun kendi sitesinden açık kaynak olarak elde edilmiştir. 2018/2019 (pandemiden önce), 2020 (pandemi dönemi) ve 2021 (pandemiden sonra) için "Tarihsel Yıllık Gerçek Zamanlı LMP'ler" veri seti olarak kullanılmıştır.

Önerilen tahmin modelinde, hem tek değişkenli (2018/19*, 2020*, 2021* olarak gösterilmiştir.) hem de çok değişkenli (2018/19, 2020, 2021 olarak gösterilmiştir.) tahminler için aynı mimari değerleri kullanır. LSTM modelinin mimari detayları Şekil 4.1'te gösterilmiştir.



Şekil 4.1 LSTM tahmin modelinin genel akış şeması

Veri setinden eksik değerler çıkarılmıştır.

Veri seti, MISO'dan toplanan 2018 için 388 Yük Bölgesi, 2019 için 391, 2020

için 393 ve 2021 için 406 "Yük Bölgesi" (Load Zone) içermektedir. Bu bölgelerin 365'i tüm yıllar için ortak olan ve kesişim bölgeleri olarak adlandırılan bölgelerdir. Bu kesişim bölgelerinden elde edilen veriler birleştirilerek ortak bir veri seti oluşturulmuştur.

Bu ortak veri setinden ilk 30 "Yük Bölgesi" örneği ileri analiz için seçilmiştir. İlk yük bölgesi "hedef bölge" (target zone) olarak seçilmiş olup, geri kalan 29 bölge "özellik" (feature) olarak adlandırılabilir. MISO enerji piyasasına ait kullanılan verinin veri seti örneğinden kesit Tablo 4.1'de gösterilmiştir.

Tablo 4.1 MISO Enerji Piyasası Veri Seti Örnek Kesiti

	AECI. ALTW	AECI. AMMO	AECI. CWLD	ALTE. ALTE	ALTW. ALTW	ALTW. BEPM. CBLD	ALTW. CMMPA. MTL	...
0	33.56	29.56	28.27	29.53	29.72	27.52	27.9	...
1	38.17	29.17	27.83	29.17	31.86	27.02	27.15	...
2	33.23	27.66	26.44	27.42	28.66	25.49	25.7	...
3	31.84	28.34	27.11	28.0	28.3	26.29	26.79	...
4	33.32	29.04	27.81	28.62	29.37	26.95	27.65	...
...	...	...	...	...	...	...	...	...

Her yıl, verilerin son yedi günü seçilerek toplamda 168 saat (7 x 24) oluşturulmuştur ve grafiklerde bu kısım sergilenmiştir.

Çalışma, 2019/18, 2020 ve 2021 değerleri için çok değişkenli (multivariate) bir tahmin modeli sunmaktadır ve aynı zamanda 2019/18*, 2020* ve 2021* için tek değişkenli (univariate) tahminleri de içermektedir. Özellikle, univariate tahminler için yalnızca bir özellik değeri girişi olarak LSTM fonksiyonu kullanılmıştır.

Modeli eğitmek için Python 3.8 ile Google Colab, derin öğrenme platformu olarak Keras ve temel çerçeve olarak TensorFlow kullanılmıştır.

En iyi parametreleri elde etmek için Scikit-Learn'den random grid search yöntemi kullanılmıştır.

Veri seti ile tahminleme yapılırken Adam optimizasyon yöntemi kullanılmıştır. Adam optimizasyonunun amacı, LSTM sinir ağlarında hata değerlerini en aza indiren optimal ağırlık kümesini belirlemektir.

Çok değişkenli ağ, lookback=24, features=30, forecast=6 için eğitilmiştir. İlk oran, epoch ve grup boyutu değerleri, verilerin yıllar boyunca değişimdeki farklılıklar nedeniyle optimize edilmeye çalışılmıştır.

4.1.2 Çok Değişkenli ve Tek Değişkenli Veri Setleri Farkı

Önerilen tahmin modeli, hem tek değişkenli (2018/19*, 2020*, 2021*) hem de çok değişkenli (2018/19, 2020, 2021) tahminler için aynı mimari değerleri kullanır. LSTM modelinin mimari detayları Tablo 4.8’de gösterilmiştir.

Çalışma, 2019/18, 2020 ve 2021 değerleri için çok değişkenli bir tahmin modeli sunmaktadır ve aynı zamanda 2019/18*, 2020* ve 2021* için tek değişkenli tahminleri de içermektedir.

Tablo 4.2 Optimizasyon için çoklu ve tek değişkenli veri setlerinin tahminlenmesinde kullanılan parametre değerleri

	2018/19	2020	2021
LSTM Layer 1	256	256	128
LSTM Layer 2	128	128	64
LSTM Layer 3	64	64	32
LSTM Layer 4	32	32	-
Learning Rate	0.001	0.001	0.001
Batch Size	128	64	64
Epoch	450	350	375

4.2 PJM Enerji Piyasası Veri Setlerini Oluşturma

4.2.1 İleriye Dönük 24 Saat Tahminlemesi Veri Seti

LMP Verileri, PJM’in kendi sitesinden açık kaynaklı olarak elde edilmiştir. “Saatlik Gerçek Zamanlı LMP Veri Seti” 2022 Haziran ile 2023 Haziran zaman dilimi seçilerek sistemden alınmıştır.

Veri seti, PJM’den toplanan 2022 1 Haziran-2023 1 Haziran için 12 yük bölgesi içermektedir.

Bu veri setinden 12 yük bölgesi örneği ileri analiz için seçilmiştir. İlk yük bölgesi "hedef bölge"(target hub) olarak seçilmiş olup, geri kalan 11 bölge "özellik"(feature) olarak adlandırılabilir.

Veri seti ile tahminleme yapılırken Adam optimizasyon yöntemi kullanılmıştır. Adam optimizasyonunun amacı, sinir ağlarında hata değerlerini en aza indiren optimal ağırlık kümesini belirlemektir.

Çok değişkenli ağ, lookback=11, features=12, forecast=1 için eğitilmiştir. İlk oran, epoch ve grup boyutu değerleri, verilerin yıllar boyunca değişimindeki farklılıklar nedeniyle optimize edilmeye çalışılmıştır. GRUs* olarak gösterilen kısım, GRUs’un mimari detaylarında güncelleme ile optimize edilmiş halidir.

Tablo 4.3 PJM Enerji Piyasası Veri Seti Kesiti

	AEP GEN HUB	AEP- DAYTON HUB	ATSI GEN HUB	CHICAGO GEN HUB	CHICAGO HUB	DOMINION HUB	...
0	66.5	68.1	67.3	65.6	66.7	69.5	...
1	74.0	75.5	74.7	72.7	73.8	77.4	...
2	55.9	57.0	56.6	54.8	55.6	58.4	...
3	52.1	53.1	52.7	51.1	51.8	54.3	...
4	51.8	52.4	51.8	49.4	50.0	53.7	...
...	...	...	...	...	...	...	...
8780	40.4	41.8	41.3	40.9	41.5	40.9	...
8781	36.5	37.7	37.0	36.8	37.3	37.2	...
8782	26.0	26.9	26.1	26.4	26.8	26.9	...
8783	22.4	23.1	22.3	22.6	22.9	22.9	...
8784	17.7	18.1	17.6	16.5	16.8	18.2	...

Tablo 4.3’de PJM veri seti LSTM için optimize edilmiştir, aynı değerlerle GRU derin öğrenme çalıştırılmıştır, GRU* ile de GRU için optimizasyon değerleri belirtilmiştir. Tüm çalışmaların mimari değerleri Tablo 4.10 içerisinde yer almaktadır.

Tablo 4.4 Optimizasyon için mimarideki LSTM ve GRU parametreleri

	2022/23	2022/23	2022/23
	LSTM	GRU	GRU*
LSTM Layer 1	64	-	-
LSTM Layer 2	-	-	-
GRU Layer 1	-	64	64
GRU Layer 1	-	-	-
Learning Rate	0.001	0.001	0.001
Batch Size	64	64	256
Epoch	300	300	500

4.2.2 K-Ortalamlar Veri Seti

Bu çalışmada yapılacak kümeleme, scikit-learn kütüphanesinin K-Ortalamlar (K-Means) uygulaması ve varsayılan ayar ve parametreleri kullanılarak yapılmıştır. Veri seti 2-24 arasındaki k değerleri kullanılarak kümelere ayrılmıştır. Detaylar Tablo 4.5 4.6 ve 4.7’de belirtilmiştir.

Kümeleme neticesinde oluşan küme setlerinde k değeri yükseldikçe beklendiği gibi bazı kümeler çok az sayıda ve derin öğrenme modeli geliştirmek için yeterli olmayacak seviyede eleman içerdiği gözlemlenmiştir. Geliştirilecek alt modellerin sayısını artırmamak ve eleman sayısı yüksek bir ana küme elde edebilmek

Tablo 4.5 Veri setine kümeleme yapılması sonucu küme-örnek dağılımları (k=2 ile k=6 aralığı)

Küme\k	6	5	4	3	2
0	4820	6696	6966	1695	8768
1	9	9	9	17	17
2	912	24	1798	7073	
3	10	2046	12		
4	3010	10			
5	24				


Tablo 4.6 Veri setine kümeleme yapılması sonucu küme-örnek dağılımları (k=7 ile k=15 aralığı)

Küme\k	15	14	13	12	11	10	9	8	7
0	3633	3729	1429	3728	2867	4041	2911	2928	2969
1	6	6	6	1	4	7	6	7	3
2	56	66	19	7	6	405	6	9	8
3	6	6	4	1396	4106	7	328	1341	8
4	739	1394	3621	5	75	2841	1321	20	858
5	2622	2744	212	2743	1341	5	4186	4148	20
6	2	2	6	4	4	2	3	329	4919
7	8	10	2654	18	357	1382	19	3	
8	12	12	759	152	1	20	5		
9	69	152	1	4	19	75			
10	4	4	71	69	5				
11	233	658	2	658					
12	1	1	1						
13	1	1							
14	1393								

amacıyla k=5 değeri için oluşan küme seti çalışmanın devamında kullanılmak üzere seçilmiştir.

Kümelemede ön işlem adımları özetlenecek olursa k=5 küme seti, 6696 elemanlı Küme 0 ve kalan kümeleri (Küme 1,2,3,4) ve 2089 elemanı içerecek şekilde ikiye bölünmüştür. Az sayıda elemanı olan kümeler ikinci büyük küme olan Küme 3'e dahil edilmiş ve bu iki ana küme için LSTM modeli geliştirilmiştir. Veri setini oluşturan 11 lokasyona ait verilerin kümelere dağılımını incelemek üzere rasgele seçilmiş üçlü kombinasyonları, şekildeki gibi üç-boyutlu dağılımlar şeklinde görselleştirilmiştir. Dağılımlarda görüldüğü gibi k-ortalamlar algoritması alt kümeleri LMP, diğer bir deyişle YMF değerlerinin ölçeğine göre gerçekleştirmiştir.

En kalabalık küme (Küme 0) üç-boyutlu dağılımlarda en küçük hacmi işgal etmektedir. Diğer kümeler ise bu dağılımlarda daha iyi gözlemlenebilmektedir.



Şekil 4.2 $k=5$ kümeleme neticesinde kümelerin 3 boyutlu dağılımı (Rasgele seçilmiş dört adet üçlü kombinasyon örneği gösterilmiştir.)


Tablo 4.7 Veri setine kümeleme yapılması sonucu küme-örnek dağılımları (k=16 ile k=24 aralığı)

Küme\k	24	23	22	21	20	19	18	17	16
0	1802	1091	2287	2192	3	2918	1851	3184	3455
1	2	2	2	2	1889	4	4	4	3
2	2	3	169	1090	2	261	109	1016	5
3	174	2350	1	4	197	4	5	4	2477
4	4	33	2	8	1	2227	1	1663	1479
5	816	225	432	1	1126	4	697	3	11
6	2304	1	9	167	11	101	2461	13	1
7	2	4	2	2	4	1	2	1	350
8	4	83	3225	1842	4	1	8	454	1
9	2	1	4	4	714	55	367	1	9
10	2	1825	64	1	2414	1806	4	109	1
11	1	2	1598	1	1	1	11	1	4
12	26	9	2	53	55	9	5	6	49
13	71	282	4	4	2	12	1092	5	63
14	377	1	11	3	8	3	64	3	873
15	7	2	2	2829	43	3	1	2258	4
16	2	4	53	9	3	1069	2	60	
17	1100	2	2	3	2112	304	2101		
18	10	3	1	2	1	2			
19	1	9	613	498	195				
20	2033	37	3	70					
21	3	2038	299						
22	2	778							
23	38								


Küçük ölçekteki verileri daha iyi görselleştirebilmek için bu sefer rasgele seçilmiş 2'li kombinasyon 4 adet iki-boyutlu dağılım eksenler logaritmik skalada olacak şekilde görselleştirilmiştir.

k=5 küme seti logaritmik skalada incelendiğinde, 6696 elemanlı Küme 0'ın küçük ölçekteki değerleri içerdiği ve kalan kümelerin (Küme 1,2,3,4) daha büyük ölçekteki verileri içerdiği gözlemlenebilmektedir. Logaritmik skalada yapılan görselleştirmelerde Küme 0 ve Küme 3 arasındaki ayrım belirsiz gibi görünse de geçiş ayrımı ölçek farkı düşünüldüğünde nettir.


Kümeleme sonuçları neticesinde LSTM modeli geliştirilirken Küme 0 ve kalan kümeler şeklinde oluşturulan iki ana küme kullanılmıştır. En büyük küme 6696 örnek ve ikinci küme 2089 örnekten oluşmaktadır. LSTM modelinin geliştirilmesi sırasında veri setinin yeterli ölçüde büyük olabilmesi için ikinci küme Küme 3 ve dışında kalan küçük kümelerden oluşturulmuştur.




Şekil 4.3 $k=5$ kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş birinci ikili kombinasyon)



Şekil 4.4 $k=5$ kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş ikinci ikili kombinasyon)



Şekil 4.5 $k=5$ kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş üçüncü ikili kombinasyon)



Şekil 4.6 $k=5$ kümeleme neticesinde kümelerin 2 boyutlu dağılımı, logaritmik eksenler (rasgele seçilmiş dördüncü ikili kombinasyon)

Kümeleme çalışmasının etkisinin değerlendirilebilmesi için LSTM modeli eğitilirken kullanılan parametreler sabit tutulmuştur.

4.3 MISO, PJM ve New England Enerji Piyasası Veri Setlerini Oluşturma

YMF veya LMP verileri, MISO'nun, PJM'in ve New England'ın kendi sitesinden açık kaynaklı olarak elde edilmiştir. 2022 1 Haziran, 2023 1 Haziran arası "Gerçek Zamanlı YMF Veri Setleri" tercih edilmiştir.

Veri setleri LSTM ve GRU için ayrı ayrı işlem görmüştür. Bu veri setlerinden 12 yük bölgesi örneği ileri analiz için seçilmiştir. İlk yük bölgesi "hedef bölge"(target hub) olarak seçilmiş olup, geri kalan 11 bölge "özellik"(feature) olarak adlandırılabilir. Çok değişkenli ağ, lookback=11, features=12, forecast=1 için eğitilmiştir. İlk oran, epoch ve grup boyutu değerleri, verilerin yıl içindeki değişimindeki farklılıklar, veri setlerinin tamamen birbirinden farklı oluşu ve farklı bölgelerden elde edilen değerler olması nedeniyle optimize edilmeye çalışılmıştır.

4.3.1 MISO İleriye Dönük 24 Saat Tahminlemesi Veri Seti

2022 1 Haziran, 2023 1 Haziran arası "MISO Gerçek Zamanlı YMF Veri Seti" açık kaynaklı olarak edinildikten sonra veri setini düzenlemek ve modeli eğitmek için Python 3.8 ile Google Colab, derin öğrenme platformu olarak Keras ve temel çerçeve olarak TensorFlow kullanılmıştır. En iyi parametreleri elde etmek için Scikit-Learn'den random grid search yöntemi kullanılmıştır.

Tablo 4.8 MISO 2022-2023 Haziran optimizasyon için mimarideki LSTM ve GRU parametreler

	LSTM	GRU
LSTM Layer 1	128	-
LSTM Layer 2	64	-
GRU Layer 1	-	128
GRU Layer 2	-	64
Learning Rate	0.001	0.001
Batch Size	128	128
Epoch	300	300

4.3.2 PJM İleriye Dönük 24 Saat Tahminlemesi Veri Seti

2022 1 Haziran, 2023 1 Haziran arası "PJM Gerçek Zamanlı YMF Veri Seti" açık kaynaklı olarak edinildikten sonra veri setini düzenlemek ve modeli eğitmek için Python 3.8 ile Google Colab, derin öğrenme platformu olarak Keras ve temel çerçeve olarak TensorFlow kullanılmıştır. En iyi parametreleri elde etmek için Scikit-Learn'den random grid search yöntemi kullanılmıştır.

Tablo 4.9 PJM 2022-2023 Haziran optimizasyon için mimarideki LSTM ve GRU parametreler

	2022/23	2022/23
	LSTM	GRU*
LSTM Layer 1	64	-
GRU Layer 1	-	64
Learning Rate	0.001	0.001
Batch Size	64	256
Epoch	300	500

4.3.3 New England İleriye Dönük 24 Saat Tahminlemesi Veri Seti

2022 1 Haziran, 2023 1 Haziran arası "New England Gerçek Zamanlı YMF Veri Seti" açık kaynaklı olarak edinildikten sonra veri setini düzenlemek ve modeli eğitmek için Python 3.8 ile Google Colab, derin öğrenme platformu olarak Keras ve temel çerçeve olarak TensorFlow kullanılmıştır. En iyi parametreleri elde etmek için Scikit-Learn'den random grid search yöntemi kullanılmıştır.

Bu tezde veri setleri kullanılan üç büyük enerji şirketi olan MISO, PJM ve New England'ın internet sitelerinde açık kaynaklı olarak paylaştıkları YMF veya literatürdeki ismiyle "Locational Marginal Pricing" verilerinin klasik makine öğrenmesi ve derin öğrenme teknikleriyle 24 saat ilerisi için uygun tahminleme ve kümeleme yöntemlerinden yararlanılmıştır. MISO Amerika'nın 15 eyaletin yanı sıra Ontario, Kanada'nın bir kısmını da içerir. PJM Amerika'nın doğusunda

Tablo 4.10 New England 2022-2023 Haziran optimizasyon için mimarideki LSTM ve GRU parametreler

	2022/23	2022/23
	LSTM	GRU*
LSTM Layer 1	64	-
LSTM Layer 2	64	-
GRU Layer 1	-	128
GRU Layer 2	-	64
GRU Layer 3	-	64
Learning Rate	0.001	0.001
Batch Size	128	64
Epoch	400	450

13 eyaleti ve Columbia Bölgesi'ni (Washington, DC) kapsar. ISO New England ise Amerika'nın kuzeydoğu bölgesinde bulunan 6 eyaleti kapsar. Bu kadar geniş coğrafyada bulunan bu etkili şirketlerin verileriyle umut vaad eden ve başarılı makine öğrenmesi yöntemleri denemeleri gerçekleştirilmiştir.

5

TAHMİNLEME SÜRECİ


5.1 MISO Enerji Piyasası Verileriyle Tahminleme

5.1.1 İleriye Dönük 24 Saat Tahminlemesi

MISO Enerji piyasası verileriyle yapılan tahminlemelerle ilgili tüm kodlar github [83] hesabında ulaşılabilir olarak verilmiştir. LMP'nin birimi, ($\$/MWh$) olarak verilmiştir. Zaman birimi saat olarak seçilmiştir. 2018/19*, 2020*, 2021* değerleri o yıllara ait tek değişkenli tahmin sonuçlarını belirtirken; 2018/19, 2020, 2021 değerleri o yıllara ait çok değişkenli tahmin değerlerini temsil eder.


Tablo 5.1 MISO performans metriklerinin değerlendirilmesi

	2018/19*	2018/19	2020*	2020	2021*	2021
<i>MAE</i>	9.54	7.83	7.22	5.57	13.75	11.81
<i>RMSE</i>	24.58	19.52	16.21	11.66	30.96	25.17
<i>R²</i>	0.58	0.73	0.46	0.72	0.32	0.56




Şekil 5.1 MISO LSTM 2018/19 için 24 saat ilerisi için tahminlerin grafikleri

MISO'dan alınan veri seti ile 2018/19 yılı için 24 saat ileriye yönelik tahminlerin grafiği görselleştirilmiştir.




Şekil 5.2 MISO LSTM 2020 için 24 saat ilerisi için tahminlerin grafikleri

MISO'dan alınan veri seti ile 2020 yılı için 24 saat ileriye yönelik tahminlerin grafiği görselleştirilmiştir.




Şekil 5.3 MISO LSTM 2021 için 24 saat ilerisi için tahminlerin grafikleri

MISO'dan alınan veri seti ile 2021 yılı için 24 saat ileriye yönelik tahminlerin grafiği görselleştirilmiştir.




Şekil 5.4 MISO LSTM 2018/19, 2020 ve 2021 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.




Şekil 5.5 MISO LSTM 2018/19, ve 2020 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.

LSTM-MISO 2018, 2021 24 Saat İlerisi İçin Tahmin Grafiği



Şekil 5.6 MISO LSTM 2018/19, ve 2021 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.


LSTM-MISO 2020, 2021 24 Saat İlerisi İçin Tahmin Grafiği




Şekil 5.7 MISO LSTM 2020 ve 2021 için 24 saat ilerisi için tahminlerin grafiksel karşılaştırması.

5.1.2 Çok Değişkenli ve Tek Değişkenli Tahminleme


Bu bölümde tahmin fonksiyonuna tek değişken verilerek ve çok değişken verilerek MISO veri seti kullanılmasıyla elde edilen tahminlerin grafiklerine yer verilmiştir. 24 saat ilerisi için tahminlerin grafiksel karşılaştırması 2018/19, 2020, 2021 (çok değişkenli) ve 2018/19*, 2020*, 2021* için (tek değişkenli) olmak üzere ifade edilmiştir.



Şekil 5.8 MISO LSTM 2018/19 yılları için 24 saat ilerisi tahminlerinin grafiksel karşılaştırması çok değişkenli 2018/19 vs. tek değişkenli 2018/19*.



Şekil 5.9 MISO LSTM 2020 yılı için 24 saat ilerisi tahminlerinin grafiksel karşılaştırması çok değişkenli 2020 vs. tek değişkenli 2020*.



Şekil 5.10 MISO LSTM 2021 yılı için 24 saat ilerisi tahminlerinin grafiksel karşılaştırması çok değişkenli 2021 vs. tek değişkenli 2021*.

5.2 PJM Enerji Piyasası Verileriyle Tahminleme

5.2.1 LSTM İleriye Dönük 24 Saat Tahminlemesi

PJM Enerji piyasası verileriyle yapılan tahminlemelerle ilgili tüm kodlar github hesabında ulaşılabilir olarak verilmiştir. YMF'nin birimi, (\$/MWh) olarak verilmiştir. Zaman birimi saat olarak seçilmiştir. Veri seti LSTM mimari parametreleriyle tahmin sırasında optimize edilmiştir. LSTM optimizasyon ayarlarıyla birebir değerler GRUs için de çalıştırılmıştır ve karşılaştırılmıştır. GRUs için ayrıca optimizasyon yapılmıştır ve GRUs* olarak gösterilmiştir. Aşağıdaki şekillerde LSTM ile PJM veri setinin tahminlemesi tüm test seti için, 30 günlük, 5 günlük ve 1 günlük olarak grafiklerle gösterilmiştir.


Tablo 5.2 PJM LSTM Performans metriklerinin değerlendirilmesi

	2022/23 LSTM
MAE	12.96
$RMSE$	56.73
R^2	0.75


İlerleyen bölümlerde burada elde edilen değerler ile GRUs derin öğrenme metodolojisi karşılaştırılmıştır.

5.2.2 K-Means (K-Ortalamalar) ile Veri Kümelemesi

Bu bölümde PJM YMF datası ile tahminleme yapmak için geliştirilen LSTM performansını iyileştirmek amacıyla kümeleme (clustering) çalışması yapılmıştır.




Şekil 5.11 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, tüm test seti




Şekil 5.12 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.13 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



Şekil 5.14 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti

PJM verisinden ayıklanmış saatlik çözünürlükte sağlanmış 12 farklı konumun LMP değerleri, 11 konumun verisi ile 12. konumun verisinin tahminlenmesi amacıyla geliştirilen LSTM modelinde elde edilen performans metrikleri aşağıdaki gibi baz alınmıştır.

Tablo 5.3 PJM K-Means kümelemede baz alınan performans değerleri

	2022/23 LSTM
<i>MAE</i>	12.96
<i>RMSE</i>	56.73
<i>R²</i>	0.75

Veri setine k-Ortalamlar ön işleme (clustering) yapılmasındaki asıl motivasyon veri setinin kümelerle ayrılabilir, kümelerin yapısı incelenmiştir. Bu makine öğrenmesi yöntemi ile alt küme setlerinden $k = 5$ olan seçilerek LSTM modelinin geliştirilmesi için seçilmiştir. Asıl veri seti ile yapılan sonuçlar ile k-means yönteminin uygulanmasıyla elde edilen performans kıyaslanmıştır ve sonuçlar değerlendirilmiştir.


K-Ortalamlar, kümeleme algoritması olarak basit ve hızlı uygulanabilirlik, ölçeklenebilirlik (büyük verilerle çalışmaya uygunluk), güncel kütüphanelerde hazır fonksiyonların bulunması gibi sebeplerle seçilmiştir.

Bu algoritma, verileri k adet küme halinde gruplamak için kullanılan bir yöntemdir. İlk olarak, rastgele k merkez nokta seçilir ve veri noktaları bu merkezlere en yakın olanlara atanır. Ardından, merkez noktalar güncellenir ve bu işlem tekrarlanarak kümeleme gerçekleştirilir. Algoritma, verileri homojen kümeler halinde gruplamak ve grupları ortaya çıkarmak için kullanılır.


Bu çalışmada yapılacak kümeleme, scikit-learn kütüphanesinin k-Ortalamlar uygulaması ve varsayılan ayar ve parametreleri kullanılarak yapılmıştır. Veri seti 2-24 arasındaki k değerleri kullanılarak kümelerle ayrılmıştır. Detaylar Tablo 4.5, 4.6 ve 4.7’te belirtilmiştir.

Kümeleme çalışmasının etkisinin değerlendirilebilmesi için LSTM modeli eğitilirken kullanılan parametreler sabit tutulmuştur.


Model eğitimleri neticesinde kümeleme yapılmadığı durumla kıyaslandığında küçük ölçekteki datalardan oluşan en büyük küme ile eğitilen modelde eğitim ve validasyon kayıplarının diğer iki duruma göre birbirine daha yakın seyrettiği gözlemlenmiştir. Bu durum en büyük küme ile eğitilen modelin tüm set ile eğitilen modele göre daha kararlı davranacağı şeklinde yorumlanabilir.



Şekil 5.15 Tüm veri seti ile LSTM modeli eğitimi boyunca eğitim ve doğrulama kayıplarının değişimi



Şekil 5.16 k=5 kümeleme neticesinde en büyük küme ile oluşturulan veri seti ile LSTM modeli eğitimi boyunca eğitim ve doğrulama kayıplarının değişimi




Şekil 5.17 $k=5$ kümeleme neticesinde en büyük küme dışında kalan kümelerden oluşturulan veri seti ile LSTM modeli eğitimi boyunca eğitim ve doğrulama kayıplarının değişimi


Tablo 5.4 Tüm veri seti ve $k=5$ ile oluşturulan küme seti ile eğitilmiş LSTM modellerinin performans metrikleri

Model	MAE	$RMSE$	R^2
Tüm Veri	12.59	56.73	0.75
k-Ortalamalar, $k=5$ Diğer	34.59	98.44	0.67
k-Ortalamalar, $k=5$ En Büyük	5.15	7.38	0.78


Benzer şekilde LSTM modeli performans metrikleri olarak belirlenen MAE, RMSE ve determinasyon katsayısı değerleri incelendiğinde, en büyük kümenin en düşük hata değerlerine ve en başarılı metriklerle sahip olduğu görülmüştür. R-Squared değeri yapılan k-ortalamalar düzenlemesi ile birlikte ilk durumdaki tüm veri data setine göre determinasyon kat sayısı özelinde %4 başarısını arttırmıştır. MAE ve RMSE değerlerindeki kayda değer keskin düşüş ise yöntemin uygulanmasındaki önemi vurgulamaktadır. Kümeleme sonrası model performanslarını değerlendirmek için test setindeki tahmin değerleri ve örnek olması açısından 5 günlük kısmını temsil eden gerçek değer ve tahminlenen değerler birlikte olacak şekilde grafikler ile verilmiştir.




Şekil 5.18 PJM 2022/2023 Haziran k=5 Tüm Veri Seti Küme Tahmin Grafikleri




Şekil 5.19 PJM 2022/2023 Haziran k=5 Diğer Kümeler Küme Tahmin Grafikleri




Şekil 5.20 PJM 2022/2023 Haziran k=5 En Büyük Küme Tahmin Grafikleri



Şekil 5.21 PJM 2022/2023 Haziran k=5 Tüm veri seti 5 günlük test seti




Şekil 5.22 PJM 2022/2023 Haziran k=5 Diğer Kümeler 5 günlük test seti




Şekil 5.23 PJM 2022/2023 Haziran k=5 En Büyük Küme Tahmin Grafikleri 5 günlük test seti

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği-Diğer




Şekil 5.24 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük-Diğer




Şekil 5.25 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği, 30 Günlük

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük-Diğer




Şekil 5.26 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği, 5 Günlük

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük-Diğer




Şekil 5.27 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan diğer kümelerle eğitilmiş LSTM modeli ile tahmin grafiği, 1 Günlük

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği-En Büyük Küme




Şekil 5.28 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği,30 Günlük-En Büyük Küme




Şekil 5.29 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği, 30 Günlük

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği,5 Günlük-En Büyük Küme



Şekil 5.30 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği, 5 Günlük

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği,1 Günlük-En Büyük Küme



Şekil 5.31 PJM 2022/2023 Haziran k=5 kümeleme neticesinde oluşturulan en büyük kümeyle eğitilmiş LSTM modeli ile tahmin grafiği, 1 Günlük

Tablo 5.5 LSTM için optimize edilmiş LSTM ve GRU parametreleri

	2022/23 LSTM	2022/23 GRU
LSTM Layer 1	64	-
GRU Layer 1	-	64
Learning Rate	0.001	0.001
Batch Size	64	64
Epoch	300	300


5.2.3 GRUs İleriye Dönük 24 Saat Tahminlemesi çalıştırılırsa: LSTM ile kıyaslayabilmek için optimize edilmiş LSTM değerleri ile GRUs

Birebir aynı parametrelerle optimize edilmeye çalışılmış iki farklı RNN yapısı olarak kullanılan LSTM ve GRU methodları LSTM'e göre optimize edilmiş parametre değerleriyle modellenerek tahmin çalışması yapılmıştır. Her iki derin öğrenme modelinde de initial rate değeri = 0.001, batch size = 64, epoch = 300 olarak ayarlanmıştır. GRU ile elde edilen sonuçlarda R-squared değeri LSTM'e göre biraz daha yüksek çıkmıştır.

Tablo 5.6 LSTM için optimize edilmiş LSTM ve GRU tahmin değerleri


	2022/23 LSTM	2022/23 GRU
<i>MAE</i>	12.96	13.76
<i>RMSE</i>	56.73	55.18
<i>R²</i>	0.75	0.77

GRUs (LSTM Parametreleri ile) PJM 2022-2023 Haziran 24 Saat İlerisi Tahmin Grafiği




Şekil 5.32 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, tüm test seti

GRUs (LSTM Parametreleri ile) PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.33 PJM Market LSTM için optimize edilmiş parametrelerle GRU 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti

GRUs (LSTM Parametreleri ile) PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.34 PJM Market LSTM için optimize edilmiş parametrelerle GRU 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti

GRUs (LSTM Parametreleri ile) PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



Şekil 5.35 PJM Market LSTM için optimize edilmiş parametrelerle GRU 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti

Tablo 5.7 k=5 k-Ortalamalar yöntemi ile LSTM'in ilk ve son değerleri

Bu bölümden k=5 seçilerek k-Ortalamalar ile elde edilen değerlere yer verilmiştir.

	2022/23 LSTM başlangıç	2022/23 k-Ortalamalar ile LSTM
<i>MAE</i>	12.96	5.15
<i>RMSE</i>	56.73	7.39
<i>R²</i>	0.75	0.78

5.2.4 Optimize edilmiş GRUs Tahminlemesi

Bu bölümde GRUs* için imari değerler optimize edilmiş ve tekrar çalıştırılmıştır. Determinasyon kat sayısının 0.80 değerine kadar yükseldiği gözlemlenmiştir.


Tablo 5.8 Optimize edilmiş GRUs* parametreleri

	2022/23 GRU
GRU Layer 1	64
Learning Rate	0.001
Batch Size	256
Epoch	500

Tablo 5.9 Optimize edilmiş GRUs* tahmin değerleri


	2022/23 GRU
<i>MAE</i>	13.89
<i>RMSE</i>	50.41
<i>R²</i>	0.80

GRUs* PJM 2022-2023 Haziran 24 Saat İlerisi Tahmin Grafiği




Şekil 5.36 PJM Market optimize GRUs* 2022/2023 24 saat ilerisi için tahmin grafikleri, tüm test seti

GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.37 PJM Market optimize GRUs* 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti

GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.38 PJM Market optimize GRUs* 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti

GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük




Şekil 5.39 PJM Market optimize GRUs* 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti


5.2.5 Kullanılan Derin Öğrenme Yöntemlerinin Karşılaştırması

LSTM için optimum parametrelerle elde edilen tahminleme grafikleri (üstte), GRUs için verilen optimize edilmiş model tahmin grafikleri (altta) yer alacak şekilde grafiklerde verilmiştir.

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük



GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük



Şekil 5.40 PJM Market optimize LSTM (üstte) ve GRUs (altta) 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti


PJM için LSTM, GRU ve GRUs* değerlerinin grafik değerleri değerlendirildikten sonra tablolarda elde edilen sonuçlar topluca gösterilmiştir.

Tablo 5.10 LSTM için optimize edilmiş LSTM ve GRUs* tahmin değerleri


	2022/23 LSTM	2022/23 GRUs*
<i>MAE</i>	12.96	13.89
<i>RMSE</i>	56.73	50.41
<i>R²</i>	0.75	0.80

LSTM için MAE değeri 12.96, RMSE değeri 56.73, R-Squared değeri yani determinasyon kat sayısı ise 0.75 olarak optimum değerlerine ulaştırılmıştır.

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük




GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük




Şekil 5.41 PJM Market optimize LSTM (üstte) ve GRUs (altta) 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



Şekil 5.42 PJM Market optimize LSTM (üstte) ve GRUs (altta) 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti

GRUs* için MAE değeri 13.89, RMSE değeri 50.41, R-Squared değeri yani determinasyon kat sayısı ise 0.80 olarak optimum değerlerine ulaştırılmıştır.

Tablo 5.11 Elde edilmiş GRUs ve GRUs* tahmin değerleri

	2022/23 GRUs	2022/23 GRUs*
<i>MAE</i>	13.76	13.89
<i>RMSE</i>	55.18	50.41
<i>R²</i>	0.77	0.80

GRU için MAE değeri 13.76, RMSE değeri 55.18, R-Squared değeri yani determinasyon kat sayısı ise 0.77 olarak optimum değerlerine ulaştırılmıştır. GRUs* için MAE değeri 13.89, RMSE değeri 50.41, R-Squared değeri yani determinasyon kat sayısı ise 0.80 olarak optimum değerlerine ulaştırılmıştır.

5.3 MISO, PJM ve New England Enerji Piyasası Bir Yıllık Veri Setiyle Tahminleme

5.3.1 MISO İleriye Dönük 24 Saat Tahminlemesi

2022 1 Haziran, 2023 1 Haziran arası "MISO Gerçek Zamanlı YMF Veri Seti" açık kaynaklı olarak edinildikten sonra veri setini düzenlemek ve modeli eğitmek için gerekli çalışmalar yapılmıştır. LMP'nin birimi, ($\$/MWh$) olarak verilmiştir. Zaman birimi saat olarak seçilmiştir.


Tablo 5.12 MISO performans metriklerinin değerlendirilmesi

	LSTM	GRU
<i>MAE</i>	16.20	15.74
<i>RMSE</i>	37.13	41.98
<i>R²</i>	0.57	0.45

MISO şirketinden datalarla 2022'nin Haziran ayından 2023'ün Haziran ayına kadar YMF verilerinin toplanmasıyla elde edilen data set, Colab üzerinden LSTM ve GRU tahminleme için uygun formata getirilmiştir. LSTM için MAE değeri 16.20, RMSE değeri 37.13, R-Squared değeri yani determinasyon kat sayısı ise 0.57 olarak optimum değerlerine ulaştırılmıştır. GRU için MAE değeri 7.83, RMSE değeri 50.41, R-Squared değeri yani determinasyon kat sayısı ise 0.80 olarak optimum değerlerine ulaştırılmıştır.


MISO şirketinden datalarla elde edilen veri seti için LSTM ile tahminleme yapılmıştır. Detaylı gözlemle için 30 günlük, 5 günlük ve 1 günlük grafiklere yer verilmiştir.

LSTM-MISO 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.43 MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti

LSTM-MISO 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.44 MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti


LSTM-MISO 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



Şekil 5.45 MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti

MISO şirketinden datalarla elde edilen veri seti için GRU ile tahminleme yapılmıştır. Detaylı gözlemle için 30 günlük, 5 günlük ve 1 günlük grafiklere yer verilmiştir.

GRUs - MISO 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.46 MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti

5.3.2 PJM İleriye Dönük 24 Saat Tahminlemesi


2022 1 Haziran, 2023 1 Haziran arası "PJM Gerçek Zamanlı YMF Veri Seti" açık kaynaklı olarak edinildikten sonra veri setini düzenlemek ve modeli eğitmek için gerekli çalışmalar yapılmıştır. LMP'nin birimi, ($\$/MWh$) olarak verilmiştir. Zaman birimi saat olarak seçilmiştir.

GRUs - MISO 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.47 MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti

GRUs - MISO 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük




Şekil 5.48 MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti

Tablo 5.13 PJM performans metriklerinin değerlendirilmesi

	LSTM	GRU
MAE	12.96	14.29
$RMSE$	56.73	51.90
R^2	0.75	0.80

PJM şirketinden datalarla 2022'nin Haziran ayından 2023'ün Haziran ayına kadar YMF verilerinin toplanmasıyla elde edilen data set, Colab ile uygun formata getirilmiştir. LSTM için MAE değeri 12.96, RMSE değeri 56.73, R-Squared değeri yani determinasyon kat sayısı ise 0.75 olarak optimum değerlerine ulaştırılmıştır. GRU için MAE değeri 14.29, RMSE değeri 51.90, R-Squared değeri yani determinasyon kat sayısı ise 0.80 olarak optimum değerlerine ulaştırılmıştır. PJM şirketinden datalarla LSTM ile tahminleme yapılmıştır. Detaylı gözlemle için 30 günlük, 5 günlük ve 1 günlük grafiklere yer verilmiştir.

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.49 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti

PJM şirketinden datalarla elde edilen veri seti için LSTM ile tahminleme yapılmıştır. Detaylı gözlemle için 30 günlük, 5 günlük ve 1 günlük grafiklere yer verilmiştir.

5.3.3 New England İleriye Dönük 24 Saat Tahminlemesi


2022 1 Haziran, 2023 1 Haziran arası "New England Gerçek Zamanlı YMF Veri Seti" açık kaynaklı olarak edinildikten sonra veri setini düzenlemek ve modeli eğitmek için gerekli çalışmalar yapılmıştır. LMP'nin birimi, (\$/MWh) olarak verilmiştir. Zaman birimi saat olarak seçilmiştir.

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük




Şekil 5.50 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti

LSTM-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük




Şekil 5.51 PJM Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti

GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.52 PJM Market optimize GRUs 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti

GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.53 PJM Market optimize GRUs 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti

GRUs*-PJM 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



Şekil 5.54 PJM Market optimize GRUs 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti

Tablo 5.14 New England performans metriklerinin değerlendirilmesi

	LSTM	GRU
<i>MAE</i>	14.50	12.19
<i>RMSE</i>	29.35	41.70
<i>R²</i>	0.77	0.53


New England şirketinden datalarla 2022'nin Haziran ayından 2023'ün Haziran ayına kadar YMF verilerinin toplanmasıyla elde edilen data set, Colab üzerinden LSTM ve GRU tahminleme için uygun formata getirilmiştir. LSTM için MAE değeri 14.50, RMSE değeri 29.35, R-Squared değeri yani determinasyon kat sayısı ise 0.77 olarak optimum değerlerine ulaştırılmıştır. GRU için MAE değeri 12.19, RMSE değeri 41.70, R-Squared değeri yani determinasyon kat sayısı ise 0.53 olarak optimum değerlerine ulaştırılmıştır.

New England şirketinden datalarla elde edilen veri seti için LSTM ile tahminleme yapılmıştır. Detaylı gözlemle için 30 günlük, 5 günlük ve 1 günlük grafiklere yer verilmiştir.

New England şirketinden datalarla elde edilen veri seti için GRU ile tahminleme yapılmıştır. Detaylı gözlemle için 30 günlük, 5 günlük ve 1 günlük grafiklere yer verilmiştir.


Bu bölümde elde edilen sonuçlar ve grafikler, sonuçların değerlendirilmesi bölümünde ayrıntılı olarak yorumlanmış ve gelecek çalışmalarda verilebilecek katkılardan söz edilmiştir.

LSTM-New Eng 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük




Şekil 5.55 MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 30 günlük test seti

LSTM-New Eng 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük




Şekil 5.56 MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 5 günlük test seti

LSTM-New Eng 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük




Şekil 5.57 MISO Market optimize LSTM 2022/2023 24 saat ilerisi için tahmin grafikleri, 1 günlük test seti

GRUs - New Eng 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 30 Günlük

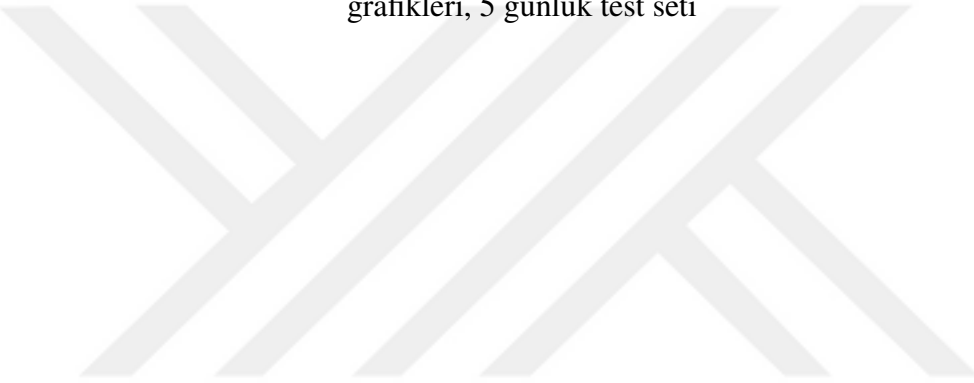


Şekil 5.58 MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 30 günlük test seti


GRUs - New Eng 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 5 Günlük



Şekil 5.59 MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 5 günlük test seti



GRUs - New Eng 2022-2023 Haziran 24 Saat İlerisi İçin Tahmin Grafiği, 1 Günlük



Şekil 5.60 MISO Market optimize GRU 2022/2023 24 saat öncesi tahmin grafikleri, 1 günlük test seti

6

SONUÇLARIN DEĞERLENDİRİLMESİ

6.1 MISO Enerji Piyasası Verilerinin Sonuçları

6.1.1 İleriye Dönük 24 Saat Tahmin Sonuçları

Geçmiş Yıllık Gerçek Zamanlı YMF (Historical Annual Real-Time LMPs) veri setlerini kullanarak, LSTM tabanlı YMF tahmini çalışması 2018/2019, 2020 ve 2021 yılları için değerlendirilmiştir. Tüm şekil ve tabloların analizine dayanarak, sonuçları ilgili hata oranları bağlamında yorumlamak önemlidir.

2018/2019 veri setine dayanan tahminler, 2021'e kıyasla çok daha düşük MAE ve RMSE değerlerine ve daha yüksek R-Kare veya diğer bir deyişle determinasyon katsayısı değerlerine sahiptir. Yani, 2018/2019 veri setine dayanan tahminler, 2021'e kıyasla çok daha düşük MAE ve RMSE değerlerine ve daha yüksek R-Kare değerlerine sahiptir. 2018/2019 veri setine dayalı olarak, R-Kare değerleri 2020 ve 2021'den çok daha iyidir. Ancak, MAE ve RMSE değerleri, 2020 için 2018/2019'dan ve 2021'den daha düşüktür. Düşük MAE ve RMSE değerleriyle elde edilen umut verici sonuçlar, LSTM modellerinin zorlu koşullar altında geliştirme potansiyelini göstermektedir.

2018/2019, 2020 ve 2021 için 24 saat ileriye yönelik tahmin grafikleri görselleştirilmiştir. Verilerin tahmin yaklaşımının performansını olumsuz etkileyebilecek dalgalı bir profil sergilemesine rağmen, tahminler beklenmeyen bir olay olan bu durumdaki pandemiye kadar farklı zaman ufukları için gerçek profili kabul edilebilir şekilde takip etmektedir.

2020 için optimizasyon ve LSTM kullanılması sayesinde, kontrol yöntemi değerleri 2018/2019 döneminde elde edilen en iyi sonuçlarla yakından uyumlu hale gelmiş ve 2018/2019 döneminde elde edilen performans seviyelerini korumamıza olanak sağlamıştır.

2020 pandemi veri seti ve 2021 pandemi sonrası veri seti için determinasyon

katsayısı deęerlendirmeleri, 2018/2019 Veri Seti'nden daha dūşüktür. Bununla birlikte, dūşük MAE ve RMSE deęerleriyle elde edilen umut verici sonuçlar, LSTM modellerinin zorlu koşullar altında iyileştirme potansiyelini göstermektedir. Genel olarak, LMP tahmini 2018/19, 2020 ve 2021'de R-Kare doęruluęunu sırasıyla %25, %56 ve %75 oranında artırmıřtır. Veriler, LMP tahmininin, doęru tahminlere dayanan bilinçli kararlar almak için güvenilir bir araç olduęunu göstermektedir.

Bu bulgular, pandemi gibi karmařık olayları daha iyi anlamak ve tahmin etmek için derin öğrenme tekniklerinin daha fazla arařtırma ve geliştirme ihtiyacını vurgulamaktadır.

Elektrik fiyatı tahminleri, güç sistemine iliřkin karar alma süreçlerinde önemli bir rol oynar. Gerçek zamanlı LMP tahminlerinin doęruluęu, akıllı řebeke, talep yanıtı ve gelir ve risk yönetimi gibi konularda etkin iřletmeyi saęlamak için önemlidir.

Bu çalışmada, Adam optimize edilmiř bir LSTM sinir aęı önerilmiř ve performansını çeřitli grafikler ve tablolar üzerinden deęerlendiriyoruz, hatta pandemi döneminde bile. Deneysel sonuçlar, LSTM sinir aęının performansının MISO'nun tahmin etmesi zor olan YMF verileri kullanılarak bile tatmin edici olduęunu göstermektedir.

Bu çalışmada kullanılan parametrelerle elektrik piyasası sisteminde sıradan bir veri seti eęitilmiř olsaydı, çok daha iyi sonuçlar elde edilecektir. Bu çalışmada, MISO tarafından açık kaynak olarak saęlanan verileri, seętięimiz yük bölgelerinde analiz etmek ve tahmin etmek zor oldu. Ayrıca, bu projeyi ilerletmek için LSTM'den farklı derin öğrenme ve optimizasyon tekniklerini deneyerek dięer yöntemlerle daha iyi sonuçlar elde etmek mümkün olacaktır.

Önerilen yöntemi daha da geliřtirmek ve iyileřtirmek için elektrik fiyatı tahminini etkileyen dięer faktörler dikkate alınacaktır. Gelecekteki çalışmalarda, hava sıcaklıęı gibi dięer ilgili veriler de göz önünde bulundurulacaktır. Bu faktörlerin entegre edilmesiyle, yöntem sistematik ve dikkatli bir řekilde test edilip doęrulandıęında, doęruluęunun ve güvenilirlięinin daha kapsamlı bir řekilde deęerlendirilmesi saęlanabilecektir.

6.1.2 Çok Deęiřkenli ve Tek Deęiřkenli Tahminleme Sonuçları

Grafiklerde gösterildięi řekilde 2018/19, 2020 ve 2021 (çok deęiřkenli) önceden tahmin grafikleri ile 2018/19*, 2020* ve 2021* (tek deęiřkenli) 24 saat ilerisi için tahmin karřılařtırması yapılmıřtır. Burada, tek bölge için LMP tahminlerinin gösterildięi, çok deęiřkenli tahminlerin tek deęiřkenli tahminlere kıyasla güçlü

tahmin performans metrikleri sergilediği görülmektedir. Bu, YMF tahmininin elektrik fiyatı tahmin modellerinin doğruluğunu artırmada önemli bir rol oynadığını vurgulamaktadır.

6.2 PJM Enerji Piyasası Verileriyle Tahminleme Sonuçları

6.2.1 LSTM İleriye Dönük 24 Saat Tahminleme Sonuçları

PJM Saatlik Gerçek Zamanlı YMF (PJM Real-Time LMPs) veri setlerini kullanarak, LSTM tabanlı YMF tahmini çalışması 1 Haziran 2022 ve 1 Haziran 2023 zaman aralığı için değerlendirilmiştir. Şekiller ve tabloların analizine dayanarak, sonuçları ilgili hata oranları bağlamında yorumlamak önemlidir.

MAE ve RMSE değerleri, bir tahmin modelinin ne kadar doğru tahmin yaptığını ve gerçek değerlerle ne kadar uyumlu olduğunu ölçmek için kullanılan hata metrikleridir. Daha düşük MAE ve RMSE değerleri, daha iyi bir tahmin modelinin işaretidir. İlk LSTM modellemesinde; MAE değeri 12.96, RMSE değeri 56.73, R-Kare değeri ise 0.75 olarak optimum değerlerine ulaştırılmıştır. Düşük MAE, ve yüksek R-Kare değerleriyle elde edilen tatmin edici sonuçlar, bir yıllık PJM verisi zaman aralığı için da geliştirme potansiyelini göstermektedir. 0.75 R-Kare değeri, LSTM modelinin veri setindeki değişkenliğin %75'ini açıkladığını gösterir.

Sonuçlar 30 günlük, 5 günlük ve 1 günlük veri setlerinde daha iyi gözlemlenebilmesi için grafiklerle verilmiştir. LSTM, RNN tabanlı bir derin öğrenme modelidir. R-Kare yani determinasyon kat sayısı, bir regresyon modelinin gözlemlenen verilerdeki değişkenliği ne kadar iyi açıkladığını gösteren bir istatistiksel ölçüdür. 0-1 aralığında değerler ortaya koyar ve 1'e en yakın sonuç elde edilmeye çalışılır. Sonuçlar 1'e yaklaştıkça veri setinin yapılan tahminlemede daha iyi açıklandığını söyleyebiliriz. Bu başlık altındaki tahminleme için %75'lik sonuç oldukça başarılı bir elde olarak sunulabilir.

6.2.2 GRUs İleriye Dönük 24 Saat Tahminleme Sonuçları

PJM Saatlik Gerçek Zamanlı YMF (PJM Real-Time LMPs) veri setlerini kullanarak, GRUs tabanlı LMP tahmini çalışması 1 Haziran 2022 ve 1 Haziran 2023 zaman aralığı için değerlendirilmiştir. Şekiller ve tabloların analizine dayanarak, sonuçları ilgili hata oranları bağlamında yorumlamak önemlidir. Bu bölümde GRUs için mimari parametreler güncellenmiş ve mümkün olan en yüksek tahmin değerlerine ulaşılmıştır.

MAE ve RMSE değerleri, buradaki tahmin modelinin ne kadar doğru tahmin

yaptığını ve gerçek değerlerle ne kadar uyumlu olduğunu ölçmek için kullanılan hata metrikleridir. Daha düşük MAE ve RMSE değerleri, daha iyi bir tahmin modelinin habercisidir. MAE değeri 13.89, RMSE değeri 50.41, R-Kare değeri yani determinasyon kat sayısı ise 0.80 olarak optimum değerlerine ulaştırılmıştır. Düşük MAE, ve yüksek R-Kare değerleriyle elde edilen tatmin edici sonuçlar, bir yıllık PJM verisi zaman aralığı için de geliştirme potansiyelini göstermektedir. 0.80 R-Kare değeri, GRU modelinin veri setindeki değişkenliğin %80'ini açıkladığını gösterir.

Sonuçlar 30 günlük, 5 günlük ve 1 günlük grafiklerle daha iyi gözlemlenebilmesi için grafiklere verilmiştir. GRUs, RNN tabanlı bir derin öğrenme modelidir. R-Kare, bir regresyon modelinin gözlemlenen verilerdeki değişkenliği ne kadar iyi açıkladığını gösteren bir istatistiksel ölçü olarak kullanılır.

6.2.3 Derin Öğrenme Yöntemleri Karşılaştırma

LSTM ve GRU, zaman serisi verileri gibi zaman bağımlı verilerin işlenmesinde kullanılan popüler ki farklı RNN modelleridir. Her iki model de benzer amaçlara hizmet ederken, bazı temel farklılıkları vardır.

LSTM, uzun vadeli bağımlılıkları daha etkili bir şekilde işleyebilme yeteneğine sahiptir. Bu, geçmiş bilginin ne kadarını koruyacağını, ne kadarını unutacağını ve ne kadar yeni bilgi ekleyeceğini düzenleyen giriş, çıkış ve unutma kapıları kullanarak gerçekleştirilir. Bu nedenle, LSTM modelleri daha karmaşık veri yapılarını yakalamak ve daha genel bir model oluşturmak için tercih edilebilir.

GRU ise daha basit bir yapıya sahiptir ve daha az parametre içerir. Bunun sonucunda, GRUs modelleri daha hızlı eğitilebilir ve daha hızlı tahmin yapabilir. Ayrıca, GRUs daha az bellek gerektirir ve daha az hesaplama yüküne sahiptir. Bu nedenle, daha küçük veri setleriyle çalışırken veya sınırlı hesaplama kaynaklarına sahipken GRU tercih edilebilir.

Her iki modelin avantajları ve dezavantajları vardır. LSTM, karmaşık veri yapılarına daha iyi uyum sağlarken, GRUs daha hızlı eğitim ve tahmin yetenekleri sunar. Hangi modelin kullanılacağı, veri setinin özelliklerine, uygulama gereksinimlerine ve kullanım senaryolarına bağlıdır. Genelleme yapılacak olursa LSTM ve GRUs gibi RNN modelleri, zaman bağımlı verilerin analizi ve tahmini için güçlü araçlar sunar ve seçim, veri ve uygulama sisteminde başarılı sonuçlar verir.

Aynı veri setiyle aynı parametrelerde GRUs'un biraz daha başarılı olduğu gözlemlenmiştir. GRUs'un daha yüksek R-Kare değerine yani determinasyon kat

sayısına sahip olduğu durumda, bu genellikle GRUs'un veri setindeki değişkenliği daha iyi açıklayabildiği ve daha iyi bir uyum sağladığı anlamına gelir. Bu, GRUs'un veri setine daha iyi uyan bir model olduğunu gösterir.

Bu durumda, GRUs'un daha yüksek R-Kare değeri, GRU modelinin tahminlerinin veri setindeki gerçek değerlere daha yakın olduğunu ve daha iyi bir performans sergilediğini gösterir. Bu, GRUs'un veriyi daha iyi anlayabildiği ve veri setindeki örüntüleri daha doğru bir şekilde yakaladığı anlamına gelebilir.

Ancak, R-Kare değeri tek başına bir modelin performansını tam olarak değerlendirmek için yeterli olmayabilir. Başka değerlendirme metriklerini ve istatistikleri de gözlemlemek önemlidir. Ayrıca, modelin genelleme yeteneği, overfitting ve underfitting gibi diğer faktörleri de göz önünde bulundurmak önemlidir.

MAE değeri, tahminlerin gerçek verilerden ortalama ne kadar uzak olduğunu gösterir. LSTM'nin MAE değeri 12.96 iken, GRUs'un MAE değeri 13.89'dur. Karşılaştırma durumunda daha düşük MAE değeri, tahminlerin gerçek verilere daha yakın olduğunu ve daha iyi bir performans sergilendiğini gösterir. Bu durumda, LSTM'nin GRUs'a göre daha iyi bir tahmin performansı olduğu söylenebilir.

RMSE değeri, tahminlerin gerçek verilere ne kadar yakın olduğunu ve tahmin hatalarının ne kadar büyük olduğunu gösterir. LSTM'nin RMSE değeri 56.73 iken, GRU'nun RMSE değeri 50.41'dir. Daha düşük RMSE değeri, tahminlerin daha az hata içerdiğini ve daha iyi bir performans sergilendiğini gösterir. Bu durumda, GRU'nun LSTM'ye göre daha iyi bir tahmin performansı gösterdiği söylenebilir, fakat değerlerin birbirine çok yakın olması sadece bu parametre ile kesin bir karşılaştırılma yapılmaması gerektiğini bize anlatır.

Sonuç olarak, verilen değerlere göre LSTM ve GRU modelleri benzer tahmin performansı göstermektedir, her ikisi de başarılı sonuçlar vermiştir. Her iki model de veri setini iyi tahmin etmekte ve benzer hata metriklerine sahiptir. Bu durumda, hangi modelin tercih edileceği, kullanım senaryosuna ve spesifik gereksinimlere bağlı olabilir. Yine de GRUs modelinin sunduğu başarılı sonuçlar veri setiyle daha uyumlu olduğunu ve başarı parametrelerinin daha yüksek olduğunu ortaya koyar.

6.2.4 K-Ortalamlar ile Veri Kümeleme Sonuçları

k=5 küme seti logaritmik skalada incelendiğinde, 6696 elemanlı Küme 0'ın küçük ölçekteki değerleri içerdiği ve kalan kümelerin (Küme 1,2,3,4) daha büyük ölçekteki verileri içerdiği gözlemlenebilmektedir. Logaritmik skalada yapılan

görselleştirmelerde Küme 0 ve Küme 3 arasındaki ayrım belirsiz gibi görünse de geçiş ayrımı ölçek farkı düşünüldüğünde nettir.

Kümeleme sonuçları neticesinde LSTM modeli geliştirilirken Küme 0 ve kalan kümeler şeklinde oluşturulan iki ana küme kullanılmıştır. En büyük küme 6696 örnek ve ikinci küme 2089 örnekten oluşmaktadır. LSTM modelinin geliştirilmesi için veri setinin yeterli ölçüde büyük olabilmesi için ikinci küme Küme 3 ve dışında kalan küçük kümelerden oluşturulmuştur.

LSTM modelinin performans başarısı kümeleme ön işleme neticesinde verinin büyük bir bölümünü içeren ana küme kullanılarak eğitilen modelde artmıştır. Daha kararlı sonuçlar verdiği gözlemlenmiştir. Anomali olarak değerlendirilebilecek az sayıda elemanı olan kümeleri de içeren ikinci ana küme kullanılarak eğitilen model ise tüm veri seti ile eğitilen kümeden çok daha düşük bir performans göstermiştir. Diğer tüm kümeleri toplayan anomali olarak değerlendirebileceğimiz kısmın determinasyon kat sayısı 0.67 düzeyinde tahmin edilebilirken, LSTM modeli performans metrikleri olarak belirlenen MAE, RMSE ve R-Kare değerleri incelendiğinde, en büyük kümenin en düşük hata değerlerine ve en başarılı metriklere sahip olduğu görülmüştür. Determinasyon kat sayısı 0.78'lik bir başarıya kadar yükselmiştir. RMSE değeri 98,44'ten 7.38 değerine kadar gerilemiştir. R-Kare yani determinasyon kat sayısı değeri yapılan k-Means düzenlemesi ile birlikte ilk durumdaki 0.75 olarak tahmin edilen tüm veri data setine göre %4 başarısını arttırmıştır ve 0.78'e ulaşmıştır. MAE ve RMSE değerlerindeki kayda değer inanılmaz düşüş ise yöntemin uygulanmasındaki önemi vurgulamaktadır. MAE değeri başlangıçta 12.96 iken 5.15'e ve RMSE değeri başlangıçta 56.73 iken 7.39'a kadar gerilemiştir. Kümeleme ile veri setinin gerçek değerlere ne kadar yaklaştırıldığı ve sonrasında LSTM'in başlangıç değerlerindeki mimari yapı değerleriye tekrar tahmin yapıldığında k-Ortalamlar methodunun başarıyı çok yükselttiği saptanmıştır.

Sonuç olarak, bu modeller kullanılarak yapılacak bir tahminleme uygulamasında tahminleme yapılırken kullanılacak girdi verisine öncelikle kümeleme modeli çalıştırılmalıdır. Kümeleme sonucunun ana kümede yer alması durumunda LSTM modeli, diğer durumda ise ikinci ana küme yerine tüm veri üzerinden eğitilen model kullanıldığında, genel olarak tahminleme başarısı, kümeleme yapılmadığı duruma göre daha yüksek olacaktır.

Daha iyi sonuçlar elde etmek için k-Means (k-Ortalamlar) yönteminin diğer k değerleri ve de başka parametreleri (mesafe hesaplama algoritması gibi) denenebileceği gibi başka kümeleri algoritmaları da denenebilir. Toplam başarıyı

artırmak için kümeleme algoritması yanında, farklı kümelere farklı derin öğrenme teknikleri ile geliştirilmiş modeller ile tahminleme uygulanabilir.

6.3 MISO, PJM ve New England Enerji Piyasası Bir Yıllık Veri Setiyle Tahminleme Sonuçları

Bu bölümde üç farklı şirket olan MISO, PJM ve ISO-New England'ın 1 Haziran 2022-2023 tarihleri arasındaki YMF değerlerini içeren veri setinde 24 saat ileriye yönelik tahminleme sürecinde elde edilen sonuç değerleri yorumlanmıştır. MISO ve New England şirketleri için LSTM yöntemini bu veri setinde kullanmak avantajlı olurken PJM için GRU kullanımı daha avantajlı sonuç ortaya koymuştur.

6.3.1 MISO İleriye Dönük 24 Saat Tahminlemesi Sonuçları

MISO'dan elde edilen verilerle yapılan tahminleme sonuçlarında temelde LSTM ve GRU derin öğrenme tekniklerini karşılaştıracak olursak R-Kare değeri GRU'da 0.45 ile doğru tahmin sağlarken, LSTM 0.57 olarak gözlemlenmiştir. LSTM tekniğinde 16.20 olan MAE değeri GRU'da 15.74 olarak tahminlenmiştir. Bu değerler karşılaştırıldığında düşük olan yöntem avantajlı görülmelidir. RMSE değeri GRU tahminlemesine göre 41.98 olarak, LSTM'deki 37.14 değerinden yüksek çıkmıştır. Bu değerlerin birbirine yakınlığı sadece MAE değerine bakılarak yorum yapılmaması gerektiğinin ve değerlerin bir bütün olarak değerlendirilmesinin daha doğru olacağının kanıtıdır. RMSE ve MAE değerlerinin bir karşılaştırma yapıldığında elde edilen düşük değer olduğu yöntemin daha iyi sonuç vermeye yatkın olduğu sonucuna ulaşılabilir. RMSE, hataların karesini alarak büyük hataları daha fazla vurgular. Burada olduğu gibi finansal tahminlemelerde hatanın büyüklüğü kritik karar alımlarında etkili olabilir. Genel bir değerlendirme yapılacak olunursa iki farklı RNN yöntemi olan LSTM ve GRU için MISO'dan elde edilen 1 Haziran 2022-2023 tarihleri arasındaki YMF değerlerini içeren veri setinde 24 saat ileriye yönelik tahminleme sürecinde LSTM daha başarılı sonuç vermiştir diyebiliriz. Daha iyi değerlere ulaşabilmek için mimari değerler değiştirilerek yeni denemeler yapılabilir.

6.3.2 PJM İleriye Dönük 24 Saat Tahminlemesi Sonuçları

PJM'den elde edilen verilerle yapılan tahminleme sonuçlarında temelde LSTM ve GRU derin öğrenme tekniklerini karşılaştıracak olursak R-Kare değeri GRU'da 0.80 ile doğru tahmin sağlarken, LSTM 0.75 olarak gözlemlenmiştir. MAE değeri GRU'da daha yüksek LSTM'de daha düşük çıkmıştır. Bu değerler

karşılaştırıldığında düşük olan yöntem avantajlı görülmelidir. LSTM tekniğinde 12.96 olan MAE değeri GRU'da 14.29 olarak tahminlenmiştir. RMSE değeri LSTM tahminlemesine göre 56.73 olarak, GRU'daki 51.90 değerinden yüksek çıkmıştır. Bu değerlerin birbirine yakınlığı sadece MAE değerine bakılarak yorum yapılmaması gerektiğinin ve değerlerin bir bütün olarak değerlendirilmesinin daha doğru olacağının kanıtıdır. RMSE ve MAE değerlerinin bir karşılaştırma yapıldığında elde edilen düşük değer olduğu yöntemin daha iyi sonuç vermeye yatkın olduğu sonucuna ulaşılabilir. Genel bir değerlendirme yapılacak olunursa iki farklı RNN yöntemi olan LSTM ve GRU için PJM'den elde edilen 1 Haziran 2022-2023 tarihleri arasındaki YMF değerlerini içeren veri setinde 24 saat ileriye yönelik tahminleme sürecinde GRU daha başarılı sonuç vermiştir diyebiliriz.

6.3.3 New England İleriye Dönük 24 Saat Tahminlemesi Sonuçları

New England'dan elde edilen verilerle yapılan tahminleme sonuçlarında temelde LSTM ve GRU derin öğrenme tekniklerini karşılaştıracak olursak R-Kare değeri GRU'da 0.53 ile doğru tahmin sağlarken, LSTM 0.77 olarak gözlemlenmiştir. LSTM tekniğinde 14.50 olan MAE değeri GRU'da 12.19 olarak tahminlenmiştir. Bu değerler karşılaştırıldığında düşük olan yöntem avantajlı görülmelidir. RMSE değeri GRU tahminlemesine göre 41.70 olarak, LSTM'deki 29.35 değerinden yüksek çıkmıştır. Bu değerlerin birbirine yakınlığı sadece MAE değerine bakılarak yorum yapılmaması gerektiğinin ve değerlerin bir bütün olarak değerlendirilmesinin daha doğru olacağının kanıtıdır. RMSE ve MAE değerlerinin bir karşılaştırma yapıldığında elde edilen düşük değer olduğu yöntemin daha iyi sonuç vermeye yatkın olduğu sonucuna ulaşılabilir. Genel bir değerlendirme yapılacak olunursa iki farklı RNN yöntemi olan LSTM ve GRU için New England'dan elde edilen 1 Haziran 2022-2023 tarihleri arasındaki YMF değerlerini içeren veri setinde 24 saat ileriye yönelik tahminleme sürecinde LSTM daha başarılı sonuç vermiştir diyebiliriz. Daha iyi değerlere ulaşabilmek için mimari değerler değiştirilerek yeni denemeler yapılabilir.

6.4 Gelecek Çalışmalar

Bu çalışmada Amerika Birleşik Devletleri'nde bulunan üç büyük enerji şirketi olan MISO, PJM ve New England'ın internet sitelerinde açık kaynaklı olarak paylaştıkları YMF veya literatürdeki ismiyle "Locational Marginal Pricing" verilerinin klasik makine öğrenmesi ve derin öğrenme teknikleriyle 24 saat ilerisi için uygun tahminleme ve kümeleme yöntemlerinden yararlanılmıştır. MISO Amerika'nın 15 eyaletin yanı sıra Ontario, Kanada'nın bir kısmını da içerir. PJM

Amerika'nın doğusunda 13 eyaleti ve Columbia Bölgesi'ni (Washington, DC) kapsar. ISO New England ise Amerika'nın kuzeydoğu bölgesinde bulunan 6 eyaleti kapsar. Bu kadar geniş coğrafyada bulunan bu etkili şirketlerin verileriyle umut vaad eden ve başarılı makine öğrenmesi yöntemleri denemeleri gerçekleştirilmiştir.

Daha etkili gelecek çalışmalar yapmak adına kullanılan yöntemlerde seçilen yük bölgeleri coğrafi konumlama olarak birbirine daha yakın bölgelerden veri setlerinin içinden özenle seçilebilir. Kullanılan veri setlerinde en iyi tahminleme yöntemlerini elde etmek için hiperparametre optimizasyonu tezde kullanılan Adam, Grid vb. dışında Hyperopt, Optuna ve genetik algoritmalar ile zenginleştirilebilir. Veri setleri birimsel açıdan aynı olsa da değerlerin bölgesel, tarihsel, toplumsal etkiler nedeniyle değişkenlik göstermesi dikkate alınmalıdır. Veri setlerindeki anormal data değişimlerine ve nedenlerine odaklanarak verinin analizi için daha detaylı ve derin inceleme yapılabilir. Kullanılan LSTM, GRU, k-ortalamlar dışında farklı hibrit yöntemler ve derin öğrenme tekniklerinden yararlanılabilir. Örneğin, kümeleme algoritmalarından yararlanılarak klasik makine öğrenmesi teknikleri derin öğrenme metotlarıyla birleştirilip farklı analizler sunulabilir. Günümüzde yapay zeka çok hızlı gelişen bir alan olmakla birlikte bu veri setleri yeni derin öğrenme ve makine öğrenmesi yöntemleriyle denenip ortaya çıkan sonuçlar değerlendirilebilir. Finans, enerji gibi sektörlerde hata oranlarının kritik, tahminleme değerlerinin önemli olduğu unutulmamalıdır. Karar vericilerin, politikacıların, iş sahiplerinin bu alanda önceden bilgi sahibi olması, bir sonraki adımda neler yapılacağını geliştirebilecekleri stratejileri tayin etmelerini sağlar. Ayrıca, finansal risklerden korunma yöntemleri belirlemelerine, kar oranını artırmaya yönelik adımlar atmalarına ve iş süreçlerini daha etkili bir şekilde yönetmelerine yardımcı olur. Bu şekilde, sektördeki değişimlere daha hızlı tepki verebilir, rekabet avantajı sağlayabilir ve başarılı sonuçlar elde edebilirler.

- [1] “Global patterns of power sector reform, 1982–2013,” *Energy Strategy Reviews*, vol. 23, pp. 152–162, 2019, issn: 2211-467X.
- [2] M. Shahidehpour, H. Yamin, Z. Li, *Market operations in electric power systems: forecasting, scheduling, and risk management*. John Wiley & Sons, 2003.
- [3] Y.-Y. Hong, J. V. Taylar, A. C. Fajardo, “Locational marginal price forecasting using deep learning network optimized by mapping-based genetic algorithm,” *IEEE Access*, vol. 8, pp. 91 975–91 988, 2020.
- [4] Y. Fu, Z. Li, “Different models and properties on Imp calculations,” in *2006 IEEE Power Engineering Society General Meeting*, IEEE, 2006, 11–pp.
- [5] *Pennsylvania-new jersey-maryland interconnection*. [Online]. Available: <http://www.pjm.com> (visited on 06/05/2023).
- [6] C. Crozier, A. Pigott, K. Baker, “Spatial arbitrage through bidirectional electric vehicle charging,” in *2022 IEEE Power & Energy Society General Meeting (PESGM)*, 2022, pp. 1–5.
- [7] Z. Zhang, M. Wu, “Energy price prediction considering generation bids variation: A two-stage convolutional long short-term memory approach,” in *2022 IEEE Power Energy Society General Meeting (PESGM)*, 2022, pp. 1–5.
- [8] G. S. Sivasankari, S. Prasanthini, N. Vijithra, K. Narayanan, G. Sharma, T. Senjyu, “Revenue maximization of utility based on price forecasting and energy scheduling in Imp market,” in *2022 2nd International Conference on Power Electronics IoT Applications in Renewable Energy and its Control (PARC)*, 2022, pp. 1–6.
- [9] Z. Zhang, M. Wu, “Real-time locational marginal price forecasting using generative adversarial network,” in *2020 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*, 2020, pp. 1–6.
- [10] D. Yadav, S. Mekhilef, B. Singh, M. Rawa, “Deep reinforcement learning and energy price prediction,” in *Artificial Intelligence-based Smart Power Systems*. 2023, pp. 207–231.
- [11] Y. Li, N. Yu, W. Wang, “Machine learning-driven virtual bidding with electricity market efficiency analysis,” *IEEE Transactions on Power Systems*, vol. 37, no. 1, pp. 354–364, 2022.

- [12] F. V. Atabay, R. M. Pagkalinawan, S. D. Pajarillo, A. R. Villanueva, J. V. Taylor, "Multivariate time series forecasting using arimax, sarimax, and rnn-based deep learning models on electricity consumption," in *2022 3rd International Informatics and Software Engineering Conference (IISEC)*, 2022, pp. 1–6.
- [13] A. Javed, R. R. Derakhshani, "Machine learning ensembles for grid congestion price forecasting," in *2022 North American Power Symposium (NAPS)*, 2022, pp. 1–6.
- [14] N. Kumar, M. M. Tripathi, "Impact analysis of wind energy on electricity price using deep neural network," in *2021 8th International Conference on Computing for Sustainable Global Development (INDIACom)*, 2021, pp. 144–148.
- [15] H. Wang, W. Jiang, C. Wu, "Is elmp harder to predict than lmp," in *2022 IEEE Sustainable Power and Energy Conference (iSPEC)*, 2022, pp. 1–5.
- [16] J. Yang, "Electricity price forecast based on metabolic gm(1,1) model under wind power development prospect," in *2022 IEEE 9th International Conference on Power Electronics Systems and Applications (PESA)*, 2022, pp. 1–7.
- [17] Z. Pu, M. Wang, H. Zheng, Z. Liu, "Optimal planning of energy storage for wind farm genco in power spot market," in *2022 7th Asia Conference on Power and Electrical Engineering (ACPEE)*, 2022, pp. 197–202.
- [18] B. Park *et al.*, "Optimal demand response incorporating distribution lmp with pv generation uncertainty," *IEEE Transactions on Power Systems*, vol. 37, no. 2, pp. 982–995, 2022.
- [19] S. Kumar, P. K. Tiwari, "Impacts of renewable energy based power plants on lmp in deregulated electricity markets: A review," in *2022 IEEE Students Conference on Engineering and Systems (SCES)*, 2022, pp. 1–5.
- [20] *U.S. Energy Information Administration, Monthly Energy Review sourced by EIA*, Accessed: April 5, 2021, 2021. [Online]. Available: <https://www.eia.gov/todayinenergy/detail.php?id=47397>.
- [21] *Annual energy outlook*, 2023. [Online]. Available: <https://www.eia.gov/outlooks/aeo/> (visited on 03/16/2023).
- [22] *Annual energy outlook 2023 (aeo2023)*, 2023. [Online]. Available: <https://www.eia.gov/todayinenergy/detail.php?id=56040> (visited on 04/03/2023).
- [23] *U.S. Electricity Grid Markets*, 2023. [Online]. Available: <https://www.epa.gov/green-power-markets/us-electricity-grid-markets#:~:text=U.S.%20electricity%20markets%20have%20both,sales%20of%20electricity%20to%20consumers> (visited on 04/18/2023).
- [24] E. Litvinov, F. Zhao, T. Zheng, "Electricity markets in the united states: Power industry restructuring processes for the present and future," *IEEE Power and Energy Magazine*, vol. 17, no. 1, pp. 32–42, 2019.

- [25] P. Du, N. V. Mago, W. Li, S. Sharma, Q. Hu, T. Ding, “New ancillary service market for ercot,” *IEEE Access*, vol. 8, pp. 178 391–178 401, 2020.
- [26] A. Schinke-Nendza, G. Blumberg, C. Weber, “A novel design for electricity markets based on the cellular approach,” in *2020 17th International Conference on the European Energy Market (EEM)*, 2020, pp. 1–6.
- [27] *Nordpool spot*. [Online]. Available: <https://www.nordpoolgroup.com/> (visited on 06/05/2023).
- [28] *Exaa*. [Online]. Available: <https://www.exaa.at/en/> (visited on 06/05/2023).
- [29] *Polish power exchange (tge)*. [Online]. Available: <https://www.tge.pl/en> (visited on 06/05/2023).
- [30] *Power exchange central europe (pxe)*. [Online]. Available: <https://www.pxe.cz/en/> (visited on 06/05/2023).
- [31] *Hungarian power exchange (hupx)*. [Online]. Available: <https://hupx.hu/en/> (visited on 06/05/2023).
- [32] *Opcom*. [Online]. Available: <https://www.opcom.ro/en/> (visited on 06/05/2023).
- [33] *Independent bulgarian energy exchange (ibex)*. [Online]. Available: <https://www.ibex.bg/en/> (visited on 06/05/2023).
- [34] *Hellenic energy exchange (henex)*. [Online]. Available: <https://www.henex.gr/> (visited on 06/05/2023).
- [35] *Omip*. [Online]. Available: <https://www.omip.pt/en/> (visited on 06/05/2023).
- [36] *Epias*. [Online]. Available: <https://www.epias.com.tr/> (visited on 06/05/2023).
- [37] *European energy exchange (eex)*. [Online]. Available: <https://www.eex.com/en> (visited on 06/05/2023).
- [38] *N2ex*. [Online]. Available: <https://www.n2ex.com/> (visited on 06/05/2023).
- [39] *Epex spot*. [Online]. Available: <https://www.epexspot.com/en/> (visited on 06/05/2023).
- [40] *Italian power exchange (ipex)*. [Online]. Available: <https://www.gme.it/en/> (visited on 06/05/2023).
- [41] *Omie*. [Online]. Available: <https://www.omie.es/en/> (visited on 06/05/2023).
- [42] *Apx group*. [Online]. Available: <https://www.apxgroup.com/> (visited on 06/05/2023).
- [43] *Belpex*. [Online]. Available: <https://www.belpex.be/en> (visited on 06/05/2023).
- [44] *Swissix*. [Online]. Available: <https://www.swissix.ch/> (visited on 06/05/2023).

- [45] O. Ruksans, I. Oleinikova, R. Prohorova, "Analysis of factors that are affecting electricity prices in baltic countries," in *2014 55th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON)*, 2014, pp. 232–237.
- [46] *Pjm-rto*. [Online]. Available: <https://www.pjm.com/> (visited on 06/05/2023).
- [47] *Comed*. [Online]. Available: <https://www.comed.com/> (visited on 06/05/2023).
- [48] *Duq*. [Online]. Available: <https://duquesnelight.com/> (visited on 06/05/2023).
- [49] *Miso*. [Online]. Available: <https://www.misoenergy.org/> (visited on 06/05/2023).
- [50] *Mid-atl/aps*. [Online]. Available: <https://www.aps.com/> (visited on 06/05/2023).
- [51] *Bge*. [Online]. Available: <https://www.bge.com/> (visited on 06/05/2023).
- [52] *Dpl*. [Online]. Available: <https://www.delmarva.com/> (visited on 06/05/2023).
- [53] *Peco*. [Online]. Available: <https://www.peco.com/> (visited on 06/05/2023).
- [54] *Pepco*. [Online]. Available: <https://www.pepco.com/> (visited on 06/05/2023).
- [55] *Ppl*. [Online]. Available: <https://www.pplelectric.com/> (visited on 06/05/2023).
- [56] *Aps*. [Online]. Available: <https://www.aps.com/> (visited on 06/05/2023).
- [57] *Aep*. [Online]. Available: <https://www.aep.com/> (visited on 06/05/2023).
- [58] *Miso lmp map*. [Online]. Available: <https://api.misoenergy.org/MISORTWD/lmpcontourmap.html> (visited on 06/05/2023).
- [59] *Pjm lmp map*. [Online]. Available: <https://www.pjm.com/library/maps/lmp-map.aspx> (visited on 06/05/2023).
- [60] *Ne lmp map*. [Online]. Available: <https://www.iso-ne.com/about/key-stats/maps-and-diagrams/#load-zones> (visited on 07/31/2023).
- [61] Y. Fu, Z. Zhang, T. Li, "Electricity market price prediction based on differential evolutionary algorithm and neural network," in *2021 3rd Asia Energy and Electrical Engineering Symposium (AEEES)*, 2021, pp. 999–1004.
- [62] K. Choi, J. Yi, C. Park, S. Yoon, "Deep learning for anomaly detection in time-series data: Review, analysis, and guidelines," *IEEE Access*, vol. 9, pp. 120 043–120 065, 2021.

- [63] S. Jittanon, Y. Mensin, C. Termritthikun, “Intelligent forecasting of energy consumption using temporal fusion transformer model,” in *2023 IEEE International Conference on Cybernetics and Innovations (ICCI)*, 2023, pp. 1–5.
- [64] S. Qin, Y. Luo, G. Tao, “Memory-augmented u-transformer for multivariate time series anomaly detection,” in *ICASSP 2023 - 2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2023, pp. 1–5.
- [65] R. Lin, “Analysis on the selection of the appropriate batch size in cnn neural network,” in *2022 International Conference on Machine Learning and Knowledge Engineering (MLKE)*, 2022, pp. 106–109.
- [66] A. Jović, K. Brkić, N. Bogunović, “A review of feature selection methods with applications,” in *2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 2015, pp. 1200–1205.
- [67] O. I. Abiodun *et al.*, “Comprehensive review of artificial neural network applications to pattern recognition,” *IEEE Access*, vol. 7, pp. 158 820–158 846, 2019.
- [68] A. Hassan, A. Mahmood, “Convolutional recurrent deep learning model for sentence classification,” *IEEE Access*, vol. 6, pp. 13 949–13 957, 2018.
- [69] S. Wang, J. Cao, P. S. Yu, “Deep learning for spatio-temporal data mining: A survey,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 34, no. 8, pp. 3681–3700, 2022.
- [70] S. Yang, X. Yu, Y. Zhou, “Lstm and gru neural network performance comparison study: Taking yelp review dataset as an example,” in *2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)*, 2020, pp. 98–101.
- [71] M. Fan, O. Imran, A. Singh, S. A. Ajila, “Using cnn-lstm model for weather forecasting,” in *2022 IEEE International Conference on Big Data (Big Data)*, 2022, pp. 4120–4125.
- [72] N. Zhao, H. Gao, X. Wen, H. Li, “Combination of convolutional neural network and gated recurrent unit for aspect-based sentiment analysis,” *IEEE Access*, vol. 9, pp. 15 561–15 569, 2021.
- [73] M. R. Raza, W. Hussain, J. M. Merigó, “Cloud sentiment accuracy comparison using rnn, lstm and gru,” in *2021 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 2021, pp. 1–5.
- [74] D. K. Molzahn *et al.*, “A survey of distributed optimization and control algorithms for electric power systems,” *IEEE Transactions on Smart Grid*, vol. 8, no. 6, pp. 2941–2962, 2017.
- [75] K. Capao, K. D. Gorro, K. D. Gorro, M. J. Sabellano, C. L. A. G. Militante, J. P. C. Manalili, “Aspect analysis of cebu establishments’ online reviews using k-means clustering and word2vec,” in *2018 3rd International Conference on Computer and Communication Systems (ICCCS)*, 2018, pp. 61–66.

- [76] A. Pugazhenth, L. S. Kumar, "Selection of optimal number of clusters and centroids for k-means and fuzzy c-means clustering: A review," in *2020 5th International Conference on Computing, Communication and Security (ICCCS)*, 2020, pp. 1–4.
- [77] C. Fry, S. Manna, "Can we group similar amazon reviews: A case study with different clustering algorithms," in *2016 IEEE Tenth International Conference on Semantic Computing (ICSC)*, 2016, pp. 374–377.
- [78] K. Afifah, I. N. Yulita, I. Sarathan, "Sentiment analysis on telemedicine app reviews using xgboost classifier," in *2021 International Conference on Artificial Intelligence and Big Data Analytics*, 2021, pp. 22–27.
- [79] M. Radhiya, Adiwijaya, M. D. Purbolaksono, "Sentiment analysis on food review from website zomato using k-nearest neighbor (knn) algorithm," in *2022 1st International Conference on Software Engineering and Information Technology (ICoSEIT)*, 2022, pp. 250–255.
- [80] P. Z. Lodetti, E. A. C. A. Neto, M. A. I. Martins, G. H. D. S. Costa, M. A. Ludwig, "Mae and rmse analysis of k-means predictive algorithm for photovoltaic generation," in *2022 International Conference on Electrical, Computer and Energy Technologies (ICECET)*, 2022, pp. 1–6.
- [81] R. Douss, I. R. Ferah, S. Durrieu, F. De Boissieu, "Regression analyses to study the benefit of sentinel and lidar data fusion for forest structure," in *2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS)*, 2020, pp. 359–362.
- [82] R. Ghanbari, K. Borna, "Multivariate time-series prediction using lstm neural networks," in *2021 26th International Computer Conference, Computer Society of Iran (CSICC)*, 2021, pp. 1–5.
- [83] *Bersozgithub*. [Online]. Available: <https://github.com/ersozbasak/Machine-Learning-Regression-Models/tree/018309f1ab4b01967dae4c8d3be2187c7bbc7b61>.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. B. E. Yildirim, S. Yildiz, A. S. Turkoglu, O. Erdinc and A. R. Boynuegri, "Evaluating LMP Forecasting with LSTM Networks: A Deep Learning Approach to Analyzing Electricity Prices During Unpredictable Events," 2023 5th Global Power, Energy and Communication Conference (GPECOM), Nevsehir, Turkiye, 2023, pp. 477-482, doi: 10.1109/GPECOM58364.2023.10175743.