

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

ELEKTRİK ENERJİ SİSTEMLERİNDEKİ
GÜÇ KALİTESİ BOZULMALARININ
AKILLI YÖNTEMLER İLE ANALİZİ

İsmail BOZDAĞ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Tezli Yüksek Lisans Programı

MAYIS 2022

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ELEKTRİK ENERJİ SİSTEMLERİNDEKİ
GÜÇ KALİTESİ BOZULMALARININ
AKILLI YÖNTEMLER İLE ANALİZİ**

İsmail BOZDAĞ

DANIŞMAN

Dr. Öğr. Üyesi Serhat Berat EFE

II. DANIŞMAN

Dr. Öğr. Üyesi İlyas ÖZER

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği Tezli Yüksek Lisans Programı

MAYIS 2022

ONAY

İsmail BOZDAĞ tarafından hazırlanan “**Elektrik Enerji Sistemlerindeki Güç Kalitesi Bozulmalarının Akıllı Yöntemler ile Analizi**” adlı tez çalışması .../.../... tarihinde yapılan sınavla aşağıdaki jüri tarafından oybirliği/oyçokluğu ile Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Ünvanı, Adı ve Soyadı

(Danışman)

Ünvanı, Adı ve Soyadı

(Üye)

Ünvanı, Adı ve Soyadı

(Üye)

Ünvanı, Adı ve Soyadı

(Üye) (varsa)

Ünvanı, Adı ve Soyadı

(Üye) (varsa)

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

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS
ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**Elektrik Enerji Sistemlerindeki Güç Kalitesi Bozulmalarının Akıllı Yöntemler ile Analizi**” 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. 27/05/2022

İsmail BOZDAĞ

ÖNSÖZ

Harmonikler, günümüz üretim teknolojilerinin değişmesi ile birlikte iletim ve dağıtım sistemlerinin artan problemleri arasındadır.

Elektrik cihazlarının tamamı saf sinüs ve sabit frekansta bulunan alternatif akım ve gerilim değerlerine göre tasarlanmaktadır. Ancak uygulamada bu karakteristikte bulunan eğrilere nadiren rastlanmaktadır. Harmonik frekanslar, temel frekansın tam katlarında oluşarak sinüzoidal eğri üzerinde bozulmalara neden olmaktadır.

1950'lerden bu yana harmonikler incelenmekte olup, etkilerini azaltmak için çalışmalara devam edilmektedir. Günümüzde alınan en birincil tedbirler arasında filtreleme yöntemleri bulunmaktadır. Bunun yanında, yapay zekâ uygulamalarındaki gelişmelere paralel olarak, filtreleme dışında harmoniklerin önceden tespit edilmesi ve buna göre önlem alınması ile ilgili çalışmalar hız kazanmıştır. Belirtilen çalışmalar, bu tezin motivasyonunu oluşturmaktadır.

Bu çalışmada, uzun-kısa bellek (LSTM) yaklaşımı kullanılarak gerçek bir güç sisteminden alınan veriler üzerinden harmoniklerin tahminlenmesi yapılmıştır. Elde edilen sonuçlar üzerinden önerilen modelin verimi incelenmiş ve öneriler sunulmuştur.

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar her konuda benden yardımlarını esirgemeyen danışman hocamlarım Sayın Dr. Öğr. Üyesi Serhat Berat EFE ve Sayın Dr. Öğr. Üyesi İlyas ÖZER'e şükranlarımı sunarım.

Bu günlere gelmemde büyük emekleri olan annem ve babama, yoğun çalışma temposunda benden maddi ve manevi desteğini esirgemeyen eşim Melda'ya, varlıkları ile birer motivasyon kaynağı olan abim Sami'ye, ablam Funda'ya teşekkür ederim.

ÖZET

YÜKSEK LİSANS TEZİ

ELEKTRİK ENERJİ SİSTEMLERİNDEKİ GÜÇ KALİTESİ BOZULMALARININ AKILLI YÖNTEMLER İLE ANALİZİ

İsmail BOZDAĞ

Bandırma Onyedi Eylül Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Serhat Berat EFE

İkinci Danışman: Dr. Öğr. Üyesi İlyas ÖZER

Mayıs 2022, 44 sayfa

Üretim teknolojisinin gelişmesi ve farklılaşması, iletim/dağıtım sistemlerinde bulunan yüklerde çeşitliliğe neden olmuştur. Meydana gelen bu çeşitliliğin en büyük etkilerinden biri ise yarı iletken teknolojisinin artması ile sistem içerisinde doğrusal olmayan yüklerin fazlalaşmasıdır.

Doğrusal olmayan yükler, akım ve gerilim karakteristiği saf sinüs formunda olmayan yükler olarak tanımlanmaktadır. Başlıca doğrusal olmayan yükler güç elektroniği elemanları, transformatörler ve yüksek güçlü endüksiyon motorlarıdır. Harmonikler sistemde ek enerji kayıplarına, ısınmalara, yalıtımlarının zarar görmelerine yol açarlar. Bu nedenle, harmoniklerin oluşmadan giderilmesi önem taşımaktadır.

Bu tezde, akıllı yöntemler ile harmoniklerin tahminlenmesi yapılarak dağıtım sisteminde verebileceği zararların engellenmesi amaçlanmıştır. Bu kapsamda Bandırma Organize Sanayi Bölgesinden alınan gerçek sistem güç kalitesi verileri kullanılarak LSTM temelli bir tahminleme algoritması geliştirilmiştir. Tez çalışmasında fiziksel bir sistemden alınan gerçek verilerin kullanılması ile benzetim çalışmalarında ihmal edilmesi olası parametrelerin de hesaplamaya

katılması saęlanmıřtır. Elde edilen sonular grafikler zerinden tartıřılmıř, tahminleme bařarımının olduka yksek olduęu gzlenmiřtir.

Anahtar kelimeler: G Sistemlerinde Harmonikler, Harmonik Bozulma, Uzun-Kısa Sreli Bellek.



ABSTRACT

M.Sc. THESIS

ANALYSIS OF POWER QUALITY DISTORTIONS IN ELECTRICAL ENERGY SYSTEMS WITH INTELLIGENT METHODS

İsmail BOZDAĞ

**Bandırma Onyedi Eylül University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Supervisor: Asst. Prof. Dr. Serhat Berat EFE

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

May 2022, 44 pages

The development and differentiation of production technology has led to diversity in loads in transmission/distribution systems. One of the biggest effects of this diversity is the increase in non-linear loads in the system with the increase in semiconductor technology.

Nonlinear loads are defined as loads whose current and voltage characteristics are not pure sinusoidal. The main non-linear loads are power electronic components, transformers and high-power induction motors. Harmonics cause additional energy losses, heating and damage to the insulation in the system. Therefore, it is important to eliminate harmonics before they occur.

In this thesis, it is aimed to prevent the damages that may occur in the distribution system by forecasting the harmonics with intelligent methods. In this context, an LSTM based estimation algorithm has been developed by using real system power quality data from Bandırma Organized Industrial Zone. By using real data from a physical system in the thesis, parameters that are likely to be neglected in simulation studies are also included in the calculation.

The results obtained were discussed over graphics, and it was observed that the forecasting performance was quite high.

Keywords: Harmonics in Power Systems, Harmonic Distortion, Long-Short-Term Memory

İÇİNDEKİLER

	Sayfa
ÖZET	I
ABSTRACT	III
İÇİNDEKİLER.....	V
ŞEKİL LİSTESİ	VII
TABLO LİSTESİ.....	VIII
SİMGE VE KISALTMA LİSTESİ.....	IX
1. GİRİŞ.....	1
2. HARMONİKLER.....	8
2.1 HARMONİK TANIMI.....	8
2.1.1 Ara Harmonikler	8
2.2 HARMONİKLER İLE İLGİLİ GENEL TERİMLER	9
2.3 HARMONİKLERİN MATEMATİKSEL MODELLERİ	11
2.3.1 Sinüzoidal Olmayan Durumlarda Elektriksel Büyüklükler.....	12
3. HARMONİK TAHMİNİNDE KULLANILAN ALGORİTMALAR	15
3.1 RNN (Recurrent Neural Network)	15
3.1.1 LSTM (Uzun – Kısa Süreli Bellek) Mimarisi.....	16
3.1.1.1 LSTM’lerin Arkasındaki Temel Fikir	17
3.1.2 GRU (Gated Recurrent Unit)	20
3.2 XCB (Extreme Gradient Boosting)	21
3.3 LGBM (Light Gradient Boosted Machine)	22
3.4 RFA (Random Forest)	23
4. GÜÇ KALİTESİ BOZULMALARININ AKILLI YÖNTEMLER İLE TAHMİNLENMESİ.....	25
4.1 UYGULAMA SİSTEMİ.....	25
4.2 VERİLERİN HAZIRLANMASI VE PROGRAM UYGULAMA ADIMLARI	27

5. DENEYSEL ANALİZ VE TAHMİNLEME	30
6. SONUÇ VE ÖNERİLER	36
7. KAYNAKLAR	38
ÖZGEÇMİŞ	44



ŞEKİL LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 1-1: Harmonik İçeren Bir Dalga Şekli	2
Şekil 1-2: Dört Katmanlı LSTM Ağı	4
Şekil 3-1: RNN Mimarisi.....	15
Şekil 3-2: LSTM Ağı Mimarisi.....	17
Şekil 3-3: LSTM Hücre Durumu	17
Şekil 3-4: LSTM 1. Adım	18
Şekil 3-5: LSTM 2. Adım	19
Şekil 3-6: LSTM 3. Adım	19
Şekil 3-7: LSTM 4. Adım	20
Şekil 3-8: GRU Mimarisi	21
Şekil 3-9: XCB Mimarisi.....	22
Şekil 3-10: LGBM Mimarisi	23
Şekil 3-11: RFA Mimarisi	24
Şekil 4-1: L1 Fazına Ait Akım Harmonikleri ve Aktif Güç Veri Grafikleri.....	25
Şekil 4-2: L2 Fazına Ait Akım Harmonikleri ve Aktif Güç Veri Grafikleri.....	26
Şekil 4-3: L3 Fazına Ait Akım Harmonikleri ve Aktif Güç Veri Grafikleri.....	26
Şekil 5-1: L1 fazına ait gerçek ve tahmin edilen değerler.....	31
Şekil 5-2: L1 fazına ait eğitim ve test kayıpları	32
Şekil 5-3: L2 fazına ait gerçek ve tahmin edilen değerler.....	33
Şekil 5-4: L2 fazına ait eğitim ve test kayıpları	33
Şekil 5-5: L3 fazına ait gerçek ve tahmin edilen değerler.....	34
Şekil 5-6: L3 fazına ait eğitim ve test kayıpları	35

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 2-1: Harmoniklerin matematiksel tanımları.....	8
Tablo 2-2: Fourier Katsayıları	12
Tablo 4-1: Metrik Değerler ve Formülleri	27
Tablo 5-1: L1, L2 ve L3 Fazlarına Ait Test Verileri	30
Tablo 5-2: L1, L2 ve L3 fazlarına ait en düşük RMSE, MAE ve MAPE değerleri.....	31



SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
V	: Gerilim
I	: Akım
Q	: Reaktif Güç
L	: Bobin
C	: Kapasitör
Hz	: Frekans
D	: Distorsiyon
THD	: Toplam harmonik bozulma
DF	: Bozulma faktörü
CF	: Tepe faktörü
HF	: Harmonik faktörü
TTD	:Toplam talep bozulması
k_f	: Şekil (Form) faktörü
$F(t)$	: Fourier bileşen
f_n	: n. frekans bileşeni
A_0	: 0. fourier katsayısı
$V(t)$	: Gerilim ani değeri
$i(t)$	: Akım ani değeri
$p(t)$	: Ani güç
P	: Aktif güç
S	: Görünür güç
GF	: Güç faktörü

Kısaltmalar	Açıklama
LSTM	: Uzun – Kısa Süreli Bellek
BGKD	: Birleşik Güç Kalitesi Düzenleyici
UPS	: Kesintisiz Güç Kaynakları
YSA	: Yapay Sinir Ağları
RNN	: Tekrarlayan Sinir Ağları
OG	: Orta Gerilim
SVM	: Destek Vektör Makinesi
SVR	: Destek vektör regresyonu
OLTC	: Yükte Kademe Değiştirici
SVC _s	: Statik VAR Kopmanzasyonu
BPNN	: Geri Yayılım Sinir Ağları
LR	: Doğrusal regresyon
RBFN	: Radayal Akıslı Sinir Ağı

1. GİRİŞ


Günümüzde ekonomiye ciddi katkılarda bulunan sanayi tesislerinde; üretimin sürekliliği başta olmak üzere, teçhizatların en güvenli ortamda çalıştırılması amaçlanmaktadır. Bir sanayi tesisi kurulurken, öncelikle temel altyapı ihtiyaçları olan enerji ihtiyacının karşılanıp karşılanamayacağı hususunu araştırma yoluna gitmektedir. Bir sonraki adım ise alınacak enerjinin kalitesinin artırılmasıdır [1].

Sanayi tesisleri, güç ve üretim konusuna bağlı olarak dağıtım veya iletim şebekelerine bağlantı yapabilirler. İlgili iletim ve dağıtım şebeke işletmecilerinin ise, sürekli ve kesintisiz enerji sağlamanın yanı sıra kaliteli enerji sağlamak ve tesislerden gelecek her türlü bozucu etkinin önüne geçmek en büyük hedefleri arasında gelmektedir [1].

Özellikle günümüz güç sistemlerinde çeşitli bozucu etkiler görülmektedir. İdeal bir alternatif akım güç sisteminde elektrik enerjisinin üretilmesi, iletilmesi ve dağıtılması belirli gerilim seviyelerinde tek ve sabit frekansta yapılır. Bu tür sistemlerde gerilim ve akım dalga şekilleri tam sinüs formundadır. Ancak pratikte bu şartlar tam olarak sağlanamaz. Güç sistemi problemlerinin temellerini ani kesintiler, frekanstaki değişimler, yük dengesizlikleri, yenilenebilir enerji kaynaklarının şebekeye bağlanması ve yıldırım gibi etkenler oluşturmaktadır [2]. Araştırmacılar, temel problemlerin başında gelen frekans değişimlerini, dinamik kontrol yöntemleri ile engellemeye çalışmaktadır [3]. M. Kesler ve E. Özdemir'in çalışmasında Birleşik Güç Kalitesi Düzenleyici (BGKD) ile şebekede meydana gelen harmoniklerin ortadan kaldırılması amaçlanmıştır. İlgili çalışma ile akım harmonikleri, yük akımında meydana gelen dengesizlikler, gerilimin tolerans değerlerin dışına çıkması gibi güç kalitesi problemleri düzeltilmiştir [4]. Bu ve benzer elektriksel problemlerin yanında, bir başka güç sistemi problemi de artan enerji talepleridir. Artan enerji talepleri ile birlikte bir güç sistemini belirli bir kararlılıkta çalıştırılması da zorlaşmaktadır. Bu zorlukların temelinde ise gerilim değeri (V) ve reaktif güç (Q) dengesi ile birlikte gelen gerilim kararlılığıdır [5].

Günümüz güç sistemlerinde, gerilim ve akımın sinüs formuna en yakın halde olması, güç faktörünün 1'e yakın olması, gerilim ve frekansın dengeli olması bir güç sisteminde bulunan problemleri çoğunlukla ortadan kaldırmaktadır [6]. İlgili problemlerin kaldırılmasında ise harmonik değerlerinin belirlenen sınır değerlerde tutulmasının büyük önemi vardır.

Harmonik kavramı, ani devreye girip çıkan yükler veya gerilim dalga şekli sinüs formundan uzak jeneratörler nedeni ile alternatif akım ve gerilimde meydana gelen bozukluklar olarak tanımlanabilir. Bu durumda, ana bileşen frekansının tam katları frekanslarda sinüzoidal bileşenler oluşmaktadır [7].



Harmonikler 1893 yıllarına kadar geçmişi olan elektriksel bozucu etkilerden biridir. Bu yıllarda ilk olarak ısınma problemi yaşanan bir motor üzerinde harmonikler gözlemlenmiştir. Isınmanın nedeninin, güç sistemi içerisinde meydana gelen rezonans nedeni ile oluştuğu tespit edilmiştir. Detaylı yapılan araştırmalar neticesinde ise meydana gelen rezonansın sistemde var olan değişken dalga şekillerinden, yani harmoniklerden dolayı oluştuğu sonucuna ulaşılmıştır. Bu tarihten sonra ise hat frekans harmonikleri nedeni ile iletim hatlarında meydana gelen sorunlar ilk harmonik sorunları arasına girmiştir. Günümüzde ise iletim veya dağıtım şebekelerinde harmonikler bozucu etkiler arasında yerini almaktadır [8].

Sanayinin gelişmesi ile paralel büyüyen teknoloji neticesinde, dağıtım sistemlerinde elektriksel karakteristiği farklı olan yükler ortaya çıkmıştır. Genelde yüklerin akım ve gerilim karakteristikleri her zaman sinüs formunda olması istenir. Ancak son yıllarda akım ve gerilim karakteristiği sinüs formundan uzak yüklerin sayısı oldukça arttığı gözlemlenmiştir [8].

Doğrusal olmayan yükler, sistem üzerinde sinüs formundan uzak akım ve gerilim dalga şekillerinin oluşmasına neden olurlar. Güç elektroniği elemanları, transformatörler, dönüştürücüler ve ark ocakları gibi elemanlar genellikle doğrusal olmayan yükler olarak

bilinmektedir. Sistem üzerinde enerji kayıplarının yaşanması, yalıtımlarda meydana gelen bozukluklar ve malzemelerde yaşanan ısınma problemleri harmoniklerin habercisidir [9].

Bunlar gibi harmoniklerden dolayı şebeke üzerinde meydana gelebilecek olumsuzlukların önüne geçebilmek için aktif ve pasif filtreleme sistemleri geliştirilmiştir. Bu sistemler harmoniklerin oluşması durumunda ya da sürekli devrede kalarak bozucu etkileri ortadan kaldırmayı hedeflemektedir.

Aktif filtreler, seri aktif filtre, şönt aktif filtre, birleşik güç kalitesi düzenleyicisi olarak ayrılırken, pasif filtreler ise seri pasif filtre ve şönt pasif filtre olarak ayrılmaktadır [7].

İleri güç elektroniği temellerine dayanan aktif filtreler, pasif filtrelere göre oldukça maliyetlidirler. Aktif filtreler, temel frekans dışındaki diğer frekanslara yok ederek harmonikleri ortadan kaldırabilmektedir. Aktif filtrenin çalışma prensibi, doğrusal olmayan yükün çekeceği temel bileşen dışındaki akımı uygun bir fazda yüke uygulamaktır [8].

Pasif filtreler, seri bağlı kondansatör ve endüktans bloğundan oluşmaktadırlar. Bu bloğa gerektiği durumlarda omik direnç de ilave edilebilir. Pasif filtrelerin çalışma prensibi, temel bileşenin katları olan harmonikli dalga formunun yüke uygulanmadan L ve C değerleri üzerinden toprak ile irtibatının sağlanmasıdır. Her bir harmonik bileşenin yok edilmesi için L ve C değerlerinin ayrı ayrı belirlenmesi gerekmektedir [8].

Günümüzde ise şebekelerde bozucu etki yaratan harmoniklerin belirli bir süre öncesinden tahmin edilerek müdahale edilmesi hedeflenmektedir. Yapılan tahminleme çalışmaları ile sürekli devrede olan filtreleme sistemlerinin harmonik oluşacağı sürelerde devreye girmesi maliyet ve teçhizat ömürleri bakımından ciddi kazançlar sağlayabilecektir.


Teknolojik cihazların gelişmesi ile tahminde bulunmak istenen alan hakkında veri elde edilebilen ölçüm cihazları ortaya çıkmıştır. Elde edilen verilerle istatistiksel analizler ortaya konarak zaman serilerinde tahminleme çalışmaları önem kazanmaya başlamıştır. Verinin giderek büyümesi ile analiz yöntemleri de gelişmeye başlamıştır. Yapay sinir ağları (YSA'lar) ve derin öğrenme uygulamaları bu alanda hızla gelişen tekniklerdir [10].

Bu teknikler kullanılarak güç sistemlerinde meydana gelen problemlerin önceden tahmini için çeşitli çalışmalar yapılmıştır. K. J. T. N. Fernando and A. Kalam tarafından geliştirilen YSA'larının eğitilmesi sonucu oluşturulan bir mimari ile gerilim kararsızlıklarının tahminlemesi yapılmış ve YSA'nın SCADA sistemlerine entegre edilerek kullanılabileceği savunulmuştur [11]. M. Negnevitsky'nin yapmış olduğu çalışmada güç sistemlerinde aşırı yükler ve voltaj kontrolünde yapılması gereken eylemleri planyan akıllı sistemler tasarlamış ve ilgili sistemin SCADA sistemine entegre edilerek kullanılabileceği savunulmuştur [12]. D. Thukaram and H. Kashyap

önerdiği YSA ile pratik bir güç sisteminde farklı yükleme koşulları için kontrolörler olarak SVCs, jeneratör uyarımı ve OLTC transformatörlerini kullanarak voltaj kararlılığı üzerinde çalışmalar yapmıştır [13]. Güç sistemlerinde her ne kadar geleneksel yapay sinir ağları ile ilgili çalışmalar yapılsa da günümüz teknolojisinde bu yapılardan daha gelişmiş olan tekrarlayan sinir ağları (RNN) kullanılmaya başlanmıştır.

Tekrarlayan sinir ağları (RNN), zaman serisi öngörü uygulamalarında daha iyi performans göstermesini sağlayan sıralı ve tekrarlı olma özelliklerine sahip yapay sinir ağlarıdır. RNN ilk kez basit tekrarlayan ağ olarak Elman tarafından önerilmiştir. Hochreiter ve Bengio ve ark. tarafından RNN ile ilgili uzun süreli öğrenme problemleri ile gradyanların güncellenmesi sorunlarına değinilmiştir [10].

RNN mimarisinden oluşan LSTM'ler ise, tekrarlayan sinir ağlarında ortaya çıkan gradyan sorununu çözen ve uzun sıralı verileri belleğinde tutabilen uzun kısa-süreli hafıza modelidir ve ilk olarak Hochreiter ve Schmidhuber tarafından tanıtılmıştır [10].



Şekil 1-2: Dört Katmanlı LSTM Ağı

Güç kalitesi sorunları genellikle harmonik gerilimler ve akımları içeren geniş bir olay yelpazesidir. Güç kalitesi sorunlarının ışığında olayların en kısa sürede algılanması ve ele alınması zorunlu hale gelmiştir. Bu aşamada ise makine öğrenimi alanında LSTM'ler sıkça kullanılmakta ve önemli sonuçlar elde edilmektedir. Bu sistemlerin uygulanmasında izlenen genel prosedür veri kümesinden özellik çıkarma ile başlar, ardından modelin eğitimi ve test edilmesiyle sonuçlanır. Analiz aşamasında bir sinyalin bölümleri oluşturulur ve bu bölümlerden anahtar istatistiksel veriler türetilir. Türetilen veriler LSTM ağına giriş verisi olarak beslenir ve tahminleme sonuçları değerlendirilir[14]. W. L. Rodrigues Junior ve ark. önerdikleri yöntem periyodik olarak ilerleyen harmonik bozulma ve kısa süreli güç kalitesi bozulmalarına karşı tasarlanmıştır. Bu tasarım sekiz

ardışık katmandan meydana gelmektedir ve bir katmanı da LSTM mimarisini barındırmaktadır. Tasarım sonucunda, harmonik tahmininde kullanılan LSTM katmanları nerede oluştuklarından bağımsız olarak ağız özelliklerini ve büyük dizileri kapsayan ilişkileri öğrendiği durumlarda iyi çalıştığı kanıtlanmıştır [15]. S. K. G. Manikonda ve ark. güç kalitesi olaylarını sınıflandırma çalışması yapmıştır. Girdi veri kümesinin büyüklüğü göz önüne alındığında verilerden önemli istatistiksel özellikler türetilerek özellik çıkarımı sağlanmıştır. Çıkarılan veriler ile LSTM eğitimi sağlanarak tahminleme aşamasında önemli sonuçlar alınmıştır [16].

M. A. Rodriguez ve ark. güç kalitesi bozulmalarının otomatik sınıflandırılması için bir algoritma önerdiler. Önerilen algoritma sinyal boyutunu küçültmek için dâhil edilen evrişimli otomatik kodlayıcı sıkıştırma mimarisi ve LSTM'den oluşmaktadır. Önerilen mimarinin algoritması dokuz bozulma için formüle edilmiş karakteristik matematiksel modellerle oluşturulan sentetik veri tabanı uygulanarak test edilmiştir. Sonuç olarak geleneksel LSTM mimarisine göre zaman işleme ve daha yüksek doğruluk açısından üstün performans göstermiştir [17]. D. Ahmad, S. Wang, and M. Alam OG havai hat iletkenlerinde arıza tespiti için LSTM yöntemi kullanan bir çalışma önerdiler. Yöntem, ölçülen voltaj sinyalinde kısmi deşarjın model analizine dayalı olarak çalışmaktadır. Bu çalışma ile LSTM yapısı kısmi deşarjın doğrusal olmayan özelliklerini öğrenebildiği ve hatayı tespit edebildiği kanıtlanmıştır [18]. Y. Zhang, X. Wang, and L. Ding LSTM kullanılarak dinamik frekansı tahmin etme çalışmasını önerdiler. Önerilen dinamik frekans tahmin yöntemi, diğer makine öğrenmesi yöntemleri üzerinde test edilmiş ve daha iyi performans gösterdiği New England sistemi üzerinden test edilmiştir [19].

Güç kalitesi sorunlarının yanında LSTM yapılarının kullanım alanlarından biri de yük tahmin çalışmalarıdır. Akıllı şebekelerin geliştirilmesi ile birlikte yük durumunun daha somut şekilde planlanması ve buna bağlı olarak talep kadar elektrik üretiminin yapılması, yük tahmininin önemini oldukça arttırmaktadır [20]. Yük tahmini ile ilgili yapılan çalışmalar içerisinde [20]'de LSTM mimarisi ile elektrik yükü tahmininde bulunulmuş ve sonuçlar kök ortalama kare hatası değerlerine göre ARIMA modeli ile karşılaştırılmıştır. Her iki model de benzer sonuçları vermiş ancak model oluşturma ve eğitim aşamalarında bazı farklılıklar oluşmuştur. LSTM'nin temel avantajı çok değişken sayısına sahip yapılarda yüksek hesaplama gücünün olduğunun tespiti yapılmıştır. Bir başka çalışma olan Y. J. Wang ve ark., iforest algoritması ve LSTM sinir ağının birleşimi ile oluşturulan mimari ile yük tahmini çalışması yaptılar. Çalışmada geçmiş verilere dayalı eğitim örnekleri oluşturulmuş ve bunlar arasında anormal olanlar iforest algoritması vasıtasıyla temizlenmiştir. Diğer kalan veriler ile LSTM eğitimi sağlanarak tahmin çalışması yapılmıştır [21]. M. R. Islam ve ark. yaptığı çalışmada ise LSTM mimarisi ile yük tahmini yapılmış

ve destek vektör makinesi (SVM) gibi geleneksel yük tahmini teknikleri kullanılarak karşılaştırılmıştır. LSTM ile yapılan çalışmanın SVM yönteminden daha iyi sonuçlar verdiği ilgili çalışma ile kanıtlanmıştır [22]. Ermatita ve ark. LSTM mimarisi kullanılarak meteorolojik veriler olmaksızın pik yük talep verilerine dayalı olarak gelecekteki en yüksek yük talebi tahmin çalışmasını önerdiler. İlgili çalışmada hafta içi günlerinde sistemin daha iyi tahmin sonuçları verdiği tespit edilmiştir [23]. A. Inteha and Nahid-Al-Masood kısa vadeli elektrik yük tahmini çalışmasında GRU – GA (Gated Recurrent Unit – Genetic Algorithm) hibrit modelini önerdiler. GA, GRU ağınnın gün gecikmesi ve gizli katmandaki nöron sayısını düzeltmede kullanıldı ve diğer parametrelerinde ayarlanarak daha doğru tahmin çalışmaları elde edilebileceği vurgulandı [24]. S. Kumar ve ark. LSTM ve GRU modellerini kullanarak enerji yükü tahmini çalışması yaptılar. Bu çalışmada GRU modelinin tahmin doğruluklarının daha yüksek olduğunu tespit ettiler [25]. G. Xiuyun ve ark. derin öğrenme çerçevesine dayalı GRU ağınnın kısa vadeli yük tahmini çalışmasını sundular. Güç yükü verileri zaman serisi ve verilerin doğrusal olmaması nedeni ile geleneksel ağların tahmin etkisinin GRU yapılarına istinaden daha zayıf olduğu tespit edildi [26]. J. Huo ve ark. farklı veri kaynakları ile elektriksel kısa vadeli yük tahmini için RFA ve SVM yapılarını karşılaştırdıkları çalışmayı sundular. Çalışmada tahmin doğruluğunun veri seti, parametreler ve mevsimlere bağlı olduğu tespit edildi. Her iki akıllı sisteminde yük tahmininde kullanışlı ve verimli olarak kullanılabileceği belirtildi [27]. H. Altınçöp A. B. Oktay RFA kullanarak hava kirliliği tahmin çalışması yaptılar. Sonuçlar YSA ve RFA ile karşılaştırıldığında RFA akıllı sistemlerinin tahminde daha başarılı olduğu belirtildi [28]. C. B. Pop ve ark. RFA ve GBM (Gradient Boosting Machine) akıllı sistemlerini kullanarak kısa vadeli enerji tüketiminin tahminlenmesi için bir çalışma önerdiler. Sonuçlar karşılaştırıldığında ise GBM akıllı sistem yapılarının RFA yapılarına istinaden daha doru tahmin sonuçları verdiğini tespit ettiler [29]. R. Cai ve ark. XCB (Extreme Gradient Boosting) akıllı sistemi kullanarak rüzgâr hızı tahmin çalışması yaptılar. Çıkan sonuçları BPNN ve LR yapıları ile karşılaştırdıklarında XCB yapılarının daha doğru tahmin sonuçları verdiğini tespit etiler [30]. S. H. Rafi ve ark. XCB akıllı sistem yapıları kullanarak kısa vadeli yük tahmini çalışması önerdiler. Çıkan sonuçları LSTM ve RBFN yapıları ile karşılaştırdıklarında ise XCB yapıların tahmin çalışmasında istikrarlı bir davranış sergilediğini tespit ettiler [31]. S. Singh and M. M. Tripathi LSTM ve XCB akıllı sistemlerini kullanarak elektrik talep tahmini çalışmasını önerdiler. Çalışmada LSTM yapısının uzun sıralı bilgileri hafızasında tutarak daha başarılı tahmin sonuçları verdiğini tespit edildi [32]. C. N. Obiora ve ark. XCB akıllı sistemi kullanılarak güneş enerjisini tahmin eden bir çalışma yaptı. Sonuç verilerinin SVM yapıları ile karşılaştırılması durumunda ise XCB akıllı sistemlerinin tahmin

doğruluk oranlarının daha yüksek olduğu tespit edildi [33]. Genel hatları ile güç kalitesi bozuklukları, yük tahmini, konuşma tanıma gibi daha birçok alanda LSTM mimarilerin yeri tahmin çalışmalarında oldukça önemli hale gelmiştir.

Bu tez çalışması ile OSB gerçek verileri kullanılarak LSTM mimarisi vasıtasıyla harmonik tahmin çalışması yapılmıştır. Tez altı bölümden oluşmaktadır. Giriş bölümünde, genel hatları ile güç kalitesi problemlerinin tanımı yapılmış ve literatür özeti verilmiştir. İkinci bölümde, güç sistemi harmoniklerinin tanımları yapılarak, harmonik ve ara harmoniklerin matematiksel modelleri verilmiştir. Üçüncü bölümde, tezin ana konusu olan harmonik tahmininde kullanılacak LSTM yöntemi detaylandırılmış. Dördüncü bölümde uygulama sistemi, verilerin tanımlanması yapılarak LSTM üzerinde kullanılmış ve tahminleme çalışması yapılmıştır. Beşinci bölümde elde edilen sonuçlar, grafikler ve tablolar yardımı ile tartışılmıştır. Tez çalışması, sonuç ve öneriler bölümü ile tamamlanmıştır.

2. HARMONİKLER

2.1 HARMONİK TANIMI

Güç sistemlerinde gerilimin tolerans (+/- %10) değerler aralığında ve sinüs formuna en yakın şekilde verilmesi ve bunun yanında frekansın temel şebeke frekansında olması cihazların verimli bir şekilde çalışması için önem arz etmektedir. Ancak harmonikli yükler, şebeke frekansının (50 Hz) katlarını içerisinde barındıran dalga formları oluşturmaktadır [34].

Güç şebekelerinde doğrusal olmayan yük, akımı ile gerilimi arasında bir ilişki olmayan yük demektir. Yük kaynağı olan gerilim ve akım eğrileri sinüzoidal değildir. Fourier analizine göre, sinüzoidal olmayan bu terimler harmonik olarak adlandırılır [35].

Enerji dağıtım sistemlerinde sinüs formundaki bir gerilim kaynağı ark ocağı, transformatör gibi doğrusal olmayan bir yüke uygulandığında sinüs formundaki dalga şeklinde bozulmalar meydana gelecektir. Sinüs formunda veya sinüs formuna yakın olması gereken akım dalga şeklinin bozulmasının nedeni temel şebeke frekansının dışında oluşan sinüs dalgalarıdır. Şebeke frekansı (50 Hz) dışındaki lineer olmayan yükten kaynaklı diğer sinüs formundaki bu akımlara harmonik denir [35].

Harmonikler ve ara-harmoniklerin tespiti belirli matematiksel modeller ile yapılmaktadır. Bu tanımlar Tablo 2-1’de verilmiştir [36].

Tablo 2-1: Harmoniklerin matematiksel tanımları

DA Bileşen	$f_{\omega} = nf_1$; n=0	n: sıfırdan büyük tamsayı f_{ω} : sinyalin spektral bileşen frekansı f_1 : temel frekans
Harmonik	$f_{\omega} = nf_1$	
Ara-harmonik	$f_{\omega} \neq nf_1$	
Alt-harmonik	$f_{\omega} > 0$ Hz ve $f_{\omega} < f_1$	

2.1.1 Ara Harmonikler

Ara harmonikler, temel frekansın tamsayı katı olmayan diğer bileşenlerden oluşan harmoniklerdir. Ara harmonik içeren gerilim dalga şeklinin tepe ve efektif genlik değerlerinde esas frekanstan sapmadan kaynaklı yükselip alçalan değişkenlik yapısı mevcuttur. Bu neden ile bu yapı gerilimde titreşimlere neden olmaktadır. Ara harmonikler iki neden ile oluşmaktadır.

Bunlar, gerilim frekansı kenar bandında üretilen bileşenlerden ve faz açıları ile genlik arasında sürekli yaşanan değişimden kaynaklanmaktadır [35].

2.2 HARMONİKLER İLE İLGİLİ GENEL TERİMLER

Sinüs olmayan büyüklüklerin güç sistemine olumsuz etkilerinin giderilmesi ve güç kalitesinin iyileştirilmesi bakımından harmoniklerin analizi ve büyüklüklerin seviyesinin bilinmesi gereklidir [35].

Sistemde harmoniklerin mevcudiyeti, elektriksel büyüklüklerinin yeniden tanımlanmasını gerektirir. Aşağıda güç sistemlerinde kalitenin belirlenebilmesi için gerekli bazı tanımlamalar yapılmıştır. Bu değerler ne kadar küçük olursa enerji tesislerinden tüketiciler tarafından çekilen enerji o kadar kaliteli olur ve sinüzoidal dalga şekline yakınsar.

Bozunum (D): Sinüzoidal gerilim veya akım dalga formunda meydana gelene bozulmadır.

Spektrum: Spektrum, harmoniklerin genliklerini içeren grafikdir [35].

Toplam Harmonik Bozunum (THD): Gerilim harmonik bileşenlerinin etkin RMS değerlerinin ana bileşenin etkin değerine oranıdır. Dalga şeklindeki bozulmayı yüzde olarak ifade eder. Gerilim için,

$$THD_V = \frac{1}{U_1} (\sum_{n=2}^{\infty} U_n^2)^{1/2} \quad (2.1)$$

şeklinde ifade edilir. Akım için toplam harmonik bozulma,

$$THD_I = \frac{1}{I_1} (\sum_{n=2}^{\infty} I_n^2)^{1/2} \quad (2.2)$$

şeklindedir.

Bozulma Faktörü (DF): Akım değeri için bozulma faktörü,

$$DF_I = \frac{1}{I} (\sum_{n=2}^{\infty} I_n^2)^{1/2} \quad (2.3)$$

şeklindedir. Gerilim için bozulma faktörü denklemi,

$$DF_V = \frac{1}{V} (\sum_{n=2}^{\infty} V_n^2)^{1/2} \quad (2.4)$$

Tepe Faktörü (CF): Sinüzoidal olmayan dalgalar için tepe faktörü,

$$CF = \frac{\text{Dalga'nın Tepe Değeri}}{\text{Dalga'nın Efektif Değeri}} \quad (2.5)$$

ifadesi ile belirtilir.

Harmonik Faktörü (HF): Harmonik bileşenlerin seviyesini belirlemede kullanılmaktadır. Örneğin gerilim için,

$$HF_n = \frac{V_n}{V_1} \quad (2.6)$$

V_n : n. harmonik gerilimine ait efektif değeri,

V_1 : geriliminin temel bileşenin efektif değerini göstermektedir.

Toplam Talep Bozunum (TTD): Akım harmonik bileşenlerinin etkin RMS, yük akımının (I_L) maksimum değerine oranıdır. Dalga şeklindeki bozulmayı yüzde olarak ifade eder.

$$TTD = \frac{\sqrt{\sum_{n=2}^{\infty} I_n^2}}{I_L} \quad (2.7)$$

Burada I_L yük akımı, besleme barasında üzerinde temel frekansta meydana gelen maksimum akımdır. On iki ay öncesinden ölçüm anına kadar olan süre zarfında ortalamaları alınarak hesaplanmaktadır.

Şekil (Form) Faktörü: Şekil faktörü sinüs olmayan bir dalga için,

$$k_f = \frac{\text{Efektif Değer}}{\text{Ortalama Değer}} \quad (2.8)$$

olarak tanımlanır. Şekil faktörü sinüs dalga şeklinin bozulma ölçütünü vermektedir. Hesaplamalarda sinüs dalga formu için, 1,11 değerinde kabul edilmektedir.

2.3 HARMONİKLERİN MATEMATİKSEL MODELLERİ

Sinüs olmayan dalganın değişik genlik ve faz açılarda birden fazla sinüs dalga formlarının toplamı şeklinde ya da yine genlikleri ve faz açıları farklı sinüs dalga formunun sinüs olmayan diğer dalgalar toplamı ile meydana geldiğini J. Fourier tarafından kanıtlanmıştır. Böyle bir fonksiyon,

$$F(t) = A_0 + A_1 (\sin 2\pi f_1 t + \varphi_1) + A_2 (\sin 2\pi f_2 t + \varphi_2) + \dots (\sin 2\pi f_n t + \varphi_n) \quad (2.9)$$

şeklinde ifade edilir. Burada A_0 ortalama değer, 1 indisi ile gösterilen terim ise temel bileşendir. Temel bileşen dışındaki bileşenlere ise harmonik bileşen denir. A_2, A_3, A_n harmoniklerin genliklerini, f_1 temel bileşen frekansını, $f_2, \dots, f_3$ harmonik bileşenlerin frekanslarını ifade etmektedir. φ_1 temel bileşen faz açısını, $\varphi_2, \dots, \varphi_n$ harmonik bileşenlerin faz açılarını göstermektedir. Temel bileşen frekansı ile n. harmonik frekansı arasında,

$$f_n = n \cdot f_1 \quad (2.10)$$

bağlantısı vardır. Denklem (2.1)'deki gibi ifade edilen “Fourier Serisi”, bu seri elemanlarına da “Fourier Bileşenleri” adı verilir. Bir sinüs olmayan dalga denklemi denklem (2.1)'deki sinüzoidal bileşenlerle ifade edildiği gibi aşağıdaki şekilde de ifade edilebilir.

$$F(t) = A_0 + A_1 \sin(W_1 t) + \dots + A_n \sin(W_n t) + B_1 \cos(W_1 t) + \dots + B_n \cos(W_n t) \quad (2.11)$$

Bu şekilde ifadelerin Fourier katsayıları aşağıdaki denklemler ile ifade edilir.

$$A_0 = \frac{1}{2\pi} \int_0^{2\pi} f(wt) dw t \quad (2.12)$$

Tablo 2-2: Fourier Katsayıları

Fonksiyon	Matematiksel Model	Fourier Katsayıları
Çift Fonksiyon	$f(-t) = f(t)$	$A_n = \frac{1}{\pi} \int_0^{2\pi} f(\omega t) \cos(n\omega t) d\omega t$ $B_n = 0$
Tek Fonksiyon	$f(-t) = -f(t)$	$A_n = 0$ $B_n = \frac{1}{\pi} \int_0^{2\pi} f(\omega t) \sin(n\omega t) d\omega t$
Yarım Dalga Simetrisi	$f(t) = -f(t + \frac{T}{2})$	n çift ise $A_n = \frac{1}{\pi} \int_0^{2\pi} f(\omega t) \cos(n\omega t) d\omega t$ n tek ise $B_n = \frac{1}{\pi} \int_0^{2\pi} f(\omega t) \sin(n\omega t) d\omega t$

$$A_n = \frac{1}{\pi} \int_0^{2\pi} f(\omega t) \sin(\omega t) d\omega t \quad (2.13)$$

$$B_n = \frac{1}{\pi} \int_0^{2\pi} f(\omega t) \cos(\omega t) d\omega t \quad (2.14)$$

Sinüs olmayan dalga formuna göre katsayılardan bazıları bir değer almaz iken, bazıları ise sıfır değerini alacaktır [35].

2.3.1 Sinüzoidal Olmayan Durumlarda Elektriksel Büyüklükler

Güç sisteminde harmonik bileşenleri bulunan, gerilim ve akımın ani değerleri Fourier Serisi ile aşağıdaki biçimde ifade edilebilir [37].

$$V(t) = \sum_{n=1}^{\infty} V_n(t) = \sum_{n=1}^{\infty} \sqrt{2} V_n \sin(n\omega_1 t + \theta_n) \quad (2.15)$$

$$i(t) = \sum_{n=1}^{\infty} i_n(t) = \sum_{n=1}^{\infty} \sqrt{2} I_n \sin(n\omega_1 t + \theta_n) \quad (2.16)$$

burada I_n ve V_n , n. harmonik akımının ve geriliminin ani değerleri olup, DC terimler işlem kolaylığı amacıyla ihmal edilmiştir. V_n ve I_n sırasıyla, n. harmonik değeri için gerilim ve akımın

efektif değerleridir. W_1 ise temel frekansa (f_1) ait açısal frekanstır. θ_n ile φ_n ise sırasıyla n. harmonik içi gerilim ve akıma ait faz açısıdır [37].

Ani güç;

$$p(t) = v(t)i(t) \quad (2.17)$$

olarak ifade edilir ve p(t)'nin T periyodunda aktif gücü aşağıdaki gibi ifade ederiz.

$$P = \left(\frac{1}{T}\right) * \int_0^T p(t)dt \quad (2.18)$$

Besleme geriliminin sinüzoidal olmaması ya da yükün doğrusal olmaması durumunda sinüzoidal olmayan akım ve gerilimler meydana gelir. Doğrusal olmayan elemanlardaki doğrusalsızlık devre uç karakteristiğinden veya manyetik malzemenin düzgün olmamasından kaynaklanmaktadır [37]. Aktif güç,

$$P = \sum_{n=1}^{\infty} V_n I_n \cos(\theta_n - \varphi_n) \quad (2.19)$$

Şeklinde hesaplanır. Farklı frekanslardaki akım ve gerilimlerin aktif güce katkısı yoktur. Ortogonal özellikler uygulandığında denklem 2.15 ve denklem 2.16'da verilen harmonikli gerilim ve akımın efektif değerleri sırasıyla;

$$V = \sqrt{\left[\frac{1}{T} * \int_0^T V^2(t)dt\right]} = \sqrt{\sum_{n=1}^{\infty} V_n^2} \quad (2.20)$$

$$I = \sqrt{\left[\frac{1}{T} * \int_0^T i^2(t)dt\right]} = \sqrt{\sum_{n=1}^{\infty} I_n^2} \quad (2.21)$$

olarak bulunur. Harmonik gerilim ve akımın tepe değerlerinin (V_{mn}, I_{mn}) kullanılmasıyla efektif gerilim ve akım,

$$V = \left[\sum_{n=1}^{\infty} V_{mn}^2 / 2\right]^{1/2} \quad (2.22)$$

$$I = \left[\sum_{n=1}^{\infty} I_{mn}^2 / 2\right]^{1/2} \quad (2.23)$$

$$S = V * I \quad (2.24)$$

Pratikte, harmonik bileşenler çoğunlukla sinüzoidal şebekeye bağlı doğrusal olmayan elemanlar sebebiyle meydana gelmektedir. Görünen gücün yaygın bir şekilde kabul edilen tanımı şu biçimdedir [37].

$$S^2 = P^2 + \theta^2 + D^2 \quad (2.25)$$

Burada D, bozulma gücü olup,

$$D = \sqrt{S^2 - P^2 - \theta^2} \quad (2.26)$$

eşitliğiyle ifade edilir. Bozulma gücü aktif olmayan bir güç olup sinüzoidal işaretli doğrusal devrelerde sıfırdır. Reaktif güç;

$$\theta = \sum_{n=1}^{\infty} V_n I_n \sin(\theta_n - \varphi_n) \quad (2.27)$$

olarak verilir. Harmonikler olmadığı zaman görünen güç, temel frekanstaki alışılagelmiş görünen güç ifadesi olan ana gerilim ve akımın çarpımına eşittir. Sinüzoidal halde, ortalama aktif ve reaktif güç ile görünen güç arasında,

$$(V_1 I_1)^2 = P_1^2 + \theta_1^2 \quad (2.28)$$

eşitliği vardır. Buradaki $\theta_1 = V_1 I_1 \sin(\theta_n - \varphi_n)$, denklemi temel bileşen n=1 için tanımlanan temel reaktif güç değeridir.

Güç faktörü, AC (alternatif akım) güç sisteminde çekilen akımın bir yük tarafından ne kadar verimlilikle kullanıldığını ölçmek için gereklidir. Sinüzoidal veya sinüzoidal olmayan durumların tamamı için toplam güç faktörü,


$$GF=P/S \quad (2.30)$$

olarak tanımlanır. Burada P aktif güçtür ve temel frekans bileşeni ile diğer harmonik bileşenlere ait güçlerin toplanmasıyla bulunur [37].

3. HARMONİK TAHMİNİNDE KULLANILAN ALGORİTMALAR

3.1 RNN (Recurrent Neural Network)

Tekrarlayan sinir ağlarının yapısının şu örnek üzerinden anlaşılacağı düşünülmektedir. İnsanlar düşüncelerini geçmişten hafızalarında olan bilgileri anlık olarak değerlendirdikten sonra aktarmaktadır. Cümle yapısında da önceki kelime sonraki kelimenin anlaşılır olmasında rol oynamaktadır. Geleneksel sinir ağları böyle bir durumda yetersiz kalmaktadırlar. RNN ise geçmişten öğrenilen veriler yardımı ile yeni veri öğrenilmesi konularını ele almaktadır. Tekrarlayan sinir 1980 yıllarına dayanmakta olup, ilk olarak basit tekrarlayan ağ (Simple Recurrent Network) adını almıştır. Sonraki zamanda ise Jeff Elman tarafından 1990’larda RNN önerilmiştir. Tekrarlayan sinir ağları sıralı bilgileri kullanarak tahmin işlemlerini yürütmektedir. Geleneksel bir sinir ağında tüm girdiler ile çıktılar birbirinden bağımsız olduğu varsayılmaktadır. Örneğin, bir cümle içinde bir sonraki kelimeyi tahmin etmek için, hangi sözcüklerin o anki kelimeden önce geldiğini bilmek gerekmektedir. RNN mimarisinde yeni öge çıktılarına bağlı olarak değerlendirilmektedir [38]. Tekrarlayan bir sinir ağı (RNN), bir ağın birden çok kopyasından oluşur. Zincir yapısına sahip RNN, bilgileri bir ağdan diğerine aktarır. Zincir yapısını bağlayarak sekans verileri öğrenme sağlar [39].



Şekil 3-1: RNN Mimarisi

3.1.1 LSTM (Uzun – Kısa Süreli Bellek) Mimarisi


LSTM yapıları konuşma tanıma, çeviri, dil modelleme gibi birçok çalışmada kullanıldığı gibi güç sistemi temel problemlerinden olan güç kalitesi bozulmalarını tahminleme çalışmalarında da kullanılmaktadır. Güç sistemleri çok karmaşık ve fazla sayıda parametre içeren yapılardır. Bu nedenle klasik yöntemlerin yanı sıra, akıllı yaklaşımlardan da faydalanılmaktadır.

Güç sistemi çalışmalarında en çok kullanılan akıllı sistemler LSTM'ler, derin öğrenme uygulamaları, destek vektör regresyonu (SVR) ve genetik algoritmalar olarak başlıca sıralanabilirler. Birçok alanda olduğu gibi güç sistemi problemlerinin tahmini, dil algılama vb. yapılarda da bu sistemler oldukça yoğun bir şekilde kullanılmaktadır. [40]'de LSTM-net uygulamasına dayalı bir sinir ağı ile çok adımlı tahmin probleminin başlangıç değerleri seçiminin uzun vadeli tahmin doğruluğu üzerindeki etkisi üzerinde bir çalışma yapılmıştır. İlgili çalışmada harmonik, genlik modülasyonlu sinyal ve frekans modülasyonlu sinyalin zaman sıralı örneklerinden oluşan zaman serileri kullanılmıştır. Özellikle maksimum tahmin doğruluğu, VarianceScaling yöntemi kullanılarak harmonik sinyal zaman serileri üzerinde gözlenmiştir. [41]'de güç sistemlerinde harmonik bastırma performansını iyileştirmek için ASMC-LSTMFNN metodu önerilmiştir. İlgili metot, özel kapı yapısı ve seçici unutkan hafıza mekanizmasına sahip RNN tabanlı LSTM yapısını içerisinde barındırmaktadır. Bu metot ile sınırlı performans ve gradyan kaybolması gibi sorunlar ortadan kaldırılmıştır.

[42]'de destek vektör regresyon yöntemi ile yük tahmini yapılmış ve tahmin çalışmalarında önemli sonuçlar alınmıştır. Yine başka bir çalışma [43]'te ise destek vektör mimarisi ile tepe elektrik yükü tahmin çalışması yapılmış ve başarılı sonuçlar elde edilmiştir. Aynı şekilde derin öğrenme uygulamaları kullanılarak ilgili alanlarda tahminleme çalışmaları yürütülmüştür. [44]'de derin öğrenme mimarisi kullanılarak 104 haftayı kapsayan haftalık pik elektriksel yük tahmin çalışması ile başarılı sonuçlar elde edilmiştir. [45]'de ise genetik algoritmalar yardımı ile yük frekans tahmin çalışmaları yürütülmüş ve şebeke çalışma güvenliği için önemli tahmin sonuçlarına ulaşılmıştır. Günümüzde ise yapısı gereği tahmin çalışmalarına daha iyi yanıtlar veren ve üstünlükleri ile öne çıkan tekrarlayan sinir ağı mimarileri kullanılmaktadır.

Uzun kısa süreli bellek ise, 1990 yıllarına dayanan tarihi ile RNN yapılarının altında geliştirilmiştir. RNN mimarisi yapısı gereği her girdi verisini bir önceki ya da daha geçmişteki çıktı verilerini göz önüne alarak denetler. Bu mimaride yaşanan gradyan kaybolması/patlama sorunu sebebi ile uzun süreli bilgiyi hatırlayabilen LSTM mimarisi geliştirilmiştir [46]. Uzun kısa


sürekli bellek (LSTM) birimleri, tekrarlayan bir sinir ağının (RNN) birimleridir. LSTM birimlerinden oluşan bir RNN'ye genellikle LSTM ağı (veya sadece LSTM) denir [47].



Şekil 3-2: LSTM Ağı Mimarisi

3.1.1.1 LSTM'lerin Arkasındaki Temel Fikir


LSTM ağlarında kilit nokta, diyagramın en üst kısmında bulunan çizginin hücre halidir. Bu hücre, bir taşıyıcı bant görevi görmektedir. Bu yapı doğrusal etkileşimlerin etkisi ile tüm zincirin altından geçer [48].



Şekil 3-3: LSTM Hücre Durumu

LSTM, geit (gate) olarak adlandırılan yapıları ierisinde barındırmaktadır. Bu yapılar hcreler arası bilgi transferi saėlamaktadır. Aynı zamanda, bilginin gnderilip gnderilmemesi hususunda da karar verebilmektedirler. Nrol aė ve katmanı ve arpma ileminde oluřmaktadır [48].


LSTM zerinde ilk adım, hcreden hangi bilginin silinmesi gerektiėine karar vermektir. Bu iřlem, “unutturma geit katmanı” unutturma geit katmanı yardımı ile yapılmaktadır. Bu ařamada, h_{t-1} ve x_t kontrol edilir ve C_{t-1} hcresinde bulunan her sayı iin 0 ile 1 arasında bir sayı belirlenir. 1 hcreden geti anlamına gelirken, 0 bunun tam tersi olarak kabul edilmektedir [48].



řekil 3-4: LSTM 1. Adım

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.1)$$

Bir sonraki adım, hcre ierisinde saklanacak bilginin belirlenmesidir. Bu iřlem iki ařamada gerekleřmektedir. İlk olarak, “giriř kapısı katmanı” ile gncellenecek deėerlere karar verilir. Ardından, bir tanh bloėu yardımı ile eklenecek yeni aday deėerlerin bir vektrleri ıkarılır. Bu ařamada gerekleřen son adım olarak, gncelleme amacı ile belirlenen iki deėer birleřtirilir [48].




Şekil 3-5: LSTM 2. Adım

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.2)$$

$$\check{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3.3)$$


Bu aşamada eski verinin bulunduğu hücre olan C_{t-1} 'in yeni hücre durumu C_t 'ye güncellenmesi gerekmektedir. Önceki adımlarda zaten ne yapılacağına karar verildi, sadece bunun gerçekten yapılması gerekiyor. Eski durum, daha önce unutmaya karar verilenleri unutarak, f_t ile çarpılacaktır. Sonra $i \sim t * C \sim t$. eklenecektir. Bu, güncellenecek değer ile yeni aday olan değerlerdir[48].



Şekil 3-6: LSTM 3. Adım

$$C_t = f_t * C_{t-1} + i_t * \check{C}_t \quad (3.4)$$

Son olarak, çıktı değeri belirlenmektedir. Belirlenecek değer en son aşamada oluşan ve tüm aşamaları başarılı bir şekilde geçen değerdir. Bu değer belirlenmesi ise yapı içerisinde bulunan sigmoid katmanın çalışması ile sağlanacaktır. Daha sonra, hücre durumunu tanh yolu üzerinde geçirilecek (değerleri -1 ve 1 arasında olacak şekilde) ve sigmoid katmanın çıktısıyla çarpılacaktır. Böylece yalnızca karar verilen parçaların çıkarılması sağlanacaktır [48].



Şekil 3-7: LSTM 4. Adım

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.5)$$


$$h_t = o_t * \tanh(C_t) \quad (3.6)$$

3.1.2 GRU (Gated Recurrent Unit)

GRU (Geçitli Yinelenen Birim), Cho ve arkadaşları tarafından ilk olarak 2014 yılında tanıtıldı. Model kaybolan gradient problemini çözmek için oluşturulmuştur [49]. Tekrarlayan sinir ağlarında her bir nöron veya işlem birimi iç durumu bir bellek olarak kullanabilir. Öte yandan, RNN'nin çıktısı bir önceki hesaplamağa bağlıdır. Bu özellik uygulanan zaman serisi sıralamasında giderek daha önemli hale gelmektedir. Bunun ile birlikte uzun seri verilerde geri yayılım süreçleri

sırasında patlayan ve kaybolan gradyanlar meydana gelebilir. Bu sorun basit bir RNN yerine gating mekanizması kullanarak çözülebilir. Bu mekanizmalardan biride GRU'dur [50].

Diğer RNN'lere kıyasla GRU basit bir yapıya sahiptir ve kaybolan gradyanlara karşı dayanıklıdır. GRU bloğu iki kapı içermektedir. Bunlar güncelleme kapısı ve sıfırlama kapısıdır. Güncelleme kapısı, geçmiş bilgilerin ne kadarının geleceğe aktarılacağına karar verir. Sıfırlama kapısı ise geçmişteki bilgilerden hangilerinin unutulacağını belirler [50].




Şekil 3-8: GRU Mimarisi

3.2 XCB (Extreme Gradient Boosting)

XGBoost algoritması, Washington Üniversitesi'nde ortaya çıkartılmıştır. XGBoost algoritması ilk olarak ilgili üniversitede araştırma projesi olarak geliştirilmiştir. XCB, regresyon, sınıflandırma, sıralama ve kullanıcı tanımlı tahmin problemlerinde kullanılmaktadırlar. XGBoost ve gradient boosting machines (LGBM'ler), gradyan iniş mimarisini kullanarak zayıf öğrenenleri artırma ilkesini uygulayan topluluk ağacı yöntemleridir. Ancak XGBoost, sistem optimizasyonu ve algoritmik geliştirmeler yoluyla temel gradient boosting machines (GBM) çerçevesini oluşturmaktadırlar [51].

Genel hatları ile XGBoost, etkili bir topluluk öğrenme modelidir. Tekrar tekrar karar ağaçları oluşturmak için bir destek stratejisi kullanır. Yeni oluşturulan karar ağacı, önceki karar ağacının tahmin artıklarını düzeltebilir. Son olarak, birden çok karar ağacı, nihai tahmini yapmak için birleştirilir ve bu, tek bir karar ağacına kıyasla doğruluğu büyük ölçüde artırır [52].




Şekil 3-9: XCB Mimarisi

3.3 LGBM (Light Gradient Boosted Machine)

LGBM, bir tür karar ağacı olarak belirli bir noktaya bağlı değildir ve çoklu karar ağaçlarından oluşmaktadırlar. Aşırı uydurmayı önleme ve güçlü genelleme yeteneği gibi avantajlara sahiptir. Genellikle sınıflandırma ve regresyon problemleri için kullanılır. Ana fikir, karar ağacı algoritmasını yinelemektir. Önceki karar ağacının kalıntısı, bir sonraki karar ağacının girdisi olarak kullanılacaktır. Sapma, yineleme yoluyla azaltılır ve son olarak, bu karar ağaçlarının sonuçları elde edilir [53].

LGBM, XCB tabanlı geliştirilmiş bir modeldir. XCB, birçok makine öğrenimi görevinde iyi performans gösterse de verinin geometrik büyümesiyle aşırı uyum ve yavaş eğitim hızı gibi bazı sorunları vardır. LGBM modeli, histogram algoritması ve derinlik kısıtlanmalı yaprak bazlı karar ağacı büyüme stratejisini içerir. LGBM, doğruluğu düşürmeden hızı hızlandırabilir ve bellek kullanım oranını azaltabilir. Daha karakteristik parametreler ve daha fazla elektrolitik hücre olduğunda, LGBM güçlü bir yapıya sahip olabilir [54].

LGBM modelinin histogram algoritmasında sürekli öz değerler k aralığa bölünür ve bölüm noktaları k aralığında seçilir. Bu nedenle, eğitim hızı ve alan verimliliği XCB'den daha iyidir [54].



Şekil 3-10: LGBM Mimarisi


3.4 RFA (Random Forest)

RFA, Leo Brieman tarafından 2000'li yıllarda rastgele seçilen veriye ait alt uzaylarda büyüyen karar ağaçlarına bir öngörü topluluğu oluşturmak için tasarlanan bir yöntemdir. Breiman'ın fikirleri, Amit ve Geman'ın (1997) geometrik özellik seçimi, Ho'nun rastgele alt uzay yöntemi (1998) ve Dietterich'in (2000) rastgele bölünmüş seçim yaklaşımıyla ilgili çalışmalarından kararlı bir şekilde etkilenmiştir [55].

RFA, içerisinde sınıflandırma ve regresyon ağaçlarını barındırmaktadır. Performansı ile başarılı sonuçlar veren yöntemler arasında yerini almıştır. Son yıllarda ekoloji, iklim değişimi, uzaktan algılama gibi alanlarda önemli çalışmalara damga vurmuştur [56].

RFA yapısı genellikle orman (forest) olarak adlandırılmaktadır. Orman içerisinde her bir karar ağacı, veri seti içerisinde değerlerin belirlenmesi ve her bir düğüm noktasında bulunan çok sayıda değişken arasından rastgele değişkenlerin belirlenmesi yoluyla çalıştırılmaktadır[56].

RFA eğitim verilerini öğrenerek bir orman yapısı oluşturduktan sonra, test verisini oluşturduğu her ağaç yapısı için dener. Her ağaç kendi içerisinde test verisi için değerlendirmesini yapar ve sonuç verir bunun sonucunda test verisi çoğunluk oylamasına göre sınıflandırılır [57].




Şekil 3-11: RFA Mimarisi

Günümüz tahminleme çalışmalarında; LSTM, GRU, XCB ve LGBM yapılarının yanında onlarca sayıda akıllı sistem yapıları kullanılmaktadır. Özellikle yapılan literatür taramaları sonucunda gerçek verilerin kullanıldığı tahminleme çalışmalarında bu akıllı sistem yapıları içerisinde LSTM ve GRU modellerinin en iyi test sonuçları verdiği tespit edilmiştir. Dolayısı ile gerçek verileri kullanarak yapmış olduğumuz test çalışmalarında GRU ve LSTM modelleri kullanılmıştır.


4. GÜÇ KALİTESİ BOZULMALARININ AKILLI YÖNTEMLER İLE TAHMİNLENMESİ

4.1 UYGULAMA SİSTEMİ


Çalışmanın bu bölümünde, tezin üçüncü bölümünde detaylı olarak anlatılan ve çalışmalarda yaygın olarak kullanılan LSTM (Uzun-Kısa Süreli Bellek) ve GRU (Gated Recurrent Unit) modelleri kullanılarak akım harmoniklerinin tahmini yapılacaktır. Çalışma modellerinde katman ve düğüm sayıları değiştirilerek detaylı analizler yapılmış ve elde edilen sonuçlar grafikler üzerinden gözlemlenmiştir. Kullanılan veri seti Bandırma Organize Sanayi Bölgesi giriş dağıtım merkezinde bulunan enerji analizörü üzerinden alınmıştır. Analizör markası Janitza UMG 512'dir. 63'e kadar tek ve çift harmonikler, ara harmonikler, pozitif, negatif ve sıfır bileşenlerin ölçümü, dengesizlik, fliker, gerilim tepe faktörü, yıldız ve üçgen bağlantılar için gerilim, akım, aktif güç, reaktif güç ve frekans yarım dalga efektif değerlerine eş zamanlı erişebilmektedir. Bunun yanında A sınıfı sertifikalı ölçüm hassasiyeti, 25.600 Hz'de gerilim ve akım ölçüm girişlerinin sürekli örneklenmesi, periyot başına 512 örnekleme noktası, ölçüm döngüsü başına 2000'den fazla ölçüm değerinin kaydı ve aktif enerji ölçüm hassasiyeti sınıfı 0,2 olması gibi önemli özelliklere de sahiptir. İlgili analizör bölge içerisinde bulunan makine, gıda, tekstil ve demir-çelik tesislerinin elektriksel karakteristiklerini kayıt altına almaktadır. İlgili veriler 06.01.2020 – 01.01.2021 tarihleri arasında oluşmuştur. Veri setinde her bir faza ait sırası ile harmonik değeri, aktif güç değeri, yıl, ay, gün, hafta içi günleri ve haftanın günü verileri .csv formatında hazırlanmıştır. Veri setinin %90'ı eğitim seti, %10'u ise test seti olarak kullanılacaktır. Verilerin periyodu 10'ar dakika olup, veri adedi 45716'dır. Her faza ait akım harmoniği ve aktif güç veri grafikleri aşağıda paylaşılmıştır.



Şekil 4-1: L1 Fazına Ait Akım Harmonikleri ve Aktif Güç Veri Grafikleri



Şekil 4-2: L2 Fazına Ait Akım Harmonikleri ve Aktif Güç Veri Grafikleri



Şekil 4-3: L3 Fazına Ait Akım Harmonikleri ve Aktif Güç Veri Grafikleri

Her bir faza ait akım harmonikleri grafiğinde görünen pik değerler, ark ocağı bulunan tesiste ocağın içerisinde eritilen malzemenin sert yapıda olması nedeni ile meydana gelen ark kopmaları nedeni ile oluştuğu tespit edilmiştir.

Uygulanan veriler sonrasında modelin çıktısında oluşan tahmin sonuçlarını değerlendirmek için ise Kök Ortalama Kare Hata (Root Mean Square -RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) değerleri kullanılmıştır.

Tablo 4-1: Metrik Değerler ve Formülleri

Açıklaması	Hata Ölçüt Formülü
RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$
MAE	$MAE = \frac{1}{n} \sum_{t=1}^n e_t $
MAPE	$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{ e_t }{ A_t }$

$$e_t = r_t - p_t \quad (4.1)$$

Tablo 4-1’de t belirli bir zamanı, r_t zaman aralığını, p_t tahmin edilen zamanı, A_t gerçek veri değerini ifade ederken hata denklemi (4.1)’de verilmiştir [58].

4.2 VERİLERİN HAZIRLANMASI VE PROGRAM UYGULAMA ADIMLARI

Verilerin hazırlanma süreci, Bandırma Organize Sanayi Bölgesi giriş dağıtım merkezi üzerinde bulunan analizöre uzaktan erişimi sağlamak için RTU cihazı montajı ile başlamıştır. GSM tabanlı bu RTU cihazı ile her bir faz özelinde excel formatında analizör üzerinden her bir faza ait aktif enerji ve akım harmonik verileri alınmıştır. Hazırlanan veriler ile LSTM (Uzun-Kısa Süreli Bellek) veya GRU (Gated Recurrent Unit) modellerinin eğitimi ve sonrasında yapılacak tahmin çalışması python programında hazırlanan yazılım ile gerçekleştirilmektedir.

Veriler ilk olarak aşağıda verilen kod parçası ile yazılım içerisine alınmaktadır.

```
dataset = read_csv('yukleme.csv', header=0, index_col=0)
values = dataset.values
values = values.astype('float32')
scaler = MinMaxScaler(feature_range=(0, 1))
scaled = scaler.fit_transform(values)
reframed = series_to_supervised(scaled, 1, 1)
reframed.drop(reframed.columns[[7,8,9,10,11]], axis=1, inplace=True)
print(reframed.head())
```

Excel (.csv) formatında olan veriler program içerisine alındıktan sonra, bu verilerin kaçının eğitim verisi ve kaçının tahmin işlemi esnasında kullanılacağı aşağıda verilen kod parçası üzerinden belirlenmektedir.

```
values = reframed.values
n_train_hours = 41144
train = values[:n_train_hours, :]
test = values[n_train_hours:, :]
train_X, train_y = train[:, :-1], train[:, -1]
test_X, test_y = test[:, :-1], test[:, -1]
train_X = train_X.reshape((train_X.shape[0], 1, train_X.shape[1]))
test_X = test_X.reshape((test_X.shape[0], 1, test_X.shape[1]))
print(train_X.shape, train_y.shape, test_X.shape, test_y.shape)
```

Eğitim ve test veri sayılarının belirlenmesinin ardından model seçimi (LSTM veya GRU) ve bu modellerde uygulanacak düğüm sayısı ve epoch sayısı aşağıda verilen kod parçası üzerinden belirlenmektedir.

```
model = Sequential()
model.add(LSTM(200, input_shape=(train_X.shape[1], train_X.shape[2])))
model.add(Dense(1))
model.compile(loss='mae', optimizer='adam')
history = model.fit(train_X, train_y, epochs=200, batch_size=72,
validation_data=(test_X, test_y), verbose=2, shuffle=False)
```

Bu kod parçası üzerinde kırmızı ile belirtilen bölümden uygulanacak modeli, (LSTM veya GRU) turuncu ve alt çizgili bölüm ile düğüm sayısını, açık mavi ve alt çizgili bölümden ise epoch sayısı belirlenmektedir.

Bu işlemlerin ardından program çalıştırılarak eğitim ve test hataları ile gerçek ve tahmin edilen değerler ayrı grafikler üzerinde verilmektedir. Bu işlemlerin gerçekleştirildiği program kod parçası ise aşağıda paylaşılmıştır.

```
plt.figure(figsize=(8,4))
plt.plot(history.history['loss'], label='Eğitim Hataları')
plt.plot(history.history['val_loss'], label='Test Hataları')
plt.title('Model Hataları')
plt.ylabel('Hata')
plt.xlabel('İterasyon Adımı')
plt.legend(loc='upper right')
plt.show();
```

```

aa=[x for x in range(4571)]
plt.figure(figsize=(8,4))
plt.plot(aa, inv_y[:4571], marker='.', label="Gerçek Değerler")
plt.plot(aa, inv_yhat[:4571], 'r', label="Tahmin Değerleri")
plt.tight_layout()
sns.despine(top=True)
plt.subplots_adjust(left=0.07)
plt.ylabel('IHD', size=15)
plt.xlabel('Zaman', size=15)
plt.legend(fontsize=15)
plt.show();

```

Son olarak ise Kök Ortalama Kare Hata (Root Mean Square -RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) değerlerinin tespiti yapılmaktadır. Bu tespitlerin yapıldığı program kod parçası aşağıda paylaşılmaktadır.

```

yhat = model.predict(test_X)
test_X = test_X.reshape((test_X.shape[0], test_X.shape[2]))
inv_yhat = concatenate((yhat, test_X[:, 1:]), axis=1)
inv_yhat = scaler.inverse_transform(inv_yhat)
inv_yhat = inv_yhat[:,0]
test_y = test_y.reshape((len(test_y), 1))
inv_y = concatenate((test_y, test_X[:, 1:]), axis=1)
inv_y = scaler.inverse_transform(inv_y)
inv_y = inv_y[:,0]
rmse = sqrt(mean_squared_error(inv_y, inv_yhat))
print('Test RMSE: %.3f' % rmse)
mae = mean_absolute_error(inv_y, inv_yhat)
print('Test MAE: %.3f' % mae)
mape = mean_absolute_percentage_error(inv_y, inv_yhat)
print('Test MAPE: %.3f' % mape)

```

5. DENEYSEL ANALİZ VE TAHMİNLEME

Harmonik değeri, aktif güç değeri, yıl, ay, gün, hafta içi günleri ve haftanın günü verilerinin uygulanacağı yapay sinir ağı modelleri üç bölümden oluşmaktadır. Bu bölümler girdi katmanı, LSTM (Uzun-Kısa Süreli Bellek) veya GRU (Gated Recurrent Unit) algoritmaları ve çıktı katmanından oluşmaktadır. Çalışmada ilgili veriler kullanılarak her bir faz için ayrı ayrı akım harmonikleri tahmin çalışması yapılmıştır. Modellerde düğüm sayıları sırası ile 25, 50, 100 ve 200 olmak üzere test edilmiş olup, eğitimin iterasyon sayısını belirten “epoch” değeri ise sabit 200 olarak uygulanmıştır. Belirtilen bu değerler LSTM (Uzun-Kısa Süreli Bellek) ve GRU (Gated Recurrent Unit) ağlarında tek ve çift katmanlı olarak ayrı ayrı test edilmiş ve Tablo 5-1’de toplu halde gösterilmiştir.


Tablo 5-1: L1, L2 ve L3 Fazlarına Ait Test Verileri

Faz	Katman	Düğüm	LSTM			GRU		
			Metrik Hatalar			Metrik Hatalar		
			RMSE	MAE	MAPE	RMSE	MAE	MAPE
L1	1	25	2,286	0,734	11,735	2,253	0,698	10,820
		50	2,411	0,760	13,615	2,571	0,963	15,762
		100	2,459	0,804	14,486	2,487	0,780	12,288
		200	2,413	0,739	13,178	2,902	1,599	30,065
	*2	25	2,534	0,654	10,424	2,334	0,916	17,065
		50	2,582	1,455	24,281	2,246	0,962	17,698
		*100	*2,193	*0,694	*12,111	2,501	0,844	13,202
		200	2,310	0,787	13,953	2,784	1,432	27,572
L2	1	25	2,382	0,680	10,074	2,768	1,460	27,921
		50	2,432	0,765	13,548	2,695	1,104	20,709
		100	2,363	0,792	14,268	2,640	0,610	9,976
		200	2,610	1,292	24,501	2,778	1,526	29,213
	*2	25	2,700	1,261	23,484	2,489	0,715	11,264
		*50	*2,354	*0,759	*12,329	2,762	1,372	26,210
		100	2,952	1,717	32,897	2,460	0,944	17,218
		200	2,497	0,838	14,350	2,973	1,553	29,614
L3	1	25	2,277	0,672	12,915	2,527	0,863	15,234
		50	2,548	1,089	23,665	2,872	1,157	24,834
		100	2,648	1,068	22,884	2,520	1,045	22,603
		200	2,515	0,793	16,219	2,508	1,074	23,321
	*2	*25	*2,116	*0,666	*11,619	2,173	0,776	13,486
		50	2,326	1,153	25,337	2,503	1,417	27,640
		100	2,447	1,104	21,394	2,159	0,782	15,860
		200	2,639	1,300	27,998	3,064	1,311	28,071

Tablo 5-2: L1, L2 ve L3 fazlarına ait en düşük RMSE, MAE ve MAPE değerleri


Faz	Katman	Düğüm	Model	Metrik Hatalar		
				RMSE	MAE	MAPE
L1	2	100	LSTM	2,193	0,694	12,111
L2	2	50	LSTM	2,354	0,759	12,329
L3	2	25	LSTM	2,116	0,666	11,619

L1, L2 ve L3 fazlarına ait en düşük RMSE, MAE, MAPE değerleri ve bu değerlerin elde edildiği model, katman ve düğüm sayısı Tablo 5-2’de gösterilmektedir.



Şekil 5-1: L1 fazına ait gerçek ve tahmin edilen değerler


Tablo 5-1’de L1 fazına ait RMSE, MAE ve MAPE değerleri ile elde edilen gerçek ve tahmin edilen IHD grafiği Şekil 5-1’de gösterilmektedir.



Şekil 5-2: L1 fazına ait eğitim ve test kayıpları


L1 fazına ait aynı tahmin değerleri ile elde edilen eğitim ve test seti hataları ise Şekil 5-2’de gösterilmiştir. Bu şekle göre eğitim seti hataları mavi renk ile belirtilmiş olup, 0,005 seviyelerinden 0,0019 seviyelerine azaldığı gözlemlenmektedir. Yine aynı şekil üzerinde test hataları turuncu renk ile gösterilmiş olup, 0,0018 değerlerinden 0,0011 değerlerine gerilediği gözlemlenmiştir. L1 fazı için en kötü RMSE, MAE ve MAPE değerleri sırası ile 2,902, 1,599 ve 30,065’tir. Bu değerler tek katmanlı 200 düğüm sayılı GRU ağı ile elde edilmiştir. L1 fazı için Tablo 5-2’de verilen LSTM ağı kullanılarak, en kötü sonuç olan GRU ağına göre RMSE, MAE ve MAPE değerleri için sırası ile %32, %130 ve %148 daha iyi bir sonuç elde edildiği tespit edilmiştir.

L2 fazı için uygulanan modellere ait elde edilen hata ölçüt değerleri Tablo 5-1’de verilmiştir. En düşük RMSE, MAE ve MAPE değerleri sırası ile 2,354, 0,759 ve 12,329’dur. Bu değerler 2 katmanlı, 50 düğüm sayılı LSTM ağı ile elde edilmiştir.



Şekil 5-3: L2 fazına ait gerçek ve tahmin edilen değerler

Tablo 5-1’de L2 fazına ait RMSE, MAE ve MAPE değerleri ile elde edilen gerçek ve tahmin edilen IHD grafiği Şekil 5-3’de gösterilmektedir.




Şekil 5-4: L2 fazına ait eğitim ve test kayıpları

L2 fazına ait aynı tahmin değerleri ile elde edilen eğitim ve test seti hataları ise Şekil 5-4’te gösterilmiştir. Bu şekle göre eğitim seti hataları mavi renk ile belirtilmiş olup, 0,005 seviyelerinden 0,0014 seviyelerine azaldığı gözlemlenmektedir. Yine aynı şekil üzerinde test hataları turuncu renk ile gösterilmiş olup, 0,003 değerlerinden 0,0011 değerlerine gerilediği


gözlemlenmiştir. L2 fazı için en kötü RMSE, MAE ve MAPE değerleri sırası ile 2,973, 1,553 ve 29,614'tir. Bu değerler çift katmanlı 200 düğüm sayılı GRU ağı ile elde edilmiştir. L2 fazı için Tablo 5-2'de verilen LSTM ağı kullanılarak, en kötü sonuç olan GRU ağına göre RMSE, MAE ve MAPE değerleri için sırası ile %26, %105 ve %140 daha iyi bir sonuç elde edildiği tespit edilmiştir.

L3 fazı için uygulanan modellere ait elde edilen hata ölçüt değerleri Tablo 5-1'de verilmiştir. En düşük RMSE, MAE ve MAPE değerleri sırası ile 2,116, 0,666 ve 11,619'dur. Bu değerler 2 katmanlı, 25 düğüm sayılı LSTM ağı ile elde edilmiştir.



Şekil 5-5: L3 fazına ait gerçek ve tahmin edilen değerler

Tablo 5-1'de L3 fazına ait RMSE, MAE ve MAPE değerleri ile elde edilen gerçek ve tahmin edilen IHD grafiği Şekil 5-5'de gösterilmektedir.



Şekil 5-6: L3 fazına ait eğitim ve test kayıpları

L3 fazına ait aynı tahmin değerleri ile elde edilen eğitim ve test seti hataları ise Şekil 5-6'te gösterilmiştir. Bu şekle göre eğitim seti hataları mavi renk ile belirtilmiş olup, 0,0045 seviyelerinden 0,0012 seviyelerine azaldığı gözlemlenmektedir. Yine aynı şekil üzerinde test hataları turuncu renk ile gösterilmiş olup, 0,0019 değerlerinden 0,0010 değerlerine gerilediği gözlemlenmiştir. L3 fazı için en kötü RMSE, MAE ve MAPE değerleri sırası ile 3,064, 1,311 ve 28,071'tir. Bu değerler çift katmanlı 200 düğüm sayılı GRU ağı ile elde edilmiştir. L3 fazı için Tablo 5-2'de verilen LSTM ağı kullanılarak, en kötü sonuç olan GRU ağına göre RMSE, MAE ve MAPE değerleri için sırası ile %45, %97 ve %142 daha iyi bir sonuç elde edildiği tespit edilmiştir.

6. SONUÇ VE ÖNERİLER

Harmonikler günümüz üretim teknolojilerinin değişmesi ile iletim/dağıtım sistemleri üzerinde oluşan olumsuz etkiler arasına girmektedir. Harmoniklerin oluşmasının en büyük nedenleri arasında ise şebeke üzerinde bulunan yüklerde çeşitliliklerin artmasıdır. Genelde bu yükler doğrusal olmayan yükler olarak kabul edilmektedir. Doğrusal olmayan yükler, akım ve gerilim karakteristiği saf sinüs formunda olmayan yükler olarak tanımlanmaktadır. Bu yükler; güç elektroniği elemanları, transformatörler, ark ocakları gibi elektriksel elemanlardan oluşmaktadır.

Günümüzde ise ekonomiye ciddi katkılarda bulunan sanayi tesisleri, oluşturulan dağıtım şebekesi üzerinden katılımcılarına 34,5 kV gerilim seviyesinden dağıtım hizmeti vermektedirler. Bu dağıtım hizmetinin bütününe bakıldığında zaman ise demir-çelik, gıda, kimya, metal işlemleri gibi sektörlerde kullanılan; transformatör, ark ocakları, invertörler vb. birçok elektriksel malzemeleri içerisinde barındıran büyük bir yapı oluşmaktadır. Bu büyük yapının içerisinde bulunan elektriksel malzemelerin üretim hızı, ürün kalite performansları, sanayinin daha gelişmiş hale gelmesi gibi olumlu etkilerin yanında, bazı elektriksel olumsuz etkileri de içerisinde barındırmaktadır. Bu olumsuz etkilerden bir tanesi de harmoniklerdir. Doğrusal olmayan yüklerin meydana getirdiği harmoniklerin üzerinde uzunca yıllardır çalışılmaktadır. Bu çalışmalar sonrası harmonikleri ortadan kaldırmak amacı ile birden fazla filtreleme sistemleri geliştirilmiştir. Geliştirilen filtreleme sistemleri sürekli devrede kalarak oluşan harmoniklere karşı reaksiyon almaktadır. Bu çalışma ile harmoniklerin önceden tahmin edilerek gerekirse filtreleme sistemlerini tahmin edilen zaman dilimlerinde devreye girmesini sağlamaktır.

Bu tez çalışmasında, Bandırma Organize Sanayi Bölgesi giriş dağıtım merkezinde bulunan enerji analizörü üzerinden alınan veriler LSTM ve GRU modellerine uygulanarak akım harmoniklerinin (IHD) tahmin (forecasting) edilmesi amaçlanmıştır. 45716 adet veri 06.01.2020 ve 01.01.2021 tarihlerini arasında gerçekleşmiştir. Veriler analizör üzerinden 10'ar dakikalık periyotlar halinde temin edilmiştir. Veri dosyası .csv formatında olup, harmonik değeri, aktif güç değeri, yıl, ay, gün, hafta içi günleri ve haftanın günü değerlerini içerisinde barındırmaktadır. Bu veri seti ile her bir faz için ayrı ayrı, LSTM ve GRU sinir ağlarını içerisinde barındıran 8 farklı model kullanılarak akım harmonikleri (IHD) tahmin çalışması yapılmış ve elde edilen sonuçlar karşılaştırılmıştır.

Modellere uygulanan veriler sonucu oluşan grafiklerde gerçek akım harmoniği (IHD) değerleri (mavi renk) ve tahmin edilen akım harmoniği (IHD) (kırmızı renk) değerleri yorumlanırken

tahminler sonucu elde edilen RMSE, MAE ve MAPE deęerleri ise modelin başarı oranlarını yorumlamaya olanak vermektedir.

RMSE, MAE ve MAPE deęerleri 0 ile ∞ arasında deęerler almaktadır. Modeller arasında RMSE, MAE ve MAPE deęerlerinin en düşük deęere sahip olması o modelin daha başarılı tahmin çalışması yaptığını ifade etmektedir.

Önerilen LSTM aęları modeli, L1 fazı için 2 katman, 100 düęüm, 200 epoch, L2 fazı için 2 katman, 50 düęüm, 200 epoch, L3 fazı için 2 katman, 25 düęüm ve 200 epoch deęerlerine sahiptir. Uygulanan LSTM ve GRU modellerinde sonuçlar incelendiğinde ilk iterasyon adımlarında öğrenme hızının yüksek olduęu, iterasyon adımlarının ortasında bu öğrenmenin bir nebze azaldığı ve iterasyon sonlarında öğrenmenin tekrar hızlı geręekleştięi gözlemlenmiştir. Her üç faz içinde 2 katmanlı modelin tek katmanlı modele istinaden daha iyi öğrenme geręekleştięi tespit edilmiştir. Kullanılan algoritmalarda ise LSTM algoritmalarının GRU algoritmalarından daha iyi tahmin sonuçları verdięi tespit edilmiştir.

7. KAYNAKLAR

- [1] İ. Bozdağ, S. Berat EFE, B. Onyedi Eylül Üniversitesi, F. Bilimleri Enstitüsü, and M. ve Doğa Bilimleri Fakültesi, “Elektrik Güç Sistemleri için Kontrollü Kesici Tasarımı Controlled Breaker Desing for Electric Power Systems Article history,” 2021.
- [2] B. Tabak and M. A. Yalçın, “Elektrik Güç Sistemlerinde Enerji Kalitesi,” *SAU Fen Bilim. Enstitüsü Derg.*, vol. 8, no. 1, pp. 52–54, 2004.
- [3] N. Gurov, V. Chuvychin, I. Andreevsky, and A. Vorzhev, “Problems of power system frequency and active power control,” *Int. Conf. Electr. Power Eng. PowerTech Budapest 1999*, p. 7, 1999, doi: 10.1109/PTC.1999.826438.
- [4] M. Kesler and E. Ozdemir, “Power quality improvement with UPQC in 3-phase 4-wire systems,” *J. Fac. Eng. Archit. Gazi Univ.*, vol. 25, no. 4, pp. 681–691, 2010.
- [5] R. Bayindir, M. Yeşilbudak, and Ü. Çetinkaya, “Güç Sistemlerinde Gerilim Kararlılığını Etkileyen Faktörler,” *Gazi Univ. J. Sci.*, vol. 3, no. 4, pp. 595–602, 2015.
- [6] A. Latran, Mohammad Barghi;Teke, “Güç Kalitesi Problemlerini Düzeltten Dağıtım Sistemine Paralel Bağlı Evirici Tabanlı Kompanzatorların İncelenmesi,” vol. 29, no. 4, pp. 349–354, 2010.
- [7] B. ŞERBETÇİ, Mehmet, “Harmonik Problemi Olan Tesislerde Harmonik Filtreli Kompanzasyon Sistemlerinin Tasarımı ve Analizi,” 2019.
- [8] Serhat Berat EFE, “Güç Sistemlerinde Harmonikler ve Harmoniklerin Analizi,” İnönü Üniversitesi Fen Bilimleri Enstitüsü, 2006.
- [9] C. Filiz, “Güç Sistemlerinde Harmonikler ve Filtrelemelerin İncelenmesi,” Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, 2006.
- [10] Onur DERYA, “Uzun Kısa Süreli Hafıza Derin Yapay Sinir Ağı İle Giresun İli Minimum Sıcaklık Öngörüsü,” Giresun Üniversitesi Fen Bilimleri Enstitüsü, 2021.
- [11] K. J. T. N. Fernando and A. Kalam, “Voltage instability in power systems and the use of artificial intelligence methods for its prediction,” *2008 Australas. Univ. Power Eng. Conf. AUPEC 2008*, pp. 1–4, 2008.
- [12] M. Negnevitsky, “Artificial intelligence applications to security control in power systems,” *Int. Conf. Electr. Power Eng. PowerTech Budapest 1999*, p. 25, 1999, doi: 10.1109/PTC.1999.826456.
- [13] D. Thukaram and H. Kashyap, “Artificial Neural Network Application to Power System . Voltage Stability Improvement,” pp. 3–7, 2003.

- [14] Y. Deng, H. Jia, P. Li, X. Tong, and F. Li, "A Deep Learning Method based on Long Short Term Memory and Sliding Time Window for Type Recognition and Time Location of Power Quality Disturbance," *Proc. 2018 Chinese Autom. Congr. CAC 2018*, pp. 1764–1768, 2019, doi: 10.1109/CAC.2018.8623810.
- [15] W. L. Rodrigues Junior, F. A. Silva Borges, R. D. A. Lira Rabelo, B. V. A. De Lima, and J. E. Almeida De Alencar, "Classification of Power Quality Disturbances Using Convolutional Network and Long Short-Term Memory Network," *Proc. Int. Jt. Conf. Neural Networks*, vol. 2019-July, no. July, pp. 1–6, 2019, doi: 10.1109/IJCNN.2019.8852287.
- [16] S. K. G. Manikonda, J. Santhosh, S. P. K. Sreekala, S. Gangwani, and D. N. Gaonkar, "Power Quality Event Classification Using Long Short-Term Memory Networks," *2019 IEEE Int. Conf. Distrib. Comput. VLSI, Electr. Circuits Robot. Discov. 2019 - Proc.*, pp. 1–5, 2019, doi: 10.1109/DISCOVER47552.2019.9008009.
- [17] M. A. Rodriguez, J. Felipe Sotomonte, J. Cifuentes, and M. Bueno-Lopez, "Power quality disturbance classification via deep convolutional auto-encoders and stacked LSTM recurrent neural networks," *SEST 2020 - 3rd Int. Conf. Smart Energy Syst. Technol.*, 2020, doi: 10.1109/SEST48500.2020.9203082.
- [18] D. Ahmad, S. Wang, and M. Alam, "Long short term memory based deep learning method for fault power line detection in a MV overhead lines with covered conductors," *2020 21st Natl. Power Syst. Conf. NPSC 2020*, 2020, doi: 10.1109/NPSC49263.2020.9331843.
- [19] Y. Zhang, X. Wang, and L. Ding, "LSTM-based dynamic frequency prediction," *IEEE Power Energy Soc. Gen. Meet.*, vol. 2020-Augus, pp. 1–5, 2020, doi: 10.1109/PESGM41954.2020.9281602.
- [20] A. Kelimeler *et al.*, "SHORT TERM ELECTRICAL LOAD FORECASTING BASED ON ARTIFICIAL NEURAL," vol. 2, no. 2, pp. 364–379, 2021.
- [21] Y. J. Wang, C. Lu, and D. W. Li, "Short Term Load Forecasting Based on iForest-LSTM," *Appl. Mech. Mater.*, vol. 672–674, pp. 1413–1420, 2014, doi: 10.4028/www.scientific.net/AMM.672-674.1413.
- [22] M. R. Islam, A. Al Mamun, M. Sohel, M. L. Hossain, and M. M. Uddin, "LSTM-Based Electrical Load Forecasting for Chattogram City of Bangladesh," *2020 Int. Conf. Emerg. Smart Comput. Informatics, ESCI 2020*, pp. 188–192, 2020, doi: 10.1109/ESCI48226.2020.9167536.

- [23] Ermatita, I. Pahendra, E. Darnila, M. Sadli, M. Sinambela, and W. Fuadi, "Peak Load Forecasting Based on Long Short Term Memory," *Proc. - 1st Int. Conf. Informatics, Multimedia, Cyber Inf. Syst. ICIMCIS 2019*, pp. 137–140, 2019, doi: 10.1109/ICIMCIS48181.2019.8985197.
- [24] A. Inteha and Nahid-Al-Masood, "A GRU-GA Hybrid Model Based Technique for Short Term Electrical Load Forecasting," *Int. Conf. Robot. Electr. Signal Process. Tech.*, pp. 515–519, 2021, doi: 10.1109/ICREST51555.2021.9331156.
- [25] S. Kumar, L. Hussain, S. Banarjee, and M. Reza, "Energy Load Forecasting using Deep Learning Approach-LSTM and GRU in Spark Cluster," *Proc. 5th Int. Conf. Emerg. Appl. Inf. Technol. EAIT 2018*, pp. 2–5, 2018, doi: 10.1109/EAIT.2018.8470406.
- [26] G. Xiuyun, W. Ying, G. Yang, S. Chengzhi, X. Wen, and Y. Yimiao, "Network Based on Deep Learning Framework," *2018 2nd IEEE Conf. Energy Internet Energy Syst. Integr.*, pp. 1–4, 2018.
- [27] J. Huo, T. Shi, and J. Chang, "Comparison of Random Forest and SVM for electrical short-Term load forecast with different data sources," *Proc. IEEE Int. Conf. Softw. Eng. Serv. Sci. ICSESS*, vol. 0, pp. 1077–1080, 2016, doi: 10.1109/ICSESS.2016.7883252.
- [28] H. Altınçöp and A. B. Oktay, "Air Pollution Forecasting with Random Forest Time Series Analysis [Rastgele Orman Zaman Serisi Analizi ile Hava Kirliliği Tahmini]," *2018 Int. Conf. Artif. Intell. Data Process. IDAP 2018*, pp. 8–12, 2019, [Online]. Available: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85062484784&doi=10.1109%2FIDAP.2018.8620768&partnerID=40&md5=8ec58a60e93d963aa8e2a8642e31c7db>.
- [29] C. B. Pop, V. R. Chifu, C. Cordea, E. S. Chifu, and O. Barsan, "Forecasting the Short-Term Energy Consumption Using Random Forests and Gradient Boosting," *Proc. - RoEduNet IEEE Int. Conf.*, vol. 2021-Novem, 2021, doi: 10.1109/RoEduNet54112.2021.9638276.
- [30] R. Cai, S. Xie, B. Wang, R. Yang, D. Xu, and Y. He, "Wind speed forecasting based on extreme gradient boosting," *IEEE Access*, vol. 8, pp. 175063–175069, 2020, doi: 10.1109/ACCESS.2020.3025967.
- [31] S. H. Rafi, Nahid-Al-Masood, and M. M. Mahdi, "A Short-Term Load Forecasting Technique Using Extreme Gradient Boosting Algorithm," pp. 1–5, 2022, doi: 10.1109/isgtasia49270.2021.9715272.
- [32] S. Singh and M. M. Tripathi, "A Comparative Analysis of Extreme Gradient Boosting

- Technique with Long Short-Term Memory and Layered Recurrent Neural Network for Electricity Demand Forecas,” *2021 6th Int. Conf. Recent Trends Electron. Information, Commun. Technol. RTEICT 2021*, pp. 297–302, 2021, doi: 10.1109/RTEICT52294.2021.9573988.
- [33] C. N. Obiora, A. Ali, and A. N. Hasan, “Implementing extreme gradient boosting (xgboost) algorithm in predicting solar irradiance,” *2021 IEEE PES/IAS PowerAfrica, PowerAfrica 2021*, 2021, doi: 10.1109/PowerAfrica52236.2021.9543159.
- [34] A. E. DİNÇER, S. C. Temel, and S. M. Öztürk, “Düzce Üniversitesi Bilim ve Teknoloji Dergisi,” *Düzce Üniversitesi Bilim ve Teknol. Derg.*, vol. 9, no. 1, pp. 278–292, 2021.
- [35] H. Eroğlu, “Bir Dağıtım Şebekesinin Güç Kalitesi ve Harmonikler Yönünden İncelenmesi,” SELÇUK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ, 2009.
- [36] S. B. EFE, “Harmonic and Inter-Harmonic Analysis in Electric Machines,” *Electron. Lett. Sci. Eng.*, vol. 7, no. 2, pp. 2–6, 2011.
- [37] İ. İLASLANER, “Güç Kalitesinde Harmonikler ve Filtrelenmesi,” GAZİ ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ, 2006.
- [38] F. B. Gürbüz, “Tekrarlayan Sinir Ağı -Recurrent Neural Networks (RNN),” 2020. <https://medium.com/@batincangurbuz/tekrarlayan-sinir-agı-recurrent-neural-networks-rnn-17b517dd0b3e>.
- [39] M. Imani, “Long short-term memory network and support vector regression for electrical load forecasting,” *5th Int. Conf. Power Gener. Syst. Renew. Energy Technol. PGSRET 2019*, pp. 26–27, 2019, doi: 10.1109/PGSRET.2019.8882730.
- [40] Y. Timoshenkova, N. Safiullin, and S. Porshnev, “About Influence of Weight Initialization Algorithms on Accuracy of the Forecast with LSTM-net for Harmonic Signals,” *Proc. - 2021 Ural Symp. Biomed. Eng. Radioelectron. Inf. Technol. USBEREIT 2021*, no. 1, pp. 330–333, 2021, doi: 10.1109/USBEREIT51232.2021.9455014.
- [41] L. Liu, J. Fei, and C. An, “Adaptive Sliding Mode Long Short-Term Memory Fuzzy Neural Control for Harmonic Suppression,” *IEEE Access*, vol. 9, pp. 69724–69734, 2021, doi: 10.1109/ACCESS.2021.3077646.
- [42] W. C. Hong, C. Y. Lai, W. M. Hung, and Y. Dong, “Electric load forecasting by SVR with chaotic ant swarm optimization,” *2010 IEEE Conf. Cybern. Intell. Syst. CIS 2010*, pp. 102–107, 2010, doi: 10.1109/ICCIS.2010.5518572.
- [43] J. Dhillon, S. A. Rahman, S. U. Ahmad, and M. J. Hossain, “Peak electricity load forecasting using online support vector regression,” *Can. Conf. Electr. Comput. Eng.*, vol.

- 2016-Octob, pp. 1–4, 2016, doi: 10.1109/CCECE.2016.7726784.
- [44] B. S. Kwon, R. J. Park, and K. Bin Song, “Weekly Peak Load Forecasting for 104 Weeks Using Deep Learning Algorithm,” *Asia-Pacific Power Energy Eng. Conf. APPEEC*, vol. 2019-Decem, pp. 1–4, 2019, doi: 10.1109/APPEEC45492.2019.8994442.
- [45] Y. L. Abdel-Magid and M. M. Dawoud, “Genetic algorithms applications in load frequency control,” *IEE Conf. Publ.*, no. 414, pp. 207–213, 1995, doi: 10.1049/cp:19951050.
- [46] A. KARA, “Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini,” *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, vol. 7, no. 4, pp. 882–892, 2019, doi: 10.29109/gujsc.571831.
- [47] A. Ioanes and R. Tirnovan, “Energy Price Prediction on the Romanian Market using Long Short-Term Memory Networks,” *2019 54th Int. Univ. Power Eng. Conf. UPEC 2019 - Proc.*, 2019, doi: 10.1109/UPEC.2019.8893550.
- [48] DevHUNTER, “Uzun-Kısa Süreli Bellek (Long Short-Term Memory),” 2018. <https://devhunteryz.wordpress.com/2018/07/14/uzun-kisa-sureli-bellek-long-short-term-memory/>.
- [49] S. TURAN, “Uzun Kısa Süreli Hafıza ve Geçitli Yinelenen Birimi İle Borsa İstanbul 100 Endeks Değeri Tahmini Üzerine Bir Uygulama,” *YILDIZ TEKNİK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ*, 2019.
- [50] G. Javid, M. Basset, and D. O. Abdeslam, “Adaptive Online Gated Recurrent Unit for Lithium-Ion Battery SOC Estimation,” *IECON Proc. (Industrial Electron. Conf.)*, vol. 2020-Octob, no. Cc, pp. 3583–3587, 2020, doi: 10.1109/IECON43393.2020.9254506.
- [51] Vishal Morde, “XGBoost Algorithm,” 2019. <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>.
- [52] M. G. Alfarizi, J. Vatn, and S. Yin, “An Extreme Gradient Boosting Aided Fault Diagnosis Approach: A Case Study of Fuse Test Bench,” *IEEE Trans. Artif. Intell.*, vol. 00, no. 0, pp. 1–1, 2022, doi: 10.1109/tai.2022.3165137.
- [53] L. Wei and J. Li, “Short-term load forecasting based on MA-LSSVM,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 781, no. 4, pp. 934–939, 2021, doi: 10.1088/1755-1315/781/4/042012.
- [54] M. Lin and L. Ma, “Research on Setting Voltage of Electrolyzer Based on LGBM-LSTM Algorithm,” *2021 IEEE 4th Int. Conf. Comput. Commun. Eng. Technol. CCET 2021*, pp. 414–419, 2021, doi: 10.1109/CCET52649.2021.9544496.

- [55] Özlem BEZEK GÜRE, “Öğrencilerin Matematik Başarılarını Etkileyen Faktörlerin Rastgele Orman, Çok Katmanlı Algılayıcı ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağları Yöntemleri İle Tahminleme Yeteneği Açısından Karşılaştırılması: Türkiye Örneği,” 2019.
- [56] S. ÖZDEMİR, “Potential Distribution Modelling and Mapping Using Random Forest Method: an Example of Yukarıgökdere District,” *Turkish J. For. | Türkiye Orman. Derg.*, vol. 19, no. 1, pp. 51–56, 2018, doi: 10.18182/tjf.342504.
- [57] E. C. GÖK, “Kan Değerleri İle Covid-19 Enfekte Düzeyinin Rassal Orman Sınıflandırıcı İle Tahmin Edilmesi,” 2021.
- [58] Y. GÜLTEPE, “Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme,” *Eur. J. Sci. Technol.*, no. 16, pp. 8–15, 2019, doi: 10.31590/ejosat.530347.

ÖZGEÇMİŞ

Kişisel Bilgiler		Fotoğraf
Adı Soyadı	İsmail BOZDAĞ	
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	

Makale ve Bildiriler
İ. Bozdağ and S. B. Efe, “Elektrik Güç Sistemleri için Kontrollü Kesici Tasarımı” Mühendislik Bilimleri ve Araştırmaları Dergisi, 3(2), 226–234, 2021.