



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ELEKTRİK ENERJİSİ TALEP TAHMİNİ: AYDIN, DENİZLİ VE MUĞLA
BÖLGESİ ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

Hakan ELBAŞ

Akıllı Sistemler Mühendisliği Anabilim Dalı

Akıllı Sistemler Mühendisliği Tezli Yüksek Lisans Programı

OCAK 2025

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ELEKTRİK ENERJİSİ TALEP TAHMİNİ: AYDIN, DENİZLİ VE MUĞLA
BÖLGESİ ÖRNEĞİ**

YÜKSEK LİSANS TEZİ

**Hakan ELBAŞ
(21434998014)**

**Akıllı Sistemler Mühendisliği Anabilim Dalı
Akıllı Sistemler Mühendisliği Tezli Yüksek Lisans Programı**

Danışman: Prof. Dr. Turgay Tugay BİLGİN

OCAK 2025

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 21434998014 numaralı Yüksek Lisans Öğrencisi Hakan ELBAŞ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ELEKTRİK ENERJİSİ TALEP TAHMİNİ: AYDIN, DENİZLİ VE MUĞLA BÖLGESİ ÖRNEĞİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Turgay Tugay BİLGİN**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Kubilay DEMİR**
Bursa Teknik Üniversitesi

Doç. Dr. Ersen YILMAZ
Uludağ Üniversitesi

Teslim Tarihi :
Savunma Tarihi : 03 Şubat 2025



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Hakan ELBAŞ

İmzası:



Aileme,

ÖNSÖZ

Akademik yolculuğum boyunca bana her daim destek olan sevgili aileme en derin minnettarlığımı sunmak isterim. Bu tezin her aşamasında sabrı ve anlayışıyla yanımda olan değerli danışmanım Prof. Dr. Turgay Tugay Bilgin'e içtenlikle teşekkür ederim. Kendisi, bilgi ve rehberliğiyle bu çalışmayı başarıyla tamamlamamda büyük bir rol oynamıştır.

Ayrıca, süreç boyunca bilgi ve deneyimlerini benimle cömertçe paylaşan iş arkadaşlarıma, her zaman yanımda olan müdürüme ve yöneticime teşekkür etmek istiyorum. Profesyonel yaşamımda gösterdikleri anlayış ve verdikleri destek, bu tezin hayata geçirilmesine önemli katkılar sağlamıştır.

Bu çalışma, elektrik talep tahmininde modern derin öğrenme ve makine öğrenimi yaklaşımlarının etkinliğini ortaya koymayı amaçlamaktadır. Bu tezin, enerji yönetimi ve tahmin modelleri alanında yeni ufuklar açarak gelecekteki araştırmalara ilham kaynağı olmasını yürekten temenni ederim.

Ocak 2025

Hakan ELBAŞ

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	viii
KISALTMALAR	x
SEMBOLLER	xi
ÇİZELGE LİSTESİ.....	xii
ŞEKİL LİSTESİ.....	xiii
ÖZET.....	xv
SUMMARY	xvi
1. GİRİŞ	1
1.1 Tezin Motivasyonu.....	2
1.2 Tezin Amacı	3
1.3 Tezin Katkıları ve Ana Hatları	4
2. LİTERATÜR TARAMASI	7
2.1 Elektrik Tüketimini Etkileyen Faktörler	7
2.2 Talep Tahmin Yöntemleri	12
2.2.1 İstatiksel yöntemler	12
2.2.2 Makine öğrenmesi tabanlı yöntemler.....	17
2.2.3 Hibrit yöntemler.....	22
3. TÜRKİYE ELEKTRİK PİYASASI.....	26
3.1 Türkiye Elektrik Enerjisi Piyasasının Gelişimi	26
3.1.1 1980 öncesi dönem.....	28
3.1.2 1980 sonrası özelleştirme dönemi ve 3096 Sayılı Kanun	29
3.1.3 1990'lı yıllar ve 3996 Sayılı Kanun	30
3.1.4 4628 Sayılı Elektrik Piyasası Kanunu ve EPDK'nın kurulması	31
3.2 Gün Öncesi ve Gün İçi Piyasası	33
4. MATERYAL VE YÖNTEM.....	35
4.1 Yapay Sinir Ağlarının Öğrenmesi.....	35
4.1.1 İleri yayılım ve geri yayılım.....	38
4.1.2 Optimizasyon algoritmaları.....	41
4.1.3 Aktivasyon fonksiyonları	46
4.1.3.1 Sigmoid fonksiyonu	47
4.1.3.2 Düzeltilmiş lineer birim (ReLU) fonksiyonu	48
4.1.3.3 Hiperbolik tanjant fonksiyonu	49
4.1.3.4 Softmax fonksiyonu	50
4.2 Derin Öğrenme Mimarileri ve Catboost.....	50
4.2.1 Zaman serilerinde derin öğrenme mimarileri.....	51
4.2.1.1 Tekrarlayan sinir ağları (RNN)	52
4.2.1.2 Uzun kısa süreli bellek (LSTM).....	54
4.2.1.3 Çift yönlü uzun kısa süreli bellek (BiLSTM)	56
4.2.1.4 Transformer.....	57

4.2.1.5 CatBoost	60
4.3 Performans Metrikleri	61
4.3.1 Ortalama mutlak yüzde hata (MAPE)	61
4.3.2 Kök ortalama kare hatası (RMSE)	62
5. UYGULAMA	63
5.1 Veri Toplama Süreci	63
5.1.1 Elektrik tüketim verilerinin toplanması	63
5.1.2 Hava durumu verilerinin toplanması	64
5.1.3 Solar verilerinin toplanması	65
5.2 Keşifsel Veri Analizi (EDA)	66
5.3 Veri Setinin Hazırlanması ve Özellik Mühendisliği	73
5.3.1 Özellik mühendisliği mimarisi	73
5.3.2 Lag (gecikme) özellikleri	75
5.3.3 Mevsimsellik ve spline özellikleri	76
5.3.3.1 Trigonometrik dönüşümler	76
5.3.3.2 Spline dönüşümleri	76
5.3.4 Zaman özellikleri	78
5.4 Simülasyon Ortamı ve Test Süreci	78
5.4.1 Birinci simülasyon ortamı	80
5.4.2 İkinci simülasyon ortamı	81
5.5 Zaman Serisi Modelleri	82
5.5.1 BiLSTM modeli	82
5.5.2 Transformer modeli	85
5.5.3 CatBoost modeli	87
5.6 Test Sonuçları	89
5.6.1 Birinci simülasyon sonuçları	89
5.6.2 İkinci simülasyon sonuçları	91
6. BULGULAR VE YORUMLAR	94
KAYNAKLAR	96
ÖZGEÇMİŞ	104

KISALTMALAR

Adam	: Uyarlamalı Moment Tahmini – Adaptive Moment Estimation
ARIMA	: Otoregresif Entegre Hareketli Ortalama – Auto Regressive Integrated Moving Average
BiLSTM	: Çift Yönlü Uzun Kısa Süreli Bellek – Bidirectional Long Short-Term Memory
DGP	: Dengesizlik Güç Piyasası
EPIAŞ	: Enerji Piyasaları İşletme A.Ş - EXIST
GİP	: Gün İçi Piyasası
GÖP	: Gün Öncesi Piyasası
GPU	: Grafik İşleme Birimi – Graphics Processing Unit
GRU	: Kapılı Yinelemeli Birim – Gated Recurrent Unit
GSYİH	: Gayri Safı Yurt İçi Hasıla – Gross Domestic Product (GDP)
HVAC	: Isıtma, Havalandırma ve İklimlendirme – Heating, Ventilation, and Air Conditioning
LSTM	: Uzun Kısa Süreli Bellek – Long Short-Term Memory
MAPE	: Ortalama Mutlak Yüzde Hatası – Mean Absolute Percentage Error
ReLU	: Düzeltilmiş Doğrusal Birim – Rectified Linear Unit
RMSE	: Kök Ortalama Kare Hatası – Root Mean Square Error
RNN	: Tekrarlayan Sinir Ağları – Recurrent Neural Network
SARIMA	: Mevsimsel Otoregresif Entegre Hareketli Ortalama – Seasonal Auto Regressive Integrated Moving Average
SARIMAX	: Mevsimsel Otoregresif Entegre Hareketli Ortalama Dışsal Değişkenli – Seasonal Auto Regressive Integrated Moving Average with Exogenous Variables
SGD	: Stokastik Gradyan İnişi – Stochastic Gradient Descent
Tanh	: Hiperbolik Tanjant – Hyperbolic Tangent
TCDD	: Türkiye Cumhuriyeti Devlet Demiryolları
TEDAŞ	: Türkiye Elektrik Dağıtım Anonim Şirketi
TEK	: Türkiye Elektrik Kurumu
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi

SEMBOLLER

b	: Bias katsayısı
ε	: Hata değeri
$\mathcal{L}$	: Kayıp fonksiyonu
η	: Öğrenme oranı
θ	: Model parametresi
σ	: Sigma parametresi
λ	: Keskinlik parametresi

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Türkiye'nin 2023 yılındaki mevsimsel elektrik talebi.	9
Çizelge 3.1 : Türkiye enerji piyasası gelişimler.	27
Çizelge 5.1 : Elektrik tüketim verisinin istatiksel özeti.	67
Çizelge 5.2 : Yıllara göre elektrik tüketim verisinin istatiksel özeti.	67
Çizelge 5.3 : 15 günlük mart ve temmuz ayı gerçekleşme istatistikleri.	79
Çizelge 5.4 : Birinci senaryo model sonuçları.	89
Çizelge 5.5 : İkinci simülasyon model sonuçları.	91

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Türkiye'deki elektrik tüketiminin logaritması ile reel GSYİH arasındaki korelasyon grafiği (Altınay ve Karagöl, 2005).	7
Şekil 2.2 : Türkiye'de 1990'dan 2022'ye kadar kişi başına elektrik tüketimi (Dierks, 2024).....	8
Şekil 2.3 : 2016-2020 yılları arasında Ocak-Haziran dönemi ticari tüketimi (Kök ve diğ, 2022).....	10
Şekil 2.4 : 2016-2020 yılları arasında Ocak-Haziran dönemi sanayi tüketimi (Kök ve diğ, 2022).....	11
Şekil 2.5 : 2016-2020 yılları arasında Ocak-Haziran dönemi konut tüketimi (Kök ve diğ, 2022).....	11
Şekil 3.1 : 2015 yılı Türkiye elektrik piyasası işlem hacimleri.	34
Şekil 4.1 : Nöron yapısı (Abraham, 2005).....	36
Şekil 4.2 : (a) Yapay nöron (b) Çok katmanlı yapay sinir ağı mimarisi (Abraham, 2005).....	37
Şekil 4.3 : Örnek bir ileri beslemeli sinir ağı (Naumov, 2017).	39
Şekil 4.4 : Gradyan inişi algoritması.	42
Şekil 4.5 : Momentum etkisinin SGD optimizasyonu üzerindeki karşılaştırması (LeCun et al., 2002).....	43
Şekil 4.6 : Yapay nöron ile aktivasyon fonksiyonu ilişkisinin temsili gösterimi (Sibi ve diğ, 2013).	47
Şekil 4.7 : Sigmoid fonksiyonu (Pan ve diğ, 2022).	47
Şekil 4.8 : ReLU fonksiyonu (Pratiwi ve diğ, 2020).	48
Şekil 4.9 : Tekrarlayan sinir ağları yapısı (Kingma, 2014).	53
Şekil 4.10 : (a) Orijinal bir LSTM birim mimarisi: basit bir LSTM hücresi; (b) Unutma kapısı olan bir LSTM hücresi; (c) Unutma kapısı ile modern bir LSTM hücresinin gösterimi (Smagulova ve Jame, 2019).	55
Şekil 4.11 : LSTM ve BiLSTM mimarilerinin karşılaştırılması (Shen ve diğ. 2021).	56
Şekil 4.12 : BiLSTM ağının iç mimarisi (Nacer ve diğ. 2023).	57
Şekil 4.13 : Transformerın iç mimarisi (Ahmed ve diğ, 2023).	58
Şekil 5.1 : PVlib ile veri çekme gövdesi.....	66
Şekil 5.2 : Normalize elektrik tüketim verisi.....	67
Şekil 5.3 : Genel veri seti için sıcaklık ve dağıtılan enerji korelasyon matrisi ısı haritası.	69
Şekil 5.4 : Mevsimlere göre haftalık toplam sıcaklık ve dağıtılan enerji korelasyon matrisi ısı haritaları.....	69
Şekil 5.5 : Bağlı nem, rüzgar hızı, rüzgar yönü, bulutluluk oranı, radyasyon ve yağış değişkenlerinin tüketilen elektrik enerjisiyle korelasyon matrisi ısı haritaları.....	71

Şekil 5.6 : Tüketilen elektriğin, bağıl nem, rüzgar hızı, rüzgar yönü, bulutluluk oranı, radyasyon, yağışa göre mevsimsel korelasyon değerleri.	71
Şekil 5.7 : Mevsimlere göre solar verileri ve tüketilen enerji korelasyon matrisi ısı haritaları.	72
Şekil 5.8 : Özellik çıkarımı sürecinde kullanılacak veri kaynaklarının belirlenmesi.	74
Şekil 5.9 : Özellik çıkarımı sürecinde kullanılacak özellik türlerinin belirlenmesi. .	74
Şekil 5.10 : Lag özellikleri çıkarılmasında kullanılan fonksiyon.	75
Şekil 5.11 : Solar verilerinde lag özelliği çıkarılacak kolonların belirlenmesi.....	75
Şekil 5.12 : Solar verilerinde lag özelliği çıkarılacak zaman aralıklarının belirlenmesi.	75
Şekil 5.13 : Örnek lag_features fonksiyonu çağırılması.	75
Şekil 5.14 : Eğitim – test bölünme gösterimi.	79
Şekil 5.15 : Birinci simülasyon akış diyagramı.	80
Şekil 5.16 : İkinci simülasyon akış diyagramı.	81
Şekil 5.17 : BiLSTM modelinin mimarisi.	83
Şekil 5.18 : BiLSTM eğitimi sırasında uygulanan optimize tekniklerinin kodları....	84
Şekil 5.19 : Transformer modelinin mimarisi.....	85
Şekil 5.20 : BiLSTM eğitimi sırasında uygulanan optimize tekniklerinin kodları....	86
Şekil 5.21 : CatBoost modeli için bayes optimizasyon süreci Python kodları.	88
Şekil 5.22 : Birinci simülasyon mart testi gerçekleşme ve tahmin grafiği.	89
Şekil 5.23 : Birinci simülasyon mart testi günlük MAPE grafiği.	90
Şekil 5.24 : Birinci simülasyon temmuz testi gerçekleşme ve tahmin grafiği.	90
Şekil 5.25 : Birinci simülasyon temmuz testi günlük MAPE grafiği.	91
Şekil 5.26 : İkinci simülasyon mart testi gerçekleşme ve tahmin grafiği.	92
Şekil 5.27 : İkinci simülasyon mart testi günlük MAPE grafiği.	92
Şekil 5.28 : İkinci simülasyon temmuz testi gerçekleşme ve tahmin grafiği.	93
Şekil 5.29 : İkinci simülasyon temmuz testi günlük MAPE grafiği.	93

ELEKTRİK ENERJİSİ TALEP TAHMİNİ: AYDIN, DENİZLİ VE MUĞLA BÖLGESİ ÖRNEĞİ

ÖZET

Bu çalışma, Türkiye elektrik piyasasında faaliyet gösteren dağıtım ve perakende şirketlerinin enerji tahmin algoritmalarını geliştirme sürecinde karşılaştıkları zorlukları ele alarak, Aydın, Denizli ve Muğla illerinin toplam elektrik tüketimini saatlik olarak tahmin etmeyi amaçlamaktadır. Temel hedef, enerji dağıtımında tahmin doğruluğunu artırmak, mevsimsel ve bölgesel talep değişkenliklerini analiz etmek ve hangi modellerin daha başarılı sonuçlar verdiğini belirlemektir. Bu doğrultuda CatBoost, BiLSTM ve Transformer modelleri kullanılarak saatlik elektrik talep tahminleri gerçekleştirilmiştir.

Elektrik tüketim tahminleri, 24 saatlik olarak tahmin edilmiştir. Tahminleri iki farklı senaryo ve iki farklı zaman dilimi üzerinden oluşturulmuştur. Senaryo yapısının amacı, gün içi ve gün öncesi piyasası işlemleri sonuçlarını simüle etmektir. Birinci senaryo ilk olarak her günün tahminini yaparken bir önceki günün son saatine (t-1) kadar olan verilere erişim sağlamaktadır. İkinci senaryoda ise iki gün öncesinin son saat verisine (t-25) erişim sağlamaktadır. Ayrıca modellerin farklı zaman dilimlerine nasıl tepki verdikleri gözlemlenmesi adına mart ve temmuz aylarından 15 günlük tahminler yapılmıştır. Böylelikle farklı durumlara karşı model performansları incelenebilmiştir.

Tahmin performansları MAPE ve RMSE metrikleri ile ölçülmüş ve CatBoost modelinin her iki senaryoda da en başarılı tahmin performansını sunduğunu göstermiştir. Transformer modeli, mart ayının stabil talep desenlerinde CatBoost'a yakın sonuçlar üretirken, temmuz ayının dalgalı talep yapısında performansında düşüş gözlemlenmiştir. BiLSTM modeli ise zaman serisi verilerindeki kısa vadeli dalgalanmaları yeterince yakalayamaması nedeniyle her iki senaryoda da daha yüksek hata oranlarına sahip olmuştur. Çalışmada kullanılan yaklaşımların hem gün içi piyasası hem de gün öncesi piyasası işlemlerinde güvenilir tahminlerin yapılabilmesini ve dağıtım ile perakende şirketlerinin piyasa işlemlerinde zararlarını minimize edebilecek stratejiler geliştirebileceğini göstermektedir.

Bu çalışma, elektrik talep tahmin modellerinin mevsimsel ve bölgesel dinamiklere adapte edilmesi gerektiğini vurgulamakta ve enerji yönetimi süreçlerinde veri odaklı stratejilerin geliştirilmesine önemli katkılar sunmaktadır. Elde edilen bulgular, enerji planlama ve piyasa stratejilerinin daha güvenilir ve etkin hale getirilmesine olanak sağlayarak sektöre değerli bir rehber niteliği taşımaktadır.

Anahtar kelimeler: Derin öğrenme, Makine öğrenmesi, Zaman serisi, Türkiye elektrik piyasası, CatBoost, Çift yönlü uzun kısa süreli bellek, Transformer.

ELECTRIC ENERGY DEMAND FORECASTING: THE CASE OF AYDIN, DENIZLI, AND MUĞLA REGIONS

SUMMARY

This study aims to forecast the hourly electricity consumption of Aydın, Denizli, and Muğla provinces by addressing the challenges faced by distribution and retail companies operating in the Turkish electricity market during the development of energy prediction algorithms. The primary objective is to enhance forecast accuracy in energy distribution, analyze seasonal and regional demand variability, and identify which models yield the most successful results. Accordingly, hourly electricity demand forecasts were conducted using CatBoost, BiLSTM, and Transformer models.

Electricity consumption forecasts were made on a 24-hour basis across two different scenarios and timeframes. The purpose of these scenarios is to simulate the outcomes of Day-Ahead Market (DAM) and Intraday Market (IDM) operations. In the first scenario, the forecast for each day was made using data up to the last hour of the previous day (t-1). In the second scenario, data from two days prior (t-25) were used. Additionally, 15 day forecasts were made for March and July to observe how the models responded to different time periods. This approach allowed for a detailed performance comparison of the models under varying conditions.

Forecast performance was evaluated using the MAPE (Mean Absolute Percentage Error) and RMSE (Root Mean Squared Error) metrics. The results demonstrated that the CatBoost model consistently delivered the most accurate predictions across both scenarios. While the Transformer model produced results comparable to CatBoost during March's stable demand patterns, its performance declined under the volatile demand patterns observed in July. On the other hand, the BiLSTM model exhibited higher error rates in both scenarios due to its limited ability to capture short-term fluctuations in time series data.

The findings indicate that the approaches used in this study enable reliable forecasts for both Day-Ahead Market (DAM) and Intraday Market (IDM) operations. Furthermore, these results suggest that distribution and retail companies can develop strategies to minimize financial losses in market transactions by leveraging these predictive models effectively.

This study emphasizes the necessity of adapting electricity demand forecasting models to seasonal and regional dynamics, offering significant contributions to the development of data driven strategies in energy management processes. The findings provide valuable insights for improving the reliability and efficiency of energy planning and market strategies, serving as a practical guide for stakeholders in the energy sector.

Keywords: Deep learning, Machine learning, Time series, Turkish electricity market, CatBoost, Bidirectional long short term memory (BiLSTM), Transformer.



1. GİRİŞ

Elektrik enerjisi, günlük yaşamdan endüstriyel faaliyetlere kadar geniş bir uygulama yelpazesıyla kritik bir enerji kaynağıdır. Bu enerji, petrol, kömür, doğalgaz, nükleer enerji, hidroelektrik, biyokütle, gelgit, güneş ve rüzgar enerjisi gibi birincil enerji kaynaklarının dönüştürülmesiyle üretilir. Ancak, sürekli artan elektrik talebi, kaynak kısıtlamaları ve elektriğin depolanmasıyla ilgili zorluklar, ülkeleri ve sektör katılımcılarını çeşitli planlama stratejileri uygulamaya zorlamaktadır (Haliloğlu ve Tutu, 2018).

Elektrik enerjisi, üretildikten hemen sonra tüketilmesi gereken bir enerji biçimidir. Bununla birlikte, tüketim miktarı zaman içinde değişkenlik göstermekte; aylık, günlük ve hatta saatlik dalgalanmalar yaşanmaktadır. Elektrik şebekelerinin bu anlık yük taleplerini karşılayabilmesi ve uzun vadede artan enerji ihtiyacına yanıt verebilmesi gereklidir (Şener, 2005). Öte yandan, talep tahminlerinin arzi aşması durumunda, elektrik üretiminde aşırı yüksek maliyetler ortaya çıkabilir. Bu noktada, gelecekteki elektrik talebini tahmin etmek, elektrik şebekelerinin etkin planlanması için kritik bir adım haline gelmektedir (Boltürk, 2013).

Uzun vadeli elektrik tüketimi tahmini, stratejik yatırım kararlarının şekillendirilmesi açısından büyük öneme sahiptir. Bu tahminlere dayalı yatırım kararları, enerji sektöründe gerekli kapasitenin belirlenmesinde kritik bir rol oynar. Ancak, aşırı yatırım yapılması durumunda, gereksiz kapasite israfı ve yatırımlara ayrılan kaynakların etkisiz kullanımı söz konusu olabilir. Tersine, talebin hafife alınması ve sistemin yanlış tasarımı, temel elektrik kesintileri gibi çeşitli sorunlara yol açabilir. Bu durum, bireysel refahı ve ekonomik büyümeyi olumsuz etkiler. Bu nedenle, enerji sektöründe sürdürülebilirlik ve kaynakların verimli kullanımı için doğru ve güvenilir uzun vadeli tahminler oldukça önemlidir (Akman ve diğ, 2018).

Elektrik yük tahmini, geçmiş ve mevcut koşulların ayrıntılı bir şekilde analiz edilerek değişim kalıplarının belirlenmesi ve gelecekteki talebin tahmin edilmesi esasına dayanır. Bu tahmin sürecinde nüfus artışı, bölgenin coğrafi koşulları, tarihsel yük

özellikleri, gayrisafi milli hasıla (GSMH) ve teknolojik gelişmeler gibi faktörler önemli bir rol oynar (Yoldaş, 2006). Bu faktörler, elektrik talebindeki değişimleri anlamamıza ve geleceğe yönelik daha doğru öngörülerde bulunmamıza yardımcı olmaktadır.

Uzun yıllardır elektrik enerjisi talep tahmini üzerine çeşitli yöntemler geliştirilmiş ve bu alanda önemli ilerlemeler kaydedilmiştir. İlk olarak istatistiksel yöntemlerle temelleri atılan bu çalışmalar, günümüzde makine öğrenimi ve derin öğrenme gibi ileri teknolojilerle desteklenerek daha hassas ve güvenilir sonuçlar sağlayacak hale gelmiştir. Artan veri miktarı ve hesaplama gücü, enerji sektöründe daha akıllı ve dinamik planlama stratejilerinin uygulanmasına olanak tanımaktadır. Bu ilerlemeler, elektrik arz ve talep dengesinin korunmasına yardımcı olurken, ekonomik ve çevresel sürdürülebilirlik hedeflerine ulaşılmasını da kolaylaştırmaktadır.

1.1 Tezin Motivasyonu

Elektrik enerjisi, sanayiden günlük yaşama kadar geniş bir kullanım alanına sahip kritik bir enerji kaynağıdır. Talebin sürekli artması, enerji üretim ve iletim altyapılarının verimli ve sürdürülebilir bir şekilde yönetilmesini zorunlu hale getirmektedir. Türkiye, artan nüfusu ve genişleyen sanayi yapısıyla sürekli yükselen bir enerji talebiyle karşı karşıyadır. Elektrik enerjisinin depolanamaması ve üretildiği anda tüketilmesi gerekliliği, arz ve talep dengesinin hassasiyetle planlanmasını daha önemli bir hale getirmektedir.

Elektrik talep tahmini, enerji arz güvenliğinin sağlanması, maliyetlerin optimize edilmesi ve doğru yatırım stratejilerinin belirlenmesi açısından kritik bir araçtır. Doğru tahminler, fazla ya da yetersiz yatırım risklerini azaltarak ekonomik verimliliği artırır. Türkiye’de elektrik talep tahmini üzerine yapılan çalışmalar, istatistiksel yöntemler, makine öğrenimi algoritmaları ve hibrit modellerin kullanımına odaklanmıştır. Ancak bu çalışmaların çoğu, belirli yöntemlerle sınırlı kalmış ve geniş kapsamlı performans analizleri yeterince ele alınmamıştır.

Bu tez çalışmasının temel motivasyonu, kısa vadeli elektrik talep tahmini için CatBoost, BiLSTM ve Transformer gibi ileri düzey makine öğrenimi ve derin öğrenme algoritmalarının performansını karşılaştırmak, güçlü ve zayıf yönlerini analiz etmek ve Türkiye enerji piyasasına entegre edilebilir güvenilir bir model geliştirmektir.

Ayrıca, bu çalışma gelecekteki araştırmalara metodolojik bir çerçeve sunarak enerji politikalarının daha etkin planlanmasına katkıda bulunmayı hedeflemektedir.

Enerji sektöründe kısa vadeli tahminler, özellikle Gün Öncesi Piyasası (GÖP) ve Gün İçi Piyasası (GİP) gibi dinamik mekanizmaların etkin çalışması açısından büyük önem taşımaktadır. Bu bağlamda, doğru talep tahminleri, fiyat dalgalanmalarının minimize edilmesine ve enerji arz güvenliğinin sağlanmasına doğrudan katkıda bulunmaktadır.

1.2 Tezin Amacı

Bu çalışmanın temel amacı, Türkiye'deki Aydın, Denizli ve Muğla illerinin saatlik elektrik talebini kısa vadede doğru ve güvenilir bir şekilde tahmin eden modeller geliştirmek ve bu modellerin performanslarını karşılaştırarak sektörel uygulanabilirliklerini değerlendirmektir. Bu amaç doğrultusunda, CatBoost, BiLSTM ve Transformer gibi makine öğrenimi ve derin öğrenme algoritmalarının etkinliği detaylı bir şekilde karşılaştırılacaktır.

Bu kapsamda belirlenen alt hedefler şunlardır:

- Algoritmaların Performans Karşılaştırması: CatBoost, BiLSTM ve Transformer algoritmalarının tahmin doğruluğu, hata oranları (MAPE, RMSE) performanslarını değerlendirmek.
- Optimum Model Seçimi: Karşılaştırma sonuçlarına dayanarak Türkiye enerji piyasasında kısa vadeli talep tahmini için en uygun model veya model kombinasyonunu belirlemek.
- Veri Setinin Etkin Kullanımı: Tarihsel tüketim verileri, hava durumu değişkenleri ve ekonomik göstergeler gibi değişkenlerin analizi ile modele en yüksek katkıyı sağlayacak değişkenleri belirlemek.
- Türkiye Enerji Piyasasına Entegrasyon: Geliştirilen ve doğruluğu kanıtlanan modelin Gün Öncesi Piyasası (GÖP) ve Gün İçi Piyasası (GİP) gibi mekanizmalara nasıl entegre edilebileceğini değerlendirmek.
- Sürdürülebilir Enerji Planlaması: Çalışmanın bulgularının enerji arz güvenliğine, maliyet optimizasyonuna ve ekonomik verimliliğe katkılarını analiz etmek.

- Gelecek Çalışmalar İçin Zemin Hazırlama: Araştırmanın, benzer tahmin modelleri ve algoritmalar üzerinde yapılacak gelecekteki çalışmalara metodolojik bir çerçeve sağlaması.

Bu tez çalışması, kısa vadeli elektrik talep tahminlerinin doğruluğunu artırarak enerji piyasasındaki belirsizlikleri azaltmayı, maliyetleri optimize etmeyi ve kaynakların verimli kullanılmasını sağlamayı amaçlamaktadır. Ayrıca, geliştirilen model ve elde edilen bulguların Türkiye enerji piyasası için somut ve uygulanabilir çıktılar üretmesi hedeflenmektedir.

1.3 Tezin Katkıları ve Ana Hatları

Bu tez çalışması, zaman serisi tahmini alanında yenilikçi ve güçlü performans gösteren makine öğrenmesi tabanlı modellerin karşılaştırmalı analizini sunarak, elektrik tüketim tahmini literatürüne önemli katkılar sağlamaktadır. Çalışma kapsamında geliştirilen metodoloji, özellikle Aydın, Denizli ve Muğla illerinin elektrik tüketim karakteristiklerini dikkate alarak, bölgesel ve mevsimsel dinamiklerin tahmin modellerine etkisini detaylı bir şekilde incelemektedir.

Çalışmanın elektrik tüketim tahmininde sunduğu temel yenilik, CatBoost, BiLSTM ve Transformer modellerinin performanslarının sistematik bir karşılaştırmasını yaparak, her bir modelin farklı koşullar altındaki etkinliğini ortaya koymasıdır. Özellikle mevsimsel farklılıkların belirgin olduğu mart ve temmuz aylarında yapılan analizler, modellerin değişen talep desenlerine adaptasyon yeteneklerini göstermektedir. CatBoost modelinin her iki dönemde de tutarlı performans göstermesi, kategorik verileri işleme ve ani talep değişimlerine adaptasyon konusundaki üstünlüğünü ortaya koymaktadır.

Veri entegrasyonu ve özellik mühendisliği açısından çalışma, kapsamlı bir yaklaşım sunmaktadır. ADM Elektrik Dağıtım'dan temin edilen saatlik elektrik tüketim verileri, Enercast platformundan alınan detaylı meteorolojik veriler ve PVlib kütüphanesi kullanılarak elde edilen solar veriler, 127 farklı değişkenden oluşan zengin bir veri setinin oluşturulmasını sağlamıştır. Bu veri çeşitliliği, tahmin modellerinin çok boyutlu bir analiz yapabilmesine olanak tanımıştır.

Çalışmada ele alınan bölgelerin özel karakteristikleri, tahmin modellerinin geliştirilmesinde önemli rol oynamıştır. Aydın ve Muğla'nın kış aylarında ısınma

amaçlı elektrik kullanımı, Denizli, Aydın ve Muğla'nın yaz aylarında soğutma sistemlerinden kaynaklanan yüksek tüketimi gibi bölgesel özellikler, modellerin bu farklı tüketim desenlerini öğrenmesini ve tahminlerini buna göre ayarlamasını gerektirmiştir. Bu açıdan çalışma, bölgesel karakteristiklerin tahmin modellerine entegrasyonu konusunda değerli içgörüler sunmaktadır.

Metodolojik açıdan çalışma, özellik mühendisliği teknikleri ve veri ön işleme süreçleri konusunda detaylı bir çerçeve sunmaktadır. Ham verilerden anlamlı ve modele katkı sağlayacak yeni özniteliklerin türetilmesi, korelasyon analizleri ve keşifsel veri analizleri sonucunda belirlenen ilişkilerin modellemeye dahil edilmesi, çalışmanın metodolojik katkıları arasındadır.

Tezin ana hatları şu şekilde organize edilmiştir:

Birinci bölümde, elektrik tüketim tahmininin önemi, çalışmanın motivasyonu ve amaçları detaylı bir şekilde ele alınmıştır. Elektrik talebini etkileyen faktörler ve tahmin modellerinin gerekliliği vurgulanmıştır.

İkinci bölümde, elektrik tüketim tahmini alanında yapılan önceki çalışmalar incelenmiş, farklı yaklaşımların avantaj ve dezavantajları değerlendirilmiştir. Literatürde kullanılan zaman serisi tahmin yöntemleri ve güncel çalışmalar detaylı bir şekilde analiz edilmiştir.

Üçüncü bölümde, Türkiye elektrik piyasasının yapısı ve işleyişi ele alınmış, özellikle Gün Öncesi Piyasası ve Gün İçi Piyasası mekanizmalarının işleyişi açıklanmıştır.

Dördüncü bölümde, derin öğrenme tekniklerinin teorik altyapısı sunulmuş ve bu çalışmada kullanılan yöntemlerin zaman serisi tahmini üzerindeki rolleri detaylandırılmıştır. Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Süreli Bellek (LSTM), Çift Yönlü LSTM (BiLSTM), Transformer, CatBoost gibi modellerin mimari özellikleri açıklanmış, bu mimarilerin zamansal bağımlılıkları modelleme konusundaki avantajları incelenmiştir.

Beşinci bölümde, veri toplama ve ön işleme süreçleri, özellik mühendisliği teknikleri ve model geliştirme aşamaları açıklanmıştır. Ayrıca modellerin eğitim ve test süreçleri ile performans karşılaştırmaları detaylı bir şekilde sunulmuştur.

Son bölümde, elde edilen sonuçlar değerlendirilmiş ve özellikle tüketilen enerjide kesintilerin normalizasyonu, yenilenebilir enerji kaynaklarının entegrasyonu, hava

durumu tahmin verilerinin kalitesi ve ileri düzey tahmin modellerinin geliştirilmesi konusundaki potansiyel araştırma alanları vurgulanmıştır. Bu tez çalışması, elektrik tüketim tahmininde kullanılan modern yaklaşımların karşılaştırmalı analizini sunarak, enerji sektöründeki planlama ve optimizasyon süreçlerine önemli katkılar sağlamakta; aynı zamanda gelecekte yapılacak benzer çalışmalar için değerli bir referans kaynağı oluşturmaktadır.




2. LİTERATÜR TARAMASI

2.1 Elektrik Tüketimini Etkileyen Faktörler

Bu bölümde, farklı vaka çalışmalarından elde edilen bulgular doğrultusunda, elektrik talep tahminlerini etkileyen faktörler ele alınacak ve bu faktörlerin tahmin modelleri üzerindeki yansımaları değerlendirilecektir. Bu analizler, gelecekteki enerji talep projeksiyonlarının daha sağlam ve güvenilir temellere dayanmasına katkı sağlarken, politika yapıcılar ve sektör paydaşları için stratejik kararların alınmasında önemli bir rehber olacaktır.


Türkiye'deki elektrik tüketimi ile ekonomik büyüme arasındaki ilişki, özellikle bu iki değişkenin birbirini nasıl etkilediği açısından önemli bir akademik ilgi odağı olmuştur. Altınay ve Karagöl (2005), Türkiye'de elektrik tüketiminden ekonomik büyümeye doğru tek yönlü bir nedensellik ilişkisi olduğunu belirtmektedir. Bu bulgu, artan elektrik tüketiminin ekonomik büyüme üzerinde itici bir güç olduğunu ve ekonomik kalkınmanın sürdürülebilirliği için enerji politikalarının kritik bir rol oynadığını göstermektedir. Şekil 3'te, elektrik tüketiminin logaritması ile Türkiye'nin Gayrisafi yurt içi hasıla (GSYİH) arasındaki korelasyon sunulmaktadır.



Şekil 2.1 : Türkiye'deki elektrik tüketiminin logaritması ile reel GSYİH arasındaki korelasyon grafiği (Altınay ve Karagöl, 2005).

Dierks (2024) Türkiye'deki elektrik tüketimi ile ekonomik büyüme arasındaki ilişkiyi incelemiş ve bu iki değişkenin birbirini karşılıklı olarak etkilediğini ortaya koymuştur.

Şekil 2.2’de gösterilen kişi başına elektrik tüketimindeki uzun dönem eğilimi, ekonomik büyüme gibi çeşitli faktörlerin 1990’dan 2022’ye kadar enerji kullanımındaki sürekli artışa nasıl katkı sağladığını yansıtmaktadır.



Şekil 2.2 : Türkiye’de 1990’dan 2022’ye kadar kişi başına elektrik tüketimi (Dierks, 2024).

Sanayi üretimi, enerji yoğun üretim ve imalat faaliyetleri nedeniyle elektrik talebini artırmada önemli bir role sahiptir. Sanayi sektörü büyüdükçe, makine, ekipman ve üretim süreçlerini çalıştırmak için gerekli olan elektrik ihtiyacı da artar. Bu talep, ekonomik döngülerden de etkilenir; ekonomik büyüme dönemlerinde sanayi üretimi artar ve dolayısıyla elektrik tüketimi yükselir. Arısoy ve Öztürk (2014), ekonomik aktivitedeki dalgalanmaların enerji tüketimi üzerinde doğrudan bir etkiye sahip olduğunu ve sanayi ile konut elektrik talebinin ekonomik değişkenlere duyarlılığını vurgulamıştır.

Türkiye’deki sektörel elektrik tüketimi, enerji talebinin doğru bir şekilde tahmin edilmesinde kritik bir faktördür. Sanayi, konut, ticaret ve hizmet sektörleri, her biri kendine özgü tüketim alışkanlıkları bulunmaktadır. Bu durum, her bir sektörün ihtiyaçlarına uygun şekilde enerji arz güvenliğinin sağlanabilmesi için bu tüketim profillerinin doğru tahmin edilmesi son derece önem arz etmektedir. Evrendilek ve Ertekin (2003), Türkiye’deki sektörel elektrik talebini analiz ederek sanayi ve hizmet sektörlerinde artan elektrik tüketiminin genel talep üzerindeki belirleyici etkisini vurgulamıştır.

Türkiye'deki elektrik talebini etkileyen önemli faktörlerden biri de nüfus artışı ve kentleşmedir. Kırsal alanlardan şehirlere doğru hızla gerçekleşen göç süreci, konut, ticaret ve hizmet sektörlerinde elektrik tüketiminde önemli bir artışa yol açmıştır. Tatlı (2017), Türkiye'de nüfus artışı ve kentleşmenin konut elektriği talep trendini değiştirdiğini gözlemlemiştir.

Enerji verimliliği, elektrik talebini azaltma ve enerji kaynaklarının daha etkili bir şekilde kullanılmasını sağlama çabalarının kritik bir bileşenidir. Enerji verimliliği politikalarının uygulanması, önemli enerji tasarrufları sağlayarak elektrik talebini düşüş yönde etkileyebilir. Labandeira ve diğ. (2020), enerji verimliliği politikalarının elektrik talebini %10,5 ila %8,8 oranında azaltabileceğini bulmuşlardır.

İklim koşulları, elektrik talebi üzerinde önemli bir etkiye sahiptir. Türkiye'de mevsimsel sıcaklık değişimleri, özellikle yaz aylarında artan soğutma ihtiyacı nedeniyle elektrik talebini doğrudan etkileyerek önemli bir artışa yol açar. Evrendilek ve Ertekin (2003) sıcaklık artışlarının soğutma sistemlerinin daha fazla çalışmasına neden olduğunu ve bunun sonucunda elektrik tüketiminin önemli ölçüde yükseldiğini kanıtlamıştır.

Çizelge 2.1'de, Türkiye'de 2023 yılına ait mevsimsel elektrik talebinin detaylı bir dökümünü sunarak, farklı mevsimlerde kullanılan enerji kaynaklarını göstermektedir. Bu veri, farklı mevsimlerin enerji tüketim desenleri ve kullanılan enerji kaynakları üzerindeki etkilerini anlamada kritik öneme sahiptir.


Çizelge 2.1 : Türkiye'nin 2023 yılındaki mevsimsel elektrik talebi.

SEZON	Elektrik Talebi (GWh)	Kömür (%)	Doğal Gaz (%)	Hidroelektrik (%)	Rüzgar (%)	Güneş (%)	Jeotermal (%)	Diğer Kaynaklar (%)
Kış	79.608	%39,6	%23,7	%14,8	%11,0	%3,8	%3,8	%3,4
İlkbahar	76.606	%31,6	%18,1	%26,6	%10,3	%6,2	%3,8	%3,6
Yaz	90.562	%35,0	%20,9	%21,7	%9,5	%7,3	%2,8	%2,9
Sonbahar	79.162	%40,4	%20,9	%14,6	%11,4	%5,8	%3,5	%3,4


COVID-19 pandemisi, konut enerji tüketim alışkanlıklarında önemli değişimlere yol açmıştır. Sokağa çıkma yasakları ve uzaktan çalışma düzenlemeleri nedeniyle hane halkları daha fazla zamanlarını evde geçirmiş ve bu durum enerji tüketim desenlerinde belirgin değişikliklere neden olmuştur. Tanuğur ve Zehir (2022) pandemi sürecinde konut enerji talebini incelemiş ve özellikle öğle saatlerinde enerji tüketiminin arttığını

ortaya koymuřtur. Bu tüketicim alışkanlıklarındaki değışim, enerji talebinin yönetimini zorlařtırmıřtır.


Kök ve diğ. (2022), 2016 ile 2020 yılları arasındaki Ocak-Haziran döneminde ticaret, sanayi ve konut sektörlerindeki elektrik tüketimi eğilimleri incelenmiştir. Ticaret sektörü, Mart, Nisan ve Mayıs 2020'de önemli bir tüketim düşüşü yaşamış, haziran ayında ise kısmi bir toparlanma gözlemlenmiştir. Benzer şekilde, sanayi sektörü de Nisan ve Mayıs 2020'de keskin bir düşüş göstermiş, ancak haziran ayında normalleşme çabalarıyla birlikte tüketimde artış kaydedilmiştir. Konut tüketimi ise Nisan 2020'de zirve yapmış, diğer aylarda ise tarihsel eğilimleri takip etmiştir. Şekil 2.3, Şekil 2.4 ve Şekil 2.5 COVID-19 kısıtlamalarının farklı sektörlerdeki elektrik talebi üzerindeki etkisini net bir şekilde ortaya koymaktadır.



Şekil 2.3 : 2016-2020 yılları arasında Ocak-Haziran dönemi ticari tüketimi (Kök ve diğ, 2022).



Şekil 2.4 : 2016-2020 yılları arasında Ocak-Haziran dönemi sanayi tüketimi (Kök ve diğ, 2022).



Şekil 2.5 : 2016-2020 yılları arasında Ocak-Haziran dönemi konut tüketimi (Kök ve diğ, 2022).

Yenilenebilir enerji kaynaklarının potansiyelini değerlendirmek, enerji arz güvenliği ve sürdürülebilirlik açısından büyük önem taşımaktadır. Evrendilek ve Ertekin (2003), elektrik talebine yenilenebilir enerji kaynaklarının olası etkilerini ele almış ve bu

kaynakların enerji talep tahminlerine entegre edilmesinin, istikrarlı ve sürdürülebilir bir enerji arzı sağlamak için kritik bir rol oynadığını vurgulamıştır. Yenilenebilir enerji altyapısı gelişmeye devam ettikçe, farklı yenilenebilir kaynakların katkısını anlamak, doğru tahminlerde bulunmak ve stratejik planlamalar yapmak giderek daha önemli hale gelecektir.

2.2 Talep Tahmin Yöntemleri

Elektrik talep tahmini, enerji yönetimi ve planlamasında kritik bir rol oynar. Bu sürecin daha verimli hale getirilmesi için geleneksel yöntemlerin yanı sıra Makine Öğrenimi ve Yapay Zekâ tabanlı modellerin kullanımı giderek yaygınlaşmaktadır. Bu modeller, geçmiş tüketim verilerini ve değişkenleri analiz ederek gelecekteki talebi daha hızlı ve doğru bir şekilde öngörmeyi hedefler. Böylece enerji arz-talep dengesi korunurken, kaynakların etkin ve sürdürülebilir kullanımı sağlanır. Bu bölüm, elektrik talep tahmini yöntemlerini kapsamlı bir şekilde ele alarak, mevcut araştırmalar ve modeller hakkında genel bir bakış sunmayı amaçlamaktadır.

2.2.1 İstatistiksel yöntemler

Elektrik yük talep tahmininde istatistiksel modeller, geçmiş tüketim verilerindeki eğilimleri, mevsimsel desenleri ve rastgele dalgalanmaları analiz ederek gelecekteki talebi öngörmeyi amaçlar. Regresyon modelleri, özellikle çoklu doğrusal regresyon ve polinomal regresyon, elektrik yük tahmininde önemli bir rol oynar. Bu modeller, yük talebini etkileyen bağımsız değişkenler arasındaki ilişkileri analiz ederek tahminler üretir. Örneğin, hava sıcaklığı, nem oranı ve günün saati gibi faktörler regresyon modellerinde bağımsız değişken olarak kullanılabilir. Ancak, bu yöntemlerin doğruluğu genellikle veri setinin doğruluğu ve değişkenler arasındaki ilişkilere bağlıdır (Zhao ve diğ. 2024).

Houthakker (1951), elektrik talep tahmininin ekonomik ve istatistiksel temellerini ele alan öncü bir çalışma gerçekleştirmiştir. Bu makalede, elektrik tüketimi ekonomik değişkenler ile ilişkilendirilerek analiz edilmiş ve doğrusal regresyon modelleri kullanılmıştır. Çalışma, elektrik talebinin fiyat ve gelir esnekliği üzerinden nasıl değiştiğini incelemiş ve bu faktörlerin talep üzerindeki etkilerini kantitatif yöntemlerle değerlendirmiştir. Ayrıca, mevsimsellik ve zamansal desenlerin elektrik tüketim tahminindeki rolü vurgulanmıştır. Bu çalışma, günümüzde kullanılan birçok talep

tahmin yöntemine teorik bir temel oluşturmuş ve elektrik talep modellemelerinin enerji politikaları açısından önemini ortaya koymuştur.

Tripathy (1997) çalışmasında, uzun vadeli elektrik talep tahmini için doğrusal regresyon ve log-log regresyon teknikleri kullanılmıştır. Çalışma, Hindistan Merkez Elektrik Otoritesi (CEA) tarafından hazırlanan elektrik tüketim projeksiyonlarına dayanarak gerçekleştirilmiştir. Modellerde ekonomik göstergeler, nüfus artışı ve sanayi büyümesi gibi parametreler kullanılmıştır. Tahminler, 1965-66 ile 1989-90 arasındaki 25 yıllık veri setine dayanılarak yapılmıştır. Veri seti, 1965-66 öncesine ait bazı veri gruplarına erişimin mümkün olmaması nedeniyle bu döneme sınırlı kalmıştır. Çalışma, uzun vadeli tahminlerin enerji planlaması ve altyapı yatırımları için önemli bir rehber sunduğunu ortaya koymuştur. Ancak, veri eksikliği ve doğrusal olmayan desenlerin modellenmesindeki sınırlılıklar, çalışmanın temel kısıtları arasında yer almaktadır.

Yumurtacı ve Asmaz (2004), Türkiye'nin 2050 yılına kadar elektrik enerjisi talebinin tahmin edilmesi amaçlanmıştır. Çalışmada, nüfus artışı ve kişi başına düşen enerji tüketim oranları temel alınarak projeksiyonlar oluşturulmuş ve hidroelektrik enerjinin potansiyel kullanımı analiz edilmiştir. Yöntem olarak ise, doğrusal regresyon seçilmiştir.

Toksarı (2009), Türkiye'de 2007-2025 yıllarını kapsayan dönemde elektrik üretimi ve talebinin tahmin edilmesine yönelik bir analiz gerçekleştirmiştir. Çalışmada, karınca kolonisi optimizasyonu yöntemi kullanılarak 1975-2006 dönemi için GSYİH, nüfus, ihracat, ithalat ve elektrik üretimi değişkenlerine ait resmi verilerden yararlanılmıştır. Analiz kapsamında hem doğrusal hem de ikinci dereceden modeller oluşturulmuş ve ikinci dereceden modellerin ekonomik değişkenlerdeki dalgalanmalara daha duyarlı olduğu ve tahmin performansının daha başarılı olduğu tespit edilmiştir.

Bianco ve diğ. (2009), İtalya'nın elektrik enerjisi tüketimini tahmin etmeyi amaçlamıştır. Çalışmada, 1970-2007 dönemi için elektrik tüketimi, nüfus, kişi başına düşen GSYİH ve toplam GSYİH değişkenlerine ait resmi veriler kullanılarak çoklu regresyon yöntemi uygulanmıştır. Araştırma sonucunda, 2030 yılına kadar yıllık elektrik tüketim tahminleri yapılmış ve demografik ile ekonomik faktörlerin İtalya'daki yıllık elektrik tüketimi üzerindeki etkileri incelenmiştir. Ayrıca bu

çalışmada ulusal tahmin modelleri ile tutarlılık sağlanarak modelin güvenilirliği kanıtlanmıştır.

Akan ve Tak (2010), Türkiye'de elektrik enerjisi talebinin belirleyicileri analiz edilmiş ve kısa ve uzun vadeli talep esneklikleri incelenmiştir. 1970-2000 dönemine ait yıllık zaman serisi verileri kullanılarak, farklı tüketici grupları (konutlar, sanayi, ticarethaneler, resmi daireler ve genel aydınlatma) detaylı olarak incelenmiştir. Uzun dönemli ilişkiler için en küçük kareler yöntemi ve logaritmik fonksiyonel form kullanılırken, kısa dönem dinamikleri eş bütünleşme analizi ve hata düzeltme modeli ile değerlendirilmiştir. Bulgular, elektrik talebinin gelir seviyesi, sanayi üretimi ve fiyat değişimlerinden önemli ölçüde etkilendiğini ve ekonomik büyüme ile güçlü bir pozitif ilişki gösterdiğini ortaya koymuştur. Araştırma, elektrik talep projeksiyonlarının enerji politikaları ve altyapı yatırımlarının planlanmasında kritik bir rehber niteliği taşıdığını vurgulamış ve uzun vadeli enerji politikalarının oluşturulmasında talep dinamiklerinin dikkate alınması gerektiğinin altını çizmiştir.

Dilaver ve Hunt (2011), Türkiye'nin sanayi sektörüne yönelik elektrik talebi, yapısal zaman serisi yöntemiyle analiz edilmiştir. Çalışma, sanayi sektörünün elektrik talebinin ekonomik faaliyetlerden büyük ölçüde etkilendiğini ortaya koymuş ve sektörel bazlı enerji tahminin önemine vurgu yapmıştır.

Akdi ve diğ. (2020), Türkiye'nin günlük elektrik enerjisi tüketimini tahmin etmeyi amaçlayan bir analiz gerçekleştirmiştir. Çalışmada, 2012-2016 yıllarına ait günlük elektrik tüketim verileri kullanılmış ve yöntem olarak ARIMA ile harmonik regresyon analizi uygulanmıştır. Periyogram testi ile gizli periyodik bileşenleri tespit etmiş ve bu bileşenlerin geleneksel yöntemlere kıyasla daha doğru bir şekilde belirlendiğini kanıtlanmıştır. Araştırma sonucunda, harmonik regresyon analiziyle oluşturulan modelin ARIMA (Oto-Regresif Entegre Hareketli Ortalama) modeline kıyasla daha yüksek doğrulukla çalıştığı gözlemlenmiştir.

ARIMA ve SARIMA (Mevsimsel Oto-Regresif Entegre Hareketli Ortalama) yöntemleri diğer istatistiksel yöntemlere örnek verilebilir. ARIMA, zaman serisi verilerindeki otoregresif ve hareketli ortalama bileşenlerini birleştirerek kısa ve orta vadeli tahminlerde etkin sonuçlar sağlar (Chavan ve diğ, 2024). Ancak, ARIMA mevsimsel desenleri doğrudan modelleyemediği durumlarda sınırlı kalabilir. SARIMA ise ARIMA modelinin mevsimsel bileşenleri de dikkate alan genişletilmiş

bir versiyonudur ve özellikle belirgin mevsimsel döngülerin görüldüğü zaman serilerinde başarılı tahminler sunar (Yin ve diğ., 2023). Günlük, haftalık ve mevsimsel dalgalanmaların güçlü olduğu veri setlerinde SARIMA, tekrar eden desenleri tespit ederek uzun vadeli tahminlerde daha kararlı ve güvenilir sonuçlar üretir. Her iki yöntem de zamansal ilişkileri ve verilerdeki desenleri başarılı bir şekilde modelleyebilirken, SARIMA'nın mevsimselliği doğrudan ele alabilmesi, onu özellikle periyodik talep desenlerine sahip veri setlerinde daha avantajlı hale getirmektedir.

Thompson (1976) çalışmasında, kısa vadeli elektrik talep tahmininde hava durumu değişkenlerinin rolü incelenmiştir. Çalışmada, hava sıcaklığı, nem, rüzgâr hızı ve güneş ışınımı gibi meteorolojik faktörlerin elektrik talebi üzerindeki etkileri analiz edilmiş ve saatlik bazda talep tahmini için çoklu doğrusal regresyon ARIMA ve üstel düzleştirme teknikleri kullanılmıştır. Farklı hava durumu senaryoları değerlendirilerek modellerin tahmin doğruluğu artırılmış, ani sıcaklık değişimleri ve mevsimsel dalgalanmaların kısa vadeli talep üzerindeki etkileri vurgulanmıştır. Araştırma, enerji yönetimi açısından önemli bulgular sunarken, hava durumu değişkenlerinin elektrik talep tahmin modellerine entegrasyonunun önemini ortaya koyarak, günümüzde yaygın olarak kullanılan hava durumu duyarlı tahmin modellerine teorik bir temel oluşturmuştur.

Bakırtaş ve diğ. (2000) çalışmasında, Türkiye'deki elektrik talebi ile gelir arasındaki uzun vadeli ilişki incelenmiştir. Çalışmada, 1962-1996 dönemine ait veriler kullanılmış ve eş bütünleşme analizi hata düzeltme modeli ve ARMA yöntemleri uygulanmıştır. Araştırma, elektrik tüketimi ve gelir arasında uzun vadeli bir eş bütünleşme ilişkisi olduğunu ortaya koymuş ve kısa vadede gelir değişimlerinin elektrik talebi üzerinde belirgin bir etkisi olduğunu tespit etmiştir. Ayrıca, elektrik talebinin gelecekte artmaya devam edeceği öngörülerek, enerji planlamasının uzun vadeli talep projeksiyonlarına dayanması gerektiği vurgulanmıştır.

Ediger ve Akar (2007) çalışmasında, Türkiye'nin birincil enerji talebi ARIMA ve SARIMA modelleri kullanılarak tahmin edilmiştir. Araştırma, 2005-2020 dönemi için farklı yakıt türleri (kömür, petrol, doğalgaz, hidroelektrik vb.) bazında enerji talep projeksiyonları oluşturmuş ve enerji dinamiklerini ekonomik büyüme ve enerji yoğunluğu bağlamında değerlendirmiştir. Bulgular, ARIMA modelleriyle yapılan toplam birincil enerji talep tahminlerinin, bireysel yakıt türlerinin toplamından daha güvenilir olduğunu göstermiştir.

Erdođdu (2007) alıřmasında, Trkiye'deki elektrik talebi analiz edilmiř ve geleceęe ynelik tahminler yapılmıřtır. alıřmada, eř btnleřme analizi ile uzun dnemli denge iliřkileri incelenmiř, hata dzeltme modeli ile kısa dnem dinamikleri analiz edilmiř ve ARIMA yntemiyle zaman serisi tabanlı talep tahminleri gerekleřtirilmiřtir. Elde edilen sonular, TEİAř tarafından yapılan MAED tabanlı tahminlerle karřılařtırılmıř ve alıřmada kullanılan modelin daha gvenilir sonular rettięi gzlemlenmiřtir.

Taylor ve McSharry (2007) alıřmalarında, Avrupa'nın 10 lkesinden elde edilen kısa vadeli elektrik talep verileri kullanarak farklı tahmin yntemlerinin performansları karřılařtırılmıřtır. alıřmada, periyodik AR, ift mevsimsel Holt-Winters stel dzgnleřtirme, alternatif stel dzgnleřtirme ve temel bileřen analizi yntemleri incelenmiřtir. Arařtırma bulguları, kısa vadeli yk tahminlerinde ift mevsimsel Holt-Winters ynteminin en iyi performansı sergiledięini, ARIMA ve temel bileřen analizi modellerinin ise gl ve gvenilir tahminler sunduęunu ortaya koymuřtur. Buna karřılık, periyodik AR ve alternatif stel dzgnleřtirme yntemleri beklenen bařarıyı saęlayamamıřtır.

Smer ve dię. (2009) alıřmalarında, Kayseri ve Civarı Elektrik Trk A.ř.'nin elektrik talebinin 2006-2010 dnemi iin tahmin edilmesi amalanmıřtır. Bu ama doęrultusunda, 1997-2005 yıllarına ait veriler kullanılmıř ve ARIMA, SARIMA ve regresyon modelleri uygulanmıřtır. alıřma sonucunda, nerilen modelin dięer modellere gre daha doęru tahminler saęladıęı belirlenmiřtir.

Mahmutoęlu ve ztrk (2015), Trkiye'nin 2015-2023 dnemi iin brt elektrik tketimini tahmin ederek yenilenebilir enerjiye dayalı politika nerilerine zemin hazırlamayı amalamıřtır. alıřmada, ARMA modeli kullanarak 1970-2011 yıllarına ait yıllık elektrik tketim verileri analiz edilmiřtir. Arařtırma sonucunda, model tarafından elde edilen tahminler TEİAř tahminleri ile karřılařtırılmıřtır.

Nooruldeen ve dię. (2022) řehir genelinde enerji talebinin tahmini iin LSTM ve ARIMA modelleri karřılařtırılmıřtır. LSTM modellerinin daha yksek doęruluk saęladıęı grlmřtir.

Nebati ve dię. (2021) alıřmalarında, Trkiye'nin 2035 yılına kadar elektrik tketimi tahmin edilmiřtir. alıřmada, 1970-2019 dnemine ait nfus, kiři baři gelir, satılan konut sayısı, beyaz eřya sayısı, iřyeri sayısı ve elektrik tketimi verileri kullanarak

analizler gerçekleştirilmiştir. Yöntem olarak ARIMA ve regresyon analizi tercih edilmiştir. Bulgular incelendiğinde, her iki yöntemin de Türkiye İstatistik Kurumu verileriyle tutarlı sonuçlar sunduğunu göstermiştir. Regresyon analizi, uzun vadeli eğilimleri açıklamada daha başarılı bulunurken, ARIMA modeli kısa vadeli tahminlerde daha doğru sonuçlar sağlamıştır.

Sonuç olarak, ARIMA, SARIMA ve Regresyon Modelleri, elektrik yük tahmininde temel taşlar olarak önemli roller oynar. Her bir yöntemin güçlü ve zayıf yönleri, veri setinin doğasına ve tahmin süresine bağlı olarak değişebilir. ARIMA, özellikle kısa vadeli tahminlerde doğruluğuyla öne çıkarken, SARIMA mevsimsel desenlerin güçlü olduğu durumlarda daha etkin sonuçlar sunar. Regresyon modelleri ise, bağımsız değişkenlerin talep üzerindeki etkilerini doğrudan açıklayarak geniş bir analiz kapasitesi sağlar. Ancak bu yöntemlerin hibrit modeller veya makine öğrenimi teknikleriyle entegre edilmesi, tahmin performansını daha da iyileştirme potansiyeline sahiptir.

2.2.2 Makine öğrenmesi tabanlı yöntemler

Geleneksel istatistiksel yöntemler, doğrusal varsayımlar çerçevesinde başarılı sonuçlar sunsa da karmaşık ve doğrusal olmayan veri desenlerini modellemede yetersiz kalabilmektedir. Bu noktada, Makine öğrenimi yöntemleri, büyük ve karmaşık veri setlerindeki desenleri daha etkili bir şekilde analiz ederek tahmin doğruluğunu artırma potansiyeline sahiptir. Elektrik yük talep tahmininde öne çıkan makine öğrenimi algoritmaları arasında yapay sinir ağları, destek vektör makineleri, karar ağaçları ve rastgele ormanlar gibi teknikler bulunmaktadır. Bu algoritmalar, mevsimsel desenler, ani talep değişimleri ve doğrusal olmayan ilişkiler gibi zorlukların üstesinden gelerek güvenilir tahmin sonuçları sunmaktadır.

Son yıllarda Derin Öğrenme teknikleri, özellikle Uzun Kısa Süreli Bellek (LSTM) ve Tekrarlayan Sinir Ağları (RNN), zaman serisi verilerinin analizinde güçlü performans sergileyerek elektrik yük talep tahmininde öne çıkmıştır. Bu modeller, zaman içindeki bağımlılıkları anlamada ve karmaşık dinamikleri modellemede önemli avantajlar sağlamaktadır.

Ayrıca, Gradyan Artırma Tabanlı Algoritmalar, elektrik yük talep tahmin çalışmalarında giderek daha fazla tercih edilmektedir. XGBoost (Extreme Gradient Boosting), LightGBM (Light Gradient Boosting Machine) ve CatBoost (Categorical

Boosting) gibi algoritmalar hem yüksek doğruluk oranları hem de hızlı işlem kapasiteleri sayesinde karmaşık veri setlerinde etkili sonuçlar elde edilmesine olanak tanımaktadır.

Sözen ve diğ. (2006), Türkiye'nin net enerji talebinin tahmini üzerine bir araştırma gerçekleştirmiştir. Çalışmada, yapay sinir ağları yöntemi kullanılarak 1953-2000 dönemi için kurulu güç, nüfus ve brüt üretim değişkenlerine ait veriler analiz edilmiştir. Araştırma, yapay sinir ağları modellerinin enerji talep tahmininde güvenilir bir yöntem olduğunu ve enerji politikalarının planlanmasında etkin bir stratejik araç olarak kullanılabileceğini ortaya koymuştur.

Hamzaçebi (2007), Türkiye'nin 2003-2020 dönemi için sektörel elektrik tüketiminin yapay sinir ağları yöntemiyle tahmin edilmesini amaçlamıştır. Çalışma sonucunda, yapay sinir ağlarıyla elde edilen tahminlerin, sektörel elektrik tüketiminde resmi tahminlere kıyasla daha doğru ve tutarlı sonuçlar ürettiği belirlenmiştir.

Sözen ve Arcaklıoğlu (2007), Türkiye'nin net enerji tüketimi farklı değişkenlerin etkilerini incelemek amacıyla üç farklı model kurulmuştur. Çalışmada, birinci modelde kurulu elektrik kapasitesi, enerji üretimi, ithalat ve ihracat değişkenleri girdi olarak kullanılmıştır. İkinci gayri safi milli hasıla, üçüncü modelde ise ve gayri safi yurtiçi hasıla girdi değişkenleri olarak değerlendirilmiştir. Araştırma sonucunda, gayri safi milli hasıla ve gayri safi yurtiçi hasıla değişkenlerinin net enerji tüketiminin tahmin edilmesinde daha önemli belirleyiciler olduğunu ortaya koymuştur.

Ying ve Pan (2008), Tayvan'ın bölgesel elektrik yükünün tahmin edilmesi amaçlanmıştır. Araştırmada, 1981-1996 yıllarına ait veriler eğitim aşamasında, 1997-2000 yıllarına ait veriler ise test aşamasında kullanılmıştır. Çalışmada yapay sinir ağları, ANFIS, genetik algoritmali destek vektör makineleri, genetik algoritmali tekrarlayan destek vektör makineleri ve hibrit elipsoit bulanık sistem teknikleri kullanılarak modeller oluşturulmuştur. Elde edilen tahmin sonuçları karşılaştırılmış ve en güvenilir tahminin ANFIS modeliyle elde edildiği sonucuna ulaşılmıştır.

Geem ve Roper (2009), Güney Kore'nin 2008-2025 dönemi için ulaşım enerji talebinin tahmin edilmesi amaçlanmıştır. Çalışmada, 1990-2007 dönemine ait gayri safi yurtiçi hasıla, nüfus, araç sayısı ve yolcu sayısı gibi resmi veriler, yapay sinir ağları yöntemi kullanılarak analiz edilmiştir. Elde edilen veriler, çoklu doğrusal regresyon

modelleriyle karşılaştırılmış ve yapay sinir ağları yönteminin daha güvenilir tahminler sağladığı sonucuna ulaşılmıştır.

Hotunluoğlu ve Karakaya (2011) çalışmalarında, Türkiye'nin 2009-2030 dönemi için enerji talep tahminlerinin çeşitli senaryolar aracılığıyla yapılması amaçlanmıştır. Çalışmada, 1970-2008 yılları arasındaki gayri safi yurtiçi hasıla, nüfus, ihracat ve ithalat verileri yapay sinir ağları yöntemi kullanılarak değerlendirilmiştir. Ayrıca enerji yoğunluğu değişkenine ait resmi veriler de modele dahil edilmiştir. Araştırma kapsamında statik, sürdürülebilir ve dönemsel-değişim olmak üzere üç farklı senaryo oluşturulmuştur. Elde edilen tahmin sonuçları, T.C. Enerji ve Tabii Kaynaklar Bakanlığı tahminleriyle karşılaştırılmış ve model tahminlerinin daha düşük değerler ürettiği gözlemlenmiştir.

Kankal ve diğ. (2011) çalışmalarında, Türkiye'nin enerji tüketimi, ekonomik ve demografik değişkenler temelinde yapay sinir ağları ve regresyon analizi kullanılarak modellenmiş ve tahmin edilmiştir. Çalışmada gayri safi yurtiçi hasıla, nüfus, ithalat miktarı, ihracat miktarı ve istihdam oranı gibi bağımsız değişkenler kullanılarak dört farklı yapay sinir ağı modeli geliştirilmiştir. Araştırma bulguları gayri safi yurtiçi hasıla, nüfus, ithalat ve ihracat değişkenleri kullanılan yapay sinir ağı modelinin regresyon analizine kıyasla daha doğru ve güvenilir tahminler sunduğunu ve Enerji ve Tabii Kaynaklar Bakanlığı'nın tahminlerine göre daha düşük enerji talep projeksiyonları sağladığını göstermiştir.

Kavaklıoğlu (2011), Türkiye'nin 2026 yılına kadar olan dönemi için elektrik enerjisi tüketiminin tahmin edilmesini amaçlayan bir analiz gerçekleştirmiştir. Analizde destek vektör regresyonu yöntemi kullanılarak, 1975-2006 dönemi için gayri safi milli hasıla, nüfus, ihracat ve ithalat verileri değerlendirilmiştir. Araştırma bulguları, destek vektör regresyonu modellerinin karmaşık ve doğrusal olmayan veri desenlerini başarıyla analiz ederek yüksek doğruluk oranlarına ulaştığını göstermiştir.

Es (2013) çalışmasında, Türkiye'nin 2011-2025 dönemi için elektrik enerjisi tüketiminin tahmin edilmesi amaçlanmıştır. Yapay sinir ağları yöntemi kullanılarak, 1970-2010 dönemi için gayri safi yurtiçi hasıla, nüfus, ihracat, ithalat, taşıt sayısı ve bina yüzölçümü değişkenlerine ait resmi veriler analiz edilmiştir. Araştırma bulguları, yapay sinir ağları yönteminin zaman serisi ve regresyon yöntemleriyle oluşturulan modellere kıyasla daha başarılı tahminler ürettiğini göstermiştir.

Liu ve diğ. (2014) çalışmalarında, sıcaklık odaklı elektrik yükünün haftalık tahmini dışsal değişkenli mevsimsel otoregresif bütünleşmiş hareketli ortalama modeli (SARIMAX) ve yapay sinir ağları modelleri kullanılarak gerçekleştirilmiştir. Araştırma, yapay sinir ağları modelinin sıcaklık verilerini tahmin etmede daha başarılı olduğunu, SARIMAX modelinin ise haftalık elektrik yükü tahminlerinde daha doğru sonuçlar sunduğunu ortaya koymuştur. Çalışma, elektrik yük tahminlerinde SARIMAX ve yapay sinir ağları modellerinin bir arada kullanılmasının daha yüksek doğruluk sağlayabileceğini vurgulamıştır.

Uygun (2015) çalışmasında, Türkiye'nin Nisan 2015 ve Mart 2016 dönemi için saatlik elektrik talebinin tahmin edilmesi amaçlanmıştır. Çalışmada nüfus, gayri safi yurtiçi hasıla, sanayi üretim verileri, hava sıcaklığı ve mevsimsel değişkenlere ait veriler kullanılmıştır.

Birim ve Tümtürk (2016) çalışmalarında, Türkiye'nin 2015-2023 dönemi için elektrik enerjisi tüketiminin tahmin edilmesi amaçlanmıştır. Çalışmada çoklu doğrusal regresyon ve yapay sinir ağları yöntemleri kullanılarak, 1992-2014 dönemi için gayri safi yurtiçi hasıla, nüfus, ihracat, ithalat, doğalgaz ve istihdam değişkenlerine ait resmi veriler analiz edilmiştir. Yapay sinir ağları modellerinin, çoklu doğrusal regresyon modellerine kıyasla daha düşük hata oranlarına ve daha yüksek doğruluğa sahip olduğu görülmüştür. Dört farklı modelin oluşturulduğu çalışmada elde edilen sonuçlar, Türkiye Elektrik İletim A.Ş. projeksiyonları ile karşılaştırılmış ve TEİAŞ tahminlerinin üç modelin tahminlerinden daha yüksek olduğu belirlenmiştir.

Chae ve diğ. (2016), ticari binalardaki elektrik tüketiminin 15 dakikalık aralıklarla kısa vadeli tahmini yapay sinir ağları yöntemi kullanılarak gerçekleştirilmiştir. Bayes regülasyonu ile eğitilen modelde, gün türü göstergesi, günün saati, Isıtma, Havalandırma ve İklimlendirme sistemleri (HVAC) sıcaklık ayar programı, dış hava kuru termometre sıcaklığı ve dış hava nemi gibi değişkenler girdi olarak kullanılmıştır. Model, kısa vadeli ve alt saatlik tahminlerde yüksek doğruluk sağlamış ve HVAC sıcaklık ayarları ile dış hava sıcaklığı gibi değişkenlerin tahmin performansı üzerinde belirleyici rol oynadığını ortaya koymuştur. Ayrıca, günlük elektrik yükü zirvelerini başarıyla tahmin eden model, kısa aralıklı analizlerin enerji yönetimi stratejilerinin iyileştirilmesinde kritik bir rol oynadığını vurgulamıştır.

Makas ve Karaatlı (2016), Türkiye'nin hidroelektrik enerji üretimi yapay sinir ağları yöntemi kullanılarak tahmin edilmiştir. Araştırma, Antalya Havzası'ndaki bir hidroelektrik santralin aylık üretim projeksiyonlarını doğru bir şekilde modellemeyi amaçlamış ve 2007-2014 dönemine ait veriler kullanılmıştır. Model, ileri beslemeli geri yayılım sinir ağı ile eğitilmiş; yağış, nem ve debi değişkenleri girdi, aylık hidroelektrik enerji üretimi ise çıktı değişkeni olarak değerlendirilmiştir. Yapılan analizler, yapay sinir ağı modelinin hidroelektrik enerji üretim tahminlerinde yüksek doğruluk sağladığını ve geleneksel tahmin yöntemlerine kıyasla daha düşük hata oranları sunduğunu göstermiştir.

Toros ve Aydın (2018), Türkiye'nin kısa vadeli elektrik tüketimi yapay sinir ağları yöntemi kullanılarak sıcaklık değişkenleriyle modellenmiştir. Ocak 2012- Kasım 2016 dönemine ait sıcaklık ve elektrik tüketimi verileri, Levenberg-Marquardt geri yayılım algoritması ile analiz edilerek model eğitilmiştir. Ortalama sıcaklık, bölgesel sıcaklık dağılımı ve geçmiş sıcaklık verileri (gün ve hafta öncesi) girdi değişkeni olarak kullanılmıştır. Ağırlıklı Ortalama Sıcaklık yöntemiyle, Türkiye'nin en fazla elektrik tüketen 12 iline ait sıcaklık verileri tüketim oranlarına göre ağırlıklandırılarak tahmin doğruluğu artırılmıştır. Çalışma, gelecekte yağış ve nem gibi diğer meteorolojik değişkenlerin modele dahil edilerek analizlerin daha da iyileştirilebileceğini önermektedir.

Özaydın (2019), Türkiye'nin 2017 yılı elektrik talebi, yapay sinir ağları yöntemi kullanılarak tahmin edilmiştir. Analizde, 1960-2016 dönemine ait kişi başı Gayri Safi Milli Hasıla ihracat, ithalat, kurulu güç, motorlu taşıt sayısı, şehir nüfusu ve tüketici fiyat endeksi gibi değişkenler kullanılmıştır.

Pençe ve diğ. (2019) çalışmalarında, Türkiye'nin 2017-2023 dönemi için elektrik enerjisi tüketimi tahmin edilmiştir. Çalışmada, 1970-2016 dönemine ait veriler kullanılarak ileri beslemeli yapay sinir ağı modeli uygulanmıştır. Sonuçlar incelendiğinde, geliştirilen yapay sinir ağı modelinin Türkiye Elektrik İletim A.Ş. tahminleriyle tutarlı ve yakın değerler sunduğunu incelenmiştir.

Lara-Benitez ve diğ. (2020), elektrik tüketimi tahminlerinde geçici evrimsel ağlar (TCN) ve RNN ile modeller kurulmuştur. Bu iki model kıyaslandığında ulusal elektrik talebi ve şarj istasyonları enerji talebi tahminlerinde TCN modelin daha başarılı olduğu görülmüştür.

Bu ve Cho (2020) çalışmalarında, konut enerji tüketimi tahmini için Çok Başlı Dikkat mekanizması ve CNN tabanlı derin öğrenme modelleri kullanılmıştır. Bu çalışma sonucunda, çok başlı dikkat mekanizmasının tahmin doğruluğunu artırdığı görülmüştür.

Kell ve diğ. (2021) çalışmalarında, İngiltere için kısa dönem elektrik talebi tahmini, 16 farklı makine öğrenmesi yöntemi kullanılarak gerçekleştirilmiş ve bu yöntemlerin performansları karşılaştırılmıştır. Araştırma, farklı algoritmaların kısa vadeli talep tahminindeki etkinliğini analiz ederek, en doğru ve güvenilir sonuçları sağlayan modelleri belirlemeyi amaçlamıştır.

Enes ve Aydın (2022) araştırmalarında, yük tahmini için yapay sinir ağı tabanlı tahmin algoritmalarından tekrarlayan sinir ağları (RNN) analiz edilmiştir. Çalışmada, Amerika Birleşik Devletleri'nin Eastern Kentucky bölgesine ait enerji tüketim verileri kullanılmış ve tahmin modelleri olarak RNN, uzun kısa süreli bellek (LSTM) ve hibrit evrişimli sinir ağı-uzun kısa süreli bellek (CNN-LSTM) algoritmaları uygulanmıştır. CNN-LSTM algoritmasının diğer algoritmalarla kıyasla en düşük hata oranını sunduğunu gözlemlenmiştir.

Gezmez (2022), Enerji Piyasası Düzenleme Kurumu'nun (EPDK) belirlediği tahmin metodolojisine ek olarak makine öğrenmesi yöntemleri kullanılarak elektrik talep tahmini yapılmıştır. Çalışmada, Doğrusal Regresyon ve LSTM yöntemleri kullanılarak MATLAB üzerinde uygulamalar gerçekleştirilmiştir. Çalışmanın sonucunda, kullanılan makine öğrenmesi yöntemlerinin EPDK metodolojisiyle karşılaştırıldığında uygun ve güvenilir sonuçlar sunduğunu göstermiştir

Erdemci (2023), Türkiye'nin 2020-2040 yılları arasındaki elektrik enerjisi talebi tahmin edilmiştir. Araştırmada, 1980-2019 dönemi verileri kullanılarak gayri safi yurtiçi hasıla, nüfus, ihracat, ithalat ve elektrik tüketimi değişkenleri analiz edilmiştir. Yöntem olarak yapay sinir ağları, destek vektör regresyonu ve parçacık sürü optimizasyonu teknikleri uygulanarak üç farklı senaryo oluşturulmuştur. Senaryoların karşılaştırılması sonucunda, yapay sinir ağları yönteminin diğer yöntemlere kıyasla daha başarılı bir performans sergilediği belirlenmiştir.

2.2.3 Hibrit yöntemler

Akay ve Atak (2007) çalışmalarında, Türkiye'nin elektrik talep tahmini için gri tahmin modeli ve ARIMA yöntemleri kullanılmıştır. Özellikle hareketli mekanizma ile

uygulanan gri model, kısa vadeli elektrik talep tahminlerinde yüksek doğruluk göstermiştir.

Iranmanesh ve diğ. (2012) çalışmasında, orta vadeli enerji talep tahmini için hibrit nöro-bulanık modeller kullanılmış ve bu modellerin doğruluk ve güvenilirlik açısından geleneksel yöntemlere kıyasla üstün performans sergilediği belirlenmiştir. Çalışmada, Local Linear Neuro-Fuzzy (LLNF) modeli ve Hodrick-Prescott (HP) filtresi bir arada kullanılarak geliştirilen HPLLNF hibrit modeli öne çıkmıştır. Bu model, benzin, ham petrol ve doğalgaz gibi farklı enerji türleri için uzun vadeli tahminlerde yüksek performans göstermiştir. Ayrıca, modelin karşılıklı bilgi (mutual information) tekniklerini kullanarak enerji talep desenlerindeki karmaşık ilişkileri başarıyla analiz etmiştir.

Puspitasari ve diğ. (2012) çalışmasında, Java-Bali bölgesindeki yarım saatlik elektrik yükü tahmini için hibrit ARIMA-ANFIS modeli kullanılmıştır. Çalışmada 2009-2010 yılları arası iki yıllık veri seti kullanılmıştır. Hibrit modelin, ayrı ayrı ARIMA ve ANFIS yöntemlerine göre kıyaslandığında daha doğru tahmin sonuçları sunduğu incelenmiştir.

Wang ve diğ. (2012), Kuzeybatı Çin'in elektrik talebi tahmin edilmiştir. Analizde, parçacık sürü optimizasyonu ve SARIMA yöntemleri birleştirilerek hibrit bir model geliştirilmiştir. Karşılaştırmalı analiz sonucunda, hibrit modelin tekil yöntemlere göre daha doğru tahminler sunduğu görülmüştür.

Kıran ve diğ. (2012) çalışmasında, Türkiye'nin enerji talebi, parçacık sürü optimizasyonu ve karınca kolonisi algoritması tabanlı yeni bir hibrit model kullanılarak tahmin edilmiştir. Çalışmada, 1970-2009 yıllarına ait veriler analiz edilmiş ve geliştirilen hibrit modelin geleneksel yöntemlere kıyasla daha düşük tahmin hatası sağladığı ve enerji talebi projeksiyonlarında daha başarılı sonuçlar sunduğu belirlenmiştir. Ayrıca, kuadratik formun enerji talep tahmininde daha iyi uyum sağladığı ve modelin tahmin doğruluğunu önemli ölçüde artırdığı gözlemlenmiştir.

Hamzaçebi ve Es (2014), Türkiye'nin yıllık elektrik tüketimi optimize edilmiş gri model kullanılarak tahmin edilmiştir. Sınırlı veri setleriyle çalışmanın getirdiği kısıtlamaların üstesinden gelmek için bu yaklaşım benimsenmiştir. Elde edilen sonuçlar, gri modelin doğrudan tahmin yöntemiyle yüksek doğruluk sağladığını ve

karmaşık, doğrusal olmayan enerji tüketim desenlerini etkili bir şekilde analiz edebildiğini göstermiştir.

Hekimoğlu ve Barlas (2016) çalışmalarında, ARIMA modeli ve davranış deseni ölçümleri kullanılarak hassasiyet analizi gerçekleştirilmiştir. Çalışma, birden fazla davranış moduna sahip modellerin doğruluğunu artış gösterdiği kanıtlanmıştır.

Barak ve Sadegh (2016), ARIMA ve ANFIS algoritmalarının birleşiminden oluşan hibrit bir model geliştirilmiştir. Bu model, doğrusal ARIMA yönteminin güçlü zaman serisi analiz yetenekleri ile ANFIS'in doğrusal olmayan desenleri modelleme kabiliyetini birleştirerek güvenilir ve hassas tahminler sunmuştur. Araştırmada, hibrit modelin özellikle mevsimsel desenleri daha etkili analiz ettiği ve veri yetersizliği durumlarında tekil modellerden daha başarılı sonuçlar sağladığı belirlenmiştir.

Özdemir ve diğ. (2016), Türkiye'nin doğalgaz talebi, genetik algoritma ve benzetimli tavlama yöntemlerinin birleşiminden oluşan hibrit bir algoritma kullanılarak tahmin edilmiştir. Mevsimsel ve ekonomik değişkenler dikkate alınarak geliştirilen modelin, doğalgaz talep tahminlerinde doğrusal regresyon modellerine kıyasla daha yüksek doğruluk sağladığı belirlenmiştir.

Aydoğdu ve Yıldız (2017), iyileştirilmiş uyarlanabilir gürültülü ampirik mod ayrıştırma, parçacık sürü optimizasyonu ve destek vektör regresyonu yöntemleri entegre edilerek hibrit bir model geliştirilmiştir. Bu model, kısa ve uzun vadeli elektrik talep tahminlerinde üstün performans sergileyerek dinamik desenleri başarıyla analiz etmiştir.

Baçoğlu ve Bulut (2017), Türkiye'nin günlük elektrik talep tahmini için uzman sistemler ve yapay sinir ağı tabanlı hibrit bir model geliştirilmiştir. EPSİM-NN adı verilen hibrit sistem, iki farklı yapay sinir ağı modelinden elde edilen sonuçlar birleştirilmiş ve hata oranları minimize edilmiştir. Çalışmanın sonucunda, geliştirilen hibrit modelin günlük elektrik talep tahminlerinde daha doğru sonuçlar sunduğunu ortaya koymuştur.

Karadede ve diğ. (2017), Türkiye'nin doğalgaz talebi, 2015-2030 dönemi için genetik algoritma ve benzetimli tavlama yöntemlerini kullanarak hibrit bir algoritma geliştirilmiştir.

Al-Musaylh ve diğ. (2018) çalışmalarında, iyileştirilmiş uyarlanabilir gürültülü ampirik mod ayrıştırma parçacık sürü optimizasyonu ve destek vektör regresyonu yöntemleri entegre edilerek hibrit bir model geliştirilmiştir.

Kim ve diğ. (2019), LSTM ve CNN yöntemleri entegre edilerek hibrit bir yapay sinir ağı modeli oluşturulmuştur. Bu model, sıcaklık ve nem gibi bağlamsal verileri entegre ederek ani talep değişimlerini başarılı bir şekilde tespit etmiş ve tahmin doğruluğunu artırmıştır.

Kaytez (2020), Türkiye'nin 2022 yılına kadar net elektrik tüketimi tahmin edilmiştir. Analizde, ARIMA ve en küçük kareler destek vektör makineleri yöntemleri bir araya getirilerek hibrit bir model geliştirilmiştir. Hibrit modelin yüksek doğruluk oranlarına sahip tahminler sunduğu yapılan testlerde görülmüştür.

Jiang ve diğ. (2020) araştırmasında, Çin'deki bir şehrin aylık elektrik tüketimi meyve sineği optimizasyon algoritması (FFOA) ve Holt-Winters kullanılan hibrit bir modelle tahmin edilmiştir. Farklı senaryolarda test edilen hibrit modelin güvenilir tahmin sonuçları sunduğu gözlemlenmiştir.

Khan ve diğ. (2020), eksik veri tamamlaması ve tahminleme amaçlı hibrit bir makine öğrenmesi modeli uygulanmıştır. XGBoost, CatBoost ve rassal orman algoritmalarının entegre edildiği bu model, veri boşluklarını etkin şekilde doldurmuştur. Bu çalışmada hibrit model, veri mühendisliği teknikleriyle desteklenmiştir.

Turgut ve diğ. (2021) çalışmalarında ise Türkiye'nin taşımacılık sektörü enerji talebi, statik ve tekrarlayan sinir ağı ile ARIMA yöntemleri kullanılarak tahmin edilmiştir. Polinomsal uyumlama yönteminin tahmin sonuçlarının resmi projeksiyonlara oldukça yakın olduğu gözlemlenmiştir.

Pavlicko ve diğ. (2022) çalışmalarında, Slovakya'nın 2000-2020 dönemi elektrik tüketim tahminleri gerçekleştirilmiştir. Araştırmada, yapay sinir ağı, standart gri model, doğrusal olmayan gri Bernoulli modeli ve bir hibrit model kullanılmıştır. Analiz sonucunda, hibrit modelin resmi tahminlerden daha doğru sonuçlar sunmuştur.

Sultana ve diğ. (2022) çalışmasında, Ontario eyaletinin konut sektörüne yönelik saatlik elektrik talep tahmini gerçekleştirilmiştir. Araştırmada, SARIMAX, NARX ve Bayes algoritmaları uygulanmış ve ayrıca Bayes-SARIMAX ile Bayes-NARX hibrit modelleri test edilmiştir. Kıyaslamalar sonucunda, Bayes-NARX hibrit modelinin diğer modellere kıyasla daha doğru tahmin sonuçları sunduğunu göstermiştir.

3. TÜRKİYE ELEKTRİK PİYASASI

Elektrik Piyasası Kanunu (EPK) ve Türkiye'nin elektrik enerjisi sektöründeki özelleştirme süreci, 2001 yılında başlamış ve kamu sektörünün hâkim olduğu bir yapının yerine serbest piyasa koşullarının getirilmesi amaçlanmıştır. 4628 Sayılı Kanun ile sektörün rekabetçi bir yapıya kavuşturulması hedeflenmiş, kamu hizmeti imtiyazı yerine lisanslı sistem getirilmiş ve özel sektörün piyasadaki rolü artırılmıştır. Özelleştirme süreci, TEDAŞ'ın varlıklarının devri ve 21 dağıtım bölgesinin oluşturulmasıyla başlamış, ancak sürecin bazı aşamalarında gecikmeler yaşanmıştır.

Elektrik Piyasası Kanunu ile ayrıca serbest piyasa yapısının oluşabilmesi için çeşitli piyasa mekanizmaları devreye girmiştir. Bunlar arasında gün öncesi piyasası (GÖP), gün içi piyasası (GİP) ve dengeleme güç piyasası (DGP) gibi mekanizmalar, enerji arz ve talep dengesini sağlamak amacıyla işlemektedir. GÖP, enerji arzının bir gün önceden belirlendiği, fiyatların talep ve arz dengesine göre belirlendiği piyasadır. Anlık değişimleri, aynı gün içerisinde değiştirmemize imkan sağlayan enerji ticareti yapılan piyasa gün içi piyasası olarak isimlendirilir. DGP ise sistemin dengesini sağlamak için daha dinamik ve hızlı bir şekilde fiyatların belirlendiği bir piyasadır. Bu piyasa yapıları, enerji üreticileri ve tedarikçileri için rekabetçi bir ortam yaratırken, tüketicilerin de daha uygun fiyatlarla enerji temin etmelerini sağlamayı amaçlamaktadır.

3.1 Türkiye Elektrik Enerjisi Piyasasının Gelişimi

Türkiye elektrik enerjisi piyasası, tarihsel olarak çeşitli evrelerden geçmiş ve her dönemde önemli reformlara tabi olmuştur. Elektrik enerjisi, bir ülkenin ekonomik ve toplumsal gelişimi için kritik bir sektördür. Türkiye'de bu alandaki değişim ve gelişmeler, yalnızca teknolojik ve ekonomik ihtiyaçlara değil, aynı zamanda ulusal politikaların şekillendiği sosyal ve siyasal bağlama da paralel olarak gerçekleşmiştir. Elektrik enerjisi piyasasında yaşanan bu dönüşüm, Türkiye'nin enerji bağımsızlığını ve sürdürülebilir kalkınma hedeflerini destekleyen temel adımları içermektedir.

Bu kısımda, Türkiye elektrik enerjisi piyasasında yaşanan gelişmeler dört ana döneme ayrılarak incelenecektir: İlk olarak 1980 öncesi dönemi, ardından 1980 sonrası özelleştirme sürecini ve 3096 sayılı kanunun yürürlüğe girmesiyle başlayan dönemi, 1990'lı yıllar ile 3996 sayılı kanunun etkilerini ve son olarak 4628 sayılı Elektrik Piyasası Kanunu'nun yürürlüğe girmesi ve Enerji Piyasası Düzenleme Kurumu'nun (EPDK) kurulmasıyla başlayan dönemi ele alacağız. Çizelge 3.1'de bu gelişimin özeti sunulmaktadır. Her bir dönem, Türkiye'nin elektrik enerjisi sektöründeki dönüşümünü, karşılaşılan zorlukları ve elde edilen kazanımları anlamak açısından önemlidir. Bu bağlamda, elektrik enerjisi piyasasındaki reformların nasıl şekillendiği ve hangi stratejik kararların alındığına dair kapsamlı bir değerlendirme yapılacaktır.

Çizelge 3.1 : Türkiye enerji piyasası gelişimleri.

Zaman Dilimi	Gelişmeler/Reformlar
1980 Öncesi Dönem	Elektrik sektörü devlet tekeli olarak faaliyet gösterdi. Elektrik üretim ve dağıtım faaliyetleri kamuya ait şirketler tarafından yürütüldü. Enerji arzı genellikle devlet planlamasına dayalıydı.
1980 Sonrası Özelleştirme Dönemi ve 3096 Sayılı Kanun	Özelleştirme ve liberalizasyon süreçlerinin başlangıcı. 1984'te, özel sektörün elektrik üretimine katılımı teşvik edilmiştir. 3096 sayılı kanun, özelleştirme sürecini düzenlemeye başlamıştır. Elektrik enerjisi sektöründe serbest piyasa unsurları yer almaya başladı.
1990'lı Yıllar ve 3996 Sayılı Kanun	3996 sayılı kanun (1994), enerji sektöründe özel sektörün daha fazla yer almasını sağlayacak düzenlemeler getirdi. Elektrik piyasasında serbestleşme ve düzenleyici yapıların güçlendirilmesi hedeflendi.
4628 Sayılı Elektrik Piyasası Kanunu ve EPDK'nın Kurulması	4628 sayılı Elektrik Piyasası Kanunu (2001), serbest piyasa ekonomisinin temelini attı. Enerji Piyasası Düzenleme Kurumu (EPDK) kuruldu, piyasa düzenlemeleri denetlenmeye başlandı. Elektrik piyasasında arz ve talep dengesi, fiyatlandırma mekanizmaları ve özelleştirme hız kazandı.

3.1.1 1980 öncesi dönem

Cumhuriyet öncesi dönemde şehirlerin elektrikleştirilmesi ile ilgili faaliyetler, devlet tarafından verilen ayrıcalıklarla kurulan özel ortaklıklar tarafından yürütülmekteydi. Cumhuriyetin ilanı ile bu ayrıcalıklı ortaklıklar Türkiye Cumhuriyeti Devleti'ne devredilmiş ve elektrikleştirme faaliyetleri önemli ölçüde hız kazanmıştır (Berberoğlu, 1982).

1923 yılında yalnızca İstanbul, Adapazarı ve Tarsus şehirleri elektrikten yararlanabilirken, 1930 yılına kadar elektrik altyapısı Ankara, Adana, İnebolu, Artvin, Trabzon, Mersin, İzmir, Sivas, Aksaray, Konya, Ayvalık, Bursa, Malatya, İzmit, Kütahya, Kayseri, Nazilli, Kırkağaç, Antalya, Afyon, Kırklareli, Samsun, Çorlu, Giresun, Eskişehir, Ordu, Bafra, Bandırma, Biga, Milas, Balıkesir, Kastamonu ve Tekirdağ şehirlerine ulaşmıştır (Türkoğlu, 2005).

1930'lu yıllarda, Türkiye'de yeterli ulusal ve özel sermaye birikiminin sağlanamaması, dönemin ekonomik politikalarında bir değişime neden olmuş ve liberal ekonomik yaklaşım terk edilerek ılımlı devletçilik politikası benimsenmiştir. Bu süreçte, özellikle yabancı şirketlerle yaşanan fiyat ve yatırım sorunları, birçok kamu ve özel sanayi kuruluşunun elektrik enerjisi ihtiyaçlarını kendi bünyelerinde karşılamalarına yol açmıştır (Türkoğlu, 2005).

Dönemin öne çıkan sanayi tesisleri arasında Kırıkkale MKE Fabrikası, Gölcük Tersanesi, Uşak ve Turhal Şeker Fabrikaları, Kozlu EKİ İşletmesi, Bursa Sümerbank Fabrikası, Sivas TCDD Fabrikası, Karabük Demir Çelik Tesisleri ve İzmit SEKA Tesisleri bulunmaktadır. Bu kuruluşlar, kendi elektrik enerjilerini üreterek faaliyetlerini sürdürmüş ve dönemin sanayileşme hamlesine önemli katkılarda bulunmuşlardır (Türkoğlu, 2005).

Bu dönemde kamu kuruluşlarının elektrik üretimindeki rolü giderek daha belirgin hale gelirken, 1939 yılında yabancı şirketlere tanınan imtiyazlar geri alınmış ve bu şirketlerin işlettiği tesisler devletleştirilmiştir. Elektrik şirketlerinin imtiyazlarının sona erdirilmesinin ardından, elektrik hizmetleri önce Bayındırlık Bakanlığı'na, bir yıl sonra ise belediyelere devredilmiştir (Türkoğlu, 2005).

1950'li yılların ekonomi politikası olan karma ekonomik yapı içerisinde özel sektöre ağırlık vermek ve yabancı sermayeyi ülkeye çekebilmek ilkesi enerji alanında da

etkisini göstermiş, özel sektör eliyle de santraller yapılmaya ve işletilmeye başlanmıştır (Ültanır, 1994).

Bu kapsamda Çukurova Elektrik A.Ş. (ÇEAŞ) ve Kepez A.Ş.'ye imtiyaz tanınmıştır. 1960'lı yıllara gelindiğinde ise planlı kalkınma dönemi başlamış, 1963 yılında ülkenin enerji politikasının belirlenmesi ve yürütülmesi ile görevlendirilen Enerji ve Tabi Kaynaklar Bakanlığı (ETKB) kurulmuştur (TİK, 2004).

1960'lı yıllar planlı kalkınmanın başlatıldığı, enerji alanında devletçilik uygulamaları ağır basan karma ekonominin uygulandığı bir dönem olmuştur. Planlı ekonominin elektrik sektörüne getirdiği en önemli yenilik ayrıcalıklı elektrik firmaları politikasının terk edilmesi olmuştur (Ültanır, 1994).

1970 yılında artan üretim, dağıtım ve tüketim miktarı ve hizmet alanının genişlemesi, kurumsal bir yapıyı zorunlu kılmış ve 12 Temmuz 1970 tarihinde 1312 sayılı kanunla TEK (Türkiye Elektrik Kurumu) kurulmuştu, iktisadi kuruluşu olarak oluşturulan Kurum 25.10.1970 tarihinde faaliyetine başlamıştır. Böylelikle belediyeler ve İller Bankası dışında elektrik enerjisi sektöründe üretim, iletim, dağıtım ve tedarik faaliyetleri bu kurumun bünyesinde birleştirilmiştir (Erdoğan, 2006).

3.1.2 1980 sonrası özelleştirme dönemi ve 3096 Sayılı Kanun

Türkiye'de elektrik sektörünün özelleşmesi süreci, 1980'li yıllarda başlamıştır. 1984 yılında çıkarılan 2983 sayılı "Tasarrufların Teşviki ve Kamu Yatırımlarının Hızlandırılması Hakkında Kanun" ile özelleştirme uygulamalarına yönelik ilk adım atılmıştır. Bu kanun, elektrik sektöründe de özelleştirmenin temellerini atarak, devletin ekonomik yükünü azaltma ve sektörde verimliliği artırma amacını güdüyordu. 1990'lı yıllara gelindiğinde, Türkiye'nin enerji sektöründeki yapısal değişim hız kazanmış ve özel sektöre yönelik elektrik üretimi ve dağıtımında serbestleşme adımları atılmaya başlanmıştır. Bu dönemde 1986 yılında çıkarılan 3096 sayılı "Elektrik Piyasasının Düzenlenmesi ve Özelleştirilmesi Hakkında Kanun" ile özelleştirme süreci daha da ivmelenmiş, elektrik piyasasında rekabetin artırılması hedeflenmiştir. 3096 sayılı kanun, elektrik sektöründe kamu tekeli kırımayı ve özelleştirilen şirketlerin piyasa koşullarına göre faaliyet göstermesini sağlamayı amaçlamıştır. Özelleştirme politikaları, enerji alanında rekabetin teşvik edilmesini ve devletin doğrudan müdahalesinin sınırlanmasını hedeflemiştir. Bu dönemde, kamuya ait elektrik şirketlerinin özelleştirilmesi için çeşitli düzenlemeler yapılmış ve özelleştirme

sürecinin etkin bir şekilde uygulanabilmesi için hukuki altyapılar oluşturulmuştur (Güvenek, 2009). Özelleştirme uygulamalarının temel hedeflerini yedi alt başlıkta incelenebilir:

- **Devletin Ekonomik Yükünü Azaltmak:** Özelleştirme, devletin kamu hizmetlerinde ve altyapı yatırımlarında üstlendiği mali yükü azaltmayı amaçlamıştır. Bu, bütçe açığının daraltılmasına yardımcı olmaktadır (Ültanır, 1994).
- **Verimlilik ve Rekabetin Artırılması:** Özel sektör, genellikle daha verimli bir şekilde yönetilebileceği düşünülen elektrik şirketlerinde faaliyet göstereceği için, rekabet ortamının oluşması ve verimliliğin artması hedeflenmiştir (Türkoğlu, 2005).
- **Yatırım İhtiyaçlarının Karşılanması:** Elektrik sektöründeki yatırımların artırılması amacıyla özel sektörün bu alana girmesi teşvik edilmiştir. Bu, özellikle devletin finansal kaynaklarıyla yapılması zor olan büyük yatırımlar için önemlidir (TİK, 2004).
- **Sektörel Yenilik ve Gelişimin Sağlanması:** Özelleştirme ile birlikte, sektörde yeni teknolojilerin kullanılmasına ve yönetim anlayışının modernleşmesine olanak tanınması hedeflenmiştir (Erdoğan, 2006).
- **Kamu Tekelinin Kırılması:** Elektrik sektöründe devletin tekeli kırarak ve özel sektörün bu alandaki faaliyetlerine daha fazla olanak tanımak amacıyla özelleştirme adımları atılmıştır (Ültanır, 1994).
- **Daha Etkin Yönetim ve Hizmet Sunumu:** Devletin bürokratik engellerinin ortadan kaldırılması ve daha esnek bir yönetim yapısının oluşturulmasıyla, hizmet kalitesinin artırılması beklenmiştir (Türkoğlu, 2005).
- **Uluslararası Rekabetle Uyumluluk:** Özelleştirilen sektörlerin küresel ölçekte daha rekabetçi hale gelmesi, ülkenin enerji piyasasını uluslararası düzeyde daha uyumlu hale getirmeyi amaçlanmıştır (Berberoğlu, 1982).

3.1.3 1990'lı yıllar ve 3996 Sayılı Kanun

1990'lı yıllara gelindiğinde, Türkiye'deki genel ekonomik liberalleşme politikaları elektrik sektöründe de etkisini artırmış ve bu alanda önemli düzenlemeler yapılmıştır.

1993-1994 döneminde, 93/4789 sayılı Bakanlar Kurulu kararı ile Türkiye Elektrik Kurumu (TEK), üretim ve iletimden sorumlu Türkiye Elektrik Üretim İletim A.Ş. (TEAŞ) ve dağıtım alanından sorumlu Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) olarak ikiye bölünmüştür. Bu yeniden yapılanma, sektördeki özelleştirme sürecinin hızlanmasında önemli bir adım olmuştur. 1994 yılında çıkarılan 3996 sayılı "Bazı Yatırım ve Hizmetlerin Yap-İşlet-Devret Modeli Çerçevesinde Yaptırılması Hakkında Kanun" ise, Yap İşlet Devret (YİD) modelinin en kapsamlı düzenlemesi olmuştur. Bu kanunun amacı, kamu kurumları ve kamu iktisadi teşebbüslerinin üstlendiği, ileri teknoloji ve yüksek maliyet gerektiren bazı yatırım ve hizmetlerin, elektrik piyasasında faaliyet gösteren özel sektör aracılığıyla gerçekleştirilmesini sağlamak ve kamu kesiminin kaynak yetersizliği nedeniyle gerçekleştiremediği yeni yatırımları hayata geçirmektir. 3996 sayılı kanun, köprüler, tüneller, barajlar, sulama sistemleri, içme ve atık su arıtma tesisleri, haberleşme altyapıları, maden işletmeleri, otoyollar, demiryolları, otoparklar gibi birçok projeyi, yap işlet devret modeli çerçevesinde özel sektöre devredilmesi ve işletilmesi için bir çerçeve sunmuştur. Bu düzenlemelerle, elektrik sektörü de dahil olmak üzere çeşitli alanlarda özel sektörün daha fazla yer almasını ve devletin üzerindeki yükün hafifletilmesini hedeflenmiştir (Güvenek, 2009).

3.1.4 4628 Sayılı Elektrik Piyasası Kanunu ve EPDK'nın kurulması

1990'ların sonunda, elektrik üretim şirketlerini bağlayan, hazine garantilerine dayalı ve uzun dönemli anlaşmaların sektörde sağlanmak istenen rekabet amacına uygun olmadığına dair eleştiriler gündeme gelmiştir. Bu eleştiriler doğrultusunda, Avrupa Birliği enerji mevzuatına uyum sağlamak ve liberal bir elektrik piyasası oluşturmak amacıyla önemli adımlar atılmaya başlanmıştır. Bu kapsamda, 2001 yılı mart ayında 4628 Sayılı Enerji Piyasası Kanunu (EPK) yürürlüğe girmiş ve Enerji Piyasası Düzenleme Kurumu (EPDK) kurulmuştur. Bu düzenlemeler, Türkiye elektrik sektöründe serbestleşmeyi teşvik ederek rekabetin artırılmasını, maliyetlerin düşürülmesini, kalitenin ve verimliliğin yükseltilmesini ve piyasa yapısının şeffaflaştırılmasını amaçlayan reformların temelini atmıştır.

Kanunun amacı; elektriğin yeterli, kaliteli, sürekli, düşük maliyetli ve çevreyle uyumlu bir şekilde tüketicilerin kullanımına sunulması için, rekabet ortamında özel hukuk hükümlerine göre faaliyet gösterebilecek, mali açıdan güçlü, istikrarlı ve şeffaf bir

elektrik enerjisi piyasasının oluşturulması ve bu piyasada bağımsız bir düzenleme ve denetimin sağlanması olup kanun; elektrik üretimi, iletimi, dağıtımı, toptan satışı, perakende satışı, perakende satış hizmeti, ithalat ve ihracatı ile bu faaliyetlerle ilişkili tüm gerçek ve tüzel kişilerin hak ve yükümlülüklerini, Enerji Piyasası Düzenleme Kurumu'nun (EPDK) kurulması ile çalışma usul ve esaslarını ve elektrik üretim ve dağıtım varlıklarının özelleştirilmesinde izlenecek usulü kapsamaktadır. Enerjisi Piyasası Kanunu'nun çıkarılma nedenleri:

- Piyasa için rekabet yerine piyasa içinde rekabetin sağlanması,
- Hazine garantisi olmayan sisteme geçilmesi,
- Gerçek maliyetlerin belirlenmesi, çapraz sübvansiyonun kaldırılması,
- Şeffaf ve adil bir piyasa yapısının oluşturulması,
- İdari ve mali açıdan özerk bir kurum tarafından piyasanın düzenlenmesi ve denetlenmesi olarak gösterilebilir (Gürbüz, 2006).

Elektrik Piyasası Kanunu'nun yürürlüğe girmesiyle birlikte, Türkiye Elektrik Anonim Şirketi (TEAŞ) üç temel faaliyet alanına ayrılmıştır: üretim, iletim ve toptan satış. Bu düzenleme sonucunda, Elektrik Üretim A.Ş. (EÜAŞ) üretim faaliyetlerinden, Türkiye Elektrik Ticaret ve Taahhüt A.Ş. (TETAŞ) toptan satış faaliyetlerinden ve Türkiye Elektrik İletim A.Ş. (TEDAŞ) iletim faaliyetlerinden sorumlu olacak şekilde yapılandırılmıştır.

EÜAŞ, TEAŞ'tan termik santralleri, Devlet Su İşleri ise hidroelektrik santrallerin mülkiyet ve işletme haklarını devralmıştır. Ayrıca, Enerji Piyasası Düzenleme Kurumu (EPDK) onayıyla gerektiğinde yeni üretim tesisleri kurma, kiralama ve işletme hakkına sahiptir.

TETAŞ, TEAŞ'tan devraldığı mevcut enerji alım ve satım anlaşmalarının yürütülmesinden sorumludur. Bunun yanı sıra, Yap-İşlet (Yİ), Yap-İşlet-Devret (YİD) ve İşletme Hakkı Devri (İHD) sözleşmeleri kapsamında ortaya çıkabilecek maliyetlerin karşılanması görevini üstlenmiştir.

TEDAŞ, kamuya ait tüm iletim tesislerini devralmış ve bu tesislerin bakımı, işletilmesi ve yeni iletim altyapılarının kurulması ile yükümlü hale gelmiştir. Ayrıca, piyasa mali uzlaştırma sisteminin işleyişinden sorumlu bir kurum olarak faaliyet göstermektedir.

Türkiye'nin elektrik dağıtım şebekesi, 21 dağıtım bölgesine ayrılmıştır. Bu bölgelerden Kayseri bölgesi, özel bir şirket tarafından işletilirken, kalan 20 dağıtım bölgesinde TEDAŞ tarafından dağıtım şirketleri kurulmuştur.


Bu yapılanma, Türkiye'de elektrik piyasasının daha etkin, şeffaf ve rekabetçi bir yapıya kavuşmasını amaçlamakta ve enerji arz güvenliğinin sürdürülebilirliğine önemli katkılar sağlamaktadır (Güvenek, 2009).

Türkiye Elektrik Piyasasının işleyişi ile ilgili son düzenleme 30 Mart 2013 tarihli Resmi Gazetede yayımlanarak yürürlüğe giren 6446 sayılı Elektrik Piyasası Kanunu ile gerçekleştirilmiştir. Bu kanun ile organize toptan elektrik piyasalarının işletilmesi ve bu piyasalarda gerçekleştirilen mali uzlaştırma işlemleri ile bu faaliyetlere ilişkin diğer mali işlemler piyasa işletim faaliyeti olarak tanımlanmıştır. Bu kanun kapsamında Enerji Piyasaları İşletme Anonim Şirketi (EPIAŞ) kurulmuştur. EPIAŞ, piyasa işletim lisansı kapsamında, Borsa İstanbul Anonim Şirketi ile TEİAŞ tarafından Elektrik Piyasası Kanunu kapsamında işletilen piyasalar dışında kalan organize toptan elektrik piyasalarının işletim faaliyetini yürütür. Ayrıca EPIAŞ 6446 sayılı kanuna göre TEİAŞ tarafından piyasa işletim lisansı kapsamında işletilen organize toptan elektrik piyasalarının mali uzlaştırma işlemlerini ve diğer mali işlemlerini yürütür (Güvenek, 2009).

3.2 Gün Öncesi ve Gün İçi Piyasası

Serbestleşen elektrik enerjisi piyasasında, aktörlerin doğru stratejiler geliştirebilmesi ve geleceğe yönelik doğru öngörülerde bulunabilmesi son derece önem kazanmıştır. Elektrik enerjisi sektörü, çok oyunculu ve dinamik bir piyasa yapısına dönüşmüş olup, bu durum üretici ve tedarikçilerin piyasa koşullarındaki değişimlere hızlı tepki vermesini, ellerindeki kaynakları verimli bir şekilde kullanmasını ve tüketicilere en uygun teklifleri sunmalarını gerektirmektedir. Bu başarı, amaca yönelik tahmin metodolojilerinin oluşturulmasından geçmektedir. Bugüne kadar sektör içinde ve akademik alanda uzun ve orta vadeli talep tahminleri yapılmaktadır; bu tahminler özellikle ikili anlaşmalar için önemli bir yer tutmaktadır. Geçmişte, bu tahminler genellikle elektrik enerjisi talebi üzerine yapılırken, günümüzde açık piyasa ekonomisinin etkisiyle, tahminler daha çok fiyat endeksli olarak gerçekleştirilmeye başlanmış ve enerji talebi de fiyat denklemiindeki temel bileşenlerden biri olmuştur.

2015 yılı gerçekleşen işlem hacimlerine bakıldığında, ikili anlaşmalardan sonra en çok işlem gün öncesi piyasasında yapılmaktadır (Biçen, 2016).



Şekil 3.1 : 2015 yılı Türkiye elektrik piyasası işlem hacimleri.

Gün öncesi piyasası bir gün önceden, bir gün sonrası için talep fiyat dengesinin ayarlanmaya çalışıldığı bir ortam sunmaktadır. Gerçek zamanlı olmasa da ona yakınlığı itibariyle ani dalgalanmaları yansıtmaması itibariyle bu piyasada oluşan fiyatlar referans elektrik fiyatı olarak kabul edilebilir. Tipik gün öncesi piyasası işlem sürecinde saat 11:30'a kadar bir sonraki gün için teklif bildirimlerini piyasa işletmecisine bildirmelidir. Saat 13:00'a kadar optimizasyon süreçleri tamamlanarak ilgili günün her bir saati için piyasa takas fiyat/miktarları belirlenerek katılımcılara duyurulmaktadır. Saat 14:00 itibari ile kesinleşmiş fiyatların ilan edilmektedir.

Gün içi piyasasında ise gerçek zamana kadar ortaya çıkabilecek ve öngörülemeyen olaylar (arızalar, yenilenebilir üretim merkezlerindeki dengesizlikler, vb.) nedeniyle oluşabilecek dengesizlik maliyetlerinin azaltılmasına çalışılmaktadır. Elektrik enerjisi spot piyasasında gerçek zamana yaklaştıkça fiyat riski artmakta ve tahmin edilebilirliği zorlaşmaktadır.

Gün Öncesi Piyasasında belirlenen piyasa takas fiyatları, Dengeleme Güç Piyasasında görülen sistem marjinal fiyatlarına göre daha stabil bir seyir izler. Dengeleme Güç Piyasasında fiyatlar, yüksek risk ve değişkenlik göstermekle birlikte, burada asıl amaç, hızlı çözümler üreterek sistemin güvenilirliğini temin etmektir (Biçen, 2016).

4. MATERYAL VE YÖNTEM


Derin öğrenme, son yıllarda yapay zeka ve makine öğrenimi alanlarında kayda değer ilerlemeler sağlayan bir kavramdır. Temelinde, insan beyninin işleyişini taklit eden ve karmaşık veri yapıları üzerinde analiz ve çıkarım yapabilen yapay sinir ağı modelleri yer almaktadır. Bu modeller, ileri düzey tahminlerde bulunarak karmaşık problemleri çözme kapasitesine sahiptir. Derin öğrenmenin farklı mimarileri özellikle zaman serileri ve sıralı veri analizinde önemli başarılar göstermektedir. Bu mimariler arasında Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Süreli Bellek (LSTM) ve Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM) öne çıkmaktadır. Yapay sinir ağlarının öğrenme süreçleri, ileri yayılım ve geri yayılım gibi tekniklerle desteklenirken, optimizasyon algoritmaları bu sürecin etkinliğini artırmaktadır. Aktivasyon fonksiyonları, ağın girdilere nasıl tepki vereceğini belirlemektedir.

4.1 Yapay Sinir Ağlarının Öğrenmesi

İnsan beyni, 10 milyardan fazla nörondan oluşan son derece karmaşık ve etkili bir ağ sayesinde işlevlerini yerine getirmektedir. Bu nöronlar, bilişsel, algısal ve motor işlevler gibi çeşitli görevleri gerçekleştirme kapasitesine sahiptir. Şekil 4.1'de görüldüğü gibi, her bir nöronun dendritleri, hücrenin bilgi alımı ve iletiminde görev alan dallı uzantılardır. Bu dendritler, hücrenin işlem merkezi olan soma ile bağlantılıdır.

Soma içerisinde yer alan çekirdek (nucleus), hücrenin genetik bilgisini taşır ve işlevlerinin düzenlenmesinden sorumludur. Nöronun bir diğer önemli bileşeni olan akson, hücre gövdesinden uzanan uzun bir yapıdır ve sinaptik terminaller aracılığıyla bilgiyi diğer nöronlara iletmek üzere dallara ayrılır.

Bu karmaşık organizasyon, beynin paralel işlem kapasitesini ve belirsiz bilgileri etkili bir şekilde işleme yeteneğini yansıtarak, insan beyninin karmaşık ve zorlu görevleri başarıyla gerçekleştirebilmesini sağlayan yapısal temeli oluşturur (Abraham, 2005).



Şekil 4.1 : Nöron yapısı (Abraham, 2005).

Sinapslardaki iletim, bir nörondan diğerine sinyal aktarımı sırasında verici kimyasalların salınımını içeren karmaşık bir kimyasal süreçtir. Bu işlem, alıcı nöronun soma bölgesindeki elektriksel potansiyelin değişmesine yol açar. Elektriksel potansiyel belirli bir eşik seviyesine ulaştığında, akson boyunca bir itme (impuls) yayılır ve nöron aktif hale gelir.


Yapay sinir ağları, biyolojik sinir sistemlerinden esinlenerek geliştirilen matematiksel modellerdir. McCulloch ve Pitts (1943) tarafından sunulan basit nöron modelleri, sinir ağlarına yönelik ilgiyi artırmıştır. Bu modeller, bağlantısal modeller veya paralel dağıtılmış işleme olarak da adlandırılır.

Yapay sinir ağlarının temel bileşenleri, yapay nöronlar veya düğümler olarak tanımlanır. Biyolojik sinapsların etkileri, giriş sinyallerine atanan ağırlıklarla temsil edilir. Nöronun lineer olmayan tepkisi, bir dönüşüm fonksiyonu yardımıyla ifade edilir. Bu yanıt, girişlerin dönüşüm fonksiyonu aracılığıyla modifiye edilmiş ağırlıklı toplamları olarak hesaplanır.

Yapay nöronların öğrenme yeteneği, seçilen öğrenme algoritması sayesinde ağırlıkların ayarlanmasıyla gerçekleştirilir. Tipik bir yapay nöronun ve çok katmanlı bir sinir ağının yapısı Şekil 4.2'de açıklanmaktadır. Şekilde gösterildiği gibi, girişlerden gelen sinyal akışının bir nöronun çıkış sinyal akışı (O) ile tek yönlü olduğu kabul edilmektedir. Nöronun çıkış sinyali Denklem 4.1'de matematiksel olarak tanımlanmıştır.

$$O = f(\text{net}) = f\left(\sum_{j=1}^n w_j x_j\right) \quad (4.1)$$

Şekil 4.2'nin (a) bölümünde, bir yapay nöronun şematik bir gösterimi sunulmaktadır. Bu yapay nöron, dört girişe (x_1, x_2, x_3, x_4) sahiptir. Her giriş, nörona ulaşan sinyalin etkisini belirleyen ağırlıklar (w_1, w_2, w_3, w_4) ile çarpılır. Elde edilen bu değerler, bir toplama fonksiyonu aracılığıyla bir araya getirilir. Toplam değere bir aktivasyon fonksiyonu (f) uygulanarak, nöronun nihai çıkışı (O) oluşturulur (Abraham, 2005).



Şekil 4.2 : (a) Yapay nöron (b) Çok katmanlı yapay sinir ağı mimarisi (Abraham, 2005).

Şekil 4.2'nin (b) bölümünde, çok katmanlı bir yapay sinir ağı yapısının şematik bir gösterimi yer almaktadır. Bu yapı; bir giriş katmanı, bir veya birden fazla gizli katman ve bir çıkış katmanından oluşmaktadır. Giriş katmanı, dışarıdan alınan ham verileri temsil eder. Her bir nöron, kendisinden sonraki katmandaki nöronlarla bağlantılıdır. Gizli katmanlar, verileri işleyerek daha detaylı ve karmaşık özelliklerin öğrenilmesini sağlar. Sürecin sonunda, çıkış katmanı işlenmiş veriyi nihai sonuç olarak sunar. Ağ içindeki her bağlantı, belirli ağırlık değerleri ile temsil edilir ve bu ağırlıklar, ağın eğitim süreci boyunca optimize edilir.

Yapay sinir ağlarının öğrenme süreci, verilen giriş verileri ve beklenen çıktılar arasında en doğru ilişkiyi kurmayı amaçlar. Bu amaç doğrultusunda, ağın ağırlıkları uygun şekilde ayarlanır. Ağırlık ayarlama işlemi, genellikle bir hata oranının minimize edilmesi prensibiyle gerçekleştirilir. Hata oranı, ağın ürettiği çıktı ile beklenen ideal çıktı arasındaki fark olarak tanımlanır.

Bu sürecin merkezinde yer alan geri yayılım algoritması, çıktı katmanından başlayarak her nöronda üretilen hata miktarını geriye doğru yayar. Böylece, her ağırlığın ne

ölçüde ve hangi yönde değiştirilmesi gerektiği belirlenir. Bu süreç, ağın performansını iyileştirmek amacıyla tekrarlayıcı bir şekilde devam eder.

Ağın karmaşıklığı arttıkça, katman ve nöron sayısının artışıyla birlikte öğrenme süreci daha da zorlu hale gelir. Bu durum, daha gelişmiş optimizasyon teknikleri ve daha yüksek işlem gücü gerektirir. Tüm bu süreçlerin sonunda yapay sinir ağları, girdi verileri arasındaki karmaşık desenleri ve ilişkileri başarılı bir şekilde modelleyebilir. Bu yetenekleri sayesinde, görsel tanıma, doğal dil işleme ve tahmin görevleri gibi alanlarda oldukça etkili sonuçlar üretebilir.


4.1.1 İleri yayılım ve geri yayılım

İleri yayılım ve geri yayılım, yapay sinir ağlarının eğitim sürecindeki iki temel aşamayı oluşturur. İleri yayılım aşamasında, giriş verileri ağın katmanları boyunca ilerleyerek son katmanda bir tahmin üretilir. Her katmandaki nöronların aktivasyonları, bir önceki katmandan gelen sinyallerin ağırlıklı toplamı ve aktivasyon fonksiyonu kullanılarak hesaplanır.

Geri yayılım aşamasında ise ağın ürettiği çıktı ile beklenen sonuç arasındaki hata, katmanlar boyunca geriye doğru yayılır. Bu süreçte, her bir ağırlığın hata üzerindeki katkısı hesaplanarak ağırlıkların güncellenmesi sağlanır. Bu çift yönlü işlem, ağın doğru tahminler yapabilmesi için gerekli olan öğrenme ve adaptasyon sürecinin gerçekleşmesine olanak tanır.

İleri beslemeli sinir ağları, üst üste yerleştirilmiş tam bağlantılı katmanlardan oluşan bir yapıya sahiptir. Her katman, kendine özgü bir ağırlık matrisi $W^{(k)}$ ve bias vektörü $b^{(k)}$ ile tanımlanır. Bu katmanlar, bir önceki katmandan gelen girdi vektörünü $z^{(k-1)}$ olarak, ilgili katmanın çıktı vektörünü $z^{(k)}$ oluşturur. Bu işlem $k=1 \dots l$ için tekrar eder ve $z^{(l)}$ vektörü, ağın nihai çıktısını temsil eder. Şekil 4.3'te bu yapı görsel olarak sunulmaktadır.

Bazı durumlarda, ağ daha seyrek bağlantılarla basitleştirilebilir. Bu durum, $W^{(k)}$ ağırlık matrisinin seyrek bir yapıya sahip olmasına neden olur. Ancak, katmanlar arasındaki bağlantılar her zaman veri akışının yönlü ve döngüsüz bir grafik yapısını korumasını sağlar (Naumov, 2017).



Şekil 4.3 : Örnek bir ileri beslemeli sinir ağı (Naumov, 2017).

Bir girdi vektörü x^* verildiğinde, sinir ağının çıkışı $z^{(l)}$ aşağıda verilen Denklem 4.2 ve Denklem 4.3 kullanılarak ardışık bir şekilde hesaplanmaktadır. İlgili denklemler doğrultusunda, $k=1 \dots l$ ve $z^0 = x^*$ olarak tanımlanır. Literatürde bu işlem, ileri yayılım olarak adlandırılmaktadır (Naumov, 2017). Eğitim veri seti D üzerinden alınan bir örnek veri, $(x^* z^*)$ biçiminde temsil edilmektedir. İleri yayılım yöntemiyle gerçek çıktı $z^{(l)}$ elde edilir. Hata, Denklem 4.4 kullanılarak $\frac{1}{2}L$ şeklinde hesaplanır ve burada L , kayıp fonksiyonunu temsil etmektedir.

$$z^k = f(y^{(k)}) \quad (4.2)$$

$$y^k = W^{(k)} z^{(k-1)} + b^{(k)} \quad (4.3)$$

$$\varepsilon = \frac{1}{2} \|z^* - z^{(l)}\|_2^2 \quad (4.4)$$

Ağın her katmanındaki ağırlıklar w_{ij} ve bias değerleri b_i , kayıp fonksiyonu L 'nin bireysel bileşenleri E üzerinden ayarlanarak optimizasyon probleminin çözümü amaçlanmaktadır. Ağırlık ve bias güncellemeleri Denklem 4.5 ve Denklem 4.6'da verilmiştir. Burada, a öğrenme oranı olarak adlandırılan sabit bir değeri temsil etmektedir.

$$W^{(k)} - a \Delta W^{(k)} \quad (4.5)$$

$$b^{(k)} - a \Delta b^{(k)} \quad (4.6)$$

Ağırlık ($\Delta W^{(k)}$) ve bias ($\Delta b^{(k)}$) güncellemeleri, sırasıyla Denklem 4.7 üzerinden tanımlanmaktadır. Bu güncellemeler, ağırlıkların ve bias değerlerinin kayıp

fonksiyonu bileşenine olan toplam etkisinin en büyük olduğu yönü göstermektedir. İleri beslemeli sinir ağı, Denklem 4.2 ve Denklem 4.3 ile tanımlanırken, kayıp fonksiyonu bileşeni Denklem 4.4'te ifade edilmektedir. Ağırlıkların ve bias değerlerinin gradyanı ise Denklem 4.8'de (rank-1 matris için) ve Denklem 4.9'da sunulmaktadır.

$$\frac{\partial \varepsilon}{\partial \mathbf{w}_{ij}^{(k)}}, \frac{\partial \varepsilon}{\partial b_i^{(k)}} \quad (4.7)$$

$$\mathbf{G}_w^{(k)} = \mathbf{v}^k \mathbf{z}^{(k-1)T} \quad (4.8)$$

$$\mathbf{G}_b^{(k)} = \mathbf{v}^k \quad (4.9)$$

Burada $\mathbf{G}_w^{(k)} = \left[\partial \varepsilon / \partial \mathbf{w}_{ij}^{(k)} \right] m \times n$ boyutlu bir matristir, ayrıca $\mathbf{G}_b^{(k)} = \left[\partial \varepsilon / \partial b_i^{(k)} \right] m \times 1$ boyutlu vektörü $k=1, \dots, 2$, için

$$\mathbf{v}^{(l)} = -(\mathbf{z}^* - \mathbf{z}^{(l)}) \circ \mathbf{f}'(\mathbf{y}^{(l)}) \quad (4.10)$$

$$\mathbf{v}^{(k-1)} = \left(\mathbf{W}^{(k)T} \mathbf{v}^{(k)} \right) \circ \mathbf{f}'(\mathbf{y}^{(k-1)}) \quad (4.21)$$

Hadamard çarpımı olarak adlandırılan $\circ$ işlemi ile ele alınmaktadır ve $\mathbf{f}'() = [\mathbf{f}'(), \dots, \mathbf{f}'()]^T$ şeklinde tanımlanmaktadır. Kayıp fonksiyonunun ağırlıklara göre bileşen bazında kısmi türevi alınarak aşağıdaki eşitlikler elde edilmektedir.

$$\begin{aligned} \frac{\partial \varepsilon}{\partial \mathbf{w}_{ij}^{(k)}} &= \left(\frac{\partial \varepsilon}{\partial \mathbf{z}_i^{(k)}} \right) \left(\frac{\partial \mathbf{z}_i^{(k)}}{\partial \mathbf{y}_i^{(k)}} \right) \left(\frac{\partial \mathbf{y}_i^{(k)}}{\partial \mathbf{w}_{ij}^{(k)}} \right) \\ &= \left(\frac{\partial \varepsilon}{\partial \mathbf{z}_i^{(k)}} \right) \mathbf{f}'(\mathbf{y}_i^{(k)}) \mathbf{z}_j^{(k-1)} \\ &= \mathbf{v}_i^{(k)} \mathbf{z}_j^{(k-1)} \end{aligned} \quad (4.32)$$

Burada $\mathbf{f}'$, $d\mathbf{f}/d\mathbf{y}$ nin adi türevini ifade etmekte ve $\mathbf{v}_i^{(k)} = \left(\frac{\partial \varepsilon}{\partial \mathbf{z}_i^{(k)}} \right) \mathbf{f}'(\mathbf{y}_i^{(k)})$ 'dir.

Ayrıca, (4.4)'ü kullanarak çıktı katmanı $k=1$ için elde edilmiştir. Şu durumda

$$\frac{\partial \varepsilon}{\partial z_i^{(l)}} = -(z_i^* - z_i^{(l)}) \quad (4.43)$$

Eşitliği elde edilmektedir. Zincir kuralını kullanarak gizli katmanlar için ise

$$\begin{aligned} \frac{\partial \varepsilon}{\partial z_i^{(k-1)}} &= \sum_{j=1}^n \left(\frac{\partial \varepsilon}{\partial z_j^{(k)}} \right) f'(y_j^{(k)}) w_{ji}^{(k)} \\ &= \sum_{j=1}^n v_j^{(k)} w_{ji}^{(k)} \end{aligned} \quad (4.54)$$

İfadesi elde edilmektedir. Son olarak, i ve j indislerini matris formunda bir araya getirerek $G_w^{(k)}$ ifadesi elde edilmektedir. Denklem 4.12'de $\frac{\partial y_i^{(k)}}{\partial b_i^{(k)}} = 1$ eşitliğiyle birlikte $G_b^{(k)}$ için türev benzer bir yöntemle elde edilmektedir.

Denklem 4.11'de $v^{(k)}$ yardımcı vektörünün hesaplanması, Denklem 4.4'de tanımlanan hatanın, l çıkış katmanından başlayarak $k=1, \dots, 2$ katmanlarına doğru iletilmesini açıklamaktadır. Bu işlem literatürde "geriye yayılım" olarak adlandırılmaktadır (Naumov, 2017).

Hedef, genel olarak ağın çıktısında meydana gelen hataları azaltmaktır. Geri yayılım sürecinde, ağın çıktısından başlayan hata, her katmanda geriye doğru, yani giriş katmanına doğru yayılır. Bu süreç, ağın ağırlıklarının ve biaslarının nasıl güncellenmesi gerektiği hakkında önemli bilgiler sağlar. Geri yayılım, gradyan inişi yöntemiyle birlikte kullanılarak ağın ağırlıklarının optimizasyon problemine en uygun şekilde ayarlanmasını sağlar. Bu yöntem, ağın tahmin doğruluğunu artırarak öğrenme sürecini iyileştirir ve performansını yükseltir.

4.1.2 Optimizasyon algoritmaları


Optimizasyon algoritmaları, belirli hedeflere ulaşmayı veya en iyi sonucu elde etmeyi amaçlayan matematiksel yöntemlerdir. Genellikle bir fonksiyonun maksimum veya minimum değerini bulmak için kullanılırlar. Ekonomi, mühendislik, yapay zeka ve veri bilimi gibi birçok alanda geniş bir uygulama yelpazesine sahiptir. Optimizasyon, karmaşık problemlerin çözümünde kritik bir rol oynar ve en iyi ya da en verimli çözümleri sunar. Optimizasyon algoritmaları arasında gradyan inişi, genetik

algoritmalar ve parçacık sürü optimizasyonu gibi çeşitli yöntemler bulunmaktadır ve her biri farklı optimizasyon problemleri için uygun çözümler sağlar.

Yapay sinir ağlarının eğitiminde optimizasyon algoritmaları, ağın performansını artırmak ve daha doğru tahminlerde bulunabilmesini sağlamak açısından kritik bir rol oynar. Bu algoritmalar, kayıp fonksiyonunu en aza indirmek için ağın ağırlıklarını ve bias değerlerini ayarlamak amacıyla kullanılır. Gradyan inişi algoritması, bir fonksiyonun minimum değerini bulmak için kullanılan bir yöntemdir. Temel olarak, bir maliyet veya kayıp fonksiyonunun türevini (gradyanını) hesaplar ve gradyanın negatif yönünde adımlar atarak fonksiyonun minimum değerine ulaşmayı hedefler. Denklem 4.15'te gradyan inişi optimizasyon algoritması tanımlanmaktadır. Toplu gradyan inişi yönteminde, maliyet fonksiyonunun gradyanı tüm eğitim veri seti üzerinden parametreler θ kullanılarak hesaplanır. Gradyan inişi, parametreleri $\theta \in \mathbb{R}^d$ ile ifade edilen bir modelin amaç fonksiyonu $J(\theta)$ 'yi minimize etme yöntemidir (Ruder, 2016). Öğrenme oranı (η), bir yerel minimuma ulaşmak için yapılan adımların büyüklüğünü belirler.

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta) \quad (4.65)$$

Her adımda, parametreler gradyanın yönünde belirli bir oranda güncellenmektedir. Bu oran, öğrenme oranı olarak adlandırılmaktadır. Gradyan inişi, özellikle makine öğrenimi ve derin öğrenme alanlarında modellerin eğitiminde yaygın olarak kullanılan temel bir optimizasyon tekniğidir. Bu teknik, modelin performansını en üst düzeye çıkarmak için parametrelerin en uygun değerlerini belirlemeyi amaçlamaktadır.



Şekil 4.4 : Gradyan inişi algoritması.


Eğrinin başlangıç noktası, ağırlıkların rastgele bir başlangıç değerini temsil etmektedir. Bu noktadan itibaren, öğrenme adımları boyunca maliyet fonksiyonu değeri global minimuma ulaşana kadar azalmaktadır. Her bir mor nokta, öğrenme oranı tarafından belirlenen adım büyüklüğüyle yapılan iteratif ağırlık güncellemelerini temsil ederken, sarı nokta algoritmanın ulaşmayı hedeflediği minimum maliyet değerini simgelemektedir. Şekil 4.4, algoritmanın optimum değere nasıl yaklaştığını ve ağırlık değerlerinin nasıl güncellendiğini görsel olarak sunmaktadır.

Stokastik gradyan inişi (SGD) yöntemi, her bir eğitim örneği x^i ve karşılık gelen etiketi y^i için parametreleri güncellemektedir. Denklem 4.16, SGD'nin matematiksel formülasyonunu vermektedir.

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \quad (4.76)$$

Toplu gradyan inişi, büyük veri setleri söz konusu olduğunda gereksiz hesaplamalara yol açabilmektedir. Bunun nedeni, her parametre güncellemesinden önce benzer örnekler için gradyanların yeniden hesaplanmasıdır. Buna karşılık, stokastik gradyan inişi, her seferinde tek bir örnek üzerinden güncelleme yaparak bu hesaplama fazlalığını azaltır. Bu güncelleme tekniği genellikle çok daha hızlıdır. Ancak, SGD yöntemi sık güncellemeler nedeniyle yüksek varyanslı sonuçlar üretebilmektedir.

Toplu gradyan inişi, parametrelerin yerleştirildiği havzanın minimum noktasına doğru yakınsar. Öte yandan, SGD'nin doğasındaki dalgalanmalar, algoritmanın yeni ve potansiyel olarak daha iyi yerel minimum noktalarına atlamasını sağlar. Ancak bu dalgalanmalar, SGD'nin hedefin ötesine geçmesine ve kesin bir minimuma ulaşmasını zorlaştırarak yakınsama sürecini karmaşıktırır.



Şekil 4.5 : Momentum etkisinin SGD optimizasyonu üzerindeki karşılaştırması (LeCun et al., 2002).

Şekil 4.5, iki farklı SGD yöntemini göstermektedir:

(a) kısmında, momentum kullanılmadan uygulanan SGD'nin optimizasyon yüzeyindeki derin vadilerde ilerlerken dalgalanmalara maruz kaldığı ve bu durumun algoritmanın hedefe doğru tereddütlü bir ilerleme sergilemesine neden olduğu gözlemlenmektedir.

(b) kısmında ise, momentum terimi eklenen SGD'nin daha stabil ve düzgün bir yol izlediği görülmektedir. Momentum, önceki gradyanların birikimini dikkate alarak algoritmanın daha hızlı ve etkin bir şekilde ilerlemesine olanak tanır ve bu sayede yüzey üzerinde daha kararlı bir şekilde yerel minimum noktalarına ulaşmayı sağlar.

Momentum, SGD algoritmasına belirli bir yönde ivme kazandırarak osilasyonları azaltmaya yardımcı olan bir tekniktir. Bu yöntem, optimizasyon sürecinde algoritmanın daha kararlı ve hızlı bir şekilde ilerlemesini sağlar. Şekil 4.5'te, momentumun SGD üzerindeki etkisi görsel olarak sunulmaktadır. Ayrıca, Denklem 4.17'de momentum yönteminin matematiksel formülasyonu ayrıntılı bir şekilde ifade edilmiştir.

$$\begin{aligned} v_t &= \gamma v_{t-1} + \eta \nabla_{\theta} J(\theta) \\ \theta &= \theta - v_t \end{aligned} \quad (4.87)$$

Momentum, geçmiş zaman adımındaki güncelleme vektörünün belirli bir kısmının γ mevcut güncelleme vektörüne eklenmesiyle, optimizasyon sürecine ivme kazandıran bir tekniktir. Bu yöntem, birikmiş geçmiş gradyanların güncellemeler üzerinde bir ivme etkisi oluşturmasını sağlar ve algoritmanın hesaplama yüzeyindeki en dik eğimler boyunca tutarlı bir hız kazanmasına yardımcı olur.

Momentum terimi genellikle 0,9 gibi bir değere ayarlanır. Bu değer, gradyanların tutarlı yönde hareket ettiği boyutlarda ivmenin artmasını, gradyan yönlerinin değiştiği boyutlarda ise güncellemelerin azaltılmasını sağlar. Sonuç olarak, bu teknik daha hızlı bir yakınsama ve osilasyonların azaltılmasına olanak tanır (Ruder, 2016).

RMSprop ise gradyan tabanlı optimizasyon tekniklerinden biridir ve derin öğrenme modellerinin eğitiminde sıkça tercih edilen bir algoritmadır. Bu yöntem, öğrenme oranını algoritmanın önceki adımlarındaki gradyanların karesel ortalamasının köküne bölerek ayarlar. Böylece, öğrenme oranı her adımda gradyanların büyüklüğüne göre dinamik olarak uyarlanır. Bu sayede, öğrenme sürecinin başındaki hızlı ilerleme korunurken ilerleyen adımlarda daha dengeli ve stabil bir yakınsama elde edilir.

Denklem 4.18 ve Denklem 4.19, RMSprop algoritmasının matematiksel formülasyonunu ifade eder. Burada t zaman adımlarını temsil ederken, $G_t \in \mathbb{R}^{d \times d}$ bir diyagonal matris olarak tanımlanır. Diyagonal matrislerin özelliği, diyagonal dışındaki tüm elemanların sıfır, yalnızca diyagonal üzerindeki elemanların değer taşımasıdır. Bu tür matrisler, optimizasyon algoritmalarında farklı parametreler veya gradyanlar için ayrı ölçeklendirme faktörleri uygulamak amacıyla kullanılır.

$$E[g^2]_t = 0,9E[g^2]_{t-1} + 0,1g_t^2 \quad (4.18)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t \quad (4.19)$$

Uyarlanabilir Moment Kestirimi (Adam), her bir parametre için adaptif öğrenme oranları hesaplayan popüler bir optimizasyon yöntemidir (Kingma, 2014). Adam, RMSprop yöntemine benzer şekilde, geçmiş karesel gradyanların üssel olarak azalan ortalamasını v_t olarak takip eder. Ancak Adam, buna ek olarak momentum benzeri bir mekanizmayla, geçmiş gradyanların üssel olarak azalan ortalamasını da m_t olarak tutar.

Bu çift mekanizma, algoritmanın hem gradyanların yöneliminden faydalanmasını hem de her adımda daha dengeli ve güvenilir güncellemeler yapmasını sağlar. Bu sayede Adam, özellikle gürültülü gradyanlar veya düzensiz optimizasyon yüzeyleri gibi karmaşık senaryolarda daha hızlı ve kararlı bir yakınsama elde eder.

Adam optimizasyon yönteminin matematiksel formülasyonu Denklem 4.20'de verilmiştir

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{aligned} \quad (4.20)$$

m_t ve v_t , sırasıyla gradyanların birinci momenti (ortalama) ve ikinci momenti (merkezlenmemiş varyans) tahminlerini temsil eder. Bu tahminler, optimizasyon sürecinde parametre güncellemelerinin yönünü ve adım büyüklüğünü belirlemek için kullanılır. Adam yönteminin yazarları, özellikle başlangıç zaman adımlarında ve bozulma oranlarının düşük olduğu durumlarda β_1 ve β_2 değerleri 1'e yakınken, m_t ve v_t tahminlerinin sıfıra doğru ön yargılı (biased) olduğunu gözlemlemişlerdir.

Bu ön yargıları gidermek için bias düzeltmeli birinci ve ikinci moment tahminleri geliştirmişlerdir. Bu düzeltmeler, tahminlerin daha güvenilir ve doğru olmasını sağlayarak optimizasyon sürecinin performansını artırır.

Bu düzeltmelerin matematiksel ifadeleri Denklem 4.21'de verilmiştir.

$$\begin{aligned}\hat{m}_t &= \frac{m_t}{1-\beta_1^t} \\ \hat{v}_t &= \frac{v_t}{1-\beta_2^t}\end{aligned}\tag{4.21}$$

Bu tahminler daha sonra, parametre güncellemelerinde kullanılmış ve böylece Adam güncelleme kuralı elde edilmiştir. Adam'ın güncelleme kuralı, parametrelerin hem birinci moment m_t hem de ikinci moment v_t tahminleri kullanılarak optimize edilmesini sağlar.

Bu güncelleme kuralının matematiksel ifadesi Denklem 4.22'de verilmiştir.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t\tag{4.22}$$

Kingma (2014) tarafından gerçekleştirilen deneyler, Adam optimizasyon algoritmasının pratikte başarılı bir performans sergilediğini ve diğer adaptif öğrenme yöntemlerine kıyasla belirgin avantajlara sahip olduğunu göstermiştir. Bu avantajlar, algoritmanın öğrenme sürecindeki tutarlılığı ve karmaşık veri setlerinden etkili bir şekilde anlamlı desenleri öğrenme kapasitesini içermektedir.


Sonuç olarak, Adam algoritması, derin öğrenme modellerinin karmaşık ve büyük veri kümeleri üzerinde verimli bir şekilde eğitilmesine olanak tanımaktadır.

4.1.3 Aktivasyon fonksiyonları

Yapay sinir ağlarında aktivasyon fonksiyonları, bir nöronun aldığı girdi sinyallerini çıktı sinyallerine dönüştüren matematiksel işlevlerdir. Bu fonksiyonlar, nöronun ne zaman ve nasıl aktif olacağını belirler.

Lineer olmayan aktivasyon fonksiyonları, yapay sinir ağlarının karmaşık problemleri modellemesine ve lineer olmayan ilişkileri öğrenmesine olanak tanır. Bu sayede ağ, daha karmaşık veri desenlerini ve ilişkilerini keşfedebilir.

Yapay sinir ağlarında yaygın olarak kullanılan aktivasyon fonksiyonları arasında ReLU (Düzeltilmiş Lineer Birim), sigmoid ve tanh gibi fonksiyonlar bulunmaktadır. Bu fonksiyonlar, ağdaki her katmandaki nöronların çıktılarını belirler ve bu çıktılar, bir sonraki katmana veya nihai çıktı katmanına iletilerek sinyallerin şeklini ve şiddetini kontrol eder.



Şekil 4.6 : Yapay nöron ile aktivasyon fonksiyonu ilişkisinin temsili gösterimi (Sibi ve diğ, 2013).


Şekil 4.6’da bir yapay nöronun yapısını gösteren bir diyagram bulunmaktadır. Girdiler, $X_1, X_2, \dots, X_n$ olarak gösterilmektedir. Her bir girdi, ilgili ağırlıklar olan $w_1, w_2, \dots, w_n$ ile çarpılır. Ayrıca, bir bias ağırlığı olan w_0 da bu toplama eklenir.

Bu değerlerin toplamı, toplam girdi Σ olarak ifade edilir. Elde edilen toplam değer, bir aktivasyon fonksiyonu olan $f(\Sigma)$ ile işlenir ve nöronun çıktısı elde edilir.

Bu işlem, yapay nöronun aktivasyonunu belirleyerek, üretilen çıktının bir sonraki katmana nasıl iletileceğini ve sinyalin nasıl şekilleneceğini tanımlar.

4.1.3.1 Sigmoid fonksiyonu

Sigmoid aktivasyon fonksiyonu, yapay sinir ağlarında yaygın olarak kullanılan ve girdi değerlerini 0 ile 1 arasında bir değere dönüştüren bir fonksiyondur. Şekil 4.7, sigmoid aktivasyon fonksiyonunun grafiğini görsel olarak sunmaktadır.



Şekil 4.7 : Sigmoid fonksiyonu (Pan ve diğ, 2022).

Bu fonksiyon, x eksenindeki deęerler -10 ile 10 arasında deęiřirken, y eksenindeki sigmoid(x) deęerlerini 0 ile 1 arasında sınırlı bir řekilde çizmektedir. Fonksiyonun matematiksel formülü Denklem 4.23'te ifade edilmiřtir.


$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (4.23)$$

Sigmoid fonksiyonu, özellikle ikili sınıflandırma problemlerinde bir nöronun aktivasyonunu belirlemek için tercih edilmektedir. Bunun temel nedeni, çıktıları 0 ile 1 arasında bir olasılık deęeri olarak sıkıřtırarak, büyük ya da küçük girdi deęerleri karřısında dahi stabil bir çıktı saęlamasıdır.

4.1.3.2 Düzeltiřmiş lineer birim (ReLU) fonksiyonu

ReLU (Rectified Linear Unit), yapay sinir aęlarında yaygın olarak kullanılan bir aktivasyon fonksiyonu olarak bilinmektedir. Bu fonksiyon, girdisi sıfırdan büyükse girdiyi doğrudan çıktıya aktarmakta, sıfırdan küçük veya sıfıra eřitse çıktı olarak sıfır döndürmektedir. Matematiksel ifadesi Denklem 4.24'te verilmiřtir.

$$f(x) = \begin{cases} x & , x > 0 \\ 0 & , x \leq 0 \end{cases} \quad (4.24)$$



řekil 4.8 : ReLU fonksiyonu (Pratiwi ve dię, 2020).

řekil 4.8, ReLU aktivasyon fonksiyonunun grafięini göstermektedir. Grafikte, x eksenindeki negatif deęerler için fonksiyonun çıktısı sıfırdır. Pozitif x deęerlerinde ise fonksiyon çıktısı, x deęeriyle doğru orantılı olarak artmaktadır. Bu durum, ReLU'nun parçalı lineer doğasını açıkça yansıtmaktadır: negatif girdiler için çıktı sıfırken, pozitif girdiler için çıktı girdiye eřit olmaktadır.


ReLU, derin öğrenme modellerinde sıkça tercih edilmektedir çünkü hesaplama açısından oldukça verimlidir ve gradyan kaybı (vanishing gradient) sorununu azaltmaya yardımcı olmaktadır (Pratiwi ve diğ, 2020).

4.1.3.3 Hiperbolik tanjant fonksiyonu

Hiperbolik tanjant (tanh) fonksiyonu, gerçek sayıları -1 ile 1 arasında bir değere dönüştüren bir aktivasyon fonksiyonudur. Matematiksel ifadesi Denklem 4.25'te sunulmuştur.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = 2\sigma(2x) - 1 \quad (4.25)$$

Bu fonksiyon, sigmoid fonksiyonuna benzer şekilde girdileri sıkıştırır; ancak çıktı aralığı -1 ile 1 arasındadır. Bu özellik, negatif girdilere izin vererek bazı durumlarda öğrenme sürecini iyileştirebilir. Ayrıca, sıfır merkezli bir yapıya sahip olması nedeniyle, özellikle gradyan tabanlı öğrenme yöntemlerinde daha tutarlı güncellemeler sağlayarak tercih edilmektedir. Şekil 4.11, hiperbolik tanjant (tanh) aktivasyon fonksiyonunun grafiğini göstermektedir. Fonksiyon, girdi değerlerini $(-\infty, +\infty)$ aralığından $(-1, +1)$ aralığına sıkıştırır ve bu sayede çıktılar iki yönlü olarak normalleştirilir.



Şekil 4.11 : Hiperbolik tanjant fonksiyonu (Xiao ve diğ, 2005).

Grafikte, x değerlerinin -20'den +20'ye kadar olan aralıkta fonksiyonun davranışı gözlemlenmektedir. x değerleri arttıkça veya azaldıkça, tanh fonksiyonunun çıktısı asimptotik olarak +1'e veya -1'e yaklaşır. Bu özellik, fonksiyonun doğrusal olmayan

güçlü bir aktivasyon mekanizması olduğunu gösterir ve özellikle gradyanların verimli bir şekilde yayılmasına yardımcı olur.

Ek olarak, sıfır etrafında simetrik bir yapıya sahip olması, ağıın öğrenme sürecinde daha kararlı ve etkin bir güncelleme yapmasına katkı sağlar.

4.1.3.4 Softmax fonksiyonu

Softmax fonksiyonu, genellikle çok sınıflı sınıflandırma problemlerinde tercih edilen bir aktivasyon fonksiyonudur. Bu fonksiyon, bir vektördeki her bir değeri 0 ile 1 arasında bir olasılık değerine dönüştürerek, bu değerlerin toplamının 1 olmasını sağlar. Böylece, elde edilen çıktılar bir olasılık dağılımı olarak yorumlanabilir (Gao ve Pavel, 2017)

Softmax fonksiyonunun matematiksel ifadesi Denklem 4.26'da sunulmuştur.

$$\sigma_i(z) = \frac{\exp(\lambda z_i)}{\sum_{j=1}^n \exp(\lambda z_j)}, 1 \leq i \leq n \quad (4.26)$$

Bu denklemde:

- $\sigma_i(z)$, fonksiyonun i'inci çıktısını temsil eder.
- z , girdi vektörünü ifade eder.
- n , vektördeki eleman sayısını belirtir.
- λ , softmax fonksiyonunun keskinliğini ayarlayan bir parametre olarak kullanılır.

Bu parametre, çıktıların daha keskin veya daha düz bir olasılık dağılımına sahip olmasını sağlar ve modelin belirli sınıflara daha güçlü tahminlerde bulunmasına ya da daha genel bir tahmin dağılımı oluşturmaya yardımcı olur.

4.2 Derin Öğrenme Mimarileri ve Catboost

Derin öğrenme mimarileri, insan beyninin bilgi işleme mekanizmasından ilham alınarak geliştirilen, veri tabanlı öğrenme ve karar verme süreçlerini otomatize eden algoritmik yapılardır. Bu mimariler, genellikle birden fazla işleme katmanına sahip yapay sinir ağlarından oluşur ve karmaşık veri yapılarından anlamlı desenler ve ilişkiler çıkarma kapasitesine sahiptir.

Derin öğrenme sistemleri, karmaşık görevleri gerçekleştirmek için veriden özellik çıkarma ve bu özellikler arasındaki hiyerarşik ilişkileri öğrenme yeteneklerini kullanır. Görüntü tanıma, ses tanıma, doğal dil işleme (NLP), otonom araçlardaki navigasyon sistemleri, finansal tahminleme modelleri ve sağlık hizmetlerinde hastalık teşhisi gibi geniş bir uygulama yelpazesinde etkin bir şekilde kullanılmaktadır. Bu teknolojiler, makine öğreniminin en ileri uç teknikleri arasında yer almaktadır (Dikici, 2024).

Öğrenme süreci boyunca derin ağlar, kendilerine sunulan ham verilerden temsil edici özellikleri keşfetmekte ve bu özellikleri kullanarak daha önce karşılaşmadıkları veriler üzerinde tahminlerde bulunabilmektedir. Örneğin, bir derin öğrenme modeli bir görüntüdeki nesneleri tanımlarken, ilk katmanlarda temel kenar ve doku gibi basit özellikleri öğrenirken, daha derin katmanlarda daha karmaşık nesne ve bağlam ilişkilerini öğrenebilir. Benzer şekilde, doğal dil işleme modelleri bir metni analiz ederken, ilk katmanlarda kelime anlamlarını işlerken, daha derin katmanlarda cümle yapısı ve duygusal ton gibi soyut bilgileri değerlendirebilir.

Derin öğrenme modelleri ayrıca büyük miktarda veriyle beslenerek ve güçlü donanımlar (GPU ve TPU gibi) kullanılarak eğitilir. Transfer öğrenme, artırılmış öğrenme ve çevrimdışı öğrenme (offline learning) gibi teknikler, derin öğrenme modellerinin etkinliğini ve adaptasyon hızını artıran önemli stratejiler arasındadır.

Bu yetenekleri sayesinde derin öğrenme, yapay zekâ alanında en çok ilgi gören ve aktif araştırma yapılan konulardan biri haline gelmiştir. Özellikle, özyinelemeli sinir ağları (RNN), evrimsel sinir ağları (CNN) ve Transformer modelleri gibi alt mimariler, spesifik görevler için optimize edilerek geniş bir etki alanı yaratmıştır.

4.2.1 Zaman serilerinde derin öğrenme mimarileri

Zaman serileri ve sıralı diziler, günümüz veri dünyasının en karmaşık ve bilgi açısından zengin veri türleri arasında yer almaktadır. Finansal piyasalardan sağlık bilimlerine, hava durumu tahminlerinden doğal dil işlemeye kadar geniş bir uygulama yelpazesinde bu tür veriler kritik kararların alınmasında temel rol oynamaktadır. Modern teknolojiadaki ilerlemeler, bu karmaşık veri yapılarını analiz etmek ve içerdikleri anlamlı desenleri keşfetmek için derin öğrenme tekniklerinin kullanımını artırmıştır.

Derin öğrenme mimarileri, zaman serileri ve sıralı diziler üzerinde etkili sonuçlar elde etmek amacıyla özel olarak tasarlanmış ve optimize edilmiştir. Tekrarlayan Sinir

Ağları Çift Yönlü Uzun Kısa Süreli Bellek ve benzeri mimariler, özellikle zaman bağımlılıklarını modelleme ve ardışık veriler arasındaki bağlamı anlama konusunda güçlü araçlar olarak öne çıkmaktadır. Bu mimariler, verinin zamansal yapısını koruyarak tahminleme, anomali tespiti ve veri sınıflandırma gibi görevlerde önemli başarılar elde etmiştir.

Bu mimarilerin avantajları arasında uzun vadeli bağımlılıkları öğrenme yeteneği, bağlam bilgisiyle daha doğru tahminlerde bulunabilme ve karmaşık veri desenlerini modelleyebilme becerisi yer almaktadır. Öte yandan, bu mimarilerin zorlukları arasında hesaplama maliyetleri, büyük veri kümeleriyle eğitimin uzun sürmesi ve gradyan sönümlenmesi veya patlaması gibi problemler bulunmaktadır. Ancak, bu sorunların üstesinden gelmek için geliştirilen teknikler, modellerin verimliliğini artırmış ve daha geniş ölçekli uygulamaların önünü açmıştır.

Dikkat mekanizmaları ve Transformer tabanlı modeller, zaman serilerindeki uzun vadeli bağımlılıkların etkin bir şekilde modellenmesine olanak sağlayarak, RNN ve LSTM gibi geleneksel yöntemlerin sınırlamalarını aşmıştır. Transformer mimarisi, özellikle paralel işlem kapasitesi ve büyük veri kümeleriyle eğitilebilme avantajları sayesinde, zaman serisi verilerinin analizinde giderek daha fazla kullanılmaktadır.

Gelecekte, bu mimarilerin daha fazla ölçeklenebilirlik, daha düşük hesaplama maliyetleri ve daha güçlü genelleştirme yetenekleri kazanması beklenmektedir. Ayrıca, hibrit modeller ve çoklu veri türlerinin entegrasyonu ile zaman serilerinden elde edilen tahminlerin daha güvenilir ve doğru hale gelmesi hedeflenmektedir (Dikici, 2024).

4.2.1.1 Tekrarlayan sinir ağları (RNN)


Tekrarlayan Sinir Ağları (RNN), zamanla değişen verilerin işlenmesi amacıyla özel olarak tasarlanmış bir yapay sinir ağı türüdür. Temel yapısı, veriler arasındaki sıralı bağlantıları ve zaman içinde gelişen desenleri yakalama yeteneğine dayanır. Geleneksel yapay sinir ağlarından farklı olarak RNN'ler, önceki adımlardan gelen bilgileri mevcut girdi ile birleştirerek zaman serisi verileri, doğal dil, ses ve diğer sıralı veri türlerini etkin bir şekilde işler (Williams & Zipser, 1989).

RNN'lerin temelinde yer alan en önemli kavramlardan biri "gizli durum" (hidden state) olarak adlandırılan bir hafıza birimidir. Bu yapı, ağın her adımda elde ettiği bilgileri depolar ve sonraki adımların işlenmesinde kullanır. Böylece ağ, zamana bağlı

verilerdeki desenleri öğrenebilir ve bu bilgiyi gelecekteki tahminlerde kullanabilir. Örneğin, bir cümledeki sonraki kelimenin tahmin edilmesi gibi görevlerde, RNN'nin gizli durumu önceki kelimelerin bağlamını saklayarak daha doğru tahminlerde bulunmasını sağlar (Dikici, 2024).

Ancak, RNN'lerin bazı dezavantajları da bulunmaktadır. Özellikle "uzun süreli bağımlılıkların" öğrenilmesi, standart RNN yapılarında büyük bir problem yaratmaktadır. Bu sorun, kaybolan gradyan (vanishing gradient) ve patlayan gradyan problemleri olarak bilinir ve ağıın eğitimi sürecini zorlaştırır. Bu problemleri aşmak için LSTM ve GRU (Gated Recurrent Unit) gibi RNN varyasyonları geliştirilmiştir (Staudemeyer & Morris, 2019).

Şekil 4.9, bir Tekrarlayan Sinir Ağı (RNN) yapısını temsil eden bir sinir ağı modelini göstermektedir. Alt kısımda yer alan gri nöronlar, ağıın giriş katmanını oluşturarak ham veriyi temsil eder. Orta kısımda bulunan sarı nöronlar, ağıın gizli katmanlarını oluşturur ve verinin işlendiği, öğrenildiği bölgeyi temsil eder. En üstte yer alan gri nöronlar ise çıktı katmanını oluşturur ve işlenmiş verinin sonucunu temsil eder.



Şekil 4.9 : Tekrarlayan sinir ağı yapısı (Kingma, 2014).

RNN yapısında dikkati çeken unsurlardan biri, giriş katmanındaki örnekler ile yakın geçmiş örnekler arasındaki turuncu oklarla gösterilen bağlantılardır. Bu bağlantılar, ağıın geçmişteki örneklerden elde edilen bilgileri mevcut girdilerle birleştirerek çıktıyı

oluşturmasını sağlar. Böylece RNN, zamanla değişen veri desenlerini ve sıralı bağımlılıkları öğrenme kabiliyetini etkin bir şekilde kullanır.

Şekil 4.9'da ayrıca, her bir gizli katman nöronunun hem önceki katmandan hem de aynı katmandaki diğer nöronlardan girdi aldığı ve çıktı ürettiği gözlemlenmektedir. Bu karmaşık bağlantı yapısı, ağın karmaşık desenleri tanıma ve zamanla değişen verilerdeki ilişkileri modelleme kabiliyetini önemli ölçüde artırır (Dikici, 2024).

4.2.1.2 Uzun kısa süreli bellek (LSTM)


LSTM birimleri, standart tekrarlayan sinir ağlarındaki bazı sorunları çözmek için tasarlanmış özel bir RNN mimarisidir. Hochreiter (1997) tarafından tanıtılan LSTM, uzun zaman aralıklarında bağımlılıkları öğrenme yeteneği sayesinde öne çıkmaktadır. Bu özellik, LSTM'leri doğal dil işleme, konuşma tanıma ve zaman serisi analizi gibi uygulamalarda oldukça etkili ve kullanışlı hale getirmektedir.

Standart RNN'ler, kısa süreli bağımlılıkları başarıyla öğrenebilirken, uzun süreli bağımlılıkların öğrenilmesinde kaybolan gradyan ve patlayan gradyan problemleriyle karşılaşmaktadır. Kaybolan gradyan sorunu, gradyanların zamanla üstel olarak küçülmesi sonucu ağın öğrenme kapasitesini ciddi şekilde sınırlarken; patlayan gradyan sorunu, gradyanların kontrolsüz şekilde büyümesi nedeniyle ağın eğitim sürecini kararsız hale getirmektedir. LSTM, bu tür sorunları çözmek amacıyla bilgiyi uzun süre boyunca saklayabilen ve gradyan akışını düzenleyebilen özel bir mimari yapıya sahiptir (Dikici, 2024).

LSTM birimlerinin temel yapısı, verilerin ağ içinde akışını düzenleyen üç ana mekanizmaya dayanmaktadır: unutma mekanizması, giriş mekanizması ve çıkış mekanizması. Unutma mekanizması, hücre durumunun önceki bilgilerden ne kadarını unutacağını belirlerken; giriş mekanizması, mevcut giriş verisinin hücre durumuna ne ölçüde dahil edileceğine karar vermektedir. Çıkış mekanizması ise hücre durumundaki bilginin ne kadarının sonraki katmanlara aktarılacağını kontrol etmektedir. Bu mekanizmalar sayesinde LSTM, gereksiz bilgileri ortadan kaldırarak önemli bilgileri saklama ve uzun süre boyunca koruma yeteneğine sahiptir.

LSTM birimlerinde ayrıca, ağ içindeki bilgiyi taşıyan ve "hücre durumu" olarak adlandırılan bir bileşen bulunmaktadır. Hücre durumu, ağ boyunca doğrusal bir yol

izleyerek taşınır ve yalnızca mekanizmalar aracılığıyla düzenlenir. Bu yapı, bilginin uzun mesafeler boyunca bozulmadan aktarılmasına olanak tanır ve böylece uzun vadeli bağımlılıkların etkin bir şekilde öğrenilmesini sağlar (Hochreiter ve Schmidhuber, 1997). Şekil 4.10, LSTM birimlerinin mimarisini gösteren üç ayrı görseli içermektedir. Bu görseller, LSTM hücrelerinin evrimini ve kapılarını detaylı bir şekilde göstermektedir.



Şekil 4.10 : (a) Orijinal bir LSTM birim mimarisi: basit bir LSTM hücresi; (b) Unutma kapısı olan bir LSTM hücresi; (c) Unutma kapısı ile modern bir LSTM hücresinin gösterimi (Smagulova ve Jame, 2019).

İlk görsel (a), orijinal bir LSTM hücresinin mimarisini göstermektedir. Bu mimaride, hücrenin temel bileşenleri arasında bir bellek hücresi s_c ve iki ana kapı mekanizması bulunmaktadır: giriş kapısı ve çıkış kapısı. Giriş kapısı, giriş sinyalinin $g \cdot y^{in}$ hücre durumuna ne ölçüde etki edeceğini kontrol ederken, çıkış kapısı $h(s_c)$, hücre durumundan hangi bilgilerin dışarıya aktarılacağını düzenlemektedir. Bu iki kapı, hücrede bilginin ne kadar süreyle saklanacağı ve ne zaman aktarılacağı konusunda kritik bir rol oynar ve LSTM'nin zamana yayılan bağımlılıkları öğrenme yeteneğini destekler.


İkinci görsel (b), unutma kapısına sahip bir LSTM hücresini temsil etmektedir. Bu kapı, hücrenin önceki durumlarından hangi bilgilerin korunacağı ve hangilerinin silineceği konusunda karar mekanizması görevi görür. Bu yapı, LSTM'nin uzun süreli bağımlılıkları daha etkin bir şekilde öğrenmesine yardımcı olmaktadır. Unutma kapısı f_t , hücre durumuna s_c etki eden eski bilgiyi kontrol ederek, gereksiz bilgilerin "unutulmasını" ve yalnızca anlamlı bilgilerin muhafaza edilmesini sağlar.

Üçüncü görsel (c), modern bir LSTM hücresinin temsili bir yapısını sunar. Bu yapı, C_{t-1} 'den C_t 'ye bilgi akışını temsil eden hücre durumunu ve bu durum üzerinde işlem yapan üç ana kapıyı içerir: unutma kapısı f_t , giriş kapısı g_t ve çıkış kapısı o_t . Bu kapıların her biri, giriş x_t , önceki çıktı h_{t-1} ve önceki hücre durumu C_{t-1} bilgilerini kullanarak hangi bilginin saklanacağı, hangisinin atılacağı ve hangi bilginin bir sonraki katmana iletileceği konusunda karar verir.

Bu yapı, LSTM hücrelerinin veriyi etkin bir şekilde işleyebilmesini ve uzun süreli bağımlılıkları öğrenebilmesini sağlayarak, zaman serisi analizi, doğal dil işleme ve konuşma tanıma gibi karmaşık görevlerde başarılı bir şekilde kullanılmasına olanak tanır (Dikici, 2024).

4.2.1.3 Çift yönlü uzun kısa süreli bellek (BiLSTM)


Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM), zaman serileri ve sıralı verilerdeki uzun vadeli bağımlılıkları öğrenmek için etkili bir yaklaşım sunan çift yönlü bir RNN modelidir. Geleneksel LSTM ağları, sıralı verilerdeki bilgi akışını belirli bir yönde işlerken, BiLSTM, hem ileri (geçmişten geleceğe) hem de geri (gelecekte geçmişe) yöndeki bağlantıları kullanarak verideki tüm bağımlılıkları öğrenir. Bu çift yönlü yapı, modelin daha geniş bir bağlamı anlamasını ve veri içindeki örüntüleri daha etkili bir şekilde yakalamasını sağlar. Şekil 4.11, LSTM ve BiLSTM mimarilerinin karşılaştırmasını görsel olarak sunmaktadır.



Şekil 4.11 : LSTM ve BiLSTM mimarilerinin karşılaştırılması (Shen ve diğ. 2021).

BiLSTM, zamansal bağımlılıkları daha etkin bir şekilde yakalamak için ileri yönlü ve geri yönlü katmanlar olmak üzere çift yönlü çalışan iki LSTM katmanından oluşur.

İleri yönlü LSTM katmanı zaman adımlarını başlangıçtan sona doğru işlerken, geri yönlü LSTM katmanı bilgiyi sondan başa doğru işler. Bu çift yönlü yapı, verideki zamansal bağımlılıkları hem geçmişten geleceğe hem de gelecekte geçmişe doğru analiz ederek tahmin doğruluğunu artırır ve modelin bağlamsal bilgiyi daha kapsamlı bir şekilde öğrenmesini sağlar. Şekil 4.12’te, BiLSTM biriminin iç mimarisini gösterilmektedir (Nacer ve diğ. 2023).



Şekil 4.12 : BiLSTM ağının iç mimarisi (Nacer ve diğ. 2023).


4.2.1.4 Transformer

Vaswani ve diğ. (2017) yayımladıkları “Attention Is All You Need” başlıklı makale, dil çevirisi gibi ardışık veri işlemeye dayalı görevlerde RNN ve LSTM modellerinin karşılaştığı temel zorluklara yeni çözümler sunmuştur. Bu zorluklar arasında uzun vadeli bağımlılıkların öğrenilmesi, paralel işlem kapasitesinin sınırlı olması ve gradyan sönümlenmesi gibi önemli problemler yer almaktadır (Ahmed ve diğ, 2023).

RNN tabanlı modellerde veri noktaları sıralı olarak işlenirken, Transformer modeli tüm veri dizisini aynı anda işler. Bu yaklaşım, özellikle GPU ve TPU gibi donanımların sunduğu paralel işlem gücünden maksimum düzeyde yararlanmayı mümkün kılar (Z. Wang ve diğ. 2019). Transformer mimarisinin başarısının ardında, veri dizisindeki öğeler arasındaki ilişkilerin doğrudan analiz edilmesine olanak tanıyan Kendine Dikkat (Self-Attention) mekanizması bulunmaktadır. Bu mekanizma, sıralı veriyi doğrudan işlemek yerine, veri noktaları arasındaki bağımlılıkları matris çarpımları yoluyla hesaplar ve anlamlı ilişkiler kurar (Hao ve diğ. 2019).

Transformer mimarisinin zaman serisi analizinde etkin bir şekilde kullanılabilmesi, uzun dönemli bağımlılıkları öğrenme kapasitesi ve büyük veri kümeleri üzerinde verimli eğitim süreçleri sunması sayesinde mümkün olmuştur. Finans, sağlık, enerji ve trafik analizi gibi pek çok alanda Transformer tabanlı modeller, geleneksel zaman serisi analiz yöntemlerine kıyasla önemli performans artışları sağlamıştır (Ahmed ve diğ., 2023).

Transformer mimarisi, temel olarak Encoder-Decoder (Kodlayıcı-Çözücü) yapısına dayanmaktadır. Encoder, giriş verilerini temsili bir uzaya dönüştürerek anlamlı bir bağlam oluştururken; decoder, bu temsili kullanarak hedef çıktıyı üretir. Doğal dil işleme (NLP) görevleri için geliştirilen bu yapı, zaman serisi analizine doğrudan uyarlanabilir niteliktedir (Zhang ve Yan, 2023). Transformerın iç mimarisi Şekil 4.13'te gösterilmiştir.



Şekil 4.13 : Transformerın iç mimarisi (Ahmed ve diğ., 2023).

Encoder, giriş dizisini işler ve her bir öğeyi anlamlı bir vektör uzayında temsil eder. Encoder bloğu, Çoklu Başlı Kendine Dikkat (Multi-Head Self-Attention) katmanını ve İleri Beslemeli Ağ (Feed-Forward Layer) katmanından oluşur. Bu katmanlar, ardışık bir yapıda birbirine bağlanmış olup, Artık Bağlantılar (Residual Connections) ve

Katman Normalizasyonu (Layer Normalization) mekanizmalarıyla desteklenmiştir. Encoder bloğunun iş akışı;

- Giriş: İlk Encoder bloğuna giriş matrisi oluşturulur.
- Multi-Head Self-Attention (Çoklu Başlı Kendine Dikkat Katmanı): Giriş dizisindeki her elemanın diğer elemanlarla olan ilişkileri modellenir.
- Artık Bağlantı ve Normalizasyon: Dikkat mekanizmasından elde edilen çıktıya girdi eklenir ve katman normalizasyonu (Layer Normalization) uygulanır.
- İleri beslemeli ağ (Feed-Forward Network): Bağlamsal bilgiler ileri beslemeli ağ üzerinden geçirilerek daha soyut temsiller elde edilir.
- Artık Bağlantı ve Normalizasyon: İleri beslemeli ağın çıktısına bir kez daha artık bağlantı eklenir ve ardından katman normalizasyonu (Layer Normalization) gerçekleştirilir.
- Çıktı: Elde edilen çıktı, bir sonraki Encoder bloğuna giriş olarak aktarılır veya son Encoder bloğundan Decoder katmanına iletilir (Ahmed ve diğ, 2023).

Decoderin temel amacı, Encoder veya diğer decoder tarafından işlenmiş olan girdi dizisinden elde edilen temsilleri kullanarak hedef diziyi adım adım oluşturmaktır. Decoder, önceki adımlardan gelen bilgilere dayanarak mevcut adımın tahminini yapmaktadır.

Decoder bloğunun iş akışı:

- Giriş: Önceki Decoder bloğunun çıktısı veya Encoder çıktısı alınır.
- Self-Attention: Giriş dizisindeki her pozisyon diğer pozisyonlarla etkileşim kurar. (Masking uygulanır.)
- Kodlayıcı-Çözücü Dikkat Katmanı (Encoder-Decoder Attention): Encoder çıktısı, sorgu vektörleriyle etkileşime girer.
- İleri beslemeli ağ: Bağımsız doğrusal dönüşümler gerçekleştirilir.
- Artık Bağlantı ve Normalizasyon: Her katmandan sonra stabilize edici bağlantılar ve normalizasyon uygulanır.
- Çıktı: Bir sonraki Decoder bloğuna veya son bloğun çıktısı olarak modele iletilir (Ahmed ve diğ, 2023).

Transformer modellerinin zaman serisi verilerinin analizi, tahmini ve sınıflandırmasına uyarlanmasındaki temel ortak nokta, giriş katmanının zaman serisi verilerini barındıracak şekilde özelleştirilmesidir. Zaman serisi verileri, doğası gereği ardışık bağımlılıkları ve zamansal kalıpları içerir. Bu nedenle, Transformer modellerinde zaman damgası gömme (timestamp embedding), pozisyonel kodlama (positional encoding) ve özel ön işleme teknikleri (preprocessing techniques) gibi yöntemlerle çeşitli iyileştirmeler yapılabilir.

Transformer modellerinin zaman serisi verilerinde kullanımı, iki temel görevi yerine getirir: zaman serisi tahmini ve zaman serisi sınıflandırması. Zaman serisi tahmini, geçmiş verilere dayanarak gelecekteki değerlerin öngörülmesini sağlarken; zaman serisi sınıflandırması, belirli zaman aralıklarını veya kalıpları tanımlayarak verileri kategorilere ayırır. Ayrıca, Transformer tabanlı modeller, geleneksel RNN ve LSTM tabanlı modellere kıyasla daha uzun bağımlılıkları öğrenebilme, paralel işlem kapasitesi ve büyük veri kümeleri üzerinde daha verimli eğitim süreçleri sunma gibi avantajlara sahiptir (Ahmed ve diğ., 2023).

4.2.1.5 CatBoost

CatBoost, Prokhorenkova ve diğ. (2018) tarafından önerilen bir gradient boosting algoritmasıdır. Zaman serisi analizi, sınıflandırma ve regresyon gibi çeşitli alanlarda yaygın olarak kullanılan geleneksel boosting algoritmaları, büyük veri setlerinde kategorik özellikleri işlerken bazı sınırlamalarla karşılaşmaktadır. CatBoost'un temel amacı, kategorik özellikleri işlerken tahmin kaymalarını önlemek ve modelin performansını iyileştirmektir.

CatBoost'un başarısında iki önemli yenilikçi yöntem kritik bir rol oynar: Sıralı (Ordered) boosting ve sıralı hedef kodlama (Ordered Target Encoding). Bu yöntemler, CatBoost'un kategorik verileri işleme performansını geleneksel boosting algoritmalarına kıyasla önemli ölçüde artırır.

Sıralı Boosting yöntemi, aşırı uyumu azaltmak ve modelin daha doğru bir şekilde öğrenmesini sağlamak amacıyla geliştirilmiştir. Geleneksel boosting yöntemlerinde veri setindeki tüm örnekler aynı anda işlenir. Buna karşılık, CatBoost verileri sıralı olarak işler ve her adımda önceki örneklerden elde edilen bilgilere dayalı olarak

ağırlıkları günceller. Bu sıralı işleme yaklaşımı, veri sızıntısını önleyerek modelin daha güvenilir tahminler üretmesini sağlar.

CatBoost'un kategorik özellikleri işleme konusunda bir diğer kritik bileşeni ise sıralı hedef kodlama yöntemidir. Bu yöntem, kategorik özellikler ile bağımlı değişken arasındaki ilişkiyi optimize ederek kategoriye özgü etkilerin doğru bir şekilde modellenmesini sağlar. Ayrıca, sıralı hedef kodlama yöntemi, kategorik özelliklerin modele aşırı uyum göstermesini önleyerek aşırı uyum riskini azaltır.

CatBoost aynı zamanda modelleme için simetrik bir ağaç yapısı kullanır. Geleneksel boosting algoritmalarında ağaç yapıları asimetrik olabilir ve bu durum her düğümde farklı bölme koşullarına yol açarak ağacın dengesiz bir şekilde büyümesine neden olur. CatBoost ise her seviyede aynı bölme koşullarını kullanarak simetrik ağaçlar oluşturur ve tüm düğümlerde derinlik ve yapının tutarlı olmasını sağlar. Bu simetrik yapı, eğitim ve tahmin sürelerini önemli ölçüde azaltır, çünkü ağaçlar sürekli olarak dengeli ve derindir. Bu özellik, CatBoost'un büyük veri setleriyle verimli bir şekilde çalışmasına olanak tanır.

Ayrıca, CatBoost, hiper parametre optimizasyonu için gelişmiş seçenekler sunar. Öğrenme oranı, ağaç derinliği ve L2 düzenleme gibi parametrelerin ince ayarı, model performansını artırabilir. CatBoost'un GPU desteği, özellikle büyük veri setlerinde eğitim sürelerini daha da kısaltarak daha hızlı ve daha verimli model eğitime olanak tanır. Sonuç olarak, CatBoost'un simetrik ağaç yapısı ve sıralı boosting gibi özellikleri daha etkili bir şekilde kullanılabilir (Prokhorenkova ve diğ., 2018).

4.3 Performans Metrikleri

4.3.1 Ortalama mutlak yüzde hata (MAPE)

MAPE, tahmin modellerinin performansını değerlendirmede oldukça yaygın bir hata ölçütüdür; gerçek değerler ile tahmin edilen değerler arasındaki farkların yüzde cinsinden büyüklüğünü ifade eder. Bu metrik, tahmin hatalarının göreceli büyüklüğünü değerlendirme ve farklı veri setleri arasında karşılaştırma yapma açısından oldukça etkilidir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (4.27)$$

- n : Toplam veri noktası sayısı
- y_i : Gerçek değer
- $\hat{y}_i$: Tahmin edilen değer

4.3.2 Kök ortalama kare hatası (RMSE)

RMSE, bir tahmin modelinin hata büyüklüğünü değerlendirmek için kullanılan bir hata metriğidir. Büyük hataları daha ciddi şekilde cezalandırdığı için, tahminlerdeki büyük sapmaları vurgulamada oldukça etkilidir. Düşük RMSE değerleri, modelin tahminlerinin gerçek gözlenen değerlere oldukça yakın olduğunu gösterirken, yüksek RMSE değerleri modelin tutarsızlık sergilediğine işaret eder.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.28)$$

- n : Toplam veri noktası sayısı
- y_i : Gerçek değer
- $\hat{y}_i$: Tahmin edilen değer

5. UYGULAMA

5.1 Veri Toplama Süreci

Elektrik yük tahmin modellerinin doğruluğu ve güvenilirliği, kullanılan veri setlerinin kalitesine doğrudan bağlıdır. Bu çalışma kapsamında üç farklı veri kaynağından elde edilen veriler kullanılmıştır: elektrik tüketim verileri, hava durumu verileri ve solar verileri.

Elektrik tüketim verileri, ADM Elektrik Dağıtım'dan saatlik çözünürlükte ve dosya formatında temin edilmiştir. Bu veriler, uzlaştırma dönemleri sonrasında EPIAŞ sistemlerinden temin edilen onaylı sayaç verileridir. Ticarete esas ve birçok kontrol noktası olduğu için veri kalitesi güvenli ve yüksek olduğu ifade edilebilir.

Hava durumu verileri, elektrik tüketim talebi üzerindeki sıcaklık, nem ve rüzgâr hızı gibi meteorolojik değişkenlerin etkisini analiz etmek amacıyla Enercast platformundan temin edilmiştir. Enercast, enerji sektörü için yapay zekâ tabanlı hava durumu tahminleri sunan uluslararası bir şirkettir. Bu veriler, enerji tüketim tahmin modellerine önemli girdiler sağlamış ve mevsimsel etkilerin daha doğru modellenmesine olanak tanımıştır. Ayrıca, güneş enerjisi santrallerinden elde edilen enerji miktarının tahmini için PVlib kütüphanesi kullanılarak güneş enerjisi üretimini etkileyen solar verileri elde edilmiştir. Bu veriler, özellikle güneş enerjisi santrallerinin enerji üretimindeki etkisini analiz etmek ve toplam enerji tüketim tahmin modellerinin performansını iyileştirmek amacıyla kullanılmıştır.

Toplanan bu üç veri seti, analiz sürecine uygun hale getirilmek amacıyla zaman damgaları üzerinden hizalanmış ve Excel formatında tek bir veri seti olarak birleştirilmiştir. Bu işlemler sonucunda elektrik tüketim verileri dahil 127 farklı değişkenden oluşan veri seti oluşmaktadır.

5.1.1 Elektrik tüketim verilerinin toplanması

Aydın, Denizli ve Muğla şehirlerinin elektrik tüketim verileri, bu çalışmanın temel veri setini oluşturmaktadır ve saatlik çözünürlükte ADM Elektrik Dağıtım tarafından

sağlanmıştır. Excel formatında sunulan ve MWh biriminde kayıtlı olan bu veri seti, 01 Ocak 2021 – 15 Temmuz 2024 tarihleri arasındaki dönemi kapsamaktadır ve bölgedeki toplam enerji tüketimini ayrıntılı bir şekilde yansıtmaktadır. Türkiye elektrik piyasasında dağıtım şirketleri, bölgelerdeki sorumlu oldukları sayaçların Veri-Çekiş değerlerini EPIAŞ'a aylık bazda raporlamakla yükümlüdür. Ancak bir dağıtım şirketi bölgesindeki tüm sayaçlardan sorumlu değildir. Bazı stratejik sayaçların ölçümleri ve raporlamaları TEİAŞ (Türkiye Elektrik İletim A.Ş.) tarafından yapılırken, iki farklı dağıtım bölgesi arasındaki yük geçişlerini izlemek amacıyla kullanılan sayaçların sorumluluğu ise ilgili diğer EDAŞ'lara (Elektrik Dağıtım Şirketleri) aittir. ADM Elektrik tarafından sağlanan veri seti, bu raporlamaların EPIAŞ'a saatlik bazda yüklenen onaylı sayaç verilerine dayalı olarak hazırlanmış ve bölgedeki toplam saatlik enerji tüketimini yansıtan bir yapıdadır.

Veri seti, ADM Elektrik'in sorumluluğundaki trafo merkezleri, üretim santralleri ve ticarete esas sayaç noktalarından alınan veri- ve çekiş değerlerine dayalı olarak hesaplanmıştır. Bu sayaçlardan elde edilen veriler, zaman serisi analizleri için gerekli olan saatlik çözünürlükte ve tutarlılık içerisinde kaydedilmiştir. Ayrıca, zaman damgaları ve veri bütünlüğü, analiz sürecinin güvenilirliği açısından titizlikle kontrol edilmiştir. Çalışmanın ilerleyen bölümlerinde detaylı bir şekilde ele alınacak olan bu veri seti, elektrik tüketim tahmin modellerinin yapılandırılmasında ve doğruluklarının değerlendirilmesinde önemli bir temel oluşturmuştur.

5.1.2 Hava durumu verilerinin toplanması

Elektrik tüketim tahmin modellerinde hava durumu değişkenleri önemli bir role sahiptir. Bu çalışma kapsamında hava durumu verileri, Enercast platformu üzerinden elde edilmiştir.

Bu çalışmada, Denizli, Muğla, Aydın, Bodrum, Fethiye, Marmaris, Çardak, Milas ve Yatağan bölgelerine ait meteorolojik veriler saatlik çözünürlükte toplanmıştır. Toplanan başlıca meteorolojik veriler şunlardır:

- Sıcaklık (K): 2 metre yükseklikte ölçülen hava sıcaklığı.
- Bağıl Nem (%): Atmosferdeki nem oranı.
- Rüzgâr Hızı (m/s): 10 metre ve 100 metre yüksekliklerdeki rüzgâr hızı.
- Rüzgâr Yönü (derece): 10 metre ve 100 metre yüksekliklerdeki rüzgâr yönü.

- Bulutluluk Oranı (%): Belirli bir bölgedeki gökyüzü örtüsünün yüzdesi.
- Radyasyon (W/m^2): Güneşten gelen toplam ışıyım miktarı.
- Yağış (l/m^2): Belirli bir zaman diliminde ölçülen yağış miktarı.

Toplanan meteorolojik veriler, elektrik tüketim verileriyle aynı zaman diliminde hizalanarak analiz için uygun hale getirilmiştir. Eksik veri bulunmadığı gözlenmiş ve veri seti doğrudan analiz sürecine entegre edilmiştir.

5.1.3 Solar verilerinin toplanması

Elektrik tüketim tahmin modellerinde güneş kaynaklı değişkenler, özellikle güneş radyasyonu ve güneşlenme süreleri gibi parametreler, talep tahminlerinde önemli bir rol oynamaktadır. Bu çalışmada güneş verileri, açık kaynaklı bir Python kütüphanesi olan PVlib kullanılarak hesaplanmıştır.

Denizli, Honaz, Yatağan, Söke, Çine, Milas ve Menteşe bölgelerine ait güneş parametreleri analiz sürecine dâhil edilmiştir. Hesaplamalar sırasında ilgili bölgelerin enlem ve boylam değerleri, zaman dilimi (UTC+3) dikkate alınmıştır. Çalışmada kullanılan başlıca güneş parametreleri şunlardır:

- Küresel Yatay Işıyım (Global Horizontal Irradiance, W/m^2): Yatay bir yüzeye düşen toplam güneş ışıyımı.
- Doğrudan Normal Işıyım (Direct Normal Irradiance, W/m^2): Güneşten doğrudan gelen ve güneşe dik bir yüzeye düşen ışıyım miktarı.
- Güneş Zenit Açısı ($^\circ$): Güneşin ufuktan olan açısal uzaklığı.
- Güneş Yükseklik Açısı ($^\circ$): Ufuk düzlemine göre güneşin yüksekliği.
- Güneş Azimut Açısı ($^\circ$): Güneşin coğrafi kuzeye göre yatay düzlemdeki yönü.
- Zaman Denklemi (dk): Güneş saatinin ve ortalama saatin arasındaki farkı gösteren düzeltme faktörü.
- Bulanıklık Faktörü: Atmosferdeki partikül ve kirleticilerin güneş ışığını dağıtma ve emme oranı.

ADM Elektrik tarafından güneş enerji santrali (GES) yoğunluğunun en yüksek olduğu yedi bölge belirlenmiş ve analiz sürecinde bu bölgeler esas alınmıştır. Söz konusu bölgelerin koordinat (enlem ve boylam) ve rakım bilgileri, doğruluk ve tutarlılık

sağlamak amacıyla Google Maps üzerinden titizlikle tespit edilmiştir. Ayrıca, dört yıllık verinin tek seferde çekilmesi sırasında teknik hatalarla karşılaşmış ve bu durumun önüne geçebilmek için veriler yıllık periyotlar hâlinde ayrı ayrı elde edilmiştir. Elde edilen yıllık veri setleri, analiz öncesinde tek bir bütünleşik veri seti hâline getirilerek nihai hâle getirilmiştir.


```
1 list_city = ["Denizli", "Honaz", "Yatagan", "Söke", "Cine", "Milas", "Mentese"]
2 tz = 'Europe/Istanbul'
3 times = pd.date_range(start='2021-01-01', end='2021-12-31', freq='H', tz=tz)
4
5 # Lokasyon Bilgileri
6 locations = {
7     "Denizli": (37.779685, 29.070513, 324),
8     "Honaz": (37.854283, 29.399103, 540),
9     "Yatagan": (37.339124, 28.026972, 373),
10    "Söke": (37.769852, 27.427359, 23),
11    "Cine": (37.689870, 28.007762, 87),
12    "Milas": (37.218235, 27.807665, 50),
13    "Mentese": (37.233178, 28.287396, 660)
14 }
15
16 for city, (latitude, longitude, altitude) in locations.items():
17     tus = Location(latitude, longitude, tz, altitude, city)
18     cs = tus.get_clearsky(times)
19     solpos = pvlib.solarposition.get_solarposition(times, latitude, longitude)
```

Şekil 5.1 : PVlib ile veri çekme gövdesi.

Hesaplanan güneş parametreleri, elektrik tüketim ve hava durumu verileriyle zaman damgaları üzerinden hizalanarak tutarlı bir veri seti oluşturulmuştur. Ayrıca, eksik veri bulunmadığı gözlenmiş ve veriler doğrudan analiz sürecine entegre edilmiştir.

5.2 Keşifsel Veri Analizi (EDA)

Bu çalışmada kullanılan elektrik tüketim verileri, 1 Ocak 2021 saat 00:00 ile 15 Temmuz 2024 saat 23:00 tarihleri arasındaki dönemi kapsamaktadır. Veri seti, belirtilen iller için saatlik çözünürlükte toplam elektrik tüketim değerlerini MWh biriminde içermektedir. Toplam tüketilen enerjinin 0 ile 1 arasında normalize edilmiş hali Şekil 5.1’de gösterilmiş, veri setine ait istatistiksel bilgiler ise Çizelge 5.1 ve Çizelge 5.2’de sunulmuştur. Görselden de anlaşılacağı üzere, yaz ve kış aylarında belirgin tüketim artışları gözlenmiştir. Ayrıca, yıllar içerisinde artan enerji talebiyle birlikte genel bir artış eğilimi dikkat çekmektedir.



Şekil 5.2 : Normalize elektrik tüketim verisi.

Çizelge 5.1 : Elektrik tüketim verisinin istatistiksel özeti.

Minimum	Maksimum	Ortalama	Medyan	Standart S.	Çarpıklık	Basıklık
509,652	2300,494	1147,961	1123,792	290,619	0,762	0,525

Tüketilen elektrik enerjisi incelendiğinde, en düşük değer olan 509,652 ile en yüksek değer olan 2300,494 arasında geniş bir aralığın bulunduğu görülmektedir. Ortalama değer (1147,961) ve medyan değer (1123,792) birbirine oldukça yakındır. Bu durum, verinin merkezi eğilim açısından normal dağılıma yakın bir yapı sergilediğine işaret etmektedir. Ancak, pozitif çarpıklık (çarpıklık = 0,762) dağılımın yüksek değerlere doğru kaydığını ve bu durumun aykırı değerlerin varlığına işaret ettiğini göstermektedir. Diğer yandan, basıklık değeri (0,525) dağılımın nispeten düz bir yapıya sahip olduğunu ve tepe noktalarının ortalama etrafında yoğunlaşmadığını ifade etmektedir. Yıllara göre elektrik tüketim verisinin istatistiksel özeti Çizelge 5.2’de sunulmaktadır.

Çizelge 5.2 : Yıllara göre elektrik tüketim verisinin istatistiksel özeti.

Yıl	Minimum	Maksimum	Ortalama	Medyan	Standart Sapma	Çarpıklık	Basıklık
2021	509,652	2196,416	1130,627	1113,864	283,0596	0,702	0,376
2022	548,725	1956,069	1144,900	1131,208	263,5447	0,412	-0,294
2023	564,272	2169,743	1133,730	1107,730	298,6005	0,839	0,559
2024	614,510	2300,494	1211,153	1160,434	326,0386	0,950	0,628

Elektrik tüketim verilerinin yıllara göre analizi, enerji talebindeki değişimleri ve eğilimleri anlamak açısından önemli bir temel sunar. Ancak, 2024 yılı verileri yalnızca temmuz ayına kadar olduğu için, bu yıl diğerlerinden ayrı bir şekilde ele alınmıştır.

2021 yılı, veri setinin başlangıç yılı olarak öne çıkmaktadır. Minimum tüketim değeri 509,652 MWh, maksimum tüketim değeri ise 2196,416 MWh olarak hesaplanmıştır. Ortalama tüketim 1.130,627 MWh, medyan değer ise 1113,864 MWh olarak belirlenmiştir. Standart sapma değerinin 283,059 MWh olması, tüketim dağılımının görece daha homojen bir yapıya sahip olduğunu göstermektedir. Çarpıklık (0,702) ve basıklık (0,376) değerleri, verinin sağa çarpık ve hafif pikleşmiş bir dağılım sergilediğini ortaya koymaktadır.


2022 yılı, daha dengeli ve homojen bir tüketim yapısı sunmaktadır. Minimum tüketim değeri 548,725 MWh, maksimum tüketim değeri 1956,069 MWh olarak belirlenmiştir. Ortalama tüketim 1144,900 MWh, medyan değer ise 1.131.208 MWh'dir. Standart sapma değeri 263,544 MWh olarak hesaplanmış; çarpıklık (0,412) ve basıklık (-0,294) değerleri, verilerin daha istikrarlı bir dağılım sergilediğine işaret etmektedir.

2023 yılı ise tüketimdeki dalgalanmaların ve pik noktalarının daha belirgin hale geldiği bir yıl olmuştur. Minimum tüketim değeri 564,272 MWh, maksimum tüketim değeri ise 2169,743 MWh olarak hesaplanmıştır. Ortalama tüketim 1133,730 MWh, medyan değer 1107,730 MWh olarak belirlenmiştir. Standart sapma değeri 298,600 MWh olup, çarpıklık (0,839) ve basıklık (0,559) değerleri, tüketim verilerinin sağa çarpık ve pik eğilimli bir dağılım sergilediğine işaret etmektedir.

2024 yılı verileri yalnızca Ocak-Temmuz dönemini kapsamaktadır. Bu durum, diğer yıllarla doğrudan karşılaştırma yapmayı yanıltıcı hale getirebilir. Ancak, bu döneme ait veriler incelendiğinde; minimum tüketim değeri 614,510 MWh, maksimum tüketim değeri ise 2300,494 MWh olarak hesaplanmıştır. Minimum ve maksimum değerlerdeki bu artışlar, 2024 yılında elektrik talebinde diğer yıllara kıyasla belirgin bir yükseliş yaşandığını göstermektedir.


Sıcaklık değişkenleri ile dağıtılan elektrik tüketimi arasındaki ilişki incelenmiştir. İlk olarak tüm veri seti üzerinden genel bir korelasyon analizi gerçekleştirilmiş, ardından veri mevsimlere ayrılarak mevsimsel değişkenlikler değerlendirilmiştir.

Şekil 5.3'te görüldüğü üzere, tüm veri seti genelinde sıcaklık ve dağıtılan elektrik tüketimi arasında orta düzeyde pozitif bir korelasyon tespit edilmiştir (0,49 – 0,52). Ancak, mevsimsel ayrışma yapılmadan gerçekleştirilen bu analiz, farklı mevsimlerde sıcaklık ve enerji tüketimi arasındaki değişken etkileşimleri göz ardı etmektedir.



Şekil 5.3 : Genel veri seti için sıcaklık ve dağıtılan enerji korelasyon matrisi ısı haritası.


Şekil 5.4'te dört mevsim için sıcaklık ve dağıtılan elektrik tüketimi arasındaki korelasyon değerleri, haftalık toplam veriler üzerinden hesaplanarak ayrı ayrı sunulmuştur.



Şekil 5.4 : Mevsimlere göre haftalık toplam sıcaklık ve dağıtılan enerji korelasyon matrisi ısı haritaları.

- Kış Mevsimi: Korelasyon değerleri -0,76 ile -0,79 arasında değişmektedir. Bu durum, sıcaklık düştükçe elektrik talebinin arttığını ve bu ilişkinin güçlü bir negatif korelasyonla ortaya çıktığını göstermektedir. Elektrikli ısınma sistemlerinin yaygın kullanımı, bu eğilimi açıklayan önemli bir faktördür.
- İlkbahar Mevsimi: İlkbahar aylarında korelasyon değerleri -0,50 ile -0,55 arasında değişmektedir. Bu dönemde sıcaklık değişimleri ve elektrik talebi arasındaki ilişki görece zayıf kalmış ve doğrudan bir bağlantı gözlemlenememiştir.
- Yaz Mevsimi: Yaz aylarında korelasyon değerleri 0,87 ile 0,88 arasında oldukça yüksek seviyelere ulaşmıştır. Bu güçlü pozitif ilişki, yaz aylarında artan soğutma sistemleri kullanımından kaynaklanmaktadır.
- Sonbahar Mevsimi: Sonbahar aylarında korelasyon değerleri 0,77 ile 0,79 seviyelerinde yüksek düzeyde bir pozitif ilişki göstermektedir. Bu durum, sıcaklık değişimlerinin elektrik talebi üzerinde belirgin bir etkiye sahip olduğunu ortaya koymaktadır.

Bağıl nem, rüzgar hızı, rüzgar yönü, bulutluluk oranı, radyasyon ve yağış değişkenlerinin tüketilen elektrik enerjisi ile olan ilişkisi incelenmiştir. Şekil 5.5'te görüldüğü gibi, tüm veri seti genelinde hava durumu değişkenleri ile dağıtılan enerji arasındaki korelasyon değerleri oldukça zayıf kalmıştır. Bunun nedeni sıcaklık korelasyonunda olduğu gibi mevsimsel değişkenliklerden kaynaklıdır.




Şekil 5.5 : Bağıl nem, rüzgar hızı, rüzgar yönü, bulutluluk oranı, radyasyon ve yağış değişkenlerinin tüketilen elektrik enerjisiyle korelasyon matrisi ısı haritaları.

Mevsimsel olarak yapılan detaylı analizlerde, her bir değişkenin mevsime bağlı olarak farklı korelasyon değerleri sergilediği gözlemlenmiştir. Şekil 5.6’da gösterildiği üzere seçilen tüm değişkenlerin belirli mevsimlerde yüksek korelasyon göstermektedir. Enerji talep tahmin modellerinin bu değişkenlerin mevsimsel varyasyonlarını dikkate alarak oluşturulması, tahminlerin doğruluğunu ve güvenilirliğini artıracaktır.

	Değişken	Kış	İlkbahar	Yaz	Sonbahar
0	BağılNem_Denizli	-0.720000	-0.340000	-0.030000	0.650000
1	RüzgarHızı_Denizli	0.260000	-0.100000	0.530000	0.420000
2	RüzgarYönü_Denizli	0.320000	-0.050000	-0.020000	0.270000
3	BulutlulukOranı_Denizli	-0.430000	-0.720000	-0.590000	-0.270000
4	Radyasyon_Denizli	-0.400000	-0.490000	0.570000	0.790000
5	Yağış_Denizli	-0.350000	-0.260000	-0.570000	-0.110000

Şekil 5.6 : Tüketilen elektriğin, bağıl nem, rüzgar hızı, rüzgar yönü, bulutluluk oranı, radyasyon, yağışa göre mevsimsel korelasyon değerleri.

Solar değişkenlerinin (güneş ışıınımı, güneş zenit açısı, güneş yükseklik açısı, güneş azimut açısı, zaman denklemi ve bulanıklık faktörü) dağıtılan enerji üzerindeki etkisi, mevsimsel farklılıklar göz önünde bulundurularak Şekil 5.7'de detaylı bir şekilde incelenmiştir.



Şekil 5.7 : Mevsimlere göre solar verileri ve tüketilen enerji korelasyon matrisi ısı haritaları.

Güneş ışıınımı ile tüketilen enerji arasındaki korelasyon değerleri mevsimsel olarak önemli farklılıklar göstermektedir. Yaz mevsiminde Denizli_ghi (Küresel Yatay Işıınım), Denizli_dni (Doğrudan Normal Işıınım) ve Denizli_dhi (Difüz Yatay Işıınım) değişkenleri ile dağıtılan enerji arasında güçlü pozitif korelasyon değerleri tespit edilmiştir. Bu durum, yaz aylarında güneşlenme süresinin uzaması ve güneş ışıınım yoğunluğunun artmasıyla enerji talebinin doğrudan etkilendiğini göstermektedir. Buna karşılık, kış mevsiminde aynı değişkenlerin korelasyon değerlerinde önemli bir düşüş gözlemlenmiş ve bazı değişkenlerin negatif korelasyon sergilediği belirlenmiştir. Özellikle Denizli_zenith ve Denizli_elevation değişkenlerinin kış aylarında negatif korelasyon göstermesi, güneş açısının enerji tüketimi üzerindeki etkisinin doğrudan olmaktan çok dolaylı bir niteliğe sahip olduğunu düşündürmektedir.

İlkbahar ve sonbahar mevsimlerinde güneş parametrelerinin enerji talebi üzerindeki etkisi daha dengeli ve ılımlı bir seyir izlemektedir. Ancak sonbahar aylarında Denizli_radyasyon değişkeninin korelasyon değerlerinde belirgin bir artış gözlemlenmiştir. Bu durum, sonbaharda güneş ışıınının enerji tüketimi üzerinde diğer parametrelere kıyasla daha baskın bir rol oynadığını ortaya koymaktadır. Öte yandan, bulanıklık faktörü (Denizli_turbidity) ve zaman denklemi (Denizli_equation_of_time) değişkenleri, mevsimlere göre tutarsız korelasyon değerleri sergilemiştir.

Sonuç olarak, solar verilerin enerji tüketimi üzerindeki etkisi mevsimlere bağlı olarak önemli ölçüde farklılaşmaktadır. Yaz mevsiminde güneş ışıınıını değişkenleri enerji tüketimi üzerinde belirgin bir etki oluştururken, kış mevsiminde bu etkinin zayıfladığı ve bazı değişkenlerin negatif yönde bir ilişki sergilediği gözlemlenmiştir. İlkbahar ve sonbahar mevsimlerinde ise bu etkinin daha orta düzeyde ve istikrarlı bir yapıya sahip olduğu anlaşılmıştır. Elde edilen bu bulgular, enerji talep tahmin modellerinde solar parametrelerin mevsimsel farklılıkların dikkate alınarak modellenmesi gerektiğini açıkça vurgulamaktadır.

5.3 Veri Setinin Hazırlanması ve Özellik Mühendisliği

Elektrik tüketim tahmin modellerinin doğruluğunu artırmak amacıyla bu çalışmada çeşitli özellik mühendisliği teknikleri uygulanmıştır. Özellik mühendisliği, ham verilerden anlamlı ve modele katkı sağlayacak yeni özniteliklerin türetilmesi sürecini kapsar. Bu teknikler sayesinde veri seti, modellerin daha doğru ve güvenilir tahminler yapabilmesi için optimize edilmiş ve zenginleştirilmiştir. Çalışma kapsamında, korelasyon analizleri ve keşifsel veri analizleri sonucunda anlamlı ilişkiler tespit edilmiş ve bu bulgular doğrultusunda yeni öznitelikler türetilmiştir. Nihai veri seti, seçilen ve türetilen özniteliklerle birlikte modelleme aşamasına hazır hale getirilmiştir.

5.3.1 Özellik mühendisliği mimarisi

Elektrik tüketim tahmin modellerinin doğruluğunu artırmak ve zamansal bağımlılıkları daha etkin yakalamak için kapsamlı bir özellik mühendisliği mimarisi tasarlanmıştır. Bu mimari, özniteliklerin türetilme sürecini optimize etmek amacıyla yapılandırılmıştır. Sürecin uygulanmasında features_engineering_process sınıfı kullanılmış ve bu sınıf, veri kaynakları, öznitelik türleri ve tekniklerin tanımlandığı

merkezi bir yapı olarak tasarlanmıştır. Şekil 5.8 ve Şekil 5.9’da gösterildiği gibi özellik çıkarımı sürecinde kullanılacak veri kaynakları ve teknikler boolean (True/False) değerleriyle belirlenmiştir.

```
1 class features_engineering_processs :
2
3     #Hangi özelliklerin kullanılacağına karar verme
4     enercast_weather_features = True
5     solar_features = True
6     seasonality_features = True
7     target_features = True
```

Şekil 5.8 : Özellik çıkarımı sürecinde kullanılacak veri kaynaklarının belirlenmesi.

```
10     #Feature türlerine karar verme
11     seasonality_spline_features = True
12     diff_pct_features = False
13     weather_lag_features = True
14     solar_lag_features = True
15     rolling_features = False
16     rolling_shift_features = False
17     target_lag_features = True
18     target_rolling_features = False
```

Şekil 5.9 : Özellik çıkarımı sürecinde kullanılacak özellik türlerinin belirlenmesi.

Özellik mühendisliği sürecinde kullanılan tekniklerin yapılandırması ve veri setine entegrasi için ayrı ayrı fonksiyonlar tanımlanmıştır. Böylelikle features_engineering_process sınıfı içerisinde belirtilen boolean değişkenlere göre otomatik bir şekilde eğitim veri seti oluşturulabilecektir.

Örneğin, lag (gecikme) özellikleri çıkarılmasında kullanılan fonksiyon Şekil 5.10’da sunulmaktadır. Bu fonksiyon, veri seti (df_temp), lag özellikleri çıkarılacak kolonlar (columns) ve hangi zaman aralıklarında lag oluşturulacağı bilgisi (lags) ile çalışmaktadır. Kolon ve zaman aralıkları bilgileri Şekil 5.11 ve Şekil 5.12’de verildiği üzere features_engineering_process sınıfı içerisinde tanımlanmıştır. Bu durum, istenildiği taktirde oluşturulan özelliklerin hızlı bir şekilde değiştirilmesine olanak sağlamaktadır. Fonksiyon çalıştırıldığında belirtilen kolonlar için gecikme adımları hesaplanarak veri setine eklenmektedir.

```

37 def lag_features(df_temp,
38                  columns,
39                  lags):
40
41     for col in columns:
42         for lag in lags:
43             df_temp[f'lag_{lag}_{col}'] = df_temp[col].shift(lag)
44     return df_temp

```

Şekil 5.10 : Lag özellikleri çıkarılmasında kullanılan fonksiyon.

```

29 solar_lag_col = ['Denizli_ghi', 'Denizli_dni', 'Denizli_dhi', 'Denizli_zenith',
30                 'Denizli_elevation', 'Denizli_azimuth', 'Denizli_turbidity',
31                 'Yatagan_ghi', 'Yatagan_dni', 'Yatagan_dhi', 'Yatagan_zenith',
32                 'Yatagan_elevation', 'Yatagan_azimuth', 'Yatagan_turbidity',
33                 'Söke_ghi', 'Söke_dni', 'Söke_dhi', 'Söke_zenith',
34                 'Söke_elevation', 'Söke_azimuth', 'Söke_turbidity']

```

Şekil 5.11 : Solar verilerinde lag özelliği çıkarılacak kolonların belirlenmesi.

```

40 solar_lag_range = np.arange(0, -10, 11)
41

```

Şekil 5.12 : Solar verilerinde lag özelliği çıkarılacak zaman aralıklarının belirlenmesi.

Bu belirlemeler yapıldıktan sonra lag_features fonksiyonu Şekil 5.13'teki gibi çağrılarak lag özellikleri ayrı bir veri setinde oluşturulmaktadır.

```

1 if features_engineering_processs.solar_features:
2     if features_engineering_processs.solar_lag_features:
3         df_solar_lag = lag_features(data,
4                                     columns = features_engineering_processs.solar_lag_col,
5                                     lags = np.arange(-10, 11)
6                                     )

```

Şekil 5.13 : Örnek lag_features fonksiyonu çağırılması.

5.3.2 Lag (gecikme) özellikleri

Zaman serisi analizinde Lag özellikleri (Lag Features), bir değişkenin önceki zaman dilimlerine ait değerlerinin yeni özellikler olarak modele dahil edilmesiyle oluşturulan değişkenlerdir. Bu özellikler, zaman serilerindeki zamansal bağımlılığı ve verinin geçmiş değerleriyle olan ilişkisini analiz ederek, geleceğe yönelik daha doğru ve güvenilir tahminlerin yapılmasına olanak sağlar.

Örneğin, saatlik elektrik tüketimi üzerine yapılan analizde, bugünkü tüketimin yanı sıra bir haftaki önceki aynı saat veya bir önceki hafta aynı saat tüketim değerleri modele "lag" değerler olarak eklenebilir. Bu yaklaşım, verinin zamansal dinamiklerini daha net bir şekilde ortaya koyar ve modelin geçmiş eğilimleri tanıyarak gelecekteki değerleri daha doğru bir şekilde tahmin etmesini sağlar.

Çalışma kapsamında, farklı zaman adımlarında gecikmeli değerler türetilmiştir. Meteorolojik değişkenler için 0-50 saat aralığında, her 5 saatlik adımda gecikmeli özellikler oluşturulmuştur. Güneş enerjisi verileri için ise daha kısa vadeli bir perspektif benimsenmiş ve -10 ila +10 saat aralığında gecikmeli özellikler türetilmiştir. Hedef değişken olan tüketilen elektrik enerjisini için 48, 56, 64, 72 ve 96 saatlik gecikmeli özellikler hesaplanmıştır.

5.3.3 Mevsimsellik ve spline özellikleri

Mevsimsellik, zaman serisi analizinde belirli zaman dilimlerinde tekrar eden desenleri ifade eder. Elektrik tüketimi gibi veri setlerinde bu desenler, günlük, haftalık veya aylık döngülere dayalı olarak önemli bir rol oynar. Bu çalışmada, mevsimsel döngülerin modele etkili bir şekilde entegre edilmesi amacıyla trigonometrik dönüşümler ve spline dönüşümleri olmak üzere iki farklı yöntem uygulanmıştır.

5.3.3.1 Trigonometrik dönüşümler

Verinin döngüsel yapısını modellemek amacıyla sinüs (sin) ve kosinüs (cos) dönüşümleri kullanılmıştır. Bu dönüşümler, aylar veya saatler gibi döngüsel değişkenlerin doğrusal modellerde etkin bir şekilde temsil edilmesine olanak tanımaktadır. Aylar için Denklem 5.1 ve 5.2, saatler için Denklem 5.3 ve 5.4 de kullanılan trigonometrik dönüşümlerin formülleri verilmektedir.

$$\text{month sin} = \sin\left(\frac{2\pi \cdot \text{month}}{12}\right) \quad (5.1)$$

$$\text{month cos} = \cos\left(\frac{2\pi \cdot \text{month}}{12}\right) \quad (5.2)$$

$$\text{day sin} = \sin\left(\frac{2\pi \cdot \text{day}}{24}\right) \quad (5.3)$$

$$\text{day cos} = \cos\left(\frac{2\pi \cdot \text{day}}{24}\right) \quad (5.4)$$

5.3.3.2 Spline dönüşümleri

Spline dönüşümleri, zaman serisindeki karmaşık ve doğrusal olmayan döngüsel desenleri daha esnek ve pürüzsüz bir şekilde modele dahil etmeyi sağlar. Basit sinüs ve kosinüs dönüşümlerinin yakalayamadığı detaylı geçişler ve mikro paternler, spline

dönüşümleriyle daha net bir şekilde modellemektedir. Bu çalışmada, Periyodik Kübik Spline (Periodic Cubic Spline) yöntemi kullanılarak saatlik elektrik tüketim verilerindeki döngüsel paternler modellenmiştir. Bu yaklaşım başlangıç ve bitiş noktalarının sürekliliğini koruyan bir yaklaşımdır. Matematiksel olarak Denklem 5.5'te genel formülasyonu sunulmuştur. Bu çalışmada, Spline dönüşümleri kübik spline (derece 3) yaklaşımıyla uygulanmıştır. Düğüm noktaları eşit aralıklı olarak belirlenmiş ve periyodik koşullar sağlanmıştır. Periyodik koşullar, zaman serisinin başlangıç ve bitiş noktaları arasında sürekliliği koruyarak, modelin döngüsel yapıyı daha tutarlı bir şekilde temsil etmesine olanak tanımıştır.

$$S(x) = \sum_{i=1}^k c_i B_i^3(x) \quad (5.5)$$

- $S(x)$: Kübik spline dönüşümü sonucu elde edilen fonksiyon.
- k : Düğüm (knot) sayısı.
- c_i : Kontrol noktalarının ağırlıkları.
- $B_i^3(x)$: Kübik B-Spline temel fonksiyonu

Her bir temel fonksiyon $B_i^3(x)$: Denklem 5.6'daki gibi tanımlanır:

$$B_{i,3}(x) = \frac{x-t_i}{t_{i+3}-t_i} B_{i,2}(x) + \frac{t_{i+4}-x}{t_{i+4}-t_{i+1}} B_{i+1,2}(x) \quad (5.6)$$

$$B_{i,0}(x) = \begin{cases} 1, & t_i \leq x < t_{i+1} \\ 0, & \text{diğer durumlarda} \end{cases} \quad (5.7)$$

- t_i : Düğümler (knots), spline'ın segmentlerini belirleyen noktalar.
- $B_{i,d}(x)$: i indeksli ve d dereceli spline temel fonksiyonu.

Periyodik spline dönüşümünde, başlangıç x_0 ve bitiş x_n noktaları birbirine bağlıdır ve Denklem 5.8'deki koşulu sağlar:

$$S^{(r)}(x_0) = S^{(r)}(x_n), r=0,1,2 \quad (5.8)$$

- $S(r)$: Spline'in r türevi (0: kendisi, 1: birinci türev, 2: ikinci türev)

5.3.4 Zaman özellikleri


Zaman serisi analizinde, tarih ve saat bilgileri tahmin modellerinin performansını artıran kritik özniteliklerdir. Zamanlama özellikleri tarih ve saat bilgisi kullanılarak türetilen, veri setindeki zamansal desenleri açıklamaya yardımcı olan özniteliklerdir. Bu çalışmada, veri setindeki tarih ve saat bilgileri kullanılarak şu özellikler türetilmiştir:

- Ay: Verinin hangi aya ait olduğunu belirtir ve aylık döngüleri yakalamak için kullanılır.
- Saat: Gün içindeki saat bilgisini temsil eder ve gün içi tüketim desenlerini yakalamaya yardımcı olur.
- Yıl: Elektrik tüketimindeki yıllık artış veya azalış trendlerini yakalamak için kullanılır.
- Hafta: Verinin yılın kaçınıcı haftasına ait olduğunu gösterir ve haftalık döngülerin modellenmesine olanak tanır.

Türetilen bu özelliklere ek olarak, Excel üzerinde özel günlere ilişkin bir veri seti oluşturulmuştur. Bu veri setinde, elektrik tüketim alışkanlıklarını etkileyen Ramazan ayı, resmi günler, resmi tatiller ve dini tatiller gibi bilgiler 2021-2024 yıllarını kapsayacak şekilde hazırlanmıştır. Söz konusu özel günler, kategorik değişken olarak tanımlanmış ve bu değişkenler label encoder yöntemiyle sayısal formata dönüştürülmüştür.

5.4 Simülasyon Ortamı ve Test Süreci

Veri seti hazırlandıktan sonra modellerin eğitim ve test edilebilmesi için simülasyon ortamı kurulmuştur. Deneylerde, Aydın, Denizli ve Muğla şehirlerinin toplam 24 saatlik elektrik tüketimi tahmini, 1 saat ve 24 saat öncesinden tahmin edilmesi hedeflenmiştir. Bu tahminler BiLSTM, Transformer ve CatBoost modelleri kullanılarak gerçekleştirilmiştir. Bu modellerin performansları karşılaştırmak amacıyla 1-15 Mart 2024 ve 1-15 Temmuz 2024 tarihleri arasında test edilmiştir. Şekil 5.14'te genel veri setini eğitim test bölünmesi şablon üzerinde gösterilmiştir.



Şekil 5.14 : Eğitim – test bölünme gösterimi.

Bu çalışmada, elektrik tüketim tahmin modellerinin hızlı ve güvenilir bir şekilde test edilmesi için kayan pencere (sliding window) yaklaşımı temelinde bir simülasyon test ortamı oluşturulmuştur. Bu yapı, zaman serisi tahmin prensiplerine uygun olarak tasarlanmış ve veri sızıntısını önleyecek şekilde yapılandırılmıştır.

Modeller farklı tüketim trendlerine olan Mayıs ve temmuz ayları tahmin etmiştir. Böylelikle modellerin farklı tüketim trendine sahip dönemlerde doğruluklarını kıyaslanabilecektir. 15 günlük mart ve temmuz ayı gerçekleşme istatistik bilgileri Çizelge 5.3’te sunulmaktadır.

Çizelge 5.3 : 15 günlük mart ve temmuz ayı gerçekleşme istatistikleri.

Ay	Minimum	Maksimum	Ortalama	Medyan	Standart S.	Çarpıklık	Basıklık
Mart	759,766	1408,804	1094,115	1108,609	159,305	-0,090	-1,094
Temmuz	1092,97	2289,370	1711,352	1772,314	315,939	-0,271	-1,0685


Temmuz ayında elektrik talebi, mart ayına kıyasla ortalama %56 daha yüksektir ve bu durum, yaz aylarında artan klima ve elektrikli cihaz kullanımıyla ilişkilendirilebilir. Talep, hem taban seviyelerde daha yüksek seyretmiş hem de zirve değerleri mart ayına göre belirgin şekilde artmıştır. Medyan değer ortalamaya yakın olması, talebin genel olarak tutarlı ve yüksek seviyelerde gerçekleştiğini göstermektedir. Ancak, standart sapmanın temmuzda (315,94 MWh) mart ayına (159,31 MWh) kıyasla neredeyse iki kat fazla olması, talepteki dalgalanmaların ve değişkenliğin daha fazla olduğunu ortaya koymaktadır. Her iki ayda da çarpıklık ve basıklık değerleri negatiftir; bu durum, talep dağılımının daha dengeli ve uç değerlerden arınmış bir yapıda olduğunu göstermektedir. Temmuz ayında çarpıklığın daha belirgin olması, ani talep düşüşlerinin daha nadir ve kısa süreli olduğunu, basıklığın ise dağılımın daha geniş bir aralığa yayıldığını işaret etmektedir.

İki farklı tahmin ufukları için (1 saat ve 24 saat öncesi) iki farklı simülasyon ortamı kurulmuştur. Üç model ve iki farklı tahmin aralığıyla yapılan testler her bir simülasyon için 6, çalışma toplamında 12 farklı deney yapılmıştır.

5.4.1 Birinci simülasyon ortamı

Birinci simülasyon ortamında eğitim veri seti, test başlangıç gününün 1 saat öncesine kadarı seçilmiştir. Bu ortamda kayan pencere yaklaşımı kullanılarak, eğitim veri setinin son saatinden bir sonraki 24 saatlik tüketim tahmini yapılmıştır. Örneğin 1 Temmuz tahmin edilirken 30 Haziran'a kadar olan tüm veriler eğitim verisi olarak kullanılmaktadır. 1 Temmuz tahmin edilip, kaydedildikten sonra 1 Temmuz'un gerçek değerleri de eğitim verisine dahil edilerek 2 Temmuz tahmin edilir. Bu süreç, belirlenen tarih aralıklarında tekrarlanarak tahmin performansı analiz edilmiştir. Şekil 5.15'te birinci simülasyonun akış diyagramı sunulmaktadır.


Birinci simülasyon ortamı, Türkiye elektrik piyasasında gün içi ticaretlerine test ve değerlendirme ortamı oluşturmayı amaçlayan bir yapı olarak tasarlanmıştır.



Şekil 5.15 : Birinci simülasyon akış diyagramı.

5.4.2 İkinci simülasyon ortamı

İkinci simülasyon, birinci simülasyona göre 24 saat geriden tahminleme yapılmıştır. İkinci simülasyon ortamında eğitim veri seti, test başlangıç gününün 25 saat öncesine kadar seçilmiştir. Şekil 5.16’da birinci simülasyonun akış diyagramı sunulmaktadır. İkinci simülasyon ortamı, Türkiye elektrik piyasasında gün öncesi piyasa işlemlerini test ve değerlendirme ortamı oluşturmayı amaçlayan bir yapı olarak tasarlanmıştır.



Şekil 5.16 : İkinci simülasyon akış diyagramı.

5.5 Zaman Serisi Modelleri

Bu bölümde, elektrik tüketim tahmini için kullanılan üç farklı zaman serisi modelinin mimarisi ve kurulumu detaylı bir şekilde ele alınmaktadır. BiLSTM, Transformer ve CatBoost algoritmalarıyla yapılan analizler, farklı modelleme tekniklerinin zamansal bağımlılıkları ve veri özelliklerini nasıl ele aldığını karşılaştırmalı olarak değerlendirmek amacıyla gerçekleştirilmiştir.

İki farklı simülasyon ortamında aynı model mimarileri kullanılmış, yalnızca tahmin ufukları (1 saat ve 24 saat) değiştirilmiştir. Bunun yanı sıra, modeller dinamik olarak uyarlanabilir özellikler içermektedir. Örneğin, CatBoost modeli, her bir simülasyon öncesinde hiper parametre optimizasyonu gerçekleştirilirken, BiLSTM ve Transformer modellerinde eğitim sürecinde (erken durdurma) early stopping ve (öğrenme oranı azaltma) learning rate decay gibi mekanizmalar uygulanmıştır. Bu yöntemler, her bir modelin simülasyon ortamına uygun şekilde optimize edilmesini ve yüksek performans göstermesini sağlamıştır.

5.5.1 BiLSTM modeli

Bu çalışmada kullanılan BiLSTM modelinin mimarisi, zaman serisi tahminlerinde yüksek doğruluk sağlamak amacıyla optimize edilmiştir. Model, dört BiLSTM katmanından oluşmakta olup, her bir katmanda dropout, LeakyReLU aktivasyon fonksiyonu ve batch normalization teknikleri uygulanmıştır. Bu yapı, modelin aşırı öğrenme (overfitting) riskini azaltmayı ve zaman serilerindeki uzun vadeli bağımlılıkları daha etkili bir şekilde öğrenmeyi hedeflemektedir. Modelin ayrıntılı yapısı Şekil 5.17'de gösterilmiştir ve giriş katmanından başlayarak BiLSTM katmanları ve çıkış katmanına kadar tüm mimariyi kapsamlı bir şekilde sunmaktadır.



Şekil 5.17 : BiLSTM modelinin mimarisi.

Mimari Özellikler:

- Giriş Katmanı: Model, ölçeklendirilmiş zaman serisi verilerini giriş olarak alır. Bu girişler, her bir zaman adımında belirlenen öznitelikler doğrultusunda şekillendirilmiştir.
- BiLSTM Katmanları: Dört katmanlı BiLSTM yapısı, sırasıyla 256, 128, 64 ve 32 düğüme sahip katmanlardan oluşmaktadır. Bu katmanlar, zaman serisindeki hem kısa vadeli hem de uzun vadeli bağımlılıkları öğrenerek modelin tahmin performansını artırmaktadır.

- Dropout ve Batch Normalization: Aşırı öğrenmeyi önlemek için dropout uygulanmış, öğrenme sürecini stabilize etmek ve genelleştirme yeteneğini geliştirmek için batch normalization teknikleri kullanılmıştır.
- Çıkış Katmanı: Modelin tahminlerini üretmek için yoğun (dense) bir katman ile sonlandırılmıştır. Bu katman, zaman serisi tahminlerini tek bir çıktı olarak sağlar.

Eğitim, 500 epoch boyunca gerçekleştirilmiş ve her bir iterasyonda model, 64 veri noktası (batch size) üzerinde güncellenmiştir. Modelin eğitimi sırasında tahmin doğruluğunu artırmak ve öğrenme sürecini optimize etmek amacıyla bir dizi teknik uygulanmıştır. Uygulanan tekniklerin Python kodları Şekil 5.18’de sunulmaktadır.

```

1 # Modeli derle
2 # Öğrenme oranı düşük seviyede ayarlanarak modelin daha yavaş ve kararlı öğrenmesi sağlanır.
3 optimizer = Adam(learning_rate=0.0001)
4 # Tahmin performansını minimize etmek için ortalama mutlak hata (MAE) kaybı kullanılır.
5 model.compile(optimizer=optimizer, loss='mean_absolute_error')
6
7 # Eğitim sırasında erken durdurma ve öğrenme oranı azaltma mekanizmaları
8 early_stopping = EarlyStopping(
9     monitor='loss', # Modelin kayıp fonksiyonu izlenir.
10    patience=40, # 40 epoch boyunca iyileşme olmazsa eğitim durdurulur.
11    min_delta=0.0005, # Kayıptaki minimum değişim eşiği.
12    restore_best_weights=True # Eğitim sürecinde kaydedilen en iyi ağırlıklar geri yüklenir.
13 )
14 lr_scheduler = ReduceLROnPlateau(
15     monitor='loss', # Model kaybı iyileşmediğinde devreye girer.
16     factor=0.5, # Öğrenme oranı, her düşüşte %50 oranında azaltılır.
17     patience=10, # 10 epoch boyunca iyileşme olmazsa öğrenme oranı azaltılır.
18     min_lr=0.0005 # Minimum öğrenme oranı sınırı.
19 )
20
21 # Modeli eğit
22 model.fit(
23     X_train_reshaped, # Eğitim özellikleri.
24     y_train_values, # Eğitim hedef değerleri.
25     epochs=500, # Maksimum eğitim epoch sayısı.
26     batch_size=64, # Her bir iterasyonda işlenecek veri sayısı.
27     callbacks=[early_stopping, lr_scheduler], # Eğitim sırasında erken durdurma ve öğrenme oranı azaltma uygulanır.
28     verbose=1 # Eğitim sürecindeki ilerleme bilgisi konsolda gösterilir.
29 )

```


Şekil 5.18 : BiLSTM eğitimi sırasında uygulanan optimize tekniklerinin kodları.

- Optimizasyon: Adam optimizasyon algoritması, öğrenme oranı 0,0001 olarak ayarlanarak kullanılmıştır. Bu algoritma, gradyan iniş yöntemini dinamik olarak optimize ederek daha hızlı ve stabil bir öğrenme süreci sağlamıştır.
- Kayıp Fonksiyonu: Model performansı, ortalama mutlak hata (MAE) kayıp fonksiyonu ile değerlendirilmiştir. Bu fonksiyon, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasını hesaplayarak hata ölçümünde etkili bir metrik sunmaktadır.

- Erken Durdurma (Early Stopping): Loss metriği 40 epoch boyunca iyileşme göstermediğinde erken durdurma mekanizması devreye alınmıştır. Bu yöntem, aşırı öğrenme (overfitting) riskini azaltmak ve eğitim süresini optimize etmek için kullanılmıştır.
- Learning Rate Scheduler: ReduceLROnPlateau yöntemi uygulanarak, loss metriği belirli bir süre iyileşmediğinde öğrenme oranı 0,5 oranında azaltılmıştır. Minimum öğrenme oranı ise 0,0005 olarak belirlenmiştir. Bu yaklaşım, modelin zorlu optimizasyon problemlerinde daha iyi bir çözüm bulabilmesi için öğrenme oranını dinamik olarak ayarlamayı sağlamıştır.

5.5.2 Transformer modeli

Bu çalışmada kullanılan Transformer modeli, zaman serisi tahminlerinde yüksek doğruluk sağlamak amacıyla özel olarak tasarlanmış ve optimize edilmiştir. Model, üç ardışık Transformer kodlayıcı bloğundan oluşmakta olup, her bir blokta çok başlı dikkat mekanizması, katman normalizasyonu ve ileri beslemeli sinir ağı bileşenleri bulunmaktadır. Modelin mimarisi Şekil 5.19'da gösterilmiştir.



Şekil 5.19 : Transformer modelinin mimarisi.

Model, ölçeklendirilmiş zaman serisi verilerini giriş olarak alır ve bu girişler her bir zaman adımında tanımlanan özniteliklere göre düzenlenir. Giriş boyutları, zaman adımı ve özellik sayısına bağlı olarak otomatik şekilde yapılandırılır.

- **Transformer Blokları:** Model, ardışık üç Transformer bloğundan oluşmaktadır. Her blok şu alt bileşenleri içermektedir:
- **Çok başlı dikkat (Multi-Head attention):** Bu dikkat mekanizması, zaman serisi verisinin farklı zaman adımları arasındaki bağımlılıkları öğrenir.
- **Rezidüel Bağlantılar ve Katman Normalizasyonu:** Bu teknikler, öğrenme sürecini stabilize ederek gradyanların daha etkili bir şekilde akmasını sağlar.
- **Besleme İleri Ağları:** Blokların sonunda, zaman serisi verisinin daha derin özelliklerini çıkarmak için yoğun bağlantılı katmanlar kullanılmıştır.
- **Çıkış Katmanı:** Modelin tahminleri, yoğun bir katman aracılığıyla üretilir. Bu katman, zaman serisi verisine ait tahminleri tek bir çıktı olarak sağlar.

Eğitim, 500 epoch boyunca gerçekleştirilmiş ve her bir iterasyonda model, 64 veri noktası (batch size) üzerinde güncellenmiştir. Modelin eğitimi sırasında tahmin doğruluğunu artırmak ve öğrenme sürecini optimize etmek amacıyla bir dizi teknik uygulanmıştır. Uygulanan tekniklerin Python kodları Şekil 5.20’de sunulmaktadır.

```
1 # Modeli derle
2 optimizer = Adam(learning_rate=0.0001) # Öğrenme oranı ayarı
3 model.compile(optimizer=optimizer, loss='mean_absolute_error') # Kayıp fonksiyonu: Ortalama mutlak hata (MAE)
4
5 # Erken durdurma ve öğrenme oranı azaltma ayarları
6 early_stopping = EarlyStopping(
7     monitor='val_loss', # Doğrulama kaybı izlenir
8     patience=10, # 10 epoch boyunca iyileşme olmazsa eğitim durdurulur
9     min_delta=0.001, # Minimum değişim eşiği
10    restore_best_weights=True # En iyi ağırlıklar geri yüklenir
11 )
12
13 lr_scheduler = ReduceLROnPlateau(
14     monitor='val_loss', # Doğrulama kaybı izlenir
15     factor=0.2, # Öğrenme oranı %20 azaltılır
16     patience=5, # 5 epoch boyunca iyileşme olmazsa devreye girer
17     min_lr=0.000001 # Minimum öğrenme oranı
18 )
19
20 # Modeli eğit
21 model.fit(
22     X_train_reshaped, # Eğitim özellikleri.
23     y_train_values, # Eğitim hedef değerleri.
24     epochs=500, # Maksimum eğitim epoch sayısı.
25     batch_size=64, # Her bir iterasyonda işlenecek veri sayısı.
26     callbacks=[early_stopping, lr_scheduler], # Eğitim sırasında erken durdurma ve öğrenme oranı azaltma uygulanır.
27     verbose=1 # Eğitim sürecindeki ilerleme bilgisi konsolda gösterilir.
28 )
```

Şekil 5.20 : BiLSTM eğitimi sırasında uygulanan optimize tekniklerinin kodları.

- Optimizasyon: Adam optimizasyon algoritması, 0,0001 öğrenme oranıyla kullanılmıştır. Bu algoritma, gradyan iniş yöntemini dinamik olarak optimize ederek daha verimli bir öğrenme sağlamıştır.
- Kayıp Fonksiyonu: Modelin performansı, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasını hesaplayan MAE kayıp fonksiyonu ile ölçülmüştür.
- Erken Durdurma (Early Stopping): val_loss metriğinde 10 epoch boyunca bir iyileşme olmadığında erken durdurma mekanizması devreye alınmıştır. Bu yaklaşım, aşırı öğrenme riskini en aza indirmek ve eğitim süresini daha verimli hale getirmek için uygulanmıştır.
- Learning Rate Scheduler: ReduceLROnPlateau yöntemi ile val_loss metriğinde belirli bir süre iyileşme görülmediğinde öğrenme oranı %20 oranında azaltılmıştır. Minimum öğrenme oranı 0,000001 olarak belirlenmiştir. Bu yöntem, modelin karmaşık optimizasyon sorunlarını çözme kapasitesini artırmak için kullanılmıştır.

5.5.3 CatBoost modeli

Bu çalışmada, elektrik tüketimi tahminleri için kullanılan CatBoost modeli, parametrelerin Bayes optimizasyon tekniği ile optimize edilmesi sonrasında model eğitimlerine başlamıştır. Bayes optimizasyon tekniğini Python Optuna kütüphanesi kullanılarak uygulanmıştır. Hiper parametre belirlenmesi her günün tahmininden önce yapılarak en uygun parametrelerin bulunması hedeflenmiştir. Hiper parametre belirlenmesinde kullanılan Python kod bloğu Şekil 5.21’de gösterilmektedir. Hiper parametre belirlenmesinde hedef parametreler:

- İterasyon sayısı (iterations): Modelin eğitileceği iterasyon (ağaç) sayısını tanımlar ve daha karmaşık yapıları öğrenmesine imkan sağlar. Optimizasyon aralığı 500 ile 5000 arasında sınırlandırılmıştır.
- Öğrenme oranı (learning_rate): Modelin her iterasyonda parametrelerini ne kadar değiştireceğini belirler. Daha düşük öğrenme oranları, modelin daha istikrarlı bir şekilde öğrenmesine olanak tanır. Optimizasyon aralığı logaritmik ölçekle 0,001 ile 10 arasında ayarlanmıştır.

- Ağaç derinliği (depth): Karar ağaçlarının maksimum derinliğini ifade eder ve karmaşık veri yapılarını öğrenmesini sağlar. Optimizasyon aralığı 4 ile 10 arasında sınırlandırılmıştır.
- L2 düzenleme katsayısı (l2_leaf_reg): Modelin aşırı öğrenmesini önlemek amacıyla düzenleme uygular ve parametrelerin aşırı büyük değerlere ulaşmasını engeller. Optimizasyon aralığı logaritmik ölçekle 0,001 ile 10 arasında tasarlanmıştır.
- Alt örnekleme sıcaklığı (bagging_temperature): Rastgele alt örnekleme sırasında veri setindeki çeşitliliği artırarak modelin genelleştirme kabiliyetini güçlendirir. Optimizasyon aralığı 0 ile 1 arasında değişmektedir.

```

1 def bayesian_optimization(X_train, y_train, cat_features):
2     def objective(trial): # Optimizasyonun hedef fonksiyonu
3         params = {
4             'iterations': trial.suggest_int('iterations', 500, 5000), # İterasyon sayısı
5             'learning_rate': trial.suggest_float('learning_rate', 1e-4, 1e-1, log=True), # Öğrenme oranı
6             'depth': trial.suggest_int('depth', 4, 10), # Ağaç derinliği
7             'l2_leaf_reg': trial.suggest_float('l2_leaf_reg', 1e-3, 10, log=True), # L2 düzenleme katsayısı
8             'bagging_temperature': trial.suggest_float('bagging_temperature', 0, 1), # Alt örnekleme sıcaklığı
9             'loss_function': 'RMSE', # Kayıp fonksiyonu
10            'eval_metric': 'RMSE', # Değerlendirme metriği
11            'random_seed': 42, # Rastgelelik tohumu
12            'cat_features': cat_features, # Kategorik özellikler
13            'task_type': 'GPU', # GPU kullanımı
14            'devices': "0" # GPU cihazı
15        }
16        model = CatBoostRegressor(**params) # CatBoost modeli
17        model.fit(X_train, y_train, # Modeli eğit
18                early_stopping_rounds=100, # Erken durdurma ayarı
19                use_best_model=True) # En iyi model ağırlıklarını kullan
20        y_pred = model.predict(X_val) # Doğrulama verisinde tahmin yap
21        return mean_squared_error(y_val, y_pred)**0.5 # Doğrulama hatası (RMSE)
22
23    study = optuna.create_study(direction='minimize') # Optimizasyon yönü: minimize
24    study.optimize(objective, n_trials=5) # Optimizasyon deneme sayısı: 5
25
26    return study.best_params # En iyi hiperparametreleri döndür
27

```

Şekil 5.21 : CatBoost modeli için bayes optimizasyon süreci Python kodları.

CatBoost modelinin eğitimi sırasında, aşırı öğrenmeyi önlemek amacıyla erken durdurma kriteri 100 iterasyon olarak belirlenmiştir. Bunun yanı sıra, model eğitimi esnasında kategorik değişkenlerin kolon isimleri model tanımına dahil edilerek, CatBoost algoritmasının kategorik verileri doğrudan işleme yeteneklerinden faydalanılması amaçlanmıştır.

5.6 Test Sonuçları


5.6.1 Birinci simülasyon sonuçları

Birinci senaryoya ait MAPE ve RMSE sonuçları Çizelge 5.4'te gösterilmiştir.


Çizelge 5.4 : Birinci senaryo model sonuçları.

	CatBoost		BiLSTM		Transformer	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Mart	1,78	25,15	3,16	39,1	2,47	33,37
Temmuz	2,37	56,56	3,56	71,66	2,76	62,91

Mart ayında CatBoost modeli, en düşük hata oranlarını elde ederek başarılı bir performans sergilemiştir (MAPE: %1,78, RMSE: 25,15). Transformer modeli ise uzun vadeli bağımlılıkları etkin bir şekilde modelleyerek CatBoost'a yakın sonuçlar üretmiştir (MAPE: %2,47, RMSE: 33,37). Buna karşın, BiLSTM modeli kısa vadeli dalgalanmaları yeterince yakalayamamış ve diğer modellere kıyasla daha yüksek hata oranları ortaya koymuştur (MAPE: %3,16, RMSE: 39,10). Gerçek değerler ve model tahmin grafiği Şekilde 5.22'de, günlük MAPE grafiği Şekilde 5.23'te verilmiştir.




Şekil 5.22 : Birinci simülasyon mart testi gerçekleşme ve tahmin grafiği.




Şekil 5.23 : Birinci simülasyon mart testi günlük MAPE grafiği.

Temmuz ayında ise elektrik talebindeki ani sıçramalar ve dalgalanmalar, modellerin tahmin doğruluğunu önemli ölçüde etkilemiştir. Modellerin mart ayına göre daha az doğrulukla tahmin ürettiği görülmüştür CatBoost modeli, karar ağaçlarının sağladığı esneklik sayesinde ani değişimlere karşı daha dayanıklı bir performans göstermiş ve temmuz ayında da en düşük hata oranlarını elde etmiştir (MAPE: %2,37, RMSE: 56,56). Transformer modeli hata oranlarında artış gözlemlenmiştir (MAPE: %2,76, RMSE: 62,91). BiLSTM modeli ise temmuz ayının dalgalı ve karmaşık talep deseni karşısında en yüksek hata oranlarını üretmiştir (MAPE: %3,56, RMSE: 71,66). Gerçek değerler ve model tahmin grafiği Şekil 5.24’te, günlük MAPE grafiği Şekil 5.25’te verilmiştir.



Şekil 5.24 : Birinci simülasyon temmuz testi gerçekleşme ve tahmin grafiği.



Şekil 5.25 : Birinci simülasyon temmuz testi günlük MAPE grafiği.


5.6.2 İkinci simülasyon sonuçları

24 saatlik veri eksikliği nedeniyle model performanslarında düşüş beklenmesi son derece olağandır. Modellerin güncel verilerden yeterince beslenememesi ve kısa vadeli talep dalgalanmalarına daha az duyarlı hale gelmesi daha az doğruluklu tahminler üretilmesiyle sonuçlanmıştır. Çizelge 5.5’te sonuçlar gözlenmektedir.


Çizelge 5.5 : İkinci simülasyon model sonuçları.

	CatBoost		BiLSTM		Transformer	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
Mart	2,08	29,06	3,80	50,45	2,99	40,44
Temmuz	3,02	72,21	3,96	93,43	3,29	71,14

CatBoost modeli, ikinci senaryoda da hem mart hem de temmuz ayında en iyi performansı göstermiş ve tahmin hatalarını minimumda tutmuştur. Temmuz ayında modellerin daha çok sapma yapmış olmalarına rağmen, kendi aralarında incelendiğinde birbirlerine yakın tahminler verildiği izlenmiştir. Bu durum 24 saatlik veri kaybı olmasına karşın 3 modelinde ani yük değişimine verdiği tepkilerin birbirine yakın olduğu görülmektedir. Gerçek değerler ve model tahmin grafiği Şekil 5.26 ve günlük MAPE incelemesi Şekil 5.27’de sunulmuştur.




Şekil 5.26 : İkinci simülasyon mart testi gerçekleşme ve tahmin grafiği.




Şekil 5.27 : İkinci simülasyon mart testi günlük MAPE grafiği.

Temmuz ayındaki ani dalgalanmalar ve 24 saatlik veri kayıpları model performanslarını etkilediği görülmektedir. CatBoost modeli temmuz ayında da en iyi performansa sahip olmasına rağmen 24 saatlik veri kaybından en çok etkilenen model olduğu gözlemlenmiştir. Gerçek değerler ve model tahmin grafiği Şekil 5.28 ve günlük MAPE incelemesi Şekil 5.29’da sunulmuştur.



 ekil 5.28 : İkinci sim lasyon temmuz testi ger ekleşme ve tahmin grafiđi.



 ekil 5.29 : İkinci sim lasyon temmuz testi g nl k MAPE grafiđi.

6. BULGULAR VE YORUMLAR

Bu çalışmanın temel amacı, Türkiye elektrik piyasasında faaliyet gösteren dağıtım ve perakende şirketlerinin enerji tahmin algoritmalarını geliştirirken karşılaştıkları zorlukları anlamak ve bu zorlukların üstesinden gelmek için uygun analiz tekniklerini ortaya koymaktır. Çalışma, Aydın, Denizli ve Muğla bölgelerinde en uygun tahmin algoritmalarını belirlemek ve hangi modelin daha başarılı sonuçlar sunduğunu ortaya çıkarmak amacıyla gerçekleştirilmiştir.

Çalışmada kullanılan modeller arasında CatBoost, BiLSTM ve Transformer yer almakta olup, performansları MAPE ve RMSE metrikleriyle değerlendirilmiştir. CatBoost modeli, kategorik verileri daha etkili işlemesi ve ani talep değişimlerine daha hızlı tepki vermesi sayesinde hem mart hem de temmuz aylarında en başarılı sonuçları elde etmiştir. Transformer modeli, mart ayında CatBoost'a benzer bir performans gösterirken, temmuz ayında talep desenindeki dalgalanmalar nedeniyle hata oranlarında artış gözlenmiştir. Öte yandan, BiLSTM modeli, kısa vadeli dalgalanmaları yeterince yakalayamaması nedeniyle her iki ayda da en yüksek hata oranlarına sahip olmuştur.

Mevsimsel farklılıklar, modellerin performansını büyük ölçüde etkilemektedir. Mart ayı, talep açısından daha stabil ve öngörülebilir bir yapıya sahipken, temmuz ayı daha değişken ve karmaşık bir talep deseni sergilemiştir. Mart ayındaki düzenli döngüler, modellerin hata oranlarını minimize etmesine olanak tanırken, temmuz ayında ani sıçramalar ve standart sapmanın yüksek olması tahmin doğruluğunu olumsuz etkilemiştir. CatBoost modeli, karar ağaçları tabanlı esnek yapısı sayesinde bu değişkenliğe daha iyi adapte olarak her iki ayda da en düşük hata oranlarını elde etmiştir. Elde edilen bulgular, gün içi piyasası ve gün öncesi piyasası işlemlerinde kullanılabilecek faydalı tahmin modelleri oluşturulduğunu göstermiştir. Ayrıca, dağıtım ve perakende şirketlerine piyasa işlemlerindeki zararları en aza indirme konusunda önemli içgörüler sunmuştur.

Çalışmada kullanılan güneş enerjisi verileri PVlib kütüphanesinden, hava durumu verileri ise Enercast platformundan elde edilmiştir. Modellerin doğruluğunu artırmak

iin alternatif hava durumu veri saęlayıcılarının kullanılması nerilmektedir. Daha doęru hava durumu tahminleri, modellerin performansını nemli lde iyileřtirebilir.

alıřma, geniř bir coęrafi blgeyi kapsamakta ve Aydın, Denizli ve Muęla řehirlerini iermektedir. Ancak bu blgelerde zaman zaman TEİAř veya ADM Elektrik tarafından gerekleřtirilen planlı bakım veya plansız (arıza kaynaklı) kesintiler, enerji talep desenlerinde nemli aksaklıklara neden olabilmektedir. Bu tr kesintilerin veri setinde normalize edilmesi, daha gvenilir sonuların elde edilmesine katkı saęlayabilir.

Ayrıca, modellerinin tahmin sonularının daha iyi anlařılabilmesi iin Shapley eklentili aıklamalar (SHAP) veya yerel yorumlanabilir model baęımsız aıklamalar (LIME) gibi yntemler kullanılabilir. Bu yntemler, tahminlerde hangi zelliklerin daha etkili olduęunu belirleyerek sistem davranıřına dair daha fazla igr saęlayabilir. Bunun yanı sıra, ensemble ęrenme yntemleri veya hibrit modeller kullanılarak hem modellerinin gl ynleri birleřtirilebilir. Bu tr bir yaklařım, tahmin doęruluęunu ve modelin genel dayanıklılıęını artırarak daha kapsamlı bir zm sunabilir.

Sonu olarak, bu alıřma, elektrik talep tahmininde kullanılan modellerin performansını mevsimsel ve dıřsal faktrler zerinden deęerlendirerek nemli bulgular ortaya koymuřtur. Gelecekteki arařtırmalar, daha doęru veri kaynakları, geliřmiř modelleme teknikleri ve daha geniř kapsamlı veri setleri ile bu bulguların daha da geliřtirilebileceęini gstermektedir. Elde edilen sonular, daęıtım ve perakende řirketlerinin enerji planlama ve piyasa stratejilerini optimize etmelerine katkı saęlayarak sektrde daha gvenilir ve etkin zmler sunmaktadır.

KAYNAKLAR

- Abraham, A.** (2005). Artificial neural networks. *Handbook of Measuring System Design*. Hoboken, NJ, USA: John Wiley & Sons.
- Ahmed, S., Nielsen, I. E., Tripathi, A., Siddiqui, S., Ramachandran, R. P., & Rasool, G.** (2023). Transformers in time-series analysis: A tutorial. *Circuits, Systems, and Signal Processing*, 42(12), 7433–7466.
- Akan, Y., & Tak, S.** (2010). Türkiye elektrik enerjisi ekonometrik talep analizi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 17(1–2), 21–49.
- Akay, D., & Atak, M.** (2007). Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy*, 32(9), 1670–1675.
- Akdi, Y., Gölveren, E., & Okkaoğlu, Y.** (2020). Daily electrical energy consumption: Periodicity, harmonic regression method and forecasting. *Energy*, 191, 116524.
- Akman, T., Yılmaz, C., & Sönmez, Y.** (2018). Elektrik yükü tahmin yöntemlerinin analizi. *Gazi Mühendislik Bilimleri Dergisi*, 4(3), 168–175.
- Al-Musaylh, M. S., Deo, R. C., Li, Y., & Adamowski, J. F.** (2018). Two-phase particle swarm optimized-support vector regression hybrid model integrated with improved empirical mode decomposition with adaptive noise for multiple-horizon electricity demand forecasting. *Applied Energy*, 217, 422–439.
- Altınay, G., & Karagöl, E.** (2005). Electricity consumption and economic growth: evidence from Turkey. *Energy Economics*, 27(6), 849–856.
- Arısoy, İ., & Öztürk, İ.** (2014). Estimating industrial and residential electricity demand in Turkey: A time varying parameter approach. *Energy*, 66, 959–964.
- Aydoğdu, G., & Yildiz, O.** (2017). Forecasting the annual electricity consumption of Turkey using a hybrid model. *Proceedings of the 25th Signal Processing and Communications Applications Conference* (pp. 1–4). Antalya, Turkey: IEEE, May 15–18.
- Bakırtaş, T., Bildirici, M., & Karbuz, S.** (2000). An econometric analysis of electricity demand in Turkey. *METU Studies in Development*, 27, 23–34.
- Barak, S., & Sadegh, S. S.** (2016). Forecasting energy consumption using ensemble ARIMA-ANFIS hybrid algorithm. *International Journal of Electrical Power and Energy Systems*, 82, 92–104.
- Başıoğlu, B., & Bulut, M.** (2017). Kısa dönem elektrik talep tahminleri için yapay sinir ağlar ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(2), 575–583.

- Berberoğlu, C. N.** (1982). *Türkiye'nin ekonomik gelişmesinde elektrik enerjisi sorunu*. Eskişehir, Türkiye: Eskişehir İktisadi ve Ticari İlimler Akademisi.
- Bianco, V., Manca, O., & Nardini, S.** (2009). Electricity consumption forecasting in Italy using linear regression models. *Energy*, 34(9), 1413–1421.
- Biçen, Y.** (2016). Türkiye elektrik enerjisi piyasası gelişim süreci: Gün öncesi ve dengeleme güç piyasası özellikleri. *Karaelmas Fen ve Mühendislik Dergisi*, 6(2), 432–438.
- Birim, Ş., & Tümtürk, A.** (2016). Modeling and forecasting Turkey's electricity consumption by using artificial neural network. *American Scientific Research Journal for Engineering, Technology, and Sciences (ASRJETS)*, 25(1), 192–208.
- Boltürk, E.** (2013). *Elektrik talebi tahmininde kullanılan yöntemlerin karşılaştırılması* (Doktora tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bu, S.-J., & Cho, S.-B.** (2020). Time series forecasting with multi-headed attention-based deep learning for residential energy consumption. *Energies*, 13(18), 4722.
- Chae, Y. T., Horesh, R., Hwang, Y., & Lee, Y. M.** (2016). Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. *Energy and Buildings*, 111, 184–194.
- Chavan, M., Joshi, S. V., Patil, D. B., Kale, V. G., Kharat, P. A., & Kasar, M.** (2024). Time Series Analysis in Electrical Load Forecasting. *Power Management Journal*, 35(1), 2307.
- Dierks, Z.** (2024). Electricity consumption per capita in Turkey from 1990 to 2022 (in megawatthours). Erişim: 10 Ocak 2010, <https://www.statista.com/statistics/1370802/turkey-electricity-consumption-per-capita>
- Dikici, S.** (2024). *Python söz dizimi hatalarının derin öğrenme yöntemleri ile onarılması* (Yüksek lisans tezi). Bursa Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bursa.
- Dilaver, Z., & Hunt, L. C.** (2011). Industrial electricity demand for Turkey: a structural time series analysis. *Energy Economics*, 33(3), 426–436.
- Ediger, V. Ş., & Akar, S.** (2007). ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35(3), 1701–1708.
- Enes, A., & Aydın, M.** (2022). Elektrik Enerji Tüketim Tahmininde Yapay Yenilemeli Sinir Ağ Modellerinin Karşılaştırılması. *MAS Journal of Applied Sciences*, 7(2), 337–347.
- Erdemci, H.** (2023). *Makine Öğrenmesi Algoritmaları Kullanılarak 2040 Yılına Kadar Türkiye'nin Enerji Talep Tahmini* (Yüksek lisans tezi). Batman Üniversitesi, Lisansüstü Eğitim Enstitüsü, Batman.
- Erdoğan, E.** (2006). Türkiye Enerji Piyasası Reformları: Ekonomik Analiz (EPDK Uzmanlık Tezi). Ankara.

- Erdogdu, E.** (2007). Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey. *Energy Policy*, 35(2), 1129–1146.
- Es, H.** (2013). *Yapay Sinir Ağlar ile Türkiye Net Enerji Talep Tahmini* (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Evrendilek, F., & Ertekin, C.** (2003). Assessing the potential of renewable energy sources in Turkey. *Renewable Energy*, 28(15), 2303–2315.
- Gao, B., & Pavel, L.** (2017). On the properties of the softmax function with application in game theory and reinforcement learning. *arXiv preprint*, arXiv:1704.00805.
- Geem, Z. W., & Roper, W. E.** (2009). Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, 37(10), 4049–4054.
- Gezmez, K. Ç.** (2022). *Bir İlin Elektrik Tüketim Verilerinin Makine Öğrenmesi Yöntemleri ile Analizi* (Yüksek lisans tezi). Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Gürbüz, A.** (2006). *Elektrik sektöründe özelleştirme ve Türkiye’de serbest tüketici uygulaması* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Enerji Enstitüsü, İstanbul.
- Güvenek, B.** (2009). *Enerji piyasası reformlar ve bu reformların elektrik enerjisi piyasası üzerine etkisi: Elektrik enerjisi üreten kuruluşlar üzerine bir uygulama* (Yüksek lisans tezi). Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.
- Haliloğlu, E. Y., & Tutu, B. E.** (2018). Türkiye için kısa vadeli elektrik enerjisi talep tahmini. *Yaşar Üniversitesi E-Dergisi*, 13(51), 243–255.
- Hamzaçebi, C.** (2007). Forecasting of Turkey’s net electricity energy consumption on sectoral bases. *Energy Policy*, 35(3), 2009–2016.
- Hamzacebi, C., & Es, H. A.** (2014). Forecasting the annual electricity consumption of Turkey using an optimized grey model. *Energy*, 70, 165–171.
- Hao, J., Wang, X., Yang, B., Wang, L., Zhang, J., & Tu, Z.** (2019). Modeling recurrence for transformer. *arXiv preprint*, arXiv:1904.03092.
- Hekimoğlu, M., & Barlas, Y.** (2016). Sensitivity analysis for models with multiple behavior modes: a method based on behavior pattern measures. *System Dynamics Review*, 32(3–4), 332–362.
- Hochreiter, S.** (1997). Long short-term memory. *Neural computation*, 9(8), 1735–1780.
- Hotunluoğlu, H., & Karakaya, E.** (2011). Forecasting Turkey’s energy demand using artificial neural networks: three scenario applications. *Ege Academic Review*, 11(5), 87–94.
- Houthakker, H. S.** (1951). Some calculations on electricity consumption in Great Britain. *Journal of the Royal Statistical Society. Series A (General)*, 114(3), 359–371.
- Iranmanesh, H., Abdollahzade, M., & Miranian, A.** (2012). Mid-term energy demand forecasting by hybrid neuro-fuzzy models. *Energies*, 5(1), 1–21.

- Jiang, W., Wu, X., Gong, Y., Yu, W., & Zhong, X.** (2020). Holt–Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption. *Energy*, 193, 116779.
- Kankal, M., Akpınar, A., Kömürcü, M. I., & Özşahin, T. Ş.** (2011). Modeling and forecasting of Turkey’s energy consumption using socio-economic and demographic variables. *Applied Energy*, 88(5), 1927–1939.
- Karadede, Y., Ozdemir, G., & Aydemir, E.** (2017). Breeder hybrid algorithm approach for natural gas demand forecasting model. *Energy*, 141, 1269–1284.
- Kavaklioglu, K.** (2011). Modeling and prediction of Turkey’s electricity consumption using Support Vector Regression. *Applied Energy*, 88(1), 368–375.
- Kaytez, F.** (2020). A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption. *Energy*, 197, 117200.
- Kell, A. J. M., McGough, A. S., & Forshaw, M.** (2021). The impact of online machine-learning methods on long-term investment decisions and generator utilization in electricity markets. *Sustainable Computing: Informatics and Systems*, 30, 100532.
- Khan, P. W., Byun, Y.-C., Lee, S.-J., & Park, N.** (2020). Machine Learning Based Hybrid System for Imputation and Efficient Energy Demand Forecasting. *Energies*, 13(11), 2681.
- Kim, M., Choi, W., Jeon, Y., & Liu, L.** (2019). A hybrid neural network model for power demand forecasting. *Energies*, 12(5).
- Kingma, D. P.** (2014). Adam: A method for stochastic optimization. *arXiv preprint*, arXiv:1412.6980.
- Kiran, M. S., Özceylan, E., Gündüz, M., & Paksoy, T.** (2012). A novel hybrid approach based on Particle Swarm Optimization and Ant Colony Algorithm to forecast energy demand of Turkey. *Energy Conversion and Management*, 53(1), 75–83.
- Kök, A., Yükseltan, E., Hekimoğlu, M., Aktunç, E. A., Yücekaya, A., & Bilge, A.** (2022). Forecasting hourly electricity demand under COVID-19 restrictions. *International Journal of Energy Economics and Policy*, 12(1), 73–85.
- Labandeira, X., Labeaga, J. M., Linares, P., & López-Otero, X.** (2020). The impacts of energy efficiency policies: Meta-analysis. *Energy Policy*, 147, 111790.
- Lara-Benitez, P., Carranza-Garcia, M., Luna-Romera, J. M., & Riquelme, J. C.** (2020). Temporal convolutional networks applied to energy-related time series forecasting. *Applied Sciences*, 10(7), 2322.
- LeCun, Y., Bottou, L., Orr, G. B., & Müller, K. R.** (2002). Efficient backprop. In *Neural networks: Tricks of the trade* (pp. 9-50). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Mahmutoğlu, M., & Öztürk, F.** (2015). Türkiye elektrik tüketimi öngörüsü ve bu kapsamda geliştirilebilecek politika önerileri. In *Proceedings of the EY*

International Congress on Economics II. Ankara, Turkey: Ekonomik Yaklaşım Association, November 5-6.

- Makas, Y., & Karaatlı, M.** (2016). Yapay sinir ağlarıyla hidroelektrik enerji üretiminin çok dönemli tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(3), 757–772.
- McCulloch, W. S., & Pitts, W.** (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115–133.
- Nacer, S. M., Nadia, B., Abdelghani, R., & Mohamed, B.** (2023). A novel method for bearing fault diagnosis based on BiLSTM neural networks. *The International Journal of Advanced Manufacturing Technology*, 125(3), 1477–1492.
- Naumov, M.** (2017). Feedforward and recurrent neural networks backward propagation and hessian in matrix form. *arXiv preprint*, arXiv:1709.06080.
- Nebati, E. E., Taş, M., & Ertas, G.** (2021). Türkiye’de elektrik tüketiminde talep tahmini: zaman serisi ve regresyon analizi ile karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, 31, 348–357.
- Nooruldeen, O., Alturki, S., Baker, M. R., & Ghareeb, A.** (2022). Time series forecasting for decision making on city-wide energy demand: A comparative study. *Proceedings of the International Conference on Decision Aid Sciences and Applications* (pp. 1706–1710). United States: IEEE, March 21–24.
- Özaydın, G.** (2019). *Türkiye elektrik enerjisi talebinin yapay sinir ağları modeli ile tahmini* (Yüksek lisans tezi). İzmir Katip Çelebi Üniversitesi, Sosyal Bilimler Enstitüsü, İzmir.
- Özdemir, G., Aydemir, E., Olgun, M. O., & Mulbay, Z.** (2016). Forecasting of Turkey natural gas demand using a hybrid algorithm. *Energy Sources, Part B: Economics, Planning and Policy*, 11(4), 295–302.
- Pan, Z., Gu, Z., Jiang, X., Zhu, G., & Ma, D.** (2022). A modular approximation methodology for efficient fixed-point hardware implementation of the sigmoid function. *IEEE Transactions on Industrial Electronics*, 69(10), 10694–10703.
- Pavlicko, M., Vojteková, M., & Blažeková, O.** (2022). Forecasting of electrical energy consumption in Slovakia. *Mathematics*, 10(4), 577.
- Pençe, İ., Kalkan, A., & Çeşmeli, M. Ş.** (2019). Türkiye sanayi elektrik enerjisi tüketiminin 2017-2023 dönemi için yapay sinir ağlar ile tahmini. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 3(2), 206–228.
- Pratiwi, N. K. C., Ibrahim, N., Fu’adah, Y. N., & Masykuroh, K.** (2020). Computer-aided detection (CAD) for COVID-19 based on chest X-Ray images using convolutional neural network. *Proceedings of the IOP Conference Series* (Vol. 982, No. 1, p. 012004). United Kingdom: IOP Publishing, December 14–16.


- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A.** (2018). CatBoost: unbiased boosting with categorical features. *Advances in Neural Information Processing Systems*, 31.
- Puspitasari, I., Akbar, M. S., Lee, M. H.,** (2012). Two-level seasonal model based on hybrid ARIMA-ANFIS for forecasting short-term electricity load in Indonesia. *Proceedings of the International Conference on Statistics in Science, Business and Engineering* (pp. 1–5). Malaysia: IEEE, September 10–12.
- Ruder, S.** (2016). An overview of gradient descent optimization algorithms. *arXiv preprint*, arXiv:1609.04747.
- Şener, F.** (2005). *Yük tahmin yöntemleri ve Ankara merkez metropol alan için regresyon analizi yöntemi kullanılarak uygulanması* (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Shen, S.-L., Atangana Njock, P. G., Zhou, A., & Lyu, H.-M.** (2021). Dynamic prediction of jet grouted column diameter in soft soil using Bi-LSTM deep learning. *Acta Geotechnica*, 16(1), 303–315.
- Sibi, P., Jones, S. A., & Siddarth, P.** (2013). Analysis of different activation functions using back propagation neural networks. *Journal of Theoretical and Applied Information Technology*, 47(3), 1264–1268.
- Smagulova, K., & James, A. P.** (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313–2324.
- Sözen, A., Akçayol, M. A., & Arcaklioğlu, E.** (2006). Forecasting net energy consumption using artificial neural network. *Energy Sources, Part B*, 1(2), 147–155.
- Sözen, A., & Arcaklioğlu, E.** (2007). Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey. *Energy Policy*, 35(10), 4981–4992.
- Staudemeyer, R. C., & Morris, E. R.** (2019). Understanding LSTM—a tutorial into long short-term memory recurrent neural networks. *arXiv preprint*, arXiv:1909.09586.
- Sultana, N., Hossain, S. M. Z., Almuahini, S. H., & Düşteğör, D.** (2022). Bayesian optimization algorithm-based statistical and machine learning approaches for forecasting short-term electricity demand. *Energies*, 15(9), 3425.
- Sumer, K. K., Goktas, O., & Hepsag, A.** (2009). The application of seasonal latent variable in forecasting electricity demand as an alternative method. *Energy Policy*, 37(4), 1317–1322.
- Tanugur, M. M., & Zehir, M. A.** (2022). Investigation of residential demand response flexibility including the effects of the COVID-19 pandemic on energy usage habits in Turkey. *Proceedings of the 4th Global Power, Energy and Communication Conference* (pp. 523–528). Turkey: IEEE, June 14–17.

- Tatli, H.** (2017). Short-and long-term determinants of residential electricity demand in Turkey. *International Journal of Economics, Management and Accounting*, 25(3), 443–464.
- Taylor, J. W., & McSharry, P. E.** (2007). Short-term load forecasting methods: An evaluation based on european data. *IEEE Transactions on Power Systems*, 22(4), 2213–2219.
- Thompson, R. P.** (1976). Weather sensitive electric demand and energy analysis on a large geographically diverse power system 4Application to short term hourly electric demand forecasting. *IEEE Transactions on Power Apparatus and Systems*, 95(1), 385–393.
- Toksarı, M. D.** (2009). Estimating the net electricity energy generation and demand using the ant colony optimization approach: case of Turkey. *Energy Policy*, 37(3), 1181–1187.
- Toros, H., & Aydın, D.** (2018). Prediction of short-term electricity consumption by artificial neural networks using temperature variables. *Avrupa Bilim ve Teknoloji Dergisi*, 14, 393–398.
- Tripathy, S. C.** (1997). Demand forecasting in a power system. *Energy Conversion and Management*, 38(14), 1475–1481.
- Turgut, M. S., Eliyi, U., Turgut, O. E., Öner, E., & Eliyi, D. T.** (2021). Artificial Intelligence Approaches to Estimate the Transport Energy Demand in Turkey. *Arabian Journal for Science and Engineering*, 46(3), 2443–2476.
- Türkoğlu, G.** (2005). Enerji sektöründe liberalleşme ve Türkiye örneği. *Elektrik Mühendisleri Odası Elektrik Mühendisliği Dergisi*, 426, 40–46.
- Ültanır, M. Ö.** (1994). Ulusal Enerji Politikasına Eklenmesi Gereken Yeni Boyutlar. *Türkiye*, 6, 39.
- Uygun, İ.** (2015). *Yapay sinir ağlar yardımıyla enerji sektöründe talep tahmini* (Yüksek lisans tezi). Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I.** (2017). Attention Is All You Need. *arXiv preprint*, arXiv:1706.03762.
- Wang, Y., Wang, J., Zhao, G., & Dong, Y.** (2012). Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: A case study of China. *Energy Policy*, 48, 284–294.
- Wang, Z., Ma, Y., Liu, Z., & Tang, J.** (2019). R-transformer: Recurrent neural network enhanced transformer. *arXiv preprint*, arXiv:1907.05572.
- Williams, R. J., & Zipser, D.** (1989). A learning algorithm for continually running fully recurrent neural networks. *Neural Computation*, 1(2), 270–280.
- Xiao, F., Honma, Y., & Kono, T.** (2005). A simple algebraic interface capturing scheme using hyperbolic tangent function. *International Journal for Numerical Methods in Fluids*, 48(9), 1023–1040.
- Yin, W., Ye, W., & Liu, G.** (2023). Applying probabilistic forecasting of multidimensional time series to electricity load analysis. *Proceedings*

of the 42nd Chinese Control Conference (pp. 7267–7273). China: IEEE, July 23–25.

- Ying, L.-C., & Pan, M.-C.** (2008). Using adaptive network based fuzzy inference system to forecast regional electricity loads. *Energy Conversion and Management*, 49(2), 205–211.
- Yoldaş, U. C.** (2006). *Elektrik enerjisinde yük tahmini yöntemleri ve Türkiye'nin 2005–2020 yılları arasındaki elektrik enerjisi talep gelişimi ve arz planlaması* (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Yumurtaci, Z., & Asmaz, E.** (2004). Electric energy demand of Turkey for the year 2050. *Energy Sources*, 26(12), 1157–1164.
- Zhang, Y., & Yan, J.** (2023). Crossformer: Transformer utilizing cross-dimension dependency for multivariate time series forecasting. *Proceedings of the Eleventh International Conference on Learning Representations*. United States, May 1–5.
- Zhao, L., Wu, Z., & Du, M.** (2024). Improved Autoformer Electricity load forecasting based on model fusion. *Advances in Engineering Technology Research*, 11(1), 8.

ÖZGEÇMİŞ



Ad-Soyad : Hakan ELBAŞ

Doğum Tarihi ve Doğum Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Pamukkale Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği

MESLEKİ DENEYİM:

- ADM Elektrik Dağıtım (Enerji Tedarik ve Planlama Uzman Yardımcısı), 17.01.2023- Halen çalışıyor
- İletişim Yazılım (Yapay Zeka Mühendisi) 01.07.2021 – 01.02.2022

YAYINLAR:

Elbaş, H., & Bilgin, T. T. (2024). CatBoost ve BiLSTM Modellerinin Gün Öncesi Elektrik Tüketimi Tahmini için Karşılaştırmalı Analizi: Türkiye'nin Aydın, Denizli ve Muğla Bölgeleri Üzerine Bir Vaka Çalışması. International Journal of Advanced Natural Sciences and Engineering Researches, 8(10).

Elbaş, H., & Mesri, A. (2024). Neden Duygu Analizi Tabanlı Metrikler YouTube Kanal Performansını Ölçmek İçin Gereklidir: Deneysel Bir Çalışma. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 12(2).