

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

DAĞITIM ŞEBEKESİ İÇİN YÜK TALEBİ VE ENERJİ KALİTESİ
UNSURLARININ YAPAY ZEKÂ DESTEKLİ KESTİRİMİ

METİN AKDENİZ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Doktora Programı

EYLÜL 2025

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

DAĞITIM ŞEBEKESİ İÇİN YÜK TALEBİ VE ENERJİ KALİTESİ
UNSURLARININ YAPAY ZEKÂ DESTEKLİ KESTİRİMİ

METİN AKDENİZ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Doktora Programı

EYLÜL 2025

ONAY

Metin Akdeniz tarafından hazırlanan “**DAĞITIM ŞEBEKESİ İÇİN YÜK TALEBİ VE ENERJİ KALİTESİ UNSURLARININ YAPAY ZEKÂ DESTEKLİ KESTİRİMİ**” adlı tez çalışması 15/09/2025 tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği ile Bandırma Onyedİ Eylöl Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliğı Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Doç. Dr. Serhat Berat EFE

(Danışman)

Doç. Dr. Evren İŞEN

(Üye)

Doç. Dr. Behçet KOCAMAN

(Üye)

Doç. Dr. Mehmet Sait CENGİZ

(Üye)

Dr. Öğr. Üyesi Cem HAYDAROĞLU

(Üye)

Bu tezin kabulü, Lisansüstü Eğitim Enstitüsü Yönetim Kurulu’nun .../.../...gün ve .../... sayılı kararı ile onaylanmıştır.

Prof. Dr. Serhat Duman

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ DOKTORA TEZ ÇALIŞMASI ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**Dağıtım Şebekesi İçin Yük Talebi ve Enerji Kalitesi Unsurlarının Yapay Zekâ Destekli Kestirimi**” adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 15/09/2025

Metin AKDENİZ

ÖNSÖZ

Elektrik güç sistemleri dinamik yapıları gereği sürekli izleme ve kontrollerin sağlanması için işlem adımlarına ihtiyaç duyar. Bu sayede özellikle enerji kalitesi ve enerji verimliliği bakımından önemli faydalar sağlanabilmektedir. Bu tez çalışmasının temel motivasyonunu, bu yaklaşımlar oluşturmuştur. Bu kapsamda gerçek bir güç sisteminin YZ destekli analizi üzerinden enerji kalitesi ve talep yükü kavramları irdelenmiş, bu parametrelerin planlama safhasında faydalanılmak üzere kestirimi yapılmıştır. Elde edilen sonuçlar üzerinden YZ teknolojisindeki gelişmelerin elektrik güç sistemlerine uygulanması ile ulaşılabilecek iyileştirmeler tartışılmıştır.

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar bilgisi, tecrübesi, tevazusuyla bana her konuda yardımcı ve destek olan çok değerli danışman hocam Sayın Doç. Dr. Serhat Berat EFE'ye teşekkür ederim.

Tezde kullanılan verilerin temin edilmesinde destek sağlayan Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) ve Vangölü Elektrik Dağıtım A.Ş. (VEDAŞ) kurum yöneticilerine ve çalışanlarına teşekkürlerimi sunarım.

Destekleriyle yanımda olan aileme teşekkür ederim.

ÖZET

DOKTORA TEZİ

DAĞITIM ŞEBEKESİ İÇİN YÜK TALEBİ VE ENERJİ KALİTESİ UNSURLARININ YAPAY ZEKÂ DESTEKLİ KESTİRİMİ

Metin AKDENİZ

Bandırma Onyedi Eylül Üniversitesi

Lisansüstü Eğitim Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Serhat Berat EFE

II. Danışman: Doç. Dr. İlyas ÖZER

Eylül 2025, 70 sayfa

Bu tezde, dağıtım şebekelerinde yük talebi ve güç kalitesi unsurları yapay zekâ (YZ) yöntemleriyle incelenmiş ve farklı veri tipleri kullanılarak tahmin modelleri geliştirilmiştir. Güç sisteminde harmonik kestirimi, aktif ve reaktif güç verileri üzerinden GRU ve Bahdanau dikkat mekanizmasıyla yapılmış, karmaşık yük koşullarında güvenilir sonuçlar elde edilmiştir. Aydınlatma sistemlerinde harmonik tahminleri yalnızca gerilim verileriyle gerçekleştirilmiş; LSTM modeli hiperparametre optimizasyonu ile güçlendirilmiş ve dropout tekniğiyle sağlamlaştırılmıştır. Yük talebi için kullanılan GRU–Bahdanau hibrit model aktif güç verileriyle eğitilmiş ve ek veri olmadan güvenilir öngörüler sunmuştur. Çalışmanın katkısı hem harmonik hem de yük tahmininin aynı kapsamda ele alınması ve tüm analizlerin gerçek saha verileriyle doğrulanmasıdır. Bu bütüncül yaklaşım, literatüre yenilikçi katkılar sağlarken dağıtım şirketleri için de güçlü bir referans oluşturmaktadır. Bulgular, YZ tabanlı modellerin güç kalitesi sorunlarının erken tespiti, planlama ve yatırım süreçlerinin desteklenmesi ve enerji verimliliğinin artırılmasında uygulanabilir çözümler sunduğunu göstermektedir.

Anahtar Kelimeler: Aydınlatma, Enerji Kalitesi, Güç Sistem Analizi, Yapay Zekâ, Yük Kestirimi

ABSTRACT

Ph.D. THESIS

ARTIFICIAL INTELLIGENCE BASED FORECASTING OF LOAD DEMAND AND ENERGY QUALITY ASPECTS FOR DISTRIBUTION NETWORK

Metin AKDENİZ

Bandırma Onyedi Eylül University

Institute of Graduate Studies

Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. Dr. Serhat Berat EFE

Co-Supervisor: Assoc. Prof. Dr. İlyas ÖZER

September 2025, 70 pages

In this thesis, load demand and power quality in distribution networks were analyzed using artificial intelligence (AI) methods, and forecasting models were developed with different data types. Harmonic forecasting in power systems was performed with GRU and the Bahdanau attention mechanism using active and reactive power data, yielding reliable results under complex load conditions. In lighting systems, harmonic forecasting relied solely on voltage data, with the LSTM model improved by hyperparameter optimization and reinforced with the dropout technique. For load demand, a GRU–Bahdanau hybrid model trained on active power data provided accurate predictions without additional inputs. The main contribution of the study is the combined evaluation of both harmonic and load forecasting within a single framework, validated with real field data. This holistic approach offers innovative contributions to the literature while serving as a strong reference for utilities. The findings show that AI-based models can support early detection of power quality issues, enhance planning and investment, and provide applicable solutions for improving energy efficiency in distribution networks.

Keywords: Artificial Intelligence (AI), Lighting, Load Forecasting, Power System Analysis
Power Quality

İÇİNDEKİLER

ETİK BEYANI.....	i
ÖNSÖZ.....	ii
ÖZET.....	iii
ABSTRACT.....	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ.....	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ.....	ix
1. GİRİŞ.....	1
2. ELEKTRİK GÜÇ SİSTEMLERİ.....	13
2.1. Harmonikler.....	14
2.1.1. Harmonikli Büyüklüklerin Tanımı.....	16
2.1.1.1. Toplam Harmonik Distorsiyonu.....	16
2.1.1.2. Distorsiyon Faktörü.....	17
2.1.1.3. Tepe Faktörü (Crest factor, CF).....	18
2.1.1.4. K-Faktörü.....	18
2.1.1.5. Harmonik Faktörü.....	18
2.1.1.6. Toplam Harmonik Faktörü.....	19
2.1.2. Klasik Yöntemlerle Harmonik Analizi.....	19
2.1.2.1. Fourier Dönüşümü.....	19
2.1.2.2. Ayırık Fourier Dönüşümü (DFT).....	20
2.1.2.3. Hızlı Fourier Dönüşümü (FFT).....	20
2.2. Yapay Zekâ Destekli Analiz Yöntemleri.....	21
2.2.1. Yapay Sinir Ağları (ANN).....	22
2.2.2. Karar Ağaçları.....	23

2.2.3.	Destek Vektör Makineleri (SVM)	23
2.2.4.	K-En Yakın Komşu (k-NN)	23
2.2.5.	Gradyan Takip Tabanlı Öğrenme Yöntemleri.....	24
2.2.6.	Tekrarlayan Sinir Ağı (RNN)	24
2.2.7.	Uzun Kısa Süreli Bellek Ağı (LSTM).....	24
2.2.8.	Kapılı Tekrarlayan Ünite (GRU).....	24
3.	UYGULAMA SİSTEMİ	26
3.1.	Veri Setinin Oluşturulması	29
4.	DENEYSEL ÇALIŞMALAR	31
4.1.	Yapay Zekâ Algoritmaları	32
4.1.1.	Tekrarlayan Sinir Ağı (RNN)	32
4.1.2.	Uzun Kısa Süreli Bellek (LSTM).....	34
4.1.3.	Kapılı Tekrarlayan Ünite (GRU).....	36
4.1.4.	Bahdanau Dikkat Mekanizması (Bahdanau Attention).....	37
4.2.	Güç Sisteminde Harmonik Kestirimi.....	39
4.2.1.	Gerekli Kütüphanelerin Yüklenmesi	40
4.2.2.	Bahdanau Attention Katmanının Tanımlanması	41
4.2.3.	Veri Ön İşleme ve Özellik Mühendisliği (Feature Engineering)	41
4.2.4.	GRU + Bahdanau Attention Modelinin Tanımlanması.....	43
4.2.5.	Model Performans Ölçümü ve Grafikselleştirme	44
4.2.6.	Model Çıktılarının Değerlendirilmesi	45
4.3.	Aydınlatma Tesisleri İçin Harmonik Kestirimi	50
4.4.	Yük Kestirimi	57
5.	SONUÇ VE ÖNERİLER	60
6.	KAYNAKLAR.....	62
	ÖZGEÇMİŞ.....	70

ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 2-1: Farklı harmonik bileşenlerin temel bileşene etkileri.....	15
Şekil 3-1: Fider-5'e ait CBS enerji akış yönü.....	28
Şekil 4-1: Temel bir RNN blok şeması	34
Şekil 4-2: Temel bir LSTM blok şeması	35
Şekil 4-3: Temel Bir GRU blok şeması.....	37
Şekil 4-4: Bahdanau Dikkat Algoritması blok şeması	39
Şekil 4-5: Model mimarisi.....	40
Şekil 4-6: Faz 1'in THD'si için gerçek ve tahmin değerlerinin karşılaştırılması.....	47
Şekil 4-7: Faz 2'nin THD'si için gerçek ve tahmin değerlerinin karşılaştırılması.....	48
Şekil 4-8: Faz 3'ün THD'si için gerçek ve tahmin değerlerinin karşılaştırılması.....	49
Şekil 4-9: Kolerasyon Eğrileri.....	52
Şekil 4-10: Deneysel Kurulum	54
Şekil 4-11: Faz 1'in THD'si için gerçek ve tahmin değerlerinin karşılaştırılması.....	55
Şekil 4-12: Faz 2'nin THD'si için gerçek ve tahmin değerlerinin karşılaştırılması.....	56
Şekil 4-13: Faz 3'ün THD'si için gerçek ve tahmin değerlerinin karşılaştırılması.....	56
Şekil 4-14: Gerçek yük ile tahmin edilen yükün karşılaştırılması.....	58

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 2-1: Ortak bağlantı noktasında bireysel harmoniklerin ve toplam harmonik bozulmanın (THDV) üst sınırı	17
Tablo 2-2: 120 V–69 kV arası sistemlerde akım harmoniklerinin maksimum sınırları.....	17
Tablo 2-3: Karşılaştırma tablosu	25
Tablo 3-1: Fider-5 üzerindeki yük profili.....	27
Tablo 3-2: Veri setinin bir bölümü	30
Tablo 4-1: Farklı algoritmaların deneme sonuçları	46
Tablo 4-2: Özellikleri ile birlikte aydınlatma cihazları	53
Tablo 4-3: Eğitime ait sayısal değerler.....	55

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
ABC	: Yapay Arı Kolonisi
ADALINE	: Uyarlamalı Doğrusal Nöron
AG	: Alçak Gerilim
ANFIS	: Uyarlamalı Sinirsel-Bulanık Çıkarım Sistemi
ANN	: Yapay Sinir Ağı
BO	: Bayes Optimizasyonu
BP	: Geri Yayılımlı Sinir Ağı
BiGRU	: Çift Yönlü Kapılı Tekrarlayan Ünite
BiLSTM	: Çift Yönlü Uzun Kısa Süreli Bellek
CNN	: Evrişimli Sinir Ağı
CatBoost	: Kategorik Artırma
DBN	: Derin İnanç Ağı
DC	: Doğru Akım
DFIG	: Çift Beslemeli İndüksiyon Jeneratörü
DFT	: Ayrık Fourier Dönüşümü
DNN	: Derin Sinir Ağı
DSSLMS	: Dinamik Adım LMS
EMD	: Ampirik Mod Ayrıştırma
FARIMA	: Kesirli Oto regresif Entegre Hareketli Ortalama
FFT	: Hızlı Fourier Dönüşümü
FTS	: Bulanık Zaman Serileri
GMDH	: Grup Veri İşleme Yöntemi
GOA	: Çekirge Optimizasyon Algoritması
GRNN	: Genelleştirilmiş Regresyon Sinir Ağı

GRU	: Kapılı Tekrarlayan Ünite
HPM	: Harmonik Güç Piyasası
HRP	: Harmonik Tekrarlamalı Süreç
ICS	: Bağımsız Bileşen Analizi
IEC	: Uluslararası Elektroteknik Komisyonu
IEEE	: Elektrik ve Elektronik Mühendisleri Enstitüsü
KF	: Kalman Filtresi
KNN	: K-En Yakın Komşu
LED	: Işık Yayan Diyot
LMS	: En Küçük Ortalama Kareler
LOLIMOT	: Yerel Doğrusal Model Ağacı
LSTM	: Uzun Kısa Süreli Bellek Ağı
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MCS	: Monte Carlo Simülasyonu
MEA	: Çok Amaçlı Evrimsel Algoritma
MEPSO	: Makedonya Elektrik İletim Sistemi İşletmesi
MFFNN	: Optimize Edilmiş Çok Katmanlı İleri Beslemeli Sinir Ağı
MLP	: Çok Katmanlı Algılayıcı
MTS	: Çok Değişkenli Zaman Serisi
NARX RNN	: Dış Girişli Doğrusal Olmayan Sinir Ağı
OG	: Orta Gerilim
P&O MPPT	: Sapma ve Gözlemlili Maksimum Güç Noktası İzleme Yöntemi
PMSG	: Kalıcı Mıknatıslı Senkron Jeneratör
PRONY	: Sönümlü Sinüzoidal Bileşen Analizi Yöntemi
PV	: Fotovoltaik
RBF	: Radyal Tabanlı Fonksiyon

RLS	: Doğrusal En Küçük Kareler
RMSE	: Kök Ortalama Kare Hatası
SCA	: Sine-Cosine Algoritması
SMAPE	: Simetrik Ortalama Mutlak Yüzde Hata
SOM	: Öz örgütleyici Haritalar
STLF	: Kısa Dönemli Yük Tahmini
THD	: Toplam Harmoni Bozulma
UDR	: Tek Değişkenli Boyut İndirgeme
VSC	: Gerilim Kaynaklı Dönüştürücü
WNN	: Dalgacık Sinir Ağı
XGBoost	: Aşırı Gradyan Artırma
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zekâ

1. GİRİŞ

Son yıllarda elektrik enerjisine olan talebin artması, dağıtım şebekelerinin daha karmaşık ve dinamik yapılar haline gelmesine yol açmıştır. Yenilenebilir enerji kaynaklarının dağıtık biçimde entegrasyonu, elektrikli araçlar, akıllı sayaç sistemleri ve kullanıcı alışkanlıklarındaki değişimler, özellikle orta gerilim seviyesindeki dağıtım şebekelerinde hem yük profillerinin hem de güç kalitesi parametrelerinin öngörülmesini zorlaştırmaktadır. Bu dönüşüm, yalnızca enerji üretiminde değil; aynı zamanda iletim ve dağıtım sistemlerinde de çok boyutlu teknik sorunların gündeme gelmesine neden olmaktadır.

Dağıtım şebekelerinde karşılaşılan başlıca güç kalitesi problemleri; gerilim dalgalanmaları, harmonik bozulmalar, ani gerilim düşmeleri ve dalgalı yük akımlarıdır. Bu tür bozulmalar; yalnızca kullanıcıların elektrikli ekipmanlarının ömrünü kısaltmakla kalmaz, aynı zamanda enerji verimliliğini düşürür ve şebeke güvenilirliğini tehdit eder[1]. Özellikle inverter tabanlı üretim sistemleri ve güç elektroniği tabanlı yüklerin yaygınlaşması, şebekeye yüksek seviyede harmonik enjekte edilmesine sebep olmakta ve harmoniklerin hem alçak hem de orta gerilim seviyelerine kadar taşındığı gözlemlenmektedir. Bu bağlamda, dağıtım sistemlerinde harmonik bozulmaların kestirilebilmesi ve kontrol altına alınması, sürdürülebilir ve kaliteli bir enerji arzı için kritik öneme sahiptir[2].

Mevcut sistemlerde kullanılan klasik kestirim ve analiz yöntemleri, çoğu zaman şebekedeki karmaşık dinamikleri yeterli doğrulukla modelleyememekte; özellikle değişken yük profilleri ve ani harmonik artışları gibi durumlarda zayıf performans göstermektedir. Bu noktada YZ temelli modelleme yaklaşımları, dağıtım sistemlerinin zamanla değişen karakteristiklerini öğrenme, adaptif tahminler üretme ve çok boyutlu verilerden anlamlı çıkarımlar yapma açısından önemli avantajlar sunmaktadır[3].

Bu doktora tezinin temel amacı, orta gerilim dağıtım şebekesinden elde edilen uzun süreli ölçüm verileri üzerinden; yük talebi ve enerji kalitesi unsurlarının (harmonik bozulmaların) zaman serisi analizi ile modellenmesi ve bu parametrelerin yüksek doğrulukla tahmin edilmesidir. Bu kapsamda kullanılan veri seti, Vangölü EDAŞ işletme bölgesinde bulunan Tatvan Trafo Merkezi çıkışlı Fider-5 hattında gerçekleştirilen uzun dönemli saha ölçümlerine dayanmaktadır. Söz konusu ölçümlerle, gerçek bir orta gerilim dağıtım sistemine ait aktif/reaktif güç profilleri, harmonik oranları ve gerilim değerleri detaylı biçimde elde edilmiştir. Çalışmada farklı YZ teknikleri karşılaştırmalı olarak uygulanmış, gerçek zamanlı uygulamaya uygun öngörü modelleri geliştirilmiştir.

Tez kapsamında ayrıca; gerçek saha koşullarında yer alan ölçüm cihazlarından elde edilen büyük veri setlerinin işlenmesi, ön işleme tekniklerinin uygulanması, zaman serisi uzunluklarının optimizasyonu ve tahmin performansının çeşitli hata metrikleriyle (MAE, RMSE, MAPE, SMAPE) değerlendirilmesi gibi çok katmanlı bir metodoloji izlenmiştir. Elde edilen sonuçlar, YZ modellerinin özellikle harmonik bozulmaların tahmini gibi zorlayıcı alanlarda iyi performans gösterdiğini ortaya koymaktadır.

Tezin özgün katkısı, gerçek bir orta gerilim dağıtım bölgesinden elde edilen ölçüm verileriyle; yük ve güç kalitesi unsurlarının eş zamanlı olarak tahmin edildiği entegre bir YZ altyapısı sunmasıdır. Bu çalışma, hem akademik literatürde bu iki konunun birlikte ele alındığı nadir örneklerden biri olarak öne çıkmakta, hem de enerji kurumları için şebeke planlama, arıza önleme ve güç yönetimi gibi kritik karar süreçlerinde uygulanabilir çözümler sunmaktadır.

Literatürde güç sistemlerindeki harmonik bozulmaların tespiti ve kestirimine yönelik olarak geliştirilen veri odaklı, YZ ve hibrit yöntemler temelli çalışmalar; kullanılan veri türleri, modelleme teknikleri ve uygulama alanları bakımından geniş bir çeşitlilik sunmaktadır.

Bu kapsamda yapılan güncel araştırmalara örnek olarak Bayo ve arkadaşları, konut tipi dağıtım şebekelerinde gerilim harmonik bozulmalarının kısa vadeli öngörüsünü gerçekleştirmek amacıyla, ileri beslemeli ve geri beslemeli YZ algoritmaları kullanmışlardır. %10'luk akıllı sayaç kapsama oranıyla gerçekleştirilen çalışmada, zamansal yapılar dikkate alınmış ve farklı saatlik zaman dilimlerine göre THD tahminleri yüksek doğrulukla elde edilmiştir. Elde edilen sonuçlar, sınırlı veri erişimi koşullarında dahi yöntemin başarısını ortaya koymuş; böylece önerilen modelin saha uygulamaları açısından uygulanabilir ve ölçeklenebilir bir çözüm sunduğu ifade edilmiştir[4].

Benzer şekilde, Kabalcı ve çalışma arkadaşları, güç sistemlerinde harmonik sinyallerin genlik ve faz bileşenlerini tahmin etmek amacıyla klasik Yapay Arı Kolonisi (ABC) algoritmasını geliştirmiştir. Değiştirilmiş bu yaklaşım, düşük hesaplama süresi ve yüksek doğruluk seviyesi sağlayarak, geleneksel yöntemlere kıyasla %36 oranında daha hızlı sonuç üretmiştir[5].

Farklı bir yaklaşım olarak, Yalçın ve Vatansever, ara harmonik tahmini kapsamında Prony ile ADALINE yöntemlerini karşılaştırmışlardır. Simülasyon verileri, fotovoltaik sistemlerde kullanılan sapma ve gözlemlenilen maksimum güç noktası izleme yöntemi (P&O MPPT) ile üretilen değişken harmonik içerikler üzerinden oluşturulmuştur. Buna göre, veri seti küçük olduğunda Prony yöntemi daha uygun iken; yeterli veri ve uygun nöron yapısına sahip olduğunda ADALINE daha yüksek doğruluk sunmuştur. Bu çalışma, harmonik tahmini alanında veri hacmi ve ağ yapısının doğruluk üzerindeki etkisini ortaya koyarak klasik parametrik metodolojilerin değerlendirilmesine katkı sunmaktadır[6].

Diğer bir çalışmada, Ivry ve arkadaşları, güç sistemine bağlı birden fazla gerilim kaynaklı dönüştürücünün (VSC) neden olduğu harmonik bozulmayı, sistem ve tasarım parametrelerindeki belirsizlikleri dikkate alarak olasılıklı biçimde tahmin etmiştir. Çalışmada, tek değişkenli boyut indirgeme (Univariate Dimension Reduction – UDR) yöntemi; yaygın olarak kullanılan Monte Carlo Simülasyonu (MCS) ile karşılaştırıldığında çok daha düşük hesaplama süresiyle THD gibi metriklerin yüksek doğrulukla tahmin edilmesini sağlamıştır. Deneysel doğrulama içeren iki ayrı vaka çalışmasında, UDR algoritmasının hem hesaplama verimliliği hem de tahmin isabeti bakımından avantajlı olduğu ortaya konmuştur. Bu çalışma, YZ tabanlı olmayan fakat belirsizlik altındaki harmonik analiz yöntemlerine güçlü bir referans sunmaktadır[7].

Başka bir araştırmada, Garanayak ve arkadaşları, anlık sinyal işleme ve hızlı harmonik analizinin gerekli olduğu güç sistemleri için, Master–Slave ADALINE (MS–ADALINE) mimarisini kullanarak temel frekans bileşeni, harmonikler, alt-harmonikler, inter-harmonikler ve sönümlü doğru akım (DC) bileşenlerini gerçek zamanlı ve yüksek doğrulukla tahmin etmeye yönelik bir yapı geliştirmiştir. Slave–ADALINE, sabit büyük adım boyutlu LMS algoritmasıyla hızlı yakınsama sağlarken; Master–ADALINE, değişken adım boyutlu LMS ile kararlı düşük hata seviyeleri sağlamaktadır. Her iterasyonda iki birimin kare hatalarının ortalaması alınarak Master’ın ağırlıkları güncellenmekte ve böylece hem yakınsama hızı hem de hassasiyet artırılmaktadır. Simülasyonlar ve laboratuvar prototip uygulamaları, bu yapının tek katmanlı ADALINE ve dinamik adım LMS (DSSLMS) yapılarıyla karşılaştırıldığında <0.015 s sürede daha hızlı yakınsama ve daha düşük faz/hata salınımı sunduğunu göstermiştir. Bu yöntem, YZ destekli olmayan ancak adaptif sinir ağı temelli harmonik tahmin modelleri açısından dikkate değer bir örnektir[8].

Çağdaş bir YZ uygulaması olarak, Kuyumani ve arkadaşları, Güney Afrika’daki bir trafo merkezinde meydana gelen harmonik bozulmaların tespiti ve ileriye dönük tahmini amacıyla, evrişimli sinir ağı (CNN) ile uzun kısa süreli bellek ağı (LSTM) mimarilerinin avantajlarını bir araya getiren hibrit bir YZ modeli geliştirmiştir. Bu yapıda, CNN bileşeni giriş sinyallerinden anlamlı ve ayırt edici yapısal özellikleri çıkartırken; LSTM bileşeni, bu özellikleri kullanarak zamana bağlı öngörülerde bulunmuştur. Önerilen hibrit model, yalnızca LSTM gibi geleneksel yöntemlerle elde edilen sonuçlara kıyasla daha yüksek doğruluk ve genelleme başarısı sergilemiştir. Donanım tabanlı yöntemlere ihtiyaç duymadan, doğrudan ölçüm verileri üzerinden çalışan bu çağdaş yaklaşım, harmonik bozulmaların tahmininde etkili ve uygulanabilir bir çözüm sunmaktadır[9].

İlgili alanda yapılan başka bir incelemede, Jumilla Corral ve arkadaşları, şebekeye bağlı fotovoltaiik (PV) inverterlerin neden olduğu harmonik akım bozulmalarının modellenmesi ve

tahmini amacıyla, dışgirişli doğrusal olmayan otoregresif sinir ağı (NARX RNN) tabanlı bir yaklaşım geliştirmiştir. Çalışmada hem inverter çıkış akımı hem de şebeke akımı girdi parametresi olarak kullanılmış; deneysel veriler, laboratuvar ortamında kurulan özel bir PV simülasyon düzeneği aracılığıyla elde edilmiştir. Elde edilen sonuçlar, önerilen NARX tabanlı sistemin, şebeke dinamiklerini zaman serisi düzeyinde başarılı biçimde temsil edebildiğini ve gelecekteki harmonik davranışları yüksek doğrulukla öngörebildiğini ortaya koymaktadır. Bu bağlamda çalışma, PV entegrasyonunun neden olduğu güç kalitesi bozulmalarının veri odaklı ve öngörülebilir şekilde yönetilmesine yönelik önemli bir katkı sunmaktadır[10].

Yapılan diğer bir çalışmada, Jahan ve arkadaşları, ev tipi şebekeden bağımsız sistemlerde güç kalitesi parametrelerini (frekans, gerilim, harmonik bozulmalar) meteorolojik ve yük verilerine dayalı olarak tahmin etmeye yönelik çeşitli yöntemler uygulamışlardır. Yapay sinir ağı, farklı regresyon türleri ve karar ağacı temelli modellerin karşılaştırıldığı çalışmada, testler Çekya'daki konut tipi yükler içeren bir laboratuvar sisteminde gerçekleştirilmiştir. Sonuçlar, özellikle karar ağacı temelli yöntemlerin harmonik bozulmaların tahmininde daha başarılı olduğunu göstermiştir[11].

Gerçekleştirilen bir diğer çalışmada, Tiwari ve arkadaşları, PV-rüzgâr hibrit mikroşebekede güç kalitesini artırmak ve bozulmaları öngörmek amacıyla, proaktif bir shunt (paralel) aktif filtre ile zaman serisi tahminine dayalı yapay sinir ağı modelini entegre eden yenilikçi bir sistem geliştirmiştir. Önerilen yapıdaki aktif filtre, şebekeye giriş yapan harmonik akımları gerçek zamanlı olarak telafi ederken; sinir ağı, geçmiş verileri analiz ederek gelecekteki güç kalitesi değişimlerini tahmin etmektedir. Sistem mimarisinde yer alan kontrol algoritmaları, bozucu yüklerin oluşturabileceği dalgalanmalara karşı hem anlık düzeltme hem de önleyici müdahale olanağı sunarak, enerji sürekliliği ve şebeke kararlılığı açısından önemli bir katkı sağlamaktadır[12].

Mevcut literatürde dikkat çeken bir başka örnekte, Yang ve arkadaşları, LED aydınlatma sistemlerinden kaynaklanan THD değerlerinin tahmini için veri odaklı ve YZ destekli bir tahmin sistemi geliştirmişlerdir. Bu sistemde, farklı LED sürücü devrelerine ait harmonik karakteristik verileri toplanarak, Genelleştirilmiş Regresyon Sinir Ağı (GRNN) ile AdaBoost algoritması entegre edilerek hibrit bir model oluşturulmuştur. GRNN'in parametreleri, Çok Amaçlı Evrimsel Algoritma (MEA) ile optimize edilmiş; AdaBoost yapısına ise yumuşak geçişli eğri tabanlı bir ağırlık uyarlama mekanizması eklenerek modelin genelleme yeteneği artırılmıştır. Önerilen MEA-GRNN + İyileştirilmiş AdaBoost yapısı, klasik Geri Yayılımlı Sinir Ağı (BP) ve tek başına GRNN modellerine kıyasla %95,48 doğruluk oranı ve daha düşük hata metrikleri ile üstün performans sergilemiştir[13].

Önemli bir çalışmada, Al Hadi ve Aly, rüzgâr türbini destekli çift beslemeli indüksiyon jeneratörü (DFIG) ile güneş PV ve kalıcı mıknatıslı senkron jeneratör (PMSG) kombinasyonlarında oluşan harmonik akımların tahminine odaklanan yenilikçi bir çalışma sunmuştur. Çalışmada iki farklı yapı test edilmiş: biri LSTM ardından Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS), diğeri ANFIS ardından LSTM katmanlı modeldir. Bu modeller, rüzgâr hızı ve güneş ışınlımı gibi gerçek meteorolojik verilerle beslenen simülasyon ortamlarında harmonik üretimi taklit eden sistemlerde uygulanmıştır. Sonuçlar, ANFIS LSTM modelinin hem gerilim hem akım harmonikleri için en tutarlı ve yüksek doğruluklu tahminleri verdiğini göstermiştir[14].

Yine dikkat çeken bir başka araştırmada, Al Hadi, Aly ve Little, DFIG (Çift Beslemeli Asenkron Jeneratör) destekli rüzgâr-güneş hibrit enerji sistemlerinde oluşan harmonik bozulmaların hem tahmini hem de giderimi amacıyla ANFIS tabanlı bir model geliştirmiştir. Model, gerçek zamanlı simülasyon ortamında kullanılan meteorolojik veriler (rüzgâr hızı ve güneş ışınlımı) ile sistemde gözlemlenen harmonik akım bileşenlerini giriş olarak alarak, ANFIS mimarisi aracılığıyla gelecekteki harmonik davranışları öngörmekte ve aynı zamanda ANFIS tabanlı bir kontrol algoritması ile bu harmoniklerin bastırılmasını sağlamaktadır. Laboratuvar ve simülasyon sonuçları, önerilen yöntemin harmonik bozulmaları etkin biçimde telafi ettiğini ve sistemin dinamik kararlılığını anlamlı ölçüde artırdığını göstermektedir[15].

Kuyunani, Hasan ve Shongwe tarafından gerçekleştirilen bir araştırmada, rüzgâr santrallerinde oluşan gerilim harmoniklerinin kısa dönemli tahmini için derin öğrenme tabanlı bir yaklaşım geliştirilmiştir. Güney Afrika'daki Jeffreys Bay Rüzgâr Santrali'nden elde edilen 8103 harmonik örneği kullanılarak, LSTM mimarisiyle oluşturulan model, zamana dayalı veri dilimleme yöntemiyle elde edilen ortalama gerilim genliklerini giriş olarak almış ve gelecekteki harmonik davranışları düşük hata oranıyla tahmin etmiştir. Elde edilen sonuçlar, önerilen modelin gerilim harmoniklerinin öngörülmesinde etkili olduğunu ve şebeke güç kalitesinin iyileştirilmesine katkı sağladığını göstermektedir[16].

Benzer şekilde, Sahoo ve Subudhi tarafından yapılan çalışmada, güç sistemlerindeki harmonik bozulmaların tahmini için uyarlanabilir filtreleme tabanlı bir yöntem önerilmiştir. Çalışmada, klasik LMS (En Küçük Kareler) ve RLS (Doğrusal En Küçük Kareler) algoritmalarına ek olarak, doğrusal olmayan sistemleri temsil edebilen Volterra serileri kullanılarak genişletilmiş Volterra-LMS/F ve Volterra-RLS yapıları test edilmiştir. Bu gelişmiş algoritmaların hem harmonik hem de azalan DC bileşenlerini, gürültülü ortamlarda dahi yüksek doğrulukla tahmin edebildiği gösterilmiştir. Simülasyon sonuçları, bu yapıların harmonik genlik ve fazlarını düşük hata ile ve hızlı şekilde öngörebildiğini ortaya koymaktadır[17].

Zjavka ise yenilenebilir enerji destekli off-grid konut sistemlerinde, 24 saatlik zaman dilimi boyunca güç kalitesi parametrelerinin (örneğin gerilim, frekans, harmonikler) tahmini için istatistiksel ve derin olasılıksal öğrenmeye dayalı bir çerçeve önermiştir. Geliştirilen model, farklı evsel yük kombinasyonlarını, meteorolojik verileri ve sistem çıktılarıyla birlikte analiz ederek günlük güç kalitesi değişimlerini öngörebilmektedir. Bu hibrit yaklaşım, derin öğrenme tabanlı regülatif modelleme ile olasılıksal tahmin yöntemlerini birleştirerek, gerçek veri eksikliğini telafi etmeyi ve daha güvenilir sonuçlar üretmeyi amaçlamaktadır. Çalışma, elde edilen tahminlerin enerji kullanım planlamasını optimize etmek ve sistem kararlılığını artırmak açısından önemli katkılar sunduğunu ortaya koymuştur[18].

Ayrıca, Panoiu ve arkadaşları tarafından yapılan araştırmada, demiryolu enerji sistemlerinde tren yüklemesi sırasında oluşan harmonik bozulmaların analizine yönelik olarak ANN-GMDH (Yapay Sinir Ağı – Grup Veri İşleme Yöntemi) tabanlı bir makine öğrenmesi modeli geliştirilmiştir. Çalışmada, trafo çıkışındaki akım ve gerilim dalga formları kaydedilmiş, bu veriler üzerinden Hızlı Fourier Dönüşümü (FFT) uygulanarak harmonik bileşenler elde edilmiştir. Elde edilen frekans bileşenleri, ANN-GMDH mimarisiyle eğitilerek THD tahmini gerçekleştirilmiştir. Simülasyon sonuçları, modelin düşük hata oranı ve yüksek tahmin doğruluğu ile çalıştığını ortaya koymuştur. Ayrıca, kısa hesaplama süresi sayesinde modelin gerçek zamanlı uygulamalara uygun olduğu vurgulanmıştır. Bu yönüyle çalışma, demiryolu güç sistemlerinde harmonik izleme ve önleyici bakım stratejileri açısından literatüre önemli bir katkı sunmaktadır[19].

Bunun yanı sıra, Jahan ve arkadaşları tarafından gerçekleştirilen bir başka çalışmada, küçük ölçekli off-grid konut sistemlerinde gerilim, akım ve gerilim harmonikleri (THDu, THDi) ile güç faktörü gibi güç kalitesi parametrelerinin tahmini için özörgütleyici haritalar (SOM), K-En Yakın Komşu (KNN) ve karar ağacı algoritmalarını birleştiren hibrit bir model önerilmiştir. İlk aşamada, meteorolojik veriler (sıcaklık, basınç, UV, ışıınım vb.) ve evsel yükler (klima, TV, aydınlatma gibi cihazlar) kullanılarak veriler 3×3 boyutlu SOM haritaları ile dokuz kümeye ayrılmıştır. İkinci aşamada ise her bir SOM kümesine özel olarak KNN ve karar ağacı modelleri eğitilerek tahminler gerçekleştirilmiştir. Bu iki aşamalı yapı, özellikle değişken hava koşulları ve yük profilleri altında düşük RMSE değerleri ile yüksek doğrulukta sonuçlar üretmiş, tahmin performansını önemli ölçüde artırmıştır[20].

Altıntaş, güç sistemlerindeki harmonik ve ara harmonik (temel frekansın tam katı olmayan bileşenler) parametrelerinin doğrudan tahmini için Sine-Cosine Algoritması (SCA) tabanlı sezgisel bir optimizasyon yaklaşımı önermiştir. Çalışmada, temel frekansın 49,5–50,5 Hz aralığında değiştiği durumlarda, sinyalin frekans, genlik ve faz bilgileri bilinmeden hem harmonik hem de ara harmonik bileşenlerin tahmini gerçekleştirilmiştir. Yöntem, farklı bozulma etkilerine

sahip sentetik sinyallerin yanı sıra, gerçek iletim sistemi verileri üzerinde de test edilmiştir. Elde edilen sonuçlar, SCA'nın düşük hata oranı ve yüksek yakınsama başarımı ile klasik Ayrık Fourier Dönüşümü (DFT) yöntemine kıyasla daha üstün bir performans sunduğunu göstermiştir. Bu yapı, özellikle harmonik analizinde hem doğruluğu artırmak hem de ara harmonik bileşenleri hassas biçimde ortaya koymak açısından önemli katkılar sağlamaktadır[21].

Jahan ve arkadaşları tarafından yürütülen çalışmada, şebekeden bağımsız sistemlerde ev içi yüklerin çalışma zamanlamasını optimize etmeye yönelik bir akıllı kontrol sistemi geliştirilmiştir. Bu sistemde, karar ağacı modeli kullanılarak kısa vadeli güç kalitesi parametreleri frekans, gerilim, gerilimde toplam harmonik bozulma (THDu), akımda toplam harmonik bozulma (THDi) ve kısa vadeli flicker şiddetini tahmin edilmiştir. Elde edilen tahminler, evsel cihazların enerji talebine uygun şekilde zamanlanarak hem enerji verimliliği sağlanmış hem de güç kalitesinin iyileştirilmesi hedeflenmiştir[22].

Parametreleri ve topolojisi tam olarak bilinmeyen konut dağıtım şebekelerinde harmonik tahminine yönelik olarak, Rodríguez-Pajarón, Hernández ve Milanović tarafından yapay sinir ağı (YSA) tabanlı bir yöntem önerilmiştir. Geliştirilen model, yalnızca temel gerilim ve aktif güç ölçen yaygın akıllı sayaçlarla, sınırlı sayıda güç kalitesi ölçüm cihazı (%10'dan az) kullanılarak tüm bağlantı noktalarında harmonik seviyelerini tahmin etmektedir. Kullanılan algoritma, çok katmanlı beslemeli bir YSA (MLP) olup geri yayılım yöntemiyle eğitilmiş ve ReLU aktivasyon fonksiyonu ile yapılandırılmıştır. İki farklı Avrupa test sistemi üzerinde yapılan doğrulamalarda, önerilen sistem %0.027–0,04 arasında ortalama hata ve ≤ 2 saniyelik hesaplama süresi ile yüksek doğruluk ve hız sunmuştur. Bu yöntem hem ölçüm maliyetini azaltmakta hem de sınırlı verilerle şebeke izlemeyi mümkün kılmaktadır[23].

Bir YZ yöntemi olan Harmonik Tekrarlamalı Süreç (HRP), Zhang ve Zhou tarafından dönemi zamanla değişen ve durağan olmayan zaman serilerinin tahmini amacıyla geliştirilmiştir. Yöntem, harmonik analiz tekniğini kullanarak düzensiz periyotlu tekrar eden desenleri yakalamakta ve bu desenleri topluluk mantığıyla birleştirerek yüksek doğrulukta tahminler üretmektedir. Hem sentetik hem de gerçek veri setlerinde yapılan deneyler, HRP'nin istatistiksel ve derin öğrenme tabanlı modellere kıyasla üstün performans gösterdiğini ortaya koymuştur[24].

Garrido-Zafra ve arkadaşlarının gerçekleştirdiği çalışmada, Harmonik Güç Piyasası (HPM) planlamasında dağıtım sistemi işletmecilerine karar desteği sağlamak amacıyla, IEC 61000-4-30 ve IEC 61000-4-7 standartlarına göre ölçülen 3. ve 5. akım harmoniklerinin genlik ve faz açılarını tahmin etmeye yönelik bir yöntem geliştirilmiştir. İspanya'daki Córdoba Üniversitesi veri merkezinde 77 gün boyunca 10 dakikalık çözünürlükte toplanan veriler, çok değişkenli zaman serisi (MTS) olarak modellenmiş ve Bayes optimizasyonu ile ayarlanan farklı derin öğrenme

mimarileri (MLP, CNN, GRU, LSTM, BiGRU, BiLSTM) karşılaştırılmıştır. Sonuçlar, BiLSTM mimarisinin en düşük hata değerlerini sağladığını ve tahmin belirsizliklerinin güven aralıkları ile karakterize edilerek HPM planlamasında kullanılabilecek güvenilir bir tahmin aracı sunduğunu göstermektedir[25].

Liang Hua tarafından yürütülen bir araştırmada, dağıtım şebekesinde güç kalitesine ilişkin parametrelerin tahmini amacıyla CNN-LSTM tabanlı bir derin öğrenme modeli geliştirilmiştir. Önerilen sistemde, güç kalitesi verileri önce kaydırmalı pencere (sliding window) yöntemiyle kare grafiklere dönüştürülmekte, ardından CNN bu grafiklerden özellik çıkarımı yapmakta; elde edilen çıkış, zaman dizisi olarak LSTM'e beslenerek tahmin işlemi gerçekleştirilmektedir. IEEE-13 düğümlü aktif dağıtım ağı üzerinde gerçekleştirilen simülasyon sonuçları, bu yaklaşımın geleneksel kontrol modellerine kıyasla tahmin doğruluğunu anlamlı şekilde iyileştirdiğini göstermektedir[26].

Yapılan karşılaştırmalı bir çalışmada, Zhang ve arkadaşları güç kalitesi (PQ) parametrelerinin kısa vadeli tahmini için LSTM ve çift yönlü LSTM (BiLSTM) modellerini incelemiş ve performansı artırmak amacıyla Bayes optimizasyonu ile geliştirilmiş BiLSTM (BO-BiLSTM) modelini önermiştir. Çalışmada kullanılan veri seti, bir dağıtım sistemi üzerinden elde edilen zaman serisi PQ ölçümlerinden oluşmakta olup, farklı yük koşullarını ve harmonik bozulma, gerilim ile frekans sapması gibi göstergeleri içermektedir. Deneysel sonuçlar, BiLSTM'in LSTM'e göre daha yüksek tahmin doğruluğu sağladığını, BO-BiLSTM'in ise her iki modele kıyasla en düşük hata değerlerini elde ederek en iyi performansı gösterdiğini ortaya koymuştur[27].

Karadeniz tarafından yürütülen araştırmada, offshore rüzgâr çiftliklerinde voltaj harmonik bozulması (THDv) tahmini için tamamen simülasyon tabanlı sentetik veri kullanılmıştır. Çalışmanın temel gerekçesi, offshore rüzgâr santrallerinde uzun dönemli ve yüksek çözünürlüklü harmonik ölçüm verilerinin kısıtlıdır. Bu eksikliği gidermek için, farklı çalışma koşullarını temsil eden sentetik zaman serisi verileri üretilmiş ve bu veriler tahmin modeli eğitiminde kullanılmıştır. Çalışmanın amacı, gerçek ölçüm verilerinin sınırlı olduğu durumlarda da güvenilir THDv tahmini yapılabileceğini göstererek, offshore rüzgâr santrallerinde güç kalitesi izleme ve planlama çalışmalarına katkı sağlamaktır[28].

Thomas ve arkadaşları, doğrusal olmayan yüklerin neden olduğu harmonik bozulmaların tahmini için makine öğrenmesi tabanlı bir yaklaşım önermiştir. MATLAB/Simulink ile oluşturulan simülasyon verileri kullanılarak Random Forest, XGBoost, CatBoost ve Gradient Boosting gibi algoritmalar test edilmiş; en yüksek doğruluk stacking yöntemiyle elde edilmiştir

($R^2 = 0.9807$). Çalışma, harmonik bozulmaların veri odaklı tahmini yoluyla gerçek zamanlı analiz ve endüstriyel uygulamalar için güçlü bir temel sunmaktadır[29].

Yapılan bir araştırmada Balouji ve arkadaşları, elektrik ark ocaklarında meydana gelen zamanla hızlı değişen harmonik ve ara harmonik akımların önceden tespiti için derin öğrenme tabanlı bir yöntem geliştirmiştir. Çalışmada, zaman-frekans dönüşümleriyle elde edilen spektrum verileri derin sinir ağına (DNN) giriş olarak verilmiş ve böylece harmonik bileşenler yüksek doğrulukla ve düşük gecikmeyle tahmin edilmiştir. Önerilen yaklaşım, kompanzasyon sistemlerinin bozulmaları gerçek zamanlıya yakın hızda algılayarak şebeke kararlılığını koruyacak şekilde müdahale etmesine olanak tanımaktadır. Deneysel sonuçlar, yöntemin hem doğruluk hem de işlem süresi açısından endüstriyel uygulamalara uygun olduğunu ortaya koymuştur[30].

Zhao ve Milanović tarafından yürütülen çalışmada, seyrek izleme altyapısına sahip iletim şebekelerinde, yenilenebilir enerji entegrasyonunun etkisiyle oluşan harmonik bozulma (THD) seviyelerini tahmin etmek için ANN tabanlı bir yöntem geliştirilmiştir. Model, sınırlı sayıdaki ölçüm noktasından elde edilen harmonik verilerini ve şebeke topolojisi bilgilerini giriş olarak kullanarak tüm sistem genelindeki harmonik yayılımını öngörmektedir. Bu sayede, ölçüm altyapısının yetersiz olduğu durumlarda dahi yüksek doğrulukla tahmin yapılabilme, böylece güç kalitesi izleme ve planlama süreçleri desteklenmektedir[31].

Xie ve arkadaşlarının gerçekleştirdiği bir diğer çalışmada, elektrik güç sistemlerinde harmonik bozulmanın tahmini ve buna bağlı regülasyon stratejisinin geliştirilmesi amacıyla LSTM tabanlı derin öğrenme modeli tasarlanmıştır. Model, ölçüm verilerini giriş olarak alarak harmonik bileşenlerin genlik değişimlerini önceden tahmin etmekte ve bu tahminler doğrultusunda kompanzasyon cihazlarının çalışma parametrelerini dinamik olarak ayarlamaktadır. Böylece, güç kalitesi bozulmaları azaltılmakta ve sistemin kararlı çalışması sağlanmaktadır. Sonuçlar, önerilen yöntemin harmonik tahmininde yüksek doğruluk sunduğunu ve regülasyon stratejisinin etkinliğini artırdığını göstermektedir[32].

Taghvaie ve arkadaşlarının yürüttüğü kapsamlı inceleme, elektrik güç sistemlerinde harmonik sorunlarının tespit ve tahminine yönelik yöntemleri değerlendirmektedir. Çalışmada, geleneksel teknikler (Fourier dönüşümü, dalgacık dönüşümü, istatistiksel yöntemler vb.) ile YZ/makine öğrenmesi tabanlı yaklaşımlar (yapay sinir ağları, destek vektör makineleri, derin öğrenme, hibrit modeller) ayrıntılı olarak karşılaştırılmıştır. Ayrıca, farklı harmonik kaynaklarının (yenilenebilir enerji sistemleri, güç elektroniği tabanlı yükler, endüstriyel prosesler) şebeke üzerindeki etkileri değerlendirilmiştir. Yazarlar, hibrit tekniklerin karmaşık ve değişken şebeke koşullarında daha yüksek doğruluk sağladığını, ancak gerçek zamanlı uygulamalarda veri kalitesi ve hesaplama maliyetinin kritik sınırlayıcılar olduğunu vurgulamaktadır[33].

Son olarak Mack ve arkadaşlarının önerdiği bir diğer yöntem, dağıtım şebekelerinde harmonik durum kestirimi için fizik bilgisiyle zenginleştirilmiş yapay sinir ağları (Physics-Aware Neural Networks) tabanlıdır. Bu yöntem, güç sistemlerinin fiziksel kısıtlarını ve devre denklemlerini derin öğrenme sürecine entegre ederek, yalnızca veriye dayalı tahminlerin ötesinde fiziksel tutarlılığı da garanti altına almaktadır. Model, farklı harmonik dereceler için hem gerilim hem de akım bileşenlerinin genlik ve faz açılarını tahmin edebilmekte, aynı zamanda eksik ölçüm noktalarında dahi güvenilir sonuçlar verebilmektedir. Simülasyon ve gerçek şebeke verileri üzerinde yapılan testler, yöntemin klasik harmonik durum tahmini tekniklerine kıyasla daha yüksek doğruluk ve daha iyi genelleme kabiliyeti sunduğunu göstermektedir[34].

Güç sistemlerinin güvenilir işletimi ve planlanması açısından harmonik bozulmaların izlenmesi ve kestiriminin yanı sıra, yük talebinin doğru kestirimi de kritik öneme sahiptir. Özellikle kısa, orta ve uzun vadeli yük talep kestirimleri; üretim planlamasından iletim ve dağıtım şebekesi yönetimine, talep tarafı katılım stratejilerinden enerji piyasası operasyonlarına kadar pek çok alanda belirleyici rol oynamaktadır. Son yıllarda, yük talebi kestirimi çalışmalarında YZ, makine öğrenmesi ve hibrit yöntemlerin yaygınlaşması, farklı veri türlerinin (meteorolojik veriler, geçmiş tüketim kayıtları, sosyo-ekonomik göstergeler vb.) bir arada kullanılmasına ve model doğruluğunun artırılmasına olanak sağlamıştır.

Nti ve arkadaşları, 2010–2020 yılları arasında yayımlanan 77 araştırmayı sistematik olarak inceleyerek elektrik yük tahmini yaklaşımlarındaki eğilimleri ortaya koymuştur. Bulgular, en yaygın kullanılan dokuz modelin %90'ının YZ tabanlı olduğunu ve bunlar arasında ANN %28 ile öne çıktığını göstermektedir. Ayrıca, RMSE (%38) ve MAPE (%35) en çok tercih edilen hata metrikleri olmuş; çalışmaların %80'inin kısa vadeli yük tahminine odaklandığı belirlenmiştir[35].

Yapılan bir çalışmada Hussain ve arkadaşları, Pakistan'daki toplam ve sektör bazlı elektrik tüketimini tahmin etmek için 1980–2011 dönemi zaman serisi verilerini kullanarak Holt-Winter ve ARIMA modellerini karşılaştırmıştır. Analizler, Holt-Winter modelinin daha doğru sonuçlar verdiğini; gelecekte özellikle konut sektöründe talebin hızla artacağını ve enerji üretim kapasitesinin bu talebin gerisinde kalabileceğini göstermiştir[36].

Farklı bir çalışmada Wu ve arkadaşları, kısa vadeli elektrik yük tahmininde hibrit bir yöntem önermiştir. Çalışmada RBF, RNN, FARIMA ve ICS + FARIMA modelleri kullanılmış; ICS algoritması, FARIMA'nın parametrelerini dinamik olarak optimize ederek modelin doğruluğunu artırmıştır. Gerçek tüketim verileri üzerinde yapılan karşılaştırmalar, ICS + FARIMA'nın diğer yöntemlere kıyasla daha yüksek doğruluk ve daha iyi hesaplama verimliliği sağladığını ortaya koymuştur[37].

Bununla birlikte Talaat ve arkadaşları, orta ve kısa vadeli yük tahminlerinde Çekirge optimizasyon algoritması (GOA) ile optimize edilmiş çok katmanlı ileri beslemeli sinir ağı (MFFNN) modeli geliştirmiştir. Farklı gün ve saat dilimlerine yönelik yük tahminlerinde yüksek doğruluk sağlanmış; özellikle sıcaklık verisinin eklenmesiyle mevsimsel farklılıkların başarılı şekilde yansıtıldığı rapor edilmiştir. GOA öncesine kıyasla optimizasyon sonrası sonuçlarda belirgin iyileşme elde edilmiştir[38].

Diğer taraftan Aly, akıllı şebekelerde (smart grid) kısa vadeli yük tahmini için kümeleme temelli hibrit modeller geliştirmiştir. Kalman filtresi (KF), dalgacık sinir ağı (WNN) ve ANN kombinasyonları kullanılarak tasarlanan altı model, benzer yük davranışlarını gruplayarak tahmin doğruluğunu artırmıştır. Mısır ve Kanada’da yapılan simülasyonlar, modelin farklı coğrafi koşullarda yüksek başarı gösterdiğini ortaya koymuştur[39].

Özer ve arkadaşları ise veri yetersizliğinin yarattığı kısıtları aşmak için çapraz korelasyona dayalı transfer öğrenimi yaklaşımı geliştirmiştir. Farklı bölgelerden toplanan veriler kullanılarak, tarihsel verisi sınırlı sistemlerde bile başarılı tahminler elde edilmiştir. Gerçek enerji sistemleri üzerinde yapılan uygulamalar, önerilen yöntemin sınırlı veri koşullarında etkili sonuçlar sunduğunu göstermektedir[40].

Ayrıca Muzaffar ve Afshari, LSTM sinir ağını kullanarak kısa vadeli yük tahmini gerçekleştirmiştir. Meteorolojik veriler (sıcaklık, nem, rüzgâr hızı) modele dahil edilmiş; farklı zaman ufuklarında (24 saat–30 gün) yapılan testlerde LSTM’nin geleneksel yöntemlerden daha yüksek doğruluk sağladığı görülmüştür[41].

Farklı bir çalışmada Sadaei ve arkadaşları, bulanık zaman serileri (FTS) ile CNN birleştirerek hibrit bir kısa dönemli tahmin modeli geliştirmiştir. Yük ve sıcaklık verilerinin bulanıklaştırılmış halleri çok kanallı görsellere dönüştürülerek CNN’e aktarılmış, bu sayede önemli özellikler otomatik olarak çıkarılmış ve aşırı öğrenme riski azaltılmıştır[42].

Buna ek olarak Fan ve arkadaşları, Ampirik Mod Ayırıştırma (EMD) ile çok amaçlı Derin İnanç Ağı’nı (DBN) birleştirerek kısa vadeli yük tahmini yapmıştır. EMD ile ayrıştırılan bileşenler, ayrı DBN modelleriyle işlenmiş hem denetimsiz ön eğitim hem de denetimli ince ayar aşamalarında çok amaçlı optimizasyon uygulanmıştır[43].

Öte yandan Dedinec ve arkadaşları, Makedonya elektrik sistemi için DBN tabanlı bir kısa vadeli yük tahmini modeli geliştirmiştir. 2008–2014 saatlik tüketim verileriyle eğitilen model, MEPSO tahminlerine göre MAPE’yi %8,6 ve günlük tepe yük hatasını %21 azaltmıştır[44].

Malekizadeh ve arkadaşları ise, Takagi–Sugeno–Kang tipi ensemble neuro-fuzzy modelini LOLIMOT yöntemi ile eğiterek STLTF gerçekleştirmiştir. Modelin topolojisi günlük değişen veri

özelliklerine uyum sağlayacak şekilde otomatik belirlenmiş, sıcaklık gibi ek verilerin entegrasyonu kolaylaştırılmış ve tahmin doğruluğu artırılmıştır[45].

Genel olarak incelenen literatür, güç sistemlerinde hem harmonik bozulma kestirimi hem de yük talebi tahmini konularında veri odaklı, YZ tabanlı ve hibrit yaklaşımların giderek ön plana çıktığını göstermektedir. Farklı coğrafi bölgelerden ve çalışma koşullarından elde edilen verilerin kullanılması, modellerin genellenebilirliğini ve farklı senaryolara uyum kabiliyetini artırmaktadır. Bunun yanında, meteorolojik, ekonomik ve operasyonel değişkenlerin modele entegre edilmesiyle kestirim doğruluğunun anlamlı biçimde iyileştiği görülmektedir. Yöntem çeşitliliği, klasik istatistiksel tekniklerden derin öğrenme mimarilerine kadar geniş bir yelpazeye yayılmakta; hibrit modeller ise bu iki yaklaşımın avantajlarını birleştirerek öne çıkmaktadır. Elde edilen bulgular, güç sistemlerinde karar destek mekanizmalarının geliştirilmesi, enerji yönetim stratejilerinin optimize edilmesi ve operasyonel güvenilirliğin artırılması açısından söz konusu tekniklerin yüksek potansiyele sahip olduğunu ortaya koymaktadır.

Bu tez çalışmasının ikinci bölümünde, elektrik güç sistemleri ele alınmış, harmoniklerin tanımı, etkileri ve klasik yöntemlerle gerçekleştirilen harmonik analizleri açıklanmış, daha sonra YZ destekli analiz yöntemlerine değinilmiştir.

Üçüncü bölümde, uygulama sistemi ayrıntılı olarak tanıtılmış ve çalışmada kullanılan veri setinin oluşturulma süreci sunulmuştur.

Dördüncü bölümde deneysel çalışmalar yer almakta olup, öncelikle YZ algoritmaları (RNN, LSTM, GRU ve Bahdanau dikkat mekanizması) tanıtılmış, daha sonra güç sisteminde ve aydınlatma tesislerinde harmonik kestirimine yönelik modelleme ve değerlendirmeler verilmiştir. Ayrıca bu bölümde, güç kestirimi üzerine yapılan uygulamalara da yer verilmiştir.

Beşinci ve son bölümde ise, sonuçlara ve önerilere yer verilmiştir.

2. ELEKTRİK GÜÇ SİSTEMLERİ

Genel anlamda elektrik güç sistemleri, özelde ise güç sistem analizi, elektrik şebekesinin planlama, işletme ve kontrol aşamalarında doğru kararlar alınabilmesi için uygulanan temel mühendislik disiplini. Bu analizler sayesinde sistemin gerilim, akım, güç ve frekans gibi temel parametreleri belirlenir; şebekenin güvenliği, kararlılığı ve verimliliği değerlendirilebilir. Özellikle dağıtım şebekelerinde bu analizler, artan yük çeşitliliği, reaktif güç dengesizlikleri ve güç kalitesi problemleri nedeniyle daha karmaşık bir yapıya bürünmüştür.

Günümüzde özellikle orta gerilim seviyesindeki dağıtım şebekeleri, üretim ve tüketimin çift yönlü hâle gelmesi, evirici tabanlı üreticilerin yaygınlaşması ve enerji depolama sistemlerinin entegrasyonu nedeniyle hem yük akışı hem de harmonik analiz açısından daha detaylı değerlendirmeleri zorunlu kılmaktadır. Bu karmaşıklık, klasik analitik modellerin ötesinde yeni yaklaşımların geliştirilmesini gerekli kılmaktadır.

Güç sistem analizi genel olarak aşağıdaki temel kategorilerde incelenir:

Yük akış (power flow) analizi: Gerilim profilleri, güç akımları ve hat kayıplarının belirlenmesini sağlar. Normal işletme koşulları altında şebekenin nasıl çalıştığını modellemek için kullanılır.

Kısa devre (fault) analizi: Şebekede oluşabilecek arıza durumlarında gerilim ve akım değerlerinin ani değişimini inceler. Koruma sistemlerinin doğru seçimi ve koordinasyonu için temel teşkil eder.

Kararlılık (stability) analizi: Sistemin ani yük değişimlerine, arızalara veya rejim dışı durumlara nasıl tepki verdiğini analiz eder.

Harmonik analiz: Doğrusal olmayan yüklerin neden olduğu harmonik bozulmaların şebeke üzerindeki etkilerini inceler.

Elektrik güç sistemlerinin analizinde kullanılan klasik yöntemler, sistemin kararlı durum davranışlarını modellemek ve çözümlmek amacıyla uzun yıllardır güvenle uygulanan sayısal tekniklerdir. Bu yöntemlerin temel amacı; sistemdeki her düğümün gerilim genliğini ve açısını belirlemek, hat kayıplarını hesaplamak ve şebekenin mevcut veya planlanan işletme koşulları altında kararlı çalışıp çalışamayacağını değerlendirmektir. Klasik yük akışı analizlerinde yaygın olarak kullanılan iki temel yaklaşım Gauss–Seidel ve Newton–Raphson yöntemleridir[46].

Gauss–Seidel yöntemi, doğrusal olmayan yük akışı denklemlerinin iteratif olarak çözülmesine dayanan ve özellikle küçük sistemlerde yaygın şekilde kullanılan bir yöntem. Bu yöntemin kökeni Gauss ve Seidel'in 19. yüzyılda geliştirdiği doğrusal denklem çözümleme

algoritmasına dayanır. Elektrik mühendisliğinde bu yöntem, Newton–Raphson yöntemine kıyasla daha az hesaplama gerektirmesi nedeniyle başlangıç seviyesindeki analizlerde tercih edilir [46].

Newton–Raphson yöntemi ise çok değişkenli doğrusal olmayan sistemlerin çözümüne uygun yapıdadır ve yük akışı analizlerinde oldukça yaygın olarak kullanılır. Gerilim genlikleri ve açıları üzerinde doğrusal olmayan etkiye sahip olan güç denklemlerini çözümlmek için yüksek doğruluk ve hızlı yakınsama avantajları sunar [46].

Bu yöntemlerin geliştirilme süreci, güç sistemlerinin önce iletim seviyesinde modellenmesi ve ardından dağıtım sistemlerinin analizine doğru evrilmesiyle birlikte olmuştur. Özellikle bilgisayarların mühendislik uygulamalarına entegrasyonu ile birlikte, bu sayısal tekniklerin yaygın kullanımı mümkün hale gelmiştir. Günümüzde halen şebeke planlama yazılımlarının büyük çoğunluğunda bu klasik yöntemlerin alt yapısı kullanılmaktadır. Ancak, dağıtım sistemlerinin karmaşıklığının artması, dağıtılmış üretim kaynaklarının çoğalması ve yük profillerinin daha dinamik hale gelmesi gibi gelişmeler, bu yöntemlerin sınırlılıklarını da beraberinde getirmiştir.

Güç sistemleri için yapılan klasik harmonik analizleri, gerilim ve akım gibi elektriksel büyüklüklerde görülen sinüzoidal olmayan dalga şekillerinin, temel frekans ve katlarından oluşan harmonik bileşenlerine ayrılması esasına dayanır. Bu amaçla en yaygın olarak Fourier dönüşümü ve onun sayısal uygulamaları olan DFT ile FFT yöntemleri kullanılır. Analiz sürecinde, ölçülen sinyallerin periyodik olduğu varsayılır ve bu sayede her bir harmonik bileşenin genliği, faz açısı ve frekansı ayrıntılı şekilde belirlenir. Bu yöntemlerin teorik temelleri bir alt başlıkta ele alınacaktır.

2.1. Harmonikler

Elektrik güç sistemlerinde ideal gerilim ve akım dalga şekilleri sinüzoidal olmalıdır. Ancak, şebekeye bağlanan bazı yüklerin doğası gereği, bu dalga şekli bozulur ve içerisinde temel frekans dışında başka frekans bileşenleri de oluşur. Bu istenmeyen frekans bileşenlerine harmonik adı verilir.


Harmonikler, temel frekansın (Türkiye'de 50 Hz) tam katları olacak şekilde oluşan sinüzoidal bileşenlerdir. Bir başka deyişle, bir sinyali oluşturan 50 Hz, 100 Hz, 150 Hz gibi bileşenlerden her biri birer harmoniktir. Bir periyodik sinyal, temel frekans bileşeni ve bunun tam katları olan harmoniklerin toplamı şeklinde tanımlanabilir ve matematiksel olarak eşitlik (1)'de gösterildiği gibi ifade edilebilir[47]

$$x(t) = a_0 + \sum_{n=1}^{\infty} [a_n \cos(n\omega_0 t) + b_n \sin(n\omega_0 t)] \quad (1)$$

Burada:

- n : harmonik mertebesi (1: temel bileşen, 2: ikinci harmonik vb.)
- $\omega_0 = 2\pi f_0$: temel açısal frekans (rad/s)
- b_n : sinyalin harmonik genlik katsayılarıdır.

Güç sistemlerinde en yaygın olarak görülen harmonikler tek sayı harmoniklerdir (3., 5., 7. vb.). Özellikle 3'ün katları olan harmonikler (örneğin 3., 9., 15.), nötr hatlarda birikerek kablolarda aşırı ısınmaya ve sistem dengesizliklerine neden olabilir. Şekil 2-1'de farklı harmonik bileşenlerin gerilim dalga şekline etkisini göstermektedir.



Şekil 2-1: Farklı harmonik bileşenlerin temel bileşene etkileri

2.1.1. Harmonikli Büyüklüklerin Tanımı

Bu büyüklükler enerji kalitesi ile ilgili büyüklüklerdir. Değerleri ne kadar küçük olursa, enerji tesislerindeki akım ve gerilim değeri sinüs eğrisine daha yakın olur. Saf sinüs eğrisi durumunda harmonik bulunmayacağından, harmoniklerin değeri matematiksel olarak sıfır olacağından bu büyüklüklerin değeri de sıfır olur.

2.1.1.1. Toplam Harmonik Distorsiyonu

Harmonik bileşenlerin temel bileşene göre seviyesini belirlemek için kullanılır. Harmonik bozulmanın derecesini belirtir. Hem gerilim hem de akım için verilebilir. Gerilim için

$$THD_V = \frac{1}{V_1} \left(\sum_{n=2}^{\infty} V_n^2 \right)^{1/2} \quad (2)$$

şeklinde ifade edilir. Akım toplam harmonik distorsiyonu

$$THD_I = \frac{1}{I_1} \left(\sum_{n=2}^{\infty} I_n^2 \right)^{1/2} \quad (3)$$

şeklindedir.

IEE 519 standartlarına göre bu büyüklükler için sınır değerleri Tablo 2-1 ve Tablo 2-2’de verilmiştir[48].

Tablo 2-1: Ortak bağlantı noktasında bireysel harmoniklerin ve toplam harmonik bozulmanın (THDV) üst sınırı

Bus Voltaj Seviyesi (V)	Maks. Tekil Harmonik (%)	Maks. THDV (%)
≤ 1 kV	5.0	8.0
1–69 kV	3.0	5.0
69–161 kV	1.5	2.5
> 161 kV	1.0	1.5 (2.0)

Tablo 2-2: 120 V–69 kV arası sistemlerde akım harmoniklerinin maksimum sınırları

ISC/IL Aralığı	$3 \leq h < 11$	$11 \leq h < 17$	$17 \leq h < 23$	$23 \leq h < 35$	$35 \leq h \leq 50$	TDD (%)
< 20	4.0 %	2.0 %	1.5 %	0.6 %	0.3 %	5.0
20–50	7.0 %	3.5 %	2.5 %	1.0 %	0.5 %	8.0
50–100	10 %	4.5 %	4.0 %	1.5 %	0.7 %	12.0
100–1000	12 %	5.5 %	5.0 %	2.0 %	1.0 %	15.0
> 1000	15 %	7.0 %	6.0 %	2.5 %	1.4 %	20.0

2.1.1.2. Distorsiyon Faktörü

Gerilim ve akımın harmonik içermesi halinde efektif değerlerini bulmak için kullanılır. Gerilim için:

$$DF_V = \frac{1}{V} \left(\sum_{n=2}^{\infty} V_n^2 \right)^{1/2} \quad (4)$$

Akım için:

$$DF_I = \frac{1}{I} \left(\sum_{n=2}^{\infty} I_n^2 \right)^{1/2} \quad (5)$$

olarak ifade edilir.

2.1.1.3. Tepe Faktörü (Crest factor, CF)

CF, sinüsoidal olmayan işaretin tepe değeri ile temel bileşenin efektif değeri arasında tanımlanır. Harmonik bileşenlerin ortaya konmasını sağlar.

$$CF = \frac{\text{dalga anı tepedeğeri}}{\text{dalga anı efektifdeğeri}} \quad (6)$$

İfadesi ile belirtilir.

2.1.1.4. K-Faktörü

Kuru tip transformatörlerin K faktörü, nonlinear yüklenen ve genellikle 500KVA' nın altındaki transformatörlerde yüklenme kapasitesinin bir ölçütüdür. Bu faktör imalatçılar tarafından belirtilir. K-Faktörü

$$K_{\text{faktörü}} = \sum_{n=1}^{\infty} I_n^2 (pu) n^2 \quad (7)$$

olarak ifade edilir. Burada I_n birim değer (pu) t olarak transformatörün akım bileşenidir.

2.1.1.5. Harmonik Faktörü

Her harmonik bileşenin seviyesini belirlemede kullanılır. Örneğin akım için,

$$HF_I = \frac{I_n}{I_1} \quad (8)$$

I_n = n. harmonik akımına aitefektif değeri, I_1 akımının temel bileşeninin efektif değerini göstermektedir.

2.1.1.6. Toplam Harmonik Faktörü

Çekilen yük akımına ait distorsiyonu belirlemede kullanılır. Toplam harmonik distorsiyonu (THD)

$$THD = \frac{(\sum_{n=2}^{\infty} I_n^2)^{1/2}}{I_L} \quad (9)$$

ile belirtilir. Burada I_n harmonik akımını, I_L ise 12 ay boyunca talep edilen maksimum akımların matematiksel ortalamasını göstermektedir.

2.1.2. Klasik Yöntemlerle Harmonik Analizi

Harmonikler, güç sistemlerinde temel frekansın (örneğin 50 Hz) tam katları şeklinde oluşan sinüzoidal bileşenlerdir[48], [49]. Temel dalga şekline eklenerek toplam dalga formunu bozarlar ve bu durum, gerilim ve akımın ideal sinüzoidal formdan sapmasına neden olur[49]. Harmonikler genellikle doğrusal olmayan yükler, yarı iletken anahtarlama güç elektroniği devreleri ve çeşitli endüstriyel ekipmanlar tarafından üretilir.

Güç sistemlerinde harmonik analiz, güç kalitesini değerlendirme ve sistem kararlılığını koruma açısından kritik öneme sahiptir[48]. Bu bileşenler, temel frekansın katları şeklinde ortaya çıkarak gerilim ve akım dalga şekillerini bozar. Bu bozulmalar, iletim ve dağıtım hatlarında ek ısınma, transformatörlerde kayıp artışı, koruma sistemlerinde yanlış tetiklemeler ve haberleşme hatlarında parazit gibi olumsuz etkilere yol açar. Harmonik analiz çalışmaları, bu bozulmaların seviyesini ve kaynaklarını belirleyerek, gerekli kompanzasyon ve filtreleme çözümlerinin tasarlanmasını sağlar [50], [51].

2.1.2.1. Fourier Dönüşümü

Bir $f(t)$ fonksiyonunun fourier dönüşümü,

$$F(w) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt \quad (10)$$

$$f(t) = F_{\max} \sin(2\pi ft + \theta) \quad (11)$$

biçiminde tanımlanır ve $F(w)$, ters fourier dönüşümü,

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(w) e^{-j\omega t} dt \quad (12)$$

olarak tanımlanır. Fourier dönüşümünün en önemli avantajı, bir fonksiyonu veya dalga şeklini hem zaman hem de frekans alanında inceleme imkânı sunmasıdır.

Periyodik fakat sinüzoidal olmayan dalgaların frekans spektrumunun elde edilmesinde, frekans alanı analizinde yaygın olarak DFT ve onun hesaplama verimliliği artırılmış biçimi olan FFT kullanılmaktadır.

2.1.2.2. Ayrık Fourier Dönüşümü (DFT)

Zaman alanındaki fonksiyon ile frekans alanındaki spektrum, her periyotta N adet örnekleme ile periyodik olarak elde edildiğinde, (13) ve (14) numaralı eşitlikler DFT çifti olarak tanımlanır ve aşağıdaki gibi ifade edilir:

$$F(k\Delta\Omega) = \sum f(n\Delta T) e^{\frac{-j2\pi kn}{N}} \quad (13)$$

$$F(n\Delta T) = \sum f(k\Delta\Omega) e^{\frac{-j2\pi kn}{N}} \quad (14)$$

Burada $k, n=0,1,...,N-1$, $\Delta\Omega=\frac{2\pi}{\Delta T}$ ve $\Delta T = \frac{T}{N}$. Ölçüm verileri daima örnekleme zaman fonksiyonu biçiminde elde edilebildiğinden, harmonik ölçümlerinde DFT yöntemi yaygın olarak kullanılmaktadır. Örnekleme zaman fonksiyonu ise, sürekliliği sınırlı bir büyüklüğün sabit zaman aralıklarına bölünmesiyle elde edilen zaman alanı serisi şeklinde tanımlanmaktadır [52].

2.1.2.3. Hızlı Fourier Dönüşümü (FFT)

FFT, DFT'nin hesaplama sürecini daha verimli hale getirmek ve işlem hızını artırmak amacıyla geliştirilmiş sayısal bir algoritmadır. Bu yöntemde $W=e^{\frac{-j2\pi}{N}}$ tanımı yapılarak elde edilen

$[W^{kn}]$ matrisindeki elemanların benzerliklerinden yararlanılır. FFT algoritmasının uygulanabilmesi için örnek sayısının ikinin tam kuvveti şeklinde olması gerekir; başka bir ifadeyle, dalga'nın periyodu bu koşulu sağladığında yöntem etkin biçimde kullanılabilir. Bu sayede işlem karmaşıklığı ($N\log_2(N)$) mertebesine düşürülerek önemli bir hesaplama avantajı sağlanır.

FFT çözümü, belirli bir matematiksel algoritmaya dayanmakta olup, bu algoritmanın uygulanma sırası büyük önem taşımaktadır. Hesaplama sürecindeki her bir adım “kelebek” (butterfly) işlemi olarak adlandırılmakta ve bu işlemler özel entegre devreler aracılığıyla donanımsal olarak da gerçekleştirilebilmektedir. FFT'nin yanı sıra, Chirp-Z dönüşümü, Nyquist frekansı ve pencere fonksiyonları gibi yöntemler de farklı örnekleme ve dönüşüm işlemlerinde kullanılabilmektedir. Bu tür algoritmalarından yararlanılarak harmonik analiz ve spektrum çözümlemesi için çeşitli paket yazılımlar geliştirilmiştir[52].

Klasik harmonik analiz yöntemleri, frekans bileşenlerinin doğru şekilde belirlenmesinde uzun yıllar boyunca güvenilir çözümler sunmuş olsa da, bu yöntemler genellikle durağan ve periyodik sinyaller için yüksek doğruluk sağlar. Modern güç sistemlerinde ise yük profillerinin değişkenliği, yenilenebilir enerji kaynaklarının entegrasyonu ve güç elektroniği tabanlı ekipmanların yaygınlaşması, harmonik bozulmaların zamanla değişen ve karmaşık bir yapıya bürünmesine neden olmuştur. Bu durum, geleneksel yöntemlerin tek başına yetersiz kalabildiği ve daha esnek, uyarlanabilir analiz tekniklerine ihtiyaç duyulduğu anlamına gelmektedir. Son yıllarda, makine öğrenmesi ve derin öğrenme gibi YZ tabanlı yaklaşımlar, harmonik tahmini ve güç kalitesi analizi alanında önemli bir alternatif olarak öne çıkmıştır.

2.2. Yapay Zekâ Destekli Analiz Yöntemleri

Elektrik güç sistemlerinin giderek daha karmaşık, değişken ve dinamik hale gelmesi; klasik analiz yöntemlerinin bazı durumlarda yetersiz kalmasına yol açmaktadır. Özellikle dağıtım seviyesinde karşılaşılan doğrusal olmayan yük davranışları, değişken reaktif güç akışları, harmonik bozulmalar ve ani üretim-tüketim dengesizlikleri, klasik algoritmaların doğruluğunu ve yakınsama başarısını olumsuz etkileyebilmektedir. Bu nedenlerle, son yıllarda YZ destekli yöntemler güç sistem analizlerinde alternatif ve tamamlayıcı bir yaklaşım olarak öne çıkmaktadır.

YZ destekli analiz yöntemleri, özellikle makine öğrenmesi (ML) ve derin öğrenme (DL) temelli modellerle güç sistemlerindeki karmaşık ilişkileri öğrenebilen, zamana bağlı davranışları

analiz edebilen ve öngörü kabiliyeti yüksek çözümler sunabilen sistemlerdir. Bu yöntemler, çok sayıda ölçüm noktasından gelen büyük veri setleri üzerinde çalışarak; yük talebi tahmini, harmonik tahmini, gerilim profili analizi gibi kritik görevleri gerçekleştirmede başarılı sonuçlar üretmektedir.

YZ tabanlı modeller, klasik algoritmalardan farklı olarak sistemin matematiksel denklem formuna doğrudan ihtiyaç duymaz. Bunun yerine, geçmiş verilere dayalı olarak örüntü öğrenme ve çıkarım yapma kabiliyeti ile çalışırlar. Bu sayede çok sayıda değişkenin etkisini içeren karmaşık sistem davranışlarını öğrenebilir ve genel model kurallarını otomatik olarak çıkarabilirler.

Güç sistemlerinde yaygın olarak kullanılan YZ yöntemleri, sistemin yapısal karmaşıklığına ve veri tipine göre çeşitlilik göstermektedir. Özellikle zaman serisi veriler, doğrusal olmayan ilişkiler ve büyük veri boyutları göz önüne alındığında, her bir yöntemin avantaj sağladığı belirli alanlar bulunmaktadır.

Güç sistemlerinde yaygın olarak kullanılan YZ yöntemleri arasında; ANN, Karar Ağaçları, Destek Vektör Makineleri (SVM), K-En Yakın Komşu (k-NN), Gradyan Takip Tabanlı Öğrenme Yöntemleri, RNN, LSTM ve GRU gibi mimariler yer almaktadır. Özellikle zaman serisi verileri ile çalışan RNN, LSTM ve GRU gibi derin öğrenme modelleri, dağıtım şebekesi gibi zamanla değişen sistemlerde oldukça başarılı tahmin sonuçları vermektedir.

Bu yöntemler güç sistem analizi özelinde doğrudan uygulanmasa da yük profili tahmini, harmonik bileşen öngörüsü, gerilim saptaması kestirimi gibi klasik yöntemlerle çözülemeyen problemleri modellemek amacıyla kullanılmaktadır. Örneğin, klasik yöntemlerde anlık sistem verisiyle iteratif çözüm gerçekleştirilirken, YZ destekli modeller gelecekteki sistem davranışlarını öğrenebilir; bu da şebeke yönetiminde proaktif kararların alınmasına olanak tanır.

2.2.1. Yapay Sinir Ağları (ANN)

ANN'ler çok katmanlı yapıları sayesinde doğrusal olmayan ilişkileri öğrenmede oldukça başarılıdır. Genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Sinir hücreleri (nöronlar), ağırlıklı bağlantılar aracılığıyla veri iletimini sağlar. Aktivasyon fonksiyonları yardımıyla karmaşık örüntüler tanınabilir. Elektrik sistemlerinde yük profili tahmini,

gerilim düşümü kestirimi ve reaktif güç kompanzasyonu uygulamalarında başarıyla kullanılmaktadır.

2.2.2. Karar Ağaçları

Karar ağaçları, veriyi sınıflandırmak için dallanma temelli kurallar üreten YZ algoritmalarıdır. Her dal, bir özelliğe göre yapılan ayrımı temsil eder ve yapraklar kararları içerir. Şebekede arıza sınıflandırması, yük tipi belirleme, gerilim seviyesine göre davranış analizi gibi uygulamalarda özellikle yorumlanabilir yapıları sayesinde tercih edilir. Ancak, karmaşık problemler için tek başına sınırlı kalabilirler.

2.2.3. Destek Vektör Makineleri (SVM)

SVM, verileri sınıflandırmak ya da regresyon yapmak amacıyla yüksek boyutlu uzaylara dönüştürür ve bu uzayda maksimum ayrım yapan hiper düzlemi bulur. Güç sistemlerinde harmonik tür tanıma, bozulma sınıflandırması, yük tipine göre reaktif davranış analizi gibi alanlarda kullanılır. Küçük ve orta ölçekli veri kümelerinde yüksek başarı oranı gösterir.

2.2.4. K-En Yakın Komşu (k-NN)

Bu yöntem, sınıflandırılacak bir verinin en yakın komşularına (örneğin en yakın 3-5 veri noktasına) göre etiketlenmesini sağlar. Özellikle örüntü tanıma ve geçmiş verilerle benzerlik temelli karar sistemlerinde etkilidir. Yük profili benzeşimleri, arıza örüntüsü eşleştirmeleri, gerilim şekil sınıflandırmaları gibi uygulamalarda kullanılır. Fakat büyük veri kümelerinde işlem süresi artabilir.

2.2.5. Gradyan Takip Tabanlı Öğrenme Yöntemleri

Bu yöntemler, kayıp fonksiyonunu minimize etmek için gradyan inişi temelli optimizasyon tekniklerini kullanır. Özellikle yapay sinir ağlarının eğitilmesinde geri yayılım (backpropagation) algoritması gradyan takibi ile çalışır. LSTM, CNN ve diğer derin öğrenme modellerinin temel eğitim yaklaşımı bu gruba girer. Doğru hiperparametre ayarı yapıldığında yüksek doğrulukla çalışır.

2.2.6. Tekrarlayan Sinir Ağı (RNN)

RNN'ler, zaman serisi verilerle çalışmak üzere geliştirilmiş yapay sinir ağlarıdır. Geri besleme döngüsü sayesinde, bir zaman adımındaki çıktısı bir sonraki adımın girdisi olarak kullanılır. Bu özellik, geçmiş bilginin öğrenilmesini sağlar. Ancak, klasik RNN'ler zaman ilerledikçe bilgiyi unutma (gradyan sönümlenmesi) eğilimindedir. Kısa vadeli yük tahmini, frekans salınımı öngörüsü gibi zaman bağımlı görevlerde kullanılır.

2.2.7. Uzun Kısa Süreli Bellek Ağı (LSTM)

LSTM modelleri, RNN'lerde yaşanan bilgi kaybı sorununu çözmek için geliştirilmiştir. Giriş, unutma ve çıkış kapılarından oluşan özel bir hücre yapısı sayesinde uzun vadeli ilişkileri koruyabilir. Bu yapı, yük talebinin gün içindeki değişimlerine, hafta sonu/hafta içi farklarına veya sezonluk yük davranışlarına duyarlı tahminler yapılmasına olanak tanır. Enerji talep tahmini, harmonik kestirimi, gerilim dalgalanması analizi gibi alanlarda çok yüksek doğruluk sunar.

2.2.8. Kapılı Tekrarlayan Ünite (GRU)

GRU, LSTM'in sadeleştirilmiş halidir. Yalnızca iki kapı (güncelleme ve sıfırlama kapısı) içerir. Daha az parametreye sahip olduğundan eğitim süresi daha kısadır. Küçük veri setlerinde ve

kısa dönemli zaman serilerinde LSTM kadar başarılı sonuçlar verir. Kısa dönem yük tahmini, geçici bozulma tespiti, voltaj değişim analizi gibi görevlerde kullanılır.

Yöntemlerin güçlü ve zayıf yönleri Tablo 2-3’de verilmiştir.

Tablo 2-3: Karşılaştırma tablosu

Yöntem	Yapı Özeti	Güçlü Olduğu Alanlar	Zayıf Yanları
ANN	Çok katmanlı, ileri beslemeli	Yük tahmini, gerilim seviyesi analizi	Zaman serisi modelleme zayıf
Decision Tree	Kurallara dayalı dallanma yapısı	Arıza sınıflandırma, yorumlanabilirlik	Overfitting, düşük genelleme
SVM	Hiper düzlemle ayırıcı model	Harmonik sınıflandırma, yük tipi tanıma	Büyük veri kümelerinde yavaş
k-NN	Komşu veriye göre sınıflandırma	Yük profili benzeşimleri	Hafıza gereksinimi yüksek
RNN	Geri beslemeli döngüsel yapı	Zaman serisi analizi (kısa vadeli)	Uzun dönem bağımlılığı zayıf
LSTM	Kapılı bellek hücreleri	Uzun dönemli zaman serileri, yük tahmini	Eğitim süresi uzun, parametre karmaşık
GRU	LSTM'in sade hali	Kısa dönem tahminler, hızlı eğitim	Uzun dönem performansı LSTM'den düşük

3. UYGULAMA SİSTEMİ

Bu tez çalışmasında, YZ destekli analizlerin uygulanacağı dağıtım sistemi olarak Vangözü EDAŞ sorumluluk sahasında bulunan Tatvan TM (Trafo Merkezi) çıkışlı Fider-5 seçilmiştir. Bu fider hem yük profili çeşitliliği hem de güç kalitesi parametrelerinin değerlendirilmesi açısından uygun bir örneklem sunmaktadır.

Tatvan TM çıkışlı OG fideri üzerinde, dağıtım şebekesine ait farklı zamanlarda elde edilen veriler güç kalitesi analizi için kullanılmıştır. Ölçümler, belirli bir zaman aralığında sürekli veri kaydı yapabilen analizör cihazları aracılığıyla alınmış ve sonrasında YZ algoritmaları ile değerlendirilmek üzere işlenmiştir.

Bu uygulama sisteminin seçilme nedenleri aşağıda özetlenmiştir:


- Gerçek saha verisi kullanımı: Geliştirilen kestirim modellerinin teorik değil, uygulamaya dönük ve gerçek verilerle test edilmesini sağlar.
- OG seviyesinde çalışma: Dağıtım sistemlerinde harmonik etkilerin yoğunlaştığı orta gerilim düzeyinde yapılan analizler, enerji kalitesi açısından daha gerçekçi sonuçlar üretir.
- Veri sürekliliği: İlgili fiderde uzun dönemli ve düzenli ölçüm yapılabilmüş, bu da zaman temelli modelleme için uygun bir altyapı sağlamıştır.
- Karmaşık yük yapısı: Fiderde konut, ticarethane, sanayi tesisleri, hastane gibi farklı yük türlerinin bulunması, sistemin hem sürekli hem de geçici bozulmalara açık olmasına neden olur. Özellikle gece saatlerinde devreye giren sokak ve yol aydınlatmaları, yük profiline zamana bağlı ek harmonikler oluşturur ve analiz derinliğini artırır.

Bu sistemden elde edilen veriler, bir sonraki bölümde detaylandırılacak olan veri seti oluşturma süreci ile işlenmiş ve YZ algoritmalarına giriş olarak hazırlanmıştır. Böylece yalnızca harmonik bozulmaların değil, aynı zamanda zamanla değişen yük talebinin kestirimi de hedeflenmiştir. Tablo 3-1’de Fider-5 üzerindeki yük profili verilmiş olup Şekil 3-1’de fidere ait enerji akış yönü gösterilmiştir.

Tablo 3-1: Fider-5 üzerindeki yük profili

MERKEZ_ADİ	GÜCÜ (kVA)	CİNSİ
ONGEN ISI SAC KESME TR	100	TRP
ATATURK LİSESİ TR	160	TRP
TR32 KOK	250	BİNA İCİ
TR31 (40)	630	BİNA İCİ
TR26/41) KOK	400	BİNA İCİ
TR (19) KOK	400	BİNA İCİ
TR1 KOK	250	BİNA İCİ
TR 2 KOK	400	BİNA İCİ
9+1 KOK	250	BİNA İCİ
ATATURK LİSESİ KOK	400	BİNA İCİ
BİZİM MARKET KOK	160	BİNA İCİ
İSLETME TR62	160	TRP
TR61/1(SELAHATTIN EYYUBU	630	BİNA İCİ
TR55(22)	400	TRP
TATVAN AVİM KOK	1000	BİNA İCİ
TATVAN AVİM KOK	1000	BİNA İCİ
ATATURK LİSESİ KOK	400	BİNA İCİ
DOĞUM EVİ HASTAHANESİ KOK	400	BİNA İCİ
DDY KOK	160	BİNA İCİ
MELEKADRI KOK	630	BİNA İCİ
TR25-60 KOK	630	BİNA İCİ
TR23- KOK	1000	BİNA İCİ
KARKACTR69KOK	400	BİNA İCİ
SANAYİ KOK 1	630	BİNA İCİ
DOĞUM EVİ KOK	630	BİNA İCİ
SANAYİ KOK 3	400	BİNA İCİ
SANAYİ TR 2	400	TRP
GENCLİK MERKEZİ KOK	250	BİNA İCİ
MAHMUT SİRİNGÜL (OZSARK METAL) TR	100	TRP
BAHCELİEVLER TR 42	400	TRP
İMKB OKUL TR 47/1	250	TRP
SİRİNEVLER TR 43	250	TRP
METİN DEMİREL TR	100	TRP
AYDAR VE BASAR TEKSTİL TR	160	TRP
TR1+1	400	TRP
CEPKİ TR	250	TRP

TR 4	400	TRP
PINARBASI TR 48	250	TRP
PINARBASI TR11	250	TRP
3+1 KOK	400	BINA ICI
TR 3	400	TRP
TATVAN BELEDIYESI ICME SUYU TR	160	TRP
OGRETMEN EVI KOK	630	BINA ICI
TR-24 AVM KOK	1250	BINA ICI
TR-32/1 STAD YANI TR	1000	BINA ICI
MIGROS KOK	400	BINA ICI
DEVLET HASTANESI TR	1000	BINA ICI
METIN SUNGUR TR	160	TRP
O.EVI KOK	630	BINA ICI
TOPLAM	21360	



Şekil 3-1: Fider-5'e ait CBS enerji akış yönü

3.1. Veri Setinin Oluřturulması

Bu alıřmada kullanılan veri seti, Tatvan TM'ye baėlı Fider-5 üzerinde gerekleřtirilen saha lmlerine dayanmaktadır. İlgili fider, Tatvan Kk Sanayi Sitesi, Devlet Hastanesi ve řehir merkezi gibi farklı trde yklerin beslendiėi, karmařık ve dinamik yapıya sahip bir daėıtım hattıdır. Bu yapı hem harmonik etkilerin hem de yk profilinin deėiřkenliėinin incelenmesine olanak tanımaktadır.

Veriler, ENTES marka analizr aracılıėıyla toplanmıř ve analizrn sunduėu kayıtlar Entbus Pro yazılımı zerinden alınarak yapılandırılmıřtır. lmler, 01.07.2023 – 24.04.2024 tarihleri arasında, her 5 dakikada bir olacak řekilde yapılmıřtır. Bylece yaklaşık 10 aylık zaman dilimini kapsayan yksek znrlkl bir zaman serisi veri seti oluřturulmuřtur.

Veri seti ařaėıdaki parametreleri iermektedir:

- Her bir faz iin Gerilim Toplam Harmonik Bozulması (THDV) [%]
- Her bir faz iin Akım Toplam Harmonik Bozulması (THDI) [%]
- Fiderden ekilen  faz toplam aktif g (P) [kW]
- Fiderden ekilen  faz toplam reaktif g (Q) [kVAr]
- Fazlar arası gerilim (VL31, VL23, VL12) [kV]

Tm lmler zaman bilgisiyle eřleřtirilmıř olup, analiz ncesi veri temizleme, zaman senkronizasyonu ve eksik veri kontrol gibi n iřleme adımları gerekleřtirilmıřtir.

Elde edilen bu veri seti, 4. blmde ayrıntılarıyla sunulacak olan YZ algoritmaları iin giriř verisi olarak kullanılmıř hem harmonik bozulmaların hem de yk profilinin zaman serisi kestirimi amacıyla deėerlendirilmıřtir. Tablo 3-2'de veri setinin bir blm gsterilmıřtir.

Tablo 3-2: Veri setinin bir bölümü

Tarih	THD_I1	THD_I2	THD_I3	THD_V1	THD_V2	THD_V3	TW	VL31	VL23	VL12	TVar
1.07.2023 00:01	4,9	5,4	5,8	1,2	1,2	1,1	4.197.600,00	32.142,00	32.472,00	32.406,00	198.000,00
1.07.2023 00:06	4,8	4,8	5,6	1,2	1,2	1,2	4.197.600,00	32.208,00	32.472,00	32.505,00	198.000,00
1.07.2023 00:11	5,2	5,3	5,8	1,2	1,2	1,1	4.039.200,00	32.175,00	32.472,00	32.439,00	158.400,00
1.07.2023 00:17	5,1	5,4	5,9	1,2	1,2	1,2	4.078.800,00	32.274,00	32.604,00	32.505,00	158.400,00
1.07.2023 00:22	5,5	5,5	6,1	1,1	1,2	1,1	3.999.600,00	32.241,00	32.604,00	32.505,00	158.400,00
1.07.2023 00:27	5,8	5,8	6,2	1,1	1,2	1,1	3.999.600,00	32.241,00	32.604,00	32.538,00	198.000,00
1.07.2023 00:32	5,8	5,9	6,2	1,1	1,2	1,2	3.960.000,00	32.274,00	32.604,00	32.538,00	158.400,00
1.07.2023 00:37	6	6,1	6,5	1,2	1,2	1,1	3.880.800,00	32.340,00	32.604,00	32.637,00	118.800,00
1.07.2023 00:42	6	6	6,4	1,2	1,3	1,2	3.841.200,00	32.340,00	32.604,00	32.604,00	158.400,00
1.07.2023 00:47	5,9	6,1	6,4	1,1	1,3	1,2	3.801.600,00	32.373,00	32.670,00	32.637,00	158.400,00
1.07.2023 00:52	6,2	6,3	6,6	1,1	1,2	1,1	3.801.600,00	32.373,00	32.637,00	32.670,00	158.400,00
1.07.2023 01:01	6,3	6,4	6,6	1,1	1,2	1,1	3.722.400,00	32.373,00	32.703,00	32.670,00	118.800,00
1.07.2023 01:06	5,7	6,1	6,6	1,1	1,2	1,1	3.722.400,00	32.373,00	32.703,00	32.670,00	158.400,00
1.07.2023 01:11	6,3	6,7	7,1	1,2	1,2	1,2	3.643.200,00	32.505,00	32.802,00	32.769,00	158.400,00
1.07.2023 01:16	6,6	6,8	7,2	1,2	1,2	1,1	3.603.600,00	32.505,00	32.802,00	32.802,00	158.400,00
1.07.2023 01:21	6,5	6,7	7	1,1	1,2	1	3.564.000,00	32.505,00	32.835,00	32.802,00	158.400,00
1.07.2023 01:26	6,7	7	7,2	1,1	1,2	1,1	3.564.000,00	32.538,00	32.868,00	32.802,00	158.400,00
1.07.2023 01:31	7,1	7	7,6	1,3	1,2	1,2	3.445.200,00	32.505,00	32.868,00	32.802,00	158.400,00
1.07.2023 01:36	6,9	7	7,4	1,2	1,2	1,1	3.445.200,00	32.538,00	32.868,00	32.802,00	158.400,00
1.07.2023 01:41	7	7,1	7,5	1,1	1,3	1	3.445.200,00	32.538,00	32.901,00	32.835,00	158.400,00
1.07.2023 01:46	7	7,5	7,8	1,1	1,2	1	3.366.000,00	32.571,00	32.901,00	32.868,00	118.800,00
1.07.2023 01:51	7,7	8,5	8,9	1,3	1,2	1,1	3.326.400,00	32.670,00	32.967,00	32.967,00	158.400,00
1.07.2023 01:56	7,2	7,7	8,3	1,2	1,2	1,1	3.366.000,00	32.670,00	32.967,00	32.967,00	198.000,00
1.07.2023 02:03	7,6	8,4	8,9	1,2	1,2	1,1	3.326.400,00	32.769,00	33.066,00	33.033,00	198.000,00
1.07.2023 02:08	7,6	8,3	9	1,2	1,2	1,1	3.247.200,00	32.736,00	33.066,00	33.033,00	198.000,00
1.07.2023 02:13	7,9	8,6	9,1	1,2	1,3	1,1	3.247.200,00	32.769,00	33.066,00	33.066,00	198.000,00
1.07.2023 02:18	8	8,8	9,3	1,2	1,2	1,1	3.247.200,00	32.802,00	33.099,00	33.099,00	198.000,00
1.07.2023 02:23	7,9	8,6	9,2	1,2	1,3	1,1	3.168.000,00	32.670,00	32.967,00	32.967,00	158.400,00
1.07.2023 02:28	8,2	8,8	9	1,3	1,3	1,2	3.128.400,00	32.703,00	33.033,00	32.967,00	118.800,00
1.07.2023 02:33	8,1	8,8	9,5	1,3	1,3	1,1	3.168.000,00	32.703,00	33.066,00	33.000,00	158.400,00

4. DENEYSEL ÇALIŞMALAR

Bu bölümde, Vangölü EDAŞ Tatvan TM çıkışlı Fider-5 üzerinden elde edilen gerçek saha verileri kullanılarak yapılan deneysel analizlere yer verilmiştir. Önceki bölümlerde oluşturulan veri seti, burada çeşitli YZ algoritmaları ile işlenmiş ve hem harmonik bozulmaların hem de yük profillerinin zaman serisi tahmini gerçekleştirilmiştir.

Deneysel çalışmalar üç ana uygulama alanı üzerine kurgulanmıştır:

- **Güç Sisteminde Harmonik Kestirimi:** OG seviyesinde gözlemlenen faz bazlı harmonik değerlerin kestirimi gerçekleştirilmiş ve algoritmaların başarımı analiz edilmiştir.
- **Aydınlatma Tesisi İçin Harmonik Kestirimi:** Gece saatlerinde devreye giren aydınlatma yüklerinin oluşturduğu harmonik karakteristiklerin tahmini yapılmıştır.
- **Yük Kestirimi:** Fiderden çekilen aktif gücün tahmini ile ileriye dönük yük profili davranışlarının modellenmesi amaçlanmıştır.

Bu uygulamalarda GRU ve LSTM gibi sıralı derin öğrenme yapıları tercih edilmiş ve bazı modellerde Bahdanau dikkat (attention) mekanizması da entegre edilmiştir. Modellerin başarımı MAE, RMSE, MAPE, SMAPE gibi yaygın performans metrikleriyle değerlendirilmiş ve öngörü başarısı görsel grafiklerle desteklenmiştir.

Ortalama Kare Hata (MSE), Hataların karesinin ortalamasıdır. Büyük hataları daha fazla cezalandırır:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (15)$$

Kök Ortalama Kare Hata (RMSE), MSE'nin kareköküdür ve tahmin hatalarının büyüklüğünü aynı birimden verir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (16)$$

Ortalama Mutlak Hata (MAE), Modelin tahminleri ile gerçek değerler arasındaki farkların mutlak ortalamasını ifade eder:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (17)$$

Ortalama Mutlak Yüzde Hata (MAPE), Hata yüzdesini verir, oran cinsinden ne kadar sapma olduğunu gösterir:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (18)$$

Simetrik Ortalama Mutlak Yüzde Hata (SMAPE), zaman serisi tahminlerinin doğruluğunu ölçmek için kullanılan, % cinsinden ve simetrik bir hata metriğidir.

Klasik MAPE'nin dezavantajlarını gidermek için geliştirilmiştir; özellikle gerçek değerlerin 0'a yakın olduğu durumlarda MAPE çok yüksek sapmalar verebilirken, SMAPE bu durumu daha dengeli ele alır.

$$SMAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2} \quad (19)$$

y_i Gerçek değeri, $\hat{y}_i$ tahmin edilen değeri, n ise örnek sayısını ifade etmektedir.

4.1. Yapay Zekâ Algoritmaları

YZ temelli yöntemler arasında, özellikle zaman serisi verilerinin işlenmesinde yüksek başarı gösteren RNN, LSTM ve GRU algoritmaları öne çıkmaktadır. Bu çalışmada, harmonik analiz ve tahmin süreçlerinde veri içindeki zamansal bağımlılıkların etkin biçimde modellenebilmesi amacıyla LSTM ve GRU tabanlı yaklaşımlar esas alınacak; ayrıca, modelin önemli özelliklere odaklanma kabiliyetini artırmak için Bahdanau dikkat (attention) mekanizmasının entegrasyonu da ele alınacaktır.

4.1.1. Tekrarlayan Sinir Ağı (RNN)

Recurrent Neural Network (RNN – Geri Beslemeli Sinir Ağı) yapısı, zaman serisi verilerinde geçmişe ait bilgilerin modelin belleğinde tutulmasını sağlayan ve sıralı veriler üzerinde güçlü çıkarımlar yapabilen bir yapay sinir ağı türüdür. RNN'lerin temel farkı, klasik ileri beslemeli ağlardan farklı olarak, her bir zaman adımında sadece mevcut girdiyi değil, aynı zamanda bir önceki zaman adımındaki gizli durumu (hidden state) da dikkate almasıdır. Bu yapı sayesinde model, ardışık girdiler arasında bir bağ kurarak zaman içerisindeki dinamikleri öğrenebilir.

RNN'lerin tarihçesi, 1982 yılında John Hopfield'ın geliştirdiği Hopfield ağı ile başlar[53]. Bu ağ, geri beslemeli bir yapıya sahip olması ve nöronların kendi aralarında bağlantı kurabilmesi açısından, günümüzdeki RNN mimarisinin ilk öncülü olarak kabul edilir. Ardından, 1986 yılında David Rumelhart ve arkadaşları tarafından tanımlanan backpropagation algoritması, sinir ağlarında hataların geriye doğru yayılması prensibini ortaya koymuş ve bu mekanizmanın zamana yayılarak uygulanmasıyla birlikte Backpropagation Through Time (BPTT) yöntemi geliştirilmiştir [54]. Bu sayede, RNN'ler ardışık zaman adımlarında öğrenme yetisi kazanan ilk yapı haline gelmiştir. Rumelhart'ın RNN'leri psikoloji ve dil işleme bağlamında tanıtması, bu yapıların özellikle dil modeli, zaman serisi tahmini ve örüntü tanıma gibi alanlarda uygulanabilirliğini hızla artırmıştır [54].

Mimari olarak bir RNN hücresi, her zaman adımında giriş vektörü ile birlikte önceki zaman adımının gizli durumunu işleyerek yeni bir gizli durum ve çıkış üretir. Bu işlem matematiksel olarak;


$$h_t = \sigma_h(W_h x_t + U_h h_{t-1} + b_h) \quad (20)$$

Formülüyle tanımlanır. Burada x_t , t zamanındaki giriş, h_{t-1} bir önceki gizli durum, W_h ve U_h ağırlık matrisleri, b_h bias (sapma) vektörü, σ_h aktivasyon fonksiyonudur. Aynı şekilde çıkış değerleri de

$$y_t = \sigma_y(W_y h_t + b_y) \quad (21)$$

Formülü ile elde edilir [55].

RNN'ler zaman boyunca açılması zincir benzeri bir yapıya dönüştürüldüğünde, bu dizisel öğrenme yapısı daha da netleşir. Bu yapı sayesinde geçmiş bilgi yeni girişlerle birleştirilerek daha güçlü temsil yetenekleri ortaya çıkar. Ancak RNN'lerin en belirgin dezavantajı, uzun sekanslarda gradyanların ya çok küçük (vanishing gradient) ya da çok büyük (exploding gradient) hale gelmesidir. Bu durum, modelin uzun dönem bağımlılıkları öğrenmesini ciddi şekilde zorlaştırır. Bu sınırlılık, daha sonra geliştirilen LSTM ve GRU gibi kapı mekanizmalı mimarilerle aşılmıştır. [55]. Şekil 4-1'de temel bir RNN blok şeması verilmiştir.



Şekil 4-1: Temel bir RNN blok şeması

4.1.2. Uzun Kısa Süreli Bellek (LSTM)

LSTM ağırları, geleneksel RNN yapılarının uzun dönemli bağımlılıkları öğrenme konusundaki zorluklarını aşmak amacıyla geliştirilmiştir. 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılan bu yapı, özellikle dil modelleme, zaman serisi tahmini ve sinyal işleme gibi ardışık verilerle çalışan problemler için büyük bir başarı elde etmiştir [56]. RNN'lerde karşılaşılan kaybolan gradyan (vanishing gradient) problemi, zaman içinde bilgilerin unutulmasına neden olurken, LSTM mimarisi bu sorunu yapısal olarak çözmeyi hedeflemiştir.

LSTM mimarisi, sıradan bir RNN hücresinden farklı olarak bilgi akışını düzenleyen üç kapı (gate) ve bir hücre durumu (cell state) içerir. Bu kapılar; unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısı (output gate) olarak adlandırılır. Bu yapılar sayesinde LSTM, hangi bilginin tutulacağına, hangisinin güncelleneceğine ve hangisinin çıkışa aktarılacağına karar vererek uzun vadeli öğrenmeyi mümkün kılar.

- **Unutma kapısı:** Bir önceki hücre durumundan ne kadar bilginin taşınacağını belirler.
- **Giriş kapısı ve aday bilgi:** Mevcut zamanda alınan yeni bilgiye ne kadar yer verileceğini belirler.
- **Çıkış kapısı:** Güncellenen hücre durumunun hangi kısmının bir sonraki gizli duruma aktarılacağını belirler.

Bu mekanizmalar sayesinde LSTM, geçmişten gelen anlamlı bilgiyi uzun süre saklayabilir ve bunun tahmin sürecine etkili bir şekilde katkı sunmasını sağlar.

LSTM hücresinde her zaman adımı için hesaplamalar aşağıdaki denklemler ile ifade edilir:

$$f_t = \sigma (W_f \cdot x_t + U_f \cdot h_{t-1} + b_f) \quad (22)$$

$$i_t = \sigma (W_i \cdot x_t + U_i \cdot h_{t-1} + b_i) \quad (23)$$

$$\tilde{c}_t = \tanh(W_c \cdot x_t + U_c \cdot h_{t-1} + b_c) \quad (24)$$


$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (25)$$

$$o_t = \sigma (W_o \cdot x_t + U_o \cdot h_{t-1} + b_o) \quad (26)$$

$$h_t = o_t \odot \tanh(c_t) \quad (27)$$

x_t , t anındaki giriş, h_t , t anındaki gizli durum, c_t , bellek, σ , sigmoid aktivasyon fonksiyonu, $\tanh$, hiperbolik tanjant fonksiyonu, $\odot$, eleman bazlı çarpım fonksiyonudur.

LSTM'nin en önemli avantajı, uzun dönem bağımlılıkları öğrenebilmesi ve geçmiş bilgiyi etkili şekilde hafızada tutabilmesidir. Bu yönüyle enerji tüketimi tahmini, güç kalitesi analizi ve harmonik kestirimi gibi zaman serisi tabanlı mühendislik uygulamalarında sıkça tercih edilmektedir. Ancak, klasik RNN yapılarına kıyasla daha karmaşık bir yapıya ve yüksek hesaplama maliyetine sahiptir [57]. Şekil 4-2'de temel bir LSTM blok şeması verilmiştir.



Şekil 4-2: Temel bir LSTM blok şeması

4.1.3. Kapılı Tekrarlayan Ünite (GRU)

GRU, 2014 yılında Kyunghyun Cho ve arkadaşları tarafından tanıtılmıştır ve LSTM'nin sadeleştirilmiş bir alternatifi olarak geliştirilmiştir [58]. GRU'nun temel amacı, LSTM'nin uzun süreli bağımlılıkları modelleme yeteneğini korurken, daha az parametreyle daha hızlı ve verimli bir yapı sunmaktır. LSTM'nin sahip olduğu üç kapı mekanizması yerine GRU yalnızca iki kapı içerir: güncelleme kapısı (update gate) ve sıfırlama kapısı (reset gate). Ayrıca LSTM'deki ayrı bir hücre durumu bulunmaz; gizli durum (hidden state) bu görevi üstlenir[59].

GRU hem kısa hem uzun dönemli bağımlılıkları başarılı şekilde modelleyebilmesiyle dikkat çeker. Ayrıca yapısal olarak daha sade olduğu için özellikle küçük veri setleriyle çalışırken aşırı öğrenme (overfitting) riskini azaltabilir ve daha hızlı eğitim süreleri sunar.

- **Güncelleme kapısı:** hücrenin geçmiş bilgisinden ne kadarının korunacağına karar verir.
- **Reset kapısı:** geçmiş bilginin ne kadarının göz önünde bulundurulacağını belirler.

Bu iki mekanizma ile birlikte GRU, bilgiyi zaman içerisinde akıllıca işler ve gerekli yerlerde geçmiş veriyi sıfırlayarak günceller.


$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (28)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (29)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (30)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (31)$$

x_t : t anındaki giriş, h_t h_{t-1} : önceki ve mevcut gizli durum, z_t : güncelleme kapısı, r_t : reset kapısı, $\tilde{h}_t$: aday gizli durum, σ : sigmoid aktivasyon fonksiyonu, $\tanh$: hiperbolik tanjant aktivasyonu, $\odot$: eleman bazında çarpımı ifade eder. Şekil 4-3'te temel bir GRU blok şeması verilmiştir.



Şekil 4-3: Temel Bir GRU blok şeması

GRU, LSTM'ye kıyasla daha az parametreye sahip olması sayesinde eğitim sırasında daha az hesaplama gücü gerektirir. Bu da gerçek zamanlı uygulamalar veya sınırlı donanıma sahip sistemlerde GRU'yu öne çıkarır. Yapılan karşılaştırmalı çalışmalarda bazı problemler için GRU'nun LSTM kadar etkili, hatta bazı durumlarda daha başarılı sonuçlar verdiği gözlemlenmiştir.

4.1.4 Bahdanau Dikkat Mekanizması (Bahdanau Attention)

Bahdanau dikkat mekanizması, 2015 yılında Dzmitry Bahdanau, Kyunghyun Cho ve Yoshua Bengio tarafından, özellikle makine çevirisi gibi ardışık veri işleme problemlerinde kodlayıcı-çözücü yapılarının performansını iyileştirmek amacıyla geliştirilmiştir[60]. Klasik kodlayıcı-çözücü mimarilerinde, giriş dizisinin tamamı kodlayıcı katman tarafından sabit boyutlu bir bağlam vektörüne (context vector) dönüştürülür ve çözücü katman bu tek vektörü kullanarak çıktı üretir. Ancak uzun giriş dizilerinde bu yöntem bilgi kaybına neden olur ve modelin öğrenme kapasitesini sınırlar [61].

Bahdanau dikkat mekanizması, çözücü katmanın her adımda kodlayıcı katmanın tüm zaman adımlarındaki çıktılarından dinamik olarak yararlanmasına olanak tanır. Böylece model, her çıktı ürettiğinde girişin farklı kısımlarına odaklanarak bilgi kaybını azaltır.

Bahdanau dikkat mekanizması üç temel bileşenden oluşur: skor fonksiyonu, ağırlıkların hesaplanması ve bağlam vektörü oluşturma.

- **Skor Fonksiyonu**

Çözücü katmanının bir önceki gizli durumu s_{t-1} ile kodlayıcı katmanın j . zaman adımındaki gizli durumu h_j karşılaştırılarak skor değeri hesaplanır.

$$score(s_{t-1}, h_j) = v_a^T \tanh(W_{as_{t-1}}^2 + U_a h_j) \quad (32)$$

Burada W_a ve U_a ağırlık matrisleri, v_a ise öğrenilebilir vektördür.

- **Dikkat Ağırlıkları (Attention Weights)**

Elde edilen skorlar olasılık dağılımı normalizasyonu (softmax) ile normalize edilerek dikkat ağırlıkları elde edilir.

$$a_{ij} = \frac{\exp(score(s_{t-1}, h_j))}{\sum_k \exp(score(s_{t-1}, h_k))} \quad (33)$$


Bu ağırlıklar, modelin girişin hangi kısmına ne kadar odaklandığını ifade eder.

- **Bağlam Vektörü (Context Vektör)**

Bağlam vektörü, kodlayıcı çıktılarının ağırlıklı toplamı olarak hesaplanır:

$$c_t = \sum_j a_{ij} h_j \quad (34)$$


Bu vektör kod çözücünün mevcut adımda kullanacağı ek bilgiyi sağlar. Şekil 4-4'te Bahdanau Dikkat Algoritması blok şeması verilmiştir.



Şekil 4-4: Bahdanau Dikkat Algoritması blok şeması

4.2. Güç Sisteminde Harmonik Kestirimi

Bu bölümde, dağıtım sistemi üzerindeki harmonik bozulmaların kestirimi amacıyla geliştirilen YZ tabanlı bir tahmin modeli sunulmaktadır. Tatvan TM'ye bağlı Fider-5 üzerinden elde edilen üç fazlı harmonik akım verileri (THD_I1, THD_I2, THD_I3), geçmiş yük profili ve tarihsel zaman serisi özellikleriyle birleştirilerek modellenmiştir. Geliştirilen model, zaman bağımlı verileri işleyebilme kabiliyetiyle öne çıkan GRU mimarisi ve Bahdanau dikkat mekanizmasının entegrasyonu ile oluşturulmuştur. Model, zaman içinde değişen harmonik eğilimlerini öğrenebilmek amacıyla gecikmeli özellikler (lag), takvime bağlı parametreler ve yük karakteristikleriyle beslenmiştir. Eğitim ve test aşamalarında ortalama hata bazlı metriklerle model başarımları değerlendirilmiş; kestirim sonuçları görsel ve istatistiksel olarak analiz edilmiştir. Bu kapsamda, geliştirilen algoritmanın veri ön işleme, model mimarisi, eğitim süreci ve değerlendirme adımları ayrıntılı olarak açıklanmıştır. Şekil 4-5'te model mimarisi verilmiştir.



Şekil 4-5: Model mimarisi

4.2.1. Gerekli Kütüphanelerin Yüklenmesi

Bu bölümde, YZ tabanlı harmonik kestiriminde kullanılacak çeşitli Python kütüphaneleri içe aktarılmıştır. pandas ve numpy veri işleme ve sayısal işlemler için kullanılırken, tensorflow.keras modülü derin öğrenme modellerinin oluşturulması ve eğitilmesi için kullanılmıştır. sklearn kütüphanesinden ise veri normalizasyonu, model bölme ve hata metrikleri hesaplamaları gerçekleştirilmiştir. matplotlib.pyplot, grafiksel analizler için tercih edilmiştir. EarlyStopping gibi geri çağırma fonksiyonları ise modelin aşırı öğrenmesini (overfitting) engellemek ve öğrenme hızını optimize etmek amacıyla kullanılır.

```
import pandas as pd
import numpy as np
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras import layers
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
import matplotlib.pyplot as plt
from sklearn.metrics import mean_absolute_error, mean_squared_error
from tensorflow.keras.callbacks import EarlyStopping
import os
```

4.2.2. Bahdanau Attention Katmanının Tanımlanması

Bahdanau dikkat (attention) mekanizması, sıralı verilerde hangi zaman adımlarının modele daha fazla bilgi sağladığını belirlemek amacıyla geliştirilmiş bir yapıdır. Bu sınıf, GRU ağının çıktılarına uygulanmak üzere özelleştirilmiş bir attention bloğudur. query vektörü (genellikle GRU'nun son çıktısı), tüm zaman adımlarındaki values ile etkileşime girerek dikkat skorlarını üretir. Bu skorlar softmax fonksiyonu ile normalize edilir ve sonuçta elde edilen ağırlıklar (attention weights), geçmiş zaman adımlarına farklı oranlarda odaklanılarak bir özet vektör (context vector) oluşturur. Bu yapı, zaman serisi verilerinde modelin yalnızca belirli adımlara yoğunlaşarak daha isabetli tahminler yapmasını sağlar.

```
class BahdanauAttention(layers.Layer):
    def __init__(self, units):
        super(BahdanauAttention, self).__init__()
        self.W1 = layers.Dense(units)
        self.W2 = layers.Dense(units)
        self.V = layers.Dense(1)

    def call(self, query, values):
        query_with_time_axis = tf.expand_dims(query, 1)
        score = self.V(tf.nn.tanh(self.W1(query_with_time_axis) + self.W2(values)))
        attention_weights = tf.nn.softmax(score, axis=1)
        context_vector = attention_weights * values
        context_vector = tf.reduce_sum(context_vector, axis=1)
        return context_vector, attention_weights
```

4.2.3. Veri Ön İşleme ve Özellik Mühendisliği (Feature Engineering)

Bu bölümde, modelin eğitilmesinden önce dağıtım sisteminden elde edilen ham veriler üzerinde uygulanan ön işleme ve özellik çıkarımı işlemleri tanımlanmıştır. Preprocess_data fonksiyonu, Excel dosyasından alınan ölçüm verilerini okur, tarih sütununu datetime formatına çevirir ve THD, aktif/reaktif güç gibi sayısal alanları uygun float formatına dönüştürür. Ayrıca, Avrupa formatındaki sayılarda kullanılan virgül (",") karakteri noktaya (".") dönüştürülerek uluslararası hesaplamalara uygun hâle getirilir.

Prepare_variables fonksiyonu, zaman serisi tahmin modellerine uygun şekilde veri setini genişletir. Burada tarih ve zaman bilgilerinden hafta içi/gün sonu, ay, saat ve gün gibi türetilmiş

özellikler çıkarılır. Ayrıca geçmişe dönük bilgi eklemek amacıyla 3 gecikmeli (lag 1–3) harmonik verileri her faz için ayrı sütun olarak eklenir. Bu işlem, modelin geçmiş değerlere bakarak ileriye dönük tahmin yapabilmesini sağlar. Veriler daha sonra MinMaxScaler ile normalize edilir. Son olarak, giriş verileri pencereleme tekniğiyle sıralanır (24 zaman adımı uzunluğunda giriş dizileri) ve hem giriş hem hedef değerler uygun boyutlara getirilir.

```
def preprocess_data(file_path):
    df = pd.read_excel(file_path, sheet_name="F5feeder")
    for col in ["Active_Power (Watt)", "Reactive_Power (VAR)", "THD_I1", "THD_I2", "THD_I3"]:
        df[col] = df[col].astype(str).str.replace(".", "", regex=False).str.replace(",", ".", regex=False)
    df["Date and Time"] = pd.to_datetime(df["Date and Time"])
    return df

def prepare_variables(df, sequence_length=24, add_lag_features=True):
    df["Weekday"] = df["Date and Time"].dt.weekday
    df["Is_Weekend"] = df["Weekday"].apply(lambda x: 1 if x >= 5 else 0)
    df["Month"] = df["Date and Time"].dt.month

    if add_lag_features:
        for lag in range(1, 4):
            df[f"THD_I1_lag{lag}"] = df["THD_I1"].shift(lag)
            df[f"THD_I2_lag{lag}"] = df["THD_I2"].shift(lag)
            df[f"THD_I3_lag{lag}"] = df["THD_I3"].shift(lag)
        df = df.dropna()

    feature_cols = [
        "Hour", "Day", "Month", "Weekday", "Is_Weekend",
        "Active_Power (Watt)", "Reactive_Power (VAR)"
    ]
    if add_lag_features:
        for lag in range(1, 4):
            feature_cols += [f"THD_I1_lag{lag}", f"THD_I2_lag{lag}", f"THD_I3_lag{lag}"]

    df["Hour"] = df["Date and Time"].dt.hour
    df["Day"] = df["Date and Time"].dt.day

    X = df[feature_cols]
    Y = df[["THD_I1", "THD_I2", "THD_I3"]]

    scaler_X = MinMaxScaler()
    scaler_Y = MinMaxScaler()

    X_scaled = scaler_X.fit_transform(X)
    Y_scaled = scaler_Y.fit_transform(Y)

    X_seq, Y_seq = [], []
    for i in range(len(X_scaled) - sequence_length):
        X_seq.append(X_scaled[i:i + sequence_length])
        Y_seq.append(Y_scaled[i + sequence_length])

    X_seq = np.array(X_seq)
    Y_seq = np.array(Y_seq)

    return X_seq, Y_seq, scaler_X, scaler_Y
```

4.2.4. GRU + Bahdanau Attention Modelinin Tanımlanması

Bu fonksiyon, girdi olarak verilen boyutta bir zaman serisi verisine karşılık bir GRU tabanlı ve Bahdanau dikkat mekanizmalı regresyon modelini oluşturur. Modelin mimarisi, çok boyutlu giriş verilerini GRU katmanları ile işleyerek, dikkat ağı sayesinde önemli zaman adımlarını vurgular ve nihai tahminleri üretir. Yapı şu adımlardan oluşur:

1. Girdi Katmanı (inputs): Modelin giriş şekli, her bir örnek için (24 özellik sayısı) olacak şekilde tanımlanır.

2. GRU Katmanları:

İlki return_sequences=True parametresiyle tanımlanmıştır ve zaman eksenini boyunca tüm çıktı dizisini döndürür. Bu çıktı, attention mekanizmasının işlem yapacağı zamansal bilgiyi içerir.

İkinci GRU katmanı, girişten özet bir bilgi çıkarır (query) ve dikkat bloğuna gönderilir.

3. Bahdanau Attention:

GRU çıktılarından önemli zaman adımlarını ayıklayan mekanizmadır. query ile gru_output etkileşime sokularak context_vector (bağlamsal özet) oluşturulur.

4. Tam Bağlantılı (Dense) Katmanlar:

context_vector önce 128, ardından 64 nöronlu iki katmandan geçirilir.

Her biri ReLU aktivasyon fonksiyonu içerir ve aşırı öğrenmeyi önlemek için dropout uygulanır.

5. Çıkış Katmanı (outputs):

Model 3 hedef değişken (THD_I1, THD_I2, THD_I3) tahmin edeceğinden, 3 nöronlu lineer aktivasyonlu çıkış katmanı tanımlanmıştır.

6. Derleme Aşaması:

Optimizer olarak AdamW (ağırlık bozulmasını azaltan Adam türevi), kayıp fonksiyonu olarak Huber ve değerlendirme metriği olarak MAE, RMSE, MAPE kullanılmıştır.

Bu mimari, zaman serisi tahmininde hem geçmiş örüntüleri GRU ile yakalamayı hem de kritik zaman dilimlerine Bahdanau Attention ile odaklanmayı sağlamaktadır.

```

def build_gru_bahdanau_model(input_shape):
    inputs = keras.Input(shape=input_shape)

    gru_output = layers.GRU(128, return_sequences=True)(inputs)
    query = layers.GRU(128, return_sequences=False)(inputs)

    attention_layer = BahdanauAttention(64)
    context_vector, attention_weights = attention_layer(query, gru_output)

    x = layers.Dense(128, activation='relu')(context_vector)
    x = layers.Dropout(0.3)(x)
    x = layers.Dense(64, activation='relu')(x)
    x = layers.Dropout(0.2)(x)

    outputs = layers.Dense(3, activation='linear')(x)

    model = keras.Model(inputs, outputs)

    optimizer = tf.keras.optimizers.AdamW(learning_rate=1e-3, weight_decay=1e-4)
    model.compile(optimizer=optimizer, loss=tf.keras.losses.Huber(), metrics=["mae"])

    return model

```

4.2.5. Model Performans Ölçümü ve Grafiksel Karşılaştırma

Bu bölümde, modelin doğruluk ve genelleme başarısı değerlendirilmektedir. Bu kapsamda iki ana fonksiyon tanımlanmıştır: birincisi hata metriklerini hesaplamakta, ikincisi ise tahmin değerleri ile gerçek değerleri grafiksel olarak üst üste çizerek görsel karşılaştırma yapmaktadır.

Calculate_metrics fonksiyonu, modelin test verisinde yaptığı tahminlerle gerçek değerler arasındaki farkı çeşitli istatistiksel ölçütler kullanarak değerlendirmektedir. Hesaplanan metrikler:

- **MAE (Ortalama Mutlak Hata):** Tahmin edilen değerlerin, gerçek değerlere olan mutlak uzaklıklarının ortalamasıdır.
- **MSE (Ortalama Kare Hata):** Hataların karesinin ortalamasıdır; büyük hataları daha fazla cezalandırır.
- **RMSE (Kök Ortalama Kare Hata):** MSE'nin kareköküdür ve hata büyüklüğünü doğrudan tahmin edilen değişkenin birimiyle ifade eder.
- **MAPE (Ortalama Mutlak Yüzde Hata):** Tahmin hatalarının, gerçek değerlere oranla yüzde cinsinden ortalamasıdır. Farklı ölçeklerdeki verilerle karşılaştırmak için uygundur.

```
def calculate_metrics(y_true, y_pred, label):
    mae = mean_absolute_error(y_true, y_pred)
    mse = mean_squared_error(y_true, y_pred)
    rmse = np.sqrt(mse)
    mape = np.mean(np.abs((y_true - y_pred) / y_true)) * 100
    print(f" ♦ {label} Metrics:")
    print(f"   - MAE   : {mae:.4f}")
    print(f"   - MAPE  : {mape:.2f}%")
    print(f"   - MSE   : {mse:.4f}")
    print(f"   - RMSE  : {rmse:.4f}")
    print("-" * 40)
```

plot_superimposed_actual_vs_predicted fonksiyonu, modelin tahmin ettiği değerleri ve gerçek değerleri aynı grafikte çizerek görsel bir başarı karşılaştırması sunar. Her bir THD fazı için ayrı ayrı çağrıldığında, modelin hangi bölümlerde sapma yaptığını açıkça görmek mümkün olur. Bu görselleştirme, istatistiksel metriklerin yanı sıra sezgisel analizde de oldukça etkilidir.

```
def plot_superimposed_actual_vs_predicted(Y_actual, Y_pred, label):
    plt.figure(figsize=(10, 5))
    plt.plot(Y_actual, label=f"Actual {label}", marker='o', linestyle='--')
    plt.plot(Y_pred, label=f"Predicted {label}", marker='x', linestyle='--')
    plt.xlabel("Sample Index")
    plt.ylabel(f"{label} Value")
    plt.title(f"Superimposed Actual vs Predicted {label}")
    plt.legend()
    plt.show()
```


4.2.6. Model Çıktılarının Değerlendirilmesi

Geliştirilen GRU tabanlı dikkat mekanizmalı YZ modeli, her bir fazdaki akım harmonik bozulma oranlarını (THD_I1, THD_I2 ve THD_I3) tahmin etmek üzere eğitilmiş ve test edilmiştir. Bu bölümde, modelin test verisi üzerindeki başarımı görsel ve istatistiksel çıktılar üzerinden değerlendirilmektedir. Her bir faz için elde edilen tahmin değerleri, gerçek ölçümler ile üst üste çizilerek karşılaştırılmış ve hatalar dört farklı ölçüt (MAE, MAPE, MSE, RMSE) kullanılarak nicel olarak analiz edilmiştir. Grafiksel sonuçlar modelin öğrenme kabiliyetini, doğruluğunu ve genelleme yeteneğini ortaya koyarken; hata değerleri ise tahmin performansını nesnel olarak değerlendirmek amacıyla sunulmaktadır. Farklı algoritmaların deneme sonuçları toplu halde Tablo 4.1’de sunulmuştur.

Tablo 4-1: Farklı algoritmaların deneme sonuçları


Metric	GRU + Attention	CNN + GRU + Attention	CNN + Bidirectional GRU + Attention	GRU + Bahdanau Attention
THD_I1 MAE	0.5309	0.5061	0.4895	0,3365
THD_I1 MAPE	% 7.74	%7.37	%7.20	%5.07
THD_I1 RMSE	0.7139	0.6814	0.6528	0,465
THD_I2 MAE	0.5512	0.5212	0.5071	0,34
THD_I2 MAPE	%7.81	%7.39	%7.25	%5.00
THD_I2 RMSE	0.7469	0.7033	0.6803	0,4771
THD_I3 MAE	0.5916	0.5597	0.5409	0,3598
THD_I3 MAPE	%7.91	%7.49	%8.60	%4.99
THD_I3 RMSE	0.7994	0.7590	0.7302	0,506

Şekil 4.6' daki görselde, THD_I1 için model tarafından tahmin edilen değerlerle gerçek değerler üst üste çizilmiştir. MAPE değeri %5 seviyelerinde, MAE değeri ise 0.3'ler mertebesinde oldukça düşük bir değere sahip olmaktadır. Bu, modelin Faz-1'e ait harmonik bozulmaları genel olarak yüksek doğrulukla öngörebildiğini göstermektedir. Grafik incelendiğinde, tahmin eğrisinin gerçek değerlerle oldukça iyi örtüştüğü ve uç değerlerde dahi modelin sapmaları makul sınırlar içinde tuttuğu gözlemlenmektedir. Tahminlerin yüksek yoğunluklu bölgelerde başarılı bir şekilde yakalandığı; ani harmonik artışlarında ise bir miktar yatay sapma gözlemlense de genel dağılım yapısının korunduğu söylenebilir.




Şekil 4-6: Faz 1'in THD'si için gerçek ve tahmin değerlerinin karşılaştırılması

THD_I2 fazı için tahmin başarısı da benzer şekilde güçlüdür. Grafikselleştirilerek Şekil 4-7'deki görselden de anlaşılacağı üzere tahmin eğrilerinin gerçek değerlere paralel ilerlediği, özellikle ortalama düzeydeki harmonik yüklerde modelin hassasiyetle çalıştığı görülmektedir. MAE ve RMSE değerlerinin düşük olması, kestirimlerin istatistiksel olarak başarılı olduğunu göstermektedir. MAPE'nin %5 gibi düşük bir seviyede olması, uygulanan GRU + Bahdanau Attention mimarisinin hem ani harmonik geçişleri hem de düzenli harmonik davranışları etkili biçimde öğrenebildiğini ortaya koymaktadır.



Şekil 4-7: Faz 2'nin THD'si için gerçek ve tahmin değerlerinin karşılaştırılması

THD_I3 için tahmin performansı da güçlü olmakla birlikte, diğer fazlara kıyasla hata değerleri çok az azalma göstermektedir. Şekil 4-8'deki görsel incelendiğinde özellikle yüksek harmonik değerlerinde ($THD > \%18$) modelin tahmin doğruluğunun kısmen azaldığı, ancak ortalama seviyelerde oldukça başarılı tahminler yaptığı gözlemlenmektedir. Bu durum, modelin yüksek varyansa sahip değerleri kestirmede küçük sapmalar gösterebildiğini ancak genel eğilimleri yakalayabildiğini ortaya koymaktadır. MAPE'nin $\%4.99$ gibi düşük bir seviyede kalması, modelin güçlü bir şekilde kestirim yaptığını göstermektedir.



Şekil 4-8: Faz 3'ün THD'si için gerçek ve tahmin değerlerinin karşılaştırılması

Sunulan sonuçlar, geliştirilen GRU tabanlı Bahdanau dikkat mekanizmalı YZ modelinin harmonik bozulmaları oldukça düşük hata seviyeleriyle kestirebildiğini göstermektedir. MAE ve MAPE gibi temel metriklerin düşük değerlerde seyretmesi, modelin güvenilirliğini ve uygulanabilirliğini ortaya koymaktadır. Bu doğrultuda model, dağıtım sistemlerinde harmonik kestirimi için etkin bir araç olarak değerlendirilebilir.

4.3. Aydınlatma Tesisleri İçin Harmonik Kestirimi

Bir güç sisteminde aydınlatma elemanlarının sayısındaki artış, bu cihazların neden olduğu güç kalitesi bozulmalarında da eş zamanlı bir artışa yol açmaktadır. Bu sayı yüzlerle ifade edilen değerlere ulaştığında, bozulmalar artık alçak AG seviyeleri yerine OG seviyelerini etkilemeye başlamaktadır. Sokak ve dış mekân aydınlatması gibi belirlenmiş sistemler dışında, aydınlatma elemanlarının kullanımı; çalışma koşulları ile bireysel veya kurumsal davranışlara bağlı olarak geniş ölçüde değişkenlik göstermektedir. Bu nedenle, değişken özelliklere sahip aydınlatma elemanlarından kaynaklanan harmoniklerin yalnızca ölçülmesi, doğru ve işlevsel bir güç sistemi planlaması için yeterli değildir; aynı zamanda harmonik kestirimi de gereklidir.

Kırsal ve kentsel alanlarda ana arter, tali yol vb. çeşitli sokak tipleri bulunmaktadır. Farklı sokak aydınlatma senaryoları, farklı tipte sokak lambaları, güç değerleri ve ışık dağılımları gerektirir [62], [63], [64]. Teknolojinin ilerlemesiyle birlikte, LED sokak lambaları; şehir, kasaba ve kırsal bölgelerdeki yollar ve yaya yolları için daha uygun maliyetli ve çevre dostu bir çözüm hâline gelmiştir [65], [66], [67]. Aydınlatma cihazlarındaki gelişmeler ve çeşitlilik, enerji kalitesi sorunları gibi bazı problemlere yol açmaktadır. Çalışma prensipleri ve doğrusal olmayan karaktere sahip sürücü devrelerini içermeleri nedeniyle, aydınlatma cihazları hem OG hem de AG güç sistemlerinde en etkili harmonik kaynaklarından biridir. OG dağıtım şebekelerindeki harmonik bozulmalar, özellikle LED, HPS (yüksek basınçlı sodyum), MH (metal halide) ve kompakt floresan lambalar gibi doğrusal olmayan yükler içeren aydınlatma cihazlarından kaynaklanabilmektedir. Bu cihazlar, sinüzoidal olmayan şekilde akım çektikleri için şebekeye harmonik bileşenler enjekte ederler [68], [69], [70], [71], [72].

OG dağıtım şebekelerinde aydınlatma ekipmanlarının neden olduğu harmonik bozulmalara birçok değişken katkıda bulunur [73], [74]. Modern aydınlatma sistemleri (LED, CFL vb.) elektrik enerjisini düzenlemek için elektronik balastlar veya sürücüler kullanır. Bu bileşenler sıklıkla anahtarlama yöntemlerine dayanır ve bu durum doğal olarak harmonik üretir. Ayrıca, bu cihazların akım-gerilim ilişkisi doğrusal değildir; bu da istenen sinüzoidal formdan farklı akım dalga şekillerinin oluşmasına neden olur. Bazı aydınlatma cihazlarının düşük güç faktörü, şebekede harmonik bozulmaları daha da artırmaktadır. Bu tür cihazlar geniş ölçekte (ör. sokak aydınlatmaları, endüstriyel tesisler) uygulandığında, harmoniklerin kümülatif etkisi oldukça büyük olup, şebekenin genel güç kalitesini olumsuz yönde etkilemektedir[75].

Orta gerilim şebekelerindeki harmonikler çeşitli problemlere yol açar. Transformatörler ve diğer şebeke bileşenlerinde bakır ve demir kayıplarını artırarak genel verimi düşürür. Hassas ekipmanların (aydınlatma cihazları, kondansatörler, koruma röleleri ve transformatörler vb.) ömrünü kısaltabilir ve arızalara neden olabilir. Ayrıca, harmonikler gerilim dalga şekillerini


bozarak düşük güç kalitesi ve bağlı ekipmanlar için potansiyel işletme sorunlarına yol açar. Bazı durumlarda, harmoniklerin şebeke empedansı ile birleşmesi rezonansa neden olabilir ve harmonik seviyelerini ciddi şekilde yükselterek şebeke kararlılığını zorlayabilir [76], [77].

Tezin bu bölümündeki uygulamada, konut, sanayi ve sokak aydınlatmasını içeren karma aydınlatma ortamlarını besleyen 33 kV OG şebekesinden elde edilmiş gerçek dünya veri seti, bu tip tesislerin neden olduğu akım toplam harmonik bozulmalarının analiz, tespit ve kestirimi amacıyla kullanılmıştır. Python platformunda gerekli modül ve kütüphanelerle çalışan makine öğrenmesi yöntemleri kullanılarak, gerilim değişimleri bağımsız değişken olarak alınmak suretiyle akım harmonikleri tahmin edilmiştir. Bu yaklaşım, güç sistemlerinde en kolay ölçülebilir parametrelerden biri olarak tanımlanabilen gerilim verisinin kullanılması sayesinde avantaj sağlamaktadır.

Çalışmanın temel katkıları ve öne çıkan noktaları şu şekilde özetlenebilir:

- Gerçek dünya verilerinin kullanılması sayesinde, simülasyon tabanlı araştırmalarda göz ardı edilen veya nicel olarak belirlenmesi mümkün olmayan tüm parametreler süreç adımlarında dikkate alınmıştır.
- Önerilen modelin bütüncül tasarımı, farklı senaryo ve veri setlerinde uyarlanabilirlik ve verimlilik sağlamış; zaman bağımlı verilerin özgün zorluklarını yüksek hassasiyet ve yetkinlikle ele almıştır.

Verilerin uygunluğunu kontrol etmek amacıyla ön çalışma olarak korelasyon analizi yapılmıştır. Bu kapsamda, her bir fazın THD değerleri ile ortalama gerilim seviyesi arasındaki ilişki hesaplanmış ve Şekil 4-9’da korelasyon eğrileri olarak verilmiştir.




Şekil 4-9: Kolerasyon Eğrileri

Şekil 1’den, gerilim seviyeleri ile THD değerleri arasında görece güçlü bir korelasyon olduğu açıkça görülmektedir. Harmonik tespiti, güç kalitesi sorunlarıyla etkin şekilde mücadele etmenin temel bileşenlerinden biridir. Ayrıca, güç sistemlerinin dinamik yapısı, harmoniklerin zaman içerisinde sürekli olarak değişmesine neden olmaktadır. Bu nedenle, güç şebekesindeki harmoniklerin düzenli olarak izlenmesi kritik öneme sahiptir.

Çalışmanın temel amacına uygun olarak, gerçek dünya veri setinden oluşan deneysel bir sistem kullanılmıştır. Veri temizleme işlemi sonrasında, 5 dakikalık çözünürlükte kaydedilmiş toplam 40.846 satır akımı THD ve gerilim değerinden oluşan veri seti elde edilmiştir. Ölçüm verilerinin %70’i modellerin eğitimi, kalan %30’u ise test için ayrılmıştır. Aydınlatma cihazı parametreleri Tablo 4-2’de verilmiştir.

Tablo 4-2: Özellikleri ile birlikte aydınlatma cihazları


Aydınlatma Cihazı	Nominal Güç (W)	Işık akısı (lm)	Kullanılan adetler
 Halojen Lamba	70W	1200	16100
 LED Lamba	10W	1020	62000
 Yüksek Basıncılı Sodyum Buharlı Lamba	150W	17000	4025
 LED Sokak Armatürü	80W	10376	1350

Kullanılan metodoloji, zaman serisi tahmini için etkinliğini ve uyarlanabilirliğini artıran çeşitli ileri düzey stratejileri içermektedir. Özellik mühendisliği (feature engineering), standart modellerde sıklıkla göz ardı edilen alan-özel (domain-specific) bilgilerin entegrasyonu ile kritik bir rol oynamaktadır. Gelişmiş hiperparametre optimizasyonu, Keras Tuner kullanılarak gerçekleştirilmiş; bu sayede manuel ayarlamaların sınırlamalarını aşan, sistematik ve verimli bir en iyi model konfigürasyonu arama süreci sağlanmıştır. Model mimarisi, uzun dönemli bağımlılıkları yakalamak için birden fazla LSTM katmanını Dropout katmanları ile birlikte içermekte; aşırı öğrenmeyi (overfitting) önleyerek zaman serisi verilerine uygun, sofistike ve sağlam bir yapı sunmaktadır.

Değerlendirme süreci, aykırı değerler ve ölçek farklılıklarını dikkate alan dengeli bir metrik olan Simetrik Ortalama Mutlak Yüzde Hata (SMAPE) ile güçlendirilmiş; böylece performansın daha ayrıntılı bir şekilde yorumlanması mümkün olmuştur. Normalizasyon ve yeniden şekillendirme (reshaping) gibi ön işleme adımları, ölçeklenebilirlik ve esneklik sağlayarak yaklaşımın minimum uyarlama ile farklı veri setlerini işleyebilmesine imkân tanımaktadır. Verimlilik, hiperparametre optimizasyonunun Keras Tuner ile otomatikleştirilmesi sayesinde daha da artırılmış; optimizasyon için gereken zaman ve çaba önemli ölçüde azaltılmıştır.

Zaman serisi verileri için özel olarak uyarlanmış bu metodoloji, alan bilgisi entegrasyonu, gelişmiş optimizasyon teknikleri, sağlam değerlendirme metrikleri, ölçeklenebilirlik ve

otomasyon özelliklerini bir arada sunarak öne çıkan bir yaklaşım oluşturmaktadır. Deneysel kurulumun blok diyagramı Şekil 4-10’da özetlenmiştir.



Şekil 4-10: Deneysel Kurulum


Standartlaştırılmış ve toplanmış veriler kullanılarak üç katmanlı yapay sinir ağı modelleri oluşturulmuştur. Bu bölümler üç kategoriye ayrılmaktadır: giriş katmanı, çıkış katmanı ve LSTM algoritmaları. İlk olarak, model rastgele ağırlıklarla eğitilmiştir. Eğitim süreci başladıktan sonra, farklı rastgele ağırlıklar kullanarak elde edilen tahmin sonuçları not edilmiştir. Yapay sinir ağına dayalı tekniklerin sezgisel yapısı nedeniyle, farklı başlangıç ayarları farklı sonuçlar üretebilmektedir. Yapay sinir ağlarında katman ifadeleri, gizli katmanları belirtmektedir. Tahmin modelleri; giriş, LSTM ve çıkış olmak üzere üç katmandan oluşmaktadır. Veriler, 5 dakikalık çözünürlükte giriş katmanına uygulanmıştır.

Ağ yapıları, katman sayıları ve elde edilen hata değerleri Tablo 4-3’te gösterilmiştir. En iyi sonucu veren senaryo ise tabloda ayrıca vurgulanmıştır.


Tablo 4-3: Eğitime ait sayısal değerler

Ağ Yapısı	Katman	Düğümmler	Hesaplama Hataları			
			MSE	RMSE	MAE	SMAPE
LSTM Model + Hyperparameter	2	128	2,433	2,286	1,734	16,735
		256	2,612	2,411	1,360	12,615
		512	2,117	1,859	1,004	13,486
	*3	128	1,929	1,534	0,997	12,424
		256	1,419	1,282	0,905	11,281
		*512	*1,2834	*1,11328	*0,8095	*10,7692


Tablo 4-4’te verilen sayısal değerlere göre, tahmin performansının daha iyi anlaşılabilmesi amacıyla THD’lerin gerçek ve tahmin değerlerine ait grafikler Şekil 4-11, Şekil 4-12 ve Şekil 4-13’de sunulmuştur.



Şekil 4-11: Faz 1’in THD’si için gerçek ve tahmin değerlerinin karşılaştırılması



Şekil 4-12: Faz 2'nin THD'si için gerçek ve tahmin değerlerinin karşılaştırılması



Şekil 4-13: Faz 3'ün THD'si için gerçek ve tahmin değerlerinin karşılaştırılması

Aydınlatma sistemleri, sürücüler ve çalışma özellikleri nedeniyle önemli harmonik kaynaklarıdır. Büyük ölçekli sistemlerde bu bozulmalar, AG ve hatta OG şebekelerini önemli ölçüde etkileyebilir. Bu nedenle, harmoniklerin analiz edilmesi ve bozulmaların tahmin edilmesi, sistem koşullarının değerlendirilmesi ve dengesizliklerin önlenmesi açısından kritik öneme sahiptir.

Bu çalışmada, güç sisteminin en temel parametresi olan gerilim verileri kullanılarak sistemdeki akım harmonikleri tahmin edilmiştir. Elde edilen sonuçlar analiz edildiğinde, hata oranının tatmin edici derecede düşük olduğu görülmüştür. Bu sonuçlar, farklı özelliklere sahip olsalar bile elektriksel sistemde birbiriyle ilişkili parametreler kullanılarak tahmin yapılabileceğini ve önerilen yaklaşımın bu tür çalışmalar için öncü olabileceğini göstermektedir. Benzer bir yöntemin aydınlatma tasarımlarında da kullanılabileceği öngörülmektedir.

Bu amaca uygun olarak, karma aydınlatma tesislerini besleyen bir OG dağıtım sisteminden elde edilmiş gerçek dünya veri seti, söz konusu cihazlara dayalı harmoniklerin kestirimi amacıyla kullanılmıştır. Veri seti analizi, akım harmonikleri ile gerilim değişimleri arasında bir korelasyon bulunduğunu ortaya koymuş; gerilim kolay ölçülebilen bir güç sistemi parametresi olduğundan, algoritma bu ilişki temelinde tasarlanmıştır. En iyi sonuçlara ulaşmak amacıyla birleşik YZ modelleri kullanılmıştır. Tahmin performansı, sayısal değerler ve grafiksel ifadelerle tartışılmış olup, MSE, RMSE, MAE ve SMAPE değerleri sırasıyla 1,2834; 1,11328; 0,8095 ve 10,7692 olarak elde edilmiştir.

4.4. Yük Kestirimi


Bu uygulamada, aktif güç değerinin kestirimi amacıyla yapılandırılan GRU-Bahdanau dikkat mekanizmalı YZ modeli, giriş olarak geçmiş aktif güç değerleri ile tarihsel ve zamansal özellikleri (saat, gün, ay, hafta içi/hafta sonu bilgisi) kullanmaktadır. Modelin önceki harmonik tahmin yapısından temel farkı, çıktı katmanında yalnızca bir nöron bulunması ve aktif güç tahmini gerçekleştirmesidir. Aşağıda, modelin aktif güç kestirimi yapmasını sağlayan ilgili kod bölümü verilmiştir:

```
# Aktif güç tahmini için tek nöronlu çıktı katmanı
outputs = layers.Dense(1, activation='linear')(x)

# Model tanımlaması
model = keras.Model(inputs, outputs)

# Derleme işlemi: Huber kaybı ve AdamW optimizasyonu ile
optimizer = tf.keras.optimizers.AdamW(learning_rate=1e-3, weight_decay=1e-4)
model.compile(optimizer=optimizer, loss=tf.keras.losses.Huber(), metrics=["mae"])
```

Bu şekilde geliştirilen model, özellikle dağıtım sistemlerinde zamanla değişen yük davranışlarını dikkate alarak gelecekteki aktif güç taleplerini yüksek doğrulukla tahmin etme kapasitesine sahiptir. Yapının esnekliği ve dikkat mekanizması desteği sayesinde, yük profilinin dinamik yapısına etkili şekilde uyum sağlamaktadır. Model çıktısı Şekil 4-14’te verilmiştir.



Şekil 4-14: Gerçek yük ile tahmin edilen yükün karşılaştırılması

Modelde MAPE değeri hesaplatılmış olup MAPE değeri, modelin tahmin performansını yüzdesel olarak ifade eden önemli bir hata ölçütüdür. Bu çalışmada elde edilen %5,21’lik MAPE değeri, modelin aktif güç tahminlerinde, gerçek değerlere kıyasla ortalama olarak %5,21 oranında sapma gösterdiğini ifade eder. Bu oran, elektrik dağıtım sistemleri gibi karmaşık, zamanla değişen

yük karakteristiklerine sahip ortamlarda oldukça kabul edilebilir bir doğruluk seviyesini temsil etmektedir.

MAPE değerin düşük olması, modelin hem yüksek ve düşük yük değerlerinde görece olarak tutarlı sonuçlar ürettiğini gösterir. Özellikle 5 dakikalık ölçüm aralıklarında ve geniş bir zaman dilimine yayılan veri setinde bu seviyede bir doğruluk, modelin kestirim kabiliyetinin yüksek olduğunu ve sistem davranışını iyi öğrendiğini göstermektedir.

Grafikteki üst üste bindirilmiş tahmin ve gerçek aktif güç eğrileri, modelin yük eğilimlerini başarıyla yakaladığını göstermektedir. Ani tepe noktalarına veya çukur değerlerine yapılan tahminlerde ufak sapmalar olsa da tahmin eğrisi büyük ölçüde gerçek değerlerin şekline uyum sağlamıştır. Bu da modelin zaman serisi verisinden anlamlı örüntüler öğrenebildiğini göstermektedir. Sonuç olarak, GRU ve Bahdanau dikkat mekanizması ile oluşturulan bu yapı, yük tahmini uygulamaları için güçlü ve esnek bir çözüm sunmaktadır.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, dağıtım şebekelerinde yük talebi ve güç kalitesi unsurlarının YZ yöntemleri ile kestirimi gerçekleştirilmiştir. Çalışma kapsamında farklı veri tipleri ve farklı algoritmalar kullanılarak kapsamlı bir analiz yapılmış, elde edilen bulgular yüksek doğruluk ve uygulama açısından güçlü sonuçlar ortaya koymuştur.

Güç sisteminde harmonik kestirimi, aktif ve reaktif güç parametreleri kullanılarak gerçekleştirilmiş ve harmonik genlikleri başarılı bir şekilde öngörülmüştür. Bu amaçla GRU ve Bahdanau dikkat mekanizması algoritmaları kullanılmış, böylece karmaşık ve doğrusal olmayan yük profillerine sahip dağıtım sistemlerinde harmonik bozulmaların yüksek doğrulukla tahmini sağlanmıştır. Gerçek veriler üzerinde yapılan testler, modelin harmonik bozulmaları doğru biçimde kestirebildiğini göstermiştir. Bu yaklaşım, saha uygulamalarında güç kalitesi problemlerinin erken tespiti ve önleyici planlamalar için değerli bir katkı sunmaktadır.

Aydınlatma sistemleri özelinde gerçekleştirilen harmonik tahminlerinde ise yalnızca gerilim verileri kullanılmıştır. Bu veriler, hyperparameter optimizasyonu yapılmış LSTM modeli ile işlenmiş ve dropout tekniği uygulanarak modelin aşırı öğrenmesi engellenmiştir. Elde edilen sonuçlar, aydınlatma sistemlerinin harmonik bozulmalarının yüksek doğrulukla tahmin edilebildiğini ve bu yöntemin dağıtım şebekelerinde aydınlatma kaynaklı güç kalitesi problemlerinin analizinde uygulanabilir bir çözüm sunduğunu göstermiştir.

Yük talebi tahmini için geliştirilen GRU ve Bahdanau dikkat mekanizması algoritmalarından oluşan model aktif güç verileri kullanılarak eğitilmiştir. Bu yaklaşım sayesinde, ek veri kaynaklarına ihtiyaç duyulmadan şebekenin temel güç parametreleri üzerinden güvenilir tahminler yapılabileceği gösterilmiştir. Modelin performansı önemli bir ölçüt olan MAPE değeri ile değerlendirilmiş ve çoğu durumda %5 seviyelerinde hata oranları elde edilmiştir. Bu sonuç, yük talebinin kestiriminde kullanılan YZ tabanlı yöntemlerin saha uygulamaları için yüksek doğruluk ve güvenilirlik sunduğunu ortaya koymaktadır.

Çalışmanın özgün katkıları arasında, farklı veri tipleriyle (aktif-reaktif güç, gerilim) farklı tahmin hedeflerinin modellenmesi, harmonik ve yük tahmininin aynı kapsamda ele alınması ve tüm analizlerin gerçek saha verileri ile gerçekleştirilmiş olması öne çıkmaktadır. Bu bütüncül yaklaşım hem akademik literatüre katkı sağlamakta hem de saha uygulamaları açısından güçlü bir referans oluşturmaktadır.

Gelecek çalışmalar için, daha geniş veri kümeleri kullanılarak farklı coğrafi bölgelerden elde edilecek yük ve güç kalitesi profilleri üzerinde modellerin genelleştirilebilirliğinin test

edilebileceđi öngörölmektedir. Sektörel açıdan ise, bu tür YZ tabanlı tahmin modellerinin şebeke yönetim sistemlerine entegre edilmesi, dağıtım şirketlerinin planlama, yatırım ve güç kalitesi yönetiminde önemli avantajlar sağlayacaktır.

Sonuç olarak, bu tez çalışması, yük talebi ve güç kalitesi tahmininde YZ tabanlı yöntemlerin güvenilir, doğru ve uygulanabilir bir çözüm sunduđunu ortaya koymuştur. Gerçek saha verileriyle doğrulanan bulgular, bu tür modellerin dağıtım şebekelerinde karar destek mekanizmalarının geliştirilmesine ve enerji yönetiminde verimliliğın artırılmasına önemli katkılar sağlayacağını göstermektedir.



6. KAYNAKLAR

- [1] İ. Özer, S. B. Efe ve H. Özbay, “CNN/Bi-LSTM-based deep learning algorithm for classification of power quality disturbances by using spectrogram images”, *International Transactions on Electrical Energy Systems*, c. 31, sy 12, Ara. 2021, doi: 10.1002/2050-7038.13204.
- [2] S. B. Efe, “Harmonic filter application for an industrial installation”, içinde *2015 13th International Conference on Engineering of Modern Electric Systems (EMES)*, IEEE, Haz. 2015, ss. 1-4. doi: 10.1109/EMES.2015.7158395.
- [3] M. Akdeniz ve S. B. Efe, “Forecasting of Harmonic Distortions in MV Distribution Network Caused by Illumination Devices”, *Light & Engineering*, sy 02-2025, ss. 104-110, Nis. 2025, doi: 10.33383/2024-088.
- [4] P. Rodríguez-Pajarón, A. Hernández Bayo, ve J. V. Milanović, “Forecasting voltage harmonic distortion in residential distribution networks using smart meter data”, *International Journal of Electrical Power & Energy Systems*, c. 136, s. 107653, Mar. 2022, doi: 10.1016/j.ijepes.2021.107653.
- [5] Y. Kabalci, S. Kockanat, ve E. Kabalci, “A modified ABC algorithm approach for power system harmonic estimation problems”, *Electric Power Systems Research*, c. 154, ss. 160-173, Oca. 2018, doi: 10.1016/j.epsr.2017.08.019.
- [6] N. A. YALÇIN ve F. VATANSEVER, “Ara Harmonik Kestiriminde Prony ve ADALINE Yöntemlerinin Karşılaştırılması”, *Uludağ University Journal of The Faculty of Engineering*, ss. 405-418, Nis. 2020, doi: 10.17482/uumfd.592988.
- [7] P. M. Ivry, O. A. Oke, D. W. P. Thomas, ve M. Sumner, “Predicting Harmonic Distortion of Multiple Converters in a Power System”, *Journal of Electrical and Computer Engineering*, c. 2017, ss. 1-10, 2017, doi: 10.1155/2017/7621413.
- [8] P. Garanayak, R. T. Naayagi, ve G. Panda, “A High-Speed Master-Slave ADALINE for Accurate Power System Harmonic and Inter-Harmonic Estimation”, *IEEE Access*, c. 8, ss. 51918-51932, 2020, doi: 10.1109/ACCESS.2020.2980115.
- [9] E. M. Kuyumani, A. N. Hasan, ve T. Shongwe, “A Hybrid Model Based on CNN-LSTM to Detect and Forecast Harmonics: A Case Study of an Eskom Substation in South Africa”, *Electric Power Components and Systems*, c. 51, sy 8, ss. 746-760, May. 2023, doi: 10.1080/15325008.2023.2181883.

- [10] A. A. Jumilla-Corral, C. Perez-Tello, H. E. Campbell-Ramírez, Z. Y. Medrano-Hurtado, P. Mayorga-Ortiz, ve R. L. Avitia, “Modeling of Harmonic Current in Electrical Grids with Photovoltaic Power Integration Using a Nonlinear Autoregressive with External Input Neural Networks”, *Energies (Basel)*, c. 14, sy 13, s. 4015, Tem. 2021, doi: 10.3390/en14134015.
- [11] I. S. Jahan, V. Blazek, S. Misak, V. Snasel, ve L. Prokop, “Forecasting of Power Quality Parameters Based on Meteorological Data in Small-Scale Household Off-Grid Systems”, *Energies (Basel)*, c. 15, sy 14, s. 5251, Tem. 2022, doi: 10.3390/en15145251.
- [12] R. Tiwari vd., “Enhanced Power Quality and Forecasting for PV-Wind Microgrid Using Proactive Shunt Power Filter and Neural Network-Based Time Series Forecasting”, *Electric Power Components and Systems*, ss. 1-15, Eyl. 2023, doi: 10.1080/15325008.2023.2249894.
- [13] J. Yang, H. Ma, J. Dou, ve R. Guo, “Harmonic Characteristics Data-Driven THD Prediction Method for LEDs Using MEA-GRNN and Improved-AdaBoost Algorithm”, *IEEE Access*, c. 9, ss. 31297-31308, 2021, doi: 10.1109/ACCESS.2021.3059483.
- [14] F. M. Al Hadi ve H. H. Aly, “Harmonics Forecasting of Renewable Energy System Using Hybrid Model Based on LSTM and ANFIS”, *IEEE Access*, c. 12, ss. 50966-50985, 2024, doi: 10.1109/ACCESS.2024.3386092.
- [15] F. M. Al Hadi, H. H. Aly, ve T. Little, “Harmonics Forecasting of Wind and Solar Hybrid Model Based on Deep Machine Learning”, *IEEE Access*, c. 11, ss. 100438-100457, 2023, doi: 10.1109/ACCESS.2023.3314742.
- [16] E. M. Kuyunani, A. N. Hasan, ve T. Shongwe, “Improving voltage harmonics forecasting at a wind farm using deep learning techniques”, içinde *2021 IEEE 30th International Symposium on Industrial Electronics (ISIE)*, IEEE, Haz. 2021, ss. 1-6. doi: 10.1109/ISIE45552.2021.9576357.
- [17] H. K. Sahoo ve U. Subudhi, “Power System Harmonics Estimation Using Adaptive Filters”, içinde *Compendium of New Techniques in Harmonic Analysis*, InTech, 2018. doi: 10.5772/intechopen.74581.
- [18] L. Zjavka, “Power quality statistical predictions based on differential, deep and probabilistic learning using off-grid and meteo data in 24-hour horizon”, *Int J Energy Res*, c. 46, sy 8, ss. 10182-10196, Haz. 2022, doi: 10.1002/er.7431.
- [19] M. Panoiu, C. Panoiu, S. Mezinescu, G. Militaru, ve I. Baci, “Machine Learning Techniques Applied to the Harmonic Analysis of Railway Power Supply”, *Mathematics*, c. 11, sy 6, s. 1381, Mar. 2023, doi: 10.3390/math11061381.

- [20] I. Jahan, F. Mohamed, V. Blazek, L. Prokop, S. Misak, ve V. Snasel, "Power Quality Parameters Forecasting Based on SOM Maps with KNN Algorithm and Decision Tree", içinde *2023 23rd International Scientific Conference on Electric Power Engineering, EPE 2023*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/EPE58302.2023.10149269.
- [21] C. Altintasi, "Sine Cosine Algorithm Approaches for Directly Estimation of Power System Harmonics & Interharmonics Parameters", *IEEE Access*, c. 9, ss. 73169-73181, 2021, doi: 10.1109/ACCESS.2021.3081037.
- [22] I. S. Jahan, S. Misak, ve V. Snasel, "Smart Control System based on Power Quality Parameter Short-term Forecasting", içinde *2020 21st International Scientific Conference on Electric Power Engineering (EPE)*, IEEE, Eki. 2020, ss. 1-5. doi: 10.1109/EPE51172.2020.9269249.
- [23] P. Rodriguez-Pajaron, A. Hernandez, ve J. V. Milanovic, "Estimation of Harmonics in Partly Monitored Residential Distribution Networks With Unknown Parameters and Topology", *IEEE Trans Smart Grid*, c. 13, sy 4, ss. 3014-3027, Tem. 2022, doi: 10.1109/TSG.2022.3155976.
- [24] S. Q. Zhang ve Z. H. Zhou, "Harmonic recurrent process for time series forecasting", içinde *Frontiers in Artificial Intelligence and Applications*, IOS Press BV, Ağu. 2020, ss. 1714-1721. doi: 10.3233/FAIA200284.
- [25] J. Garrido-Zafra, A. Gil-de-Castro, A. Calleja-Madueno, M. L. Reyes, I. Moreno-Garcia, ve A. Moreno-Munoz, "Harmonic Current Magnitude and Phase Angle Forecasting to Support Harmonic Power Market Planning", *IEEE Trans Ind Appl*, ss. 1-11, 2025, doi: 10.1109/TIA.2025.3595123.
- [26] L. Hua, "Power Quality Prediction of Active Distribution Network Based on CNN-LSTM Deep Learning Model", 2021, ss. 108-122. doi: 10.1007/978-3-030-90196-7_11.
- [27] W. Zhang, B. Wang, D. Wang, J. Yu, ve C. Zhang, "Research on Power Quality Prediction Based on BiLSTM Optimized by Bayesian Algorithm", *J Phys Conf Ser*, c. 2221, sy 1, s. 012033, May. 2022, doi: 10.1088/1742-6596/2221/1/012033.
- [28] A. Karadeniz, "Advancing harmonic prediction for offshore wind farms using synthetic data and machine learning", *Computers and Electrical Engineering*, c. 127, s. 110613, Eki. 2025, doi: 10.1016/j.compeleceng.2025.110613.
- [29] K. Thomas, A. Rahman, A. Iqbal, S. Islam, U. Attique, ve M. Abdushakoor, "Predictive Modeling of Harmonic Distortion in Electrical Systems Using Machine Learning", içinde

- IECON 2024 - 50th Annual Conference of the IEEE Industrial Electronics Society*, IEEE, Kas. 2024, ss. 1-6. doi: 10.1109/IECON55916.2024.10905987.
- [30] E. Balouji, K. Backstrom, T. McKelvey, ve O. Salor, “Deep-Learning-Based Harmonics and Interharmonics Predetection Designed for Compensating Significantly Time-Varying EAF Currents”, *IEEE Trans Ind Appl*, c. 56, sy 3, ss. 3250-3260, May. 2020, doi: 10.1109/TIA.2020.2976722.
- [31] Y. Zhao ve J. V. Milanović, “Prediction of Harmonic Distortion in Sparsely Monitored Transmission Networks With Renewable Generation”, *IEEE Transactions on Power Delivery*, c. 39, sy 3, ss. 1710-1722, Haz. 2024, doi: 10.1109/TPWRD.2024.3373823.
- [32] Y. Xie vd., “Research on Harmonic Prediction and Regulation Strategy Based on Deep Learning”, içinde *2024 11th International Forum on Electrical Engineering and Automation (IFEEA)*, IEEE, Kas. 2024, ss. 415-420. doi: 10.1109/IFEEA64237.2024.10878757.
- [33] A. Taghvaie, T. Warnakulasuriya, D. Kumar, F. Zare, R. Sharma, ve D. M. Vilathgamuwa, “A Comprehensive Review of Harmonic Issues and Estimation Techniques in Power System Networks Based on Traditional and Artificial Intelligence/Machine Learning”, *IEEE Access*, c. 11, ss. 31417-31442, 2023, doi: 10.1109/ACCESS.2023.3260768.
- [34] P. Mack, M. de Koster, P. Lehnen, E. Waffenschmidt, ve I. Stadler, “Power Quality State Estimation for Distribution Grids Based on Physics-Aware Neural Networks—Harmonic State Estimation”, *Energies (Basel)*, c. 17, sy 21, s. 5452, Eki. 2024, doi: 10.3390/en17215452.
- [35] I. K. Nti, M. Teimeh, O. Nyarko-Boateng, ve A. F. Adekoya, “Electricity load forecasting: a systematic review”, *Journal of Electrical Systems and Information Technology*, c. 7, sy 1, s. 13, Ara. 2020, doi: 10.1186/s43067-020-00021-8.
- [36] A. Hussain, M. Rahman, ve J. A. Memon, “Forecasting electricity consumption in Pakistan: the way forward”, *Energy Policy*, c. 90, ss. 73-80, Mar. 2016, doi: 10.1016/j.enpol.2015.11.028.
- [37] F. Wu, C. Cattani, W. Song, ve E. Zio, “Fractional ARIMA with an improved cuckoo search optimization for the efficient Short-term power load forecasting”, *Alexandria Engineering Journal*, c. 59, sy 5, ss. 3111-3118, Eki. 2020, doi: 10.1016/j.aej.2020.06.049.
- [38] M. Talaat, M. A. Farahat, N. Mansour, ve A. Y. Hatata, “Load forecasting based on grasshopper optimization and a multilayer feed-forward neural network using regressive approach”, *Energy*, c. 196, s. 117087, Nis. 2020, doi: 10.1016/j.energy.2020.117087.

- [39] H. H. H. Aly, "A proposed intelligent short-term load forecasting hybrid models of ANN, WNN and KF based on clustering techniques for smart grid", *Electric Power Systems Research*, c. 182, s. 106191, May. 2020, doi: 10.1016/j.epsr.2019.106191.
- [40] I. Ozer, S. B. Efe, ve H. Ozbay, "A combined deep learning application for short term load forecasting", *Alexandria Engineering Journal*, c. 60, sy 4, ss. 3807-3818, Ağu. 2021, doi: 10.1016/j.aej.2021.02.050.
- [41] S. Muzaffar ve A. Afshari, "Short-Term Load Forecasts Using LSTM Networks", *Energy Procedia*, c. 158, ss. 2922-2927, Şub. 2019, doi: 10.1016/j.egypro.2019.01.952.
- [42] H. J. Sadaei, P. C. de Lima e Silva, F. G. Guimarães, ve M. H. Lee, "Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series", *Energy*, c. 175, ss. 365-377, May. 2019, doi: 10.1016/j.energy.2019.03.081.
- [43] C. Fan, C. Ding, J. Zheng, L. Xiao, ve Z. Ai, "Empirical Mode Decomposition based Multi-objective Deep Belief Network for short-term power load forecasting", *Neurocomputing*, c. 388, ss. 110-123, May. 2020, doi: 10.1016/j.neucom.2020.01.031.
- [44] A. Dedinec, S. Filiposka, A. Dedinec, ve L. Kocarev, "Deep belief network based electricity load forecasting: An analysis of Macedonian case", *Energy*, c. 115, ss. 1688-1700, Kas. 2016, doi: 10.1016/j.energy.2016.07.090.
- [45] M. Malekizadeh, H. Karami, M. Karimi, A. Moshari, ve M. J. Sanjari, "Short-term load forecast using ensemble neuro-fuzzy model", *Energy*, c. 196, s. 117127, Nis. 2020, doi: 10.1016/j.energy.2020.117127.
- [46] J. D. Glover, M. S. Sarma, ve T. Overbye, "POWER SYSTEM ANALYSIS AND DESIGN", Oca. 2011. [Çevrimiçi]. Erişim adresi: <http://www.uvic.ca/engineering/current/undergrad/index.php#section0-25>
- [47] J. , & W. N. R. Arrillaga, *Power system harmonics*, 2., c. 2. Hoboken, NJ, USA: Wiley, 2003.
- [48] IEEE Std 519-2014, "IEEE Recommended Practice and Requirements for Harmonic Control in Electric Power Systems", 2014.
- [49] MATH H.J. BOLLEN ve IRENE YU-HUA GU, *Signal Processing of Power Quality Disturbances*, Wiley-IEEE Press. Hoboken, NJ, US, 2006.
- [50] H. Akagi, "New trends in active filters for power conditioning", *IEEE Trans Ind Appl*, c. 32, sy 6, ss. 1312-1322, 1996, doi: 10.1109/28.556633.
- [51] S. Rahmani, A. Hamadi, K. Al-Haddad, ve L. A. Dessaint, "A Combination of Shunt Hybrid Power Filter and Thyristor-Controlled Reactor for Power Quality", *IEEE Transactions on*

- Industrial Electronics*, c. 61, sy 5, ss. 2152-2164, May. 2014, doi: 10.1109/TIE.2013.2272271.
- [52] Celal Kocatepe, Mehmet Uzunoglu, Recep Yumurtacı, Arif Karakaş, ve Oktay Arıkan, *Elektrik Tesislerinde Harmonikler*, Birsen Yayınevi. İstanbul, 2003.
- [53] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities.”, *Proceedings of the National Academy of Sciences*, c. 79, sy 8, ss. 2554-2558, Nis. 1982, doi: 10.1073/pnas.79.8.2554.
- [54] D. E. Rumelhart, G. E. Hinton, ve R. J. Williams, “Learning representations by back-propagating errors”, *Nature*, c. 323, sy 6088, ss. 533-536, Eki. 1986, doi: 10.1038/323533a0.
- [55] P. Sree Muhuri, “Using Long Short-Term Memory (LSTM) Recurrent Neural Network (RNN) to Classify Network Attacks”, Greensboro, North Carolina, 2019.
- [56] S. Hochreiter ve J. Schmidhuber, “Long Short-Term Memory”, *Neural Comput*, c. 9, sy 8, ss. 1735-1780, Kas. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [57] F. A. Gers, J. Schmidhuber, ve F. Cummins, “Learning to Forget: Continual Prediction with LSTM”, *Neural Comput*, c. 12, sy 10, ss. 2451-2471, Eki. 2000, doi: 10.1162/089976600300015015.
- [58] Kyunghyun Cho, Bart van Merriënboer, Dzmitry Bahdanau, ve Yoshua Bengio, “On the Properties of Neural Machine Translation: Encoder-Decoder Approaches”, içinde *Proc. Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*, Doha, Katar, 2014, ss. 103-111.
- [59] Junyoung Chung, Çağlar Gulcehre, KyungHyun Cho, ve Yoshua Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling”, *arXiv preprint arXiv:1412.3555*, 2014.
- [60] D. Bahdanau, K. Cho, ve Y. Bengio, “Neural Machine Translation by Jointly Learning to Align and Translate”, May. 2016, [Çevrimiçi]. Erişim adresi: <http://arxiv.org/abs/1409.0473>
- [61] M.-T. Luong, H. Pham, ve C. D. Manning, “Effective Approaches to Attention-based Neural Machine Translation”, Eyl. 2015, [Çevrimiçi]. Erişim adresi: <http://arxiv.org/abs/1508.04025>
- [62] M. S. Cengiz, “Lighting Master Plan Application in Living Areas”, *Light & Engineering*, sy 06-2022, ss. 124-132, Ara. 2022, doi: 10.33383/2021-111.

- [63] K. Delendik, N. Kolyago, ve O. Voitik, "Design and investigation of cooling system for high-power LED luminaire", *Computers & Mathematics with Applications*, c. 83, ss. 84-94, Şub. 2021, doi: 10.1016/j.camwa.2020.01.026.
- [64] J. Snyder, "Energy-saving strategies for luminaire-level lighting controls", *Build Environ*, c. 169, Şub. 2020, doi: 10.1016/j.buildenv.2018.10.026.
- [65] S. Yoomak, C. Jettanasen, A. Ngaopitakkul, S. Bunjongjit, ve M. Leelajindakrairerk, "Comparative study of lighting quality and power quality for LED and HPS luminaires in a roadway lighting system", *Energy Build*, c. 159, ss. 542-557, Oca. 2018, doi: 10.1016/j.enbuild.2017.11.060.
- [66] M. S. Cengiz, "Role of Functional Illumination Urban Beautification: Qatar-Doha Road Illumination Case", *Light & Engineering*, sy 03-2022, ss. 34-42, Haz. 2022, doi: 10.33383/2021-093.
- [67] I. Serkan Uncu ve M. Kayakus, "Short Free-Standing Pole LED Luminaire and Lens Design for Road Lighting", *Scientia Iranica*, c. 0, sy 0, ss. 0-0, May. 2021, doi: 10.24200/sci.2021.55819.4421.
- [68] T. F. Megahed ve M. F. Kotb, "Improved design of LED lamp circuit to enhance distribution transformer capability based on a comparative study of various standards", *Energy Reports*, c. 8, ss. 445-465, Kas. 2022, doi: 10.1016/j.egyr.2022.07.027.
- [69] S. B. Efe, H. Ozbay, ve I. Ozer, "Experimental Design and Analysis of Adaptive LED Illumination System", *Light & Engineering*, sy 04-2022, ss. 63-70, Ağu. 2022, doi: 10.33383/2021-107.
- [70] Ł. Putz, K. Bednarek, ve R. Nawrowski, "Disturbances Generated by Lighting Systems with LED Lamps and the Reduction in Their Impacts", *Applied Sciences*, c. 9, sy 22, s. 4894, Kas. 2019, doi: 10.3390/app9224894.
- [71] A. Wantuch ve M. Olesiak, "Effect of LED Lighting on Selected Quality Parameters of Electricity", *Sensors*, c. 23, sy 3, s. 1582, Şub. 2023, doi: 10.3390/s23031582.
- [72] N. Phannil, C. Jettanasen, ve A. Ngaopitakkul, "Harmonics and Reduction of Energy Consumption in Lighting Systems by Using LED Lamps", *Energies (Basel)*, c. 11, sy 11, s. 3169, Kas. 2018, doi: 10.3390/en11113169.
- [73] S. UDDIN, H. SHAREEF, O. KRAUSE, A. MOHAMED, M. A. HANNAN, ve N. N. ISLAM, "Impact of large-scale installation of LED lamps in a distribution system", *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, c. 23, ss. 1769-1780, 2015, doi: 10.3906/elk-1404-243.

- [74] J. Molina, J. J. Mesas, N. Mesbahi, ve L. Sainz, “LED lamp modelling for harmonic studies in distribution systems”, *IET Generation, Transmission & Distribution*, c. 11, sy 4, ss. 1063-1071, Mar. 2017, doi: 10.1049/iet-gtd.2016.1696.
- [75] M. S. Cengiz, “Using Electric Lighting to Support Daylighting in Architectural Building Designs”, *Light & Engineering*, sy 01-2022, ss. 113-123, Şub. 2022, doi: 10.33383/2021-086.
- [76] A. Eslami, M. Negnevitsky, E. Franklin, ve S. Lyden, “Review of AI applications in harmonic analysis in power systems”, *Renewable and Sustainable Energy Reviews*, c. 154, s. 111897, Şub. 2022, doi: 10.1016/j.rser.2021.111897.
- [77] I. D. Melo, J. L. R. Pereira, A. M. Variz, ve P. F. Ribeiro, “Allocation and sizing of single tuned passive filters in three-phase distribution systems for power quality improvement”, *Electric Power Systems Research*, c. 180, s. 106128, Mar. 2020, doi: 10.1016/j.epsr.2019.106128.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı Metin AKDENİZ
Doğum Yeri
Doğum Tarihi
Uyruğu
Telefon
E-Posta Adresi
Web Adresi

	Eğitim Bilgileri
	Lisans
Üniversite	
Fakülte	
Bölümü	
Mezuniyet Yılı	

Yüksek Lisans	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	
Mezuniyet Yılı	

Doktora	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	

Makale ve Bildiriler