

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**DERİN ÖĞRENME TABANLI ELEKTRİK DAĞITIM TRAFO
MERKEZLERİNDE YÜK TAHMİNİ: AZERBAYCAN ÖRNEĞİ**

Vusal ISAYEV

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

NİSAN 2024

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**DERİN ÖĞRENME TABANLI ELEKTRİK DAĞITIM TRAFO
MERKEZLERİNDE YÜK TAHMİNİ: AZERBAIJAN ÖRNEĞİ**

Vusal ISAYEV

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

NİSAN 2024

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME TABANLI ELEKTRİK DAĞITIM TRAFO
MERKEZLERİNDE YÜK TAHMİNİ: AZERBAYCAN ÖRNEĞİ

Vusal ISAYEV

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS

Bu tez 19/04/2024 tarihinde jüri tarafından Oybirliği / Oyçokluğu ile kabul edilmiştir.

Dr. Öğr. Üyesi Yalçın ALBAYRAK (Danışman)

Prof. Dr. Selçuk HELHEL

Dr. Öğr. Üyesi Mehmet Erhan ŞAHİN

ÖZET

DERİN ÖĞRENME TABANLI ELEKTRİK DAĞITIM TRAFO MERKEZLERİNDE YÜK TAHMİNİ: AZERBAYCAN ÖRNEĞİ

Vusal ISAYEV

Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Yalçın ALBAYRAK

NİSAN 2024 ;47 sayfa

Elektrik enerjisi, çeşitli üretim santrallerinde üretilen, dağıtım hatları ile yerleşim veya sanayilere aktarılabilen ama kontrollü bir şekilde depolanmayan enerji kaynağıdır. Gelişmekte olan teknolojilerden, ağır sanayiden ve artan nüfustan dolayı genellikle tüm enerjiye bağımlılığımız arttığı gibi elektrik enerjisinde bağımlılığımız artmaktadır. Bundan kaynaklı olarak tüm dünyada ve ülkemizde elektrik enerjisi üretimini artırmağa çalışmaktadır. Enerji üretimi arttıkça ise bazı gerekli olan üretim kaynakları ise aynı oranda düşmektedir. Bundan dolayı enerji dağıtım ve iletim akıllı sayaçlar anlık takibi yapılarak arz talep dengesini anlık izleme imkânı veren akıllı şebekeler mevcuttur.

Elektrik enerjisi tüketiminin artışıyla birlikte, tasarruflu enerji kullanımını teşvik etmek, enerji dağıtım ve iletimi sırasında meydana gelen kayıpları azaltmak için gerekli önlemleri almak büyük önem taşır. Enerjiyi verimli kullanabilmek için kullanılan yöntemlerden biri de enerji talebinin önceden tahmin edilmesidir. Çeşitli yöntemler arasında özellikle kısa dönemli enerji tahmini önem kazanmaktadır. Bu çalışmada, Azerbaycan'da Şirvan bölgesinin de yer alan bir indirim ve altı trafo merkezinin akıllı sayaçlarla her 15 dk okunan tüketim verileri ve ayrıca hava durumu verileri kullanılarak derin öğrenme tabanlı bir tüketim tahmin modeli geliştirilmiştir. Böylelikle derin öğrenme tabanlı modeli daha iyi bir performans sağlanmıştır. Her trafo ve bir indirgeme merkezi için ayrı modeller geliştirilmiş olup, %93 üzerin de bir başarı elde edilmiştir.

ANAHTAR KELİMELER: Derin Öğrenme, Trafo Merkezleri Elektrik Tahmini, Yapay Sinir Ağları, Yinelemeli Sinir Ağları

JÜRİ: Dr. Öğr. Üyesi Yalçın ALBAYRAK

Prof. Dr. Selçuk HELHEL

Dr. Öğr. Üyesi Mehmet Erhan ŞAHİN

ABSTRACT

LOAD ESTIMATION IN ELECTRICITY DISTRIBUTION SUBSTATIONS USING DEEP LEARNING: THE CASE OF AZERBAIJAN

Vusal ISAYEV

MSc. Thesis in Department of Electric-Electronic Engineering

Supervisor: Asst. Prof. Dr. Yalçın ALBAYRAK

APRIL 2024; 47 pages

Electrical energy is generated in diverse power plants and can be sent to residential or industrial regions through distribution lines, but it is not stored in a regulated manner. Owing to the advancing technology, burgeoning heavy industry, and growing population, our need on electrical energy is escalating, just as our reliance on all forms of energy is increasing. As a result, countries worldwide, including our own, are making efforts to boost the production of electrical energy. As energy production rises, certain essential production resources are diminishing at an equivalent rate. Smart grids enable real-time monitoring of energy distribution and transmission through the use of smart meters, which in turn allows for immediate assessment of the supply and demand balance.

Given the rising demand for electricity, it is crucial to implement methods that promote energy conservation and minimize losses throughout the distribution and transmission of energy. Energy demand forecasting is a method commonly employed to enhance energy efficiency. Short-term energy forecasting is becoming increasingly important among many methodologies. This paper presents the development of a consumption forecasting model based on deep learning. The model utilizes consumption data from one substation and six substations in the Shirvan region of Azerbaijan. The data is collected every 15 minutes using smart meters, along with weather data. Therefore, the deep learning based model achieves improved performance. Individual models were created for each substation and a reduction center, resulting in a success rate exceeding 93%.

KEYWORDS: Deep Learning, Substations Electricity Forecasting, Neural Network ,Recurrent Neural Network

COMMITTEE: Asst. Prof. Dr. Yalçın ALBAYRAK

Prof. Dr. Selçuk HELHEL

Asst. Prof. Dr. Mehmet Erhan ŞAHİN

ÖNSÖZ

Bu çalışmanın gerçekleştirilmesinde, değerli bilgilerini benimle paylaşan, kendisine ne zaman danışsam bana kıymetli zamanını ayırıp sabırla ve büyük bir ilgiyle bana faydalı olabilmek için elinden gelenden fazlasını sunan her sorun yaşadığımda yanına çekinmeden gidebildiğim, güler yüzünü ve samimiyetini benden esirgemeyen ve gelecekteki mesleki hayatımda da bana verdiği değerli bilgilerden faydalanacağımı düşündüğüm kıymetli ve danışman hoca statüsünü hakkıyla yerine getiren Dr.Öğr.Üyesi Yalçın Albayrak'a teşekkürü bir borç biliyor ve her zaman çalışmalarımda bana destek olan Azerışiq A.S.C kurumundan Ramil Yusufov'a şükranlarımı sunuyorum.

Çalışmamda desteğini benden esirgemeyen kardeşim Elshad Isazade ve beni bu günlere sevgi ve saygı kelimelerinin anlamlarını bilecek şekilde yetiştirerek getiren ve benden hiçbir zaman desteğini esirgemeyen bu hayattaki en büyük şansım olan aileme sonsuz teşekkürler.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ	iii
İÇİNDEKİLER	iv
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGE DİZİNİ.....	ix
1. GİRİŞ	1
1.1. Çalışmanın Amaç ve Kapsamı	1
1.2. Azerbaycan Cumhuriyeti Devleti Elektrik Şebekesi Tarihçesi.....	2
2. KAYNAK TARAMASI	4
2.1. Elektrik Tüketim Tahmini Yapılan Çalışmalar.....	4
2.2. İndirgeme ve Trafo Merkezi	7
2.3. Akıllı Elektrik Sayaçları.....	10
3. MATERYAL VE METOT	19
3.1. Veri Bileşenleri	20
3.1.1. Hava Durumu Verileri.....	22
3.2. Temel Bileşen Analizi.....	24
3.2.1. Normalizasyon	25
3.2.2. Zaman Serisini Denetimli Öğrenmeye Dönüştürme	27
3.2.3. Train Test Split.....	29
3.3. Derin Öğrenme.....	30
3.3.1. Yinelemeli Sinir Ağı	30
3.3.2. Gated Recurent Unit (GRU).....	31
3.3.3. Model Tanımı ve Metriklerin Belirlenmesi	33
3.4. Model Eğitim ve Değerlendirilmesi.....	34
3.4.1. Aykırılık Analizi	36
3.4.2. Cosf Bileşeni Aykırılık Analizi.....	36
3.4.3. Tüketim Bileşeni Aykırılık Analizi.....	37
3.4.4. Voltage ve Current Tüketim Bileşeni Aykırılık Analizi	38

4. BULGULAR VE TARTIŞMA	41
4.1. Derin Öğrenme Modelin Çıktıları.....	41
4.2. Aykırı Değer Tespiti Sonuçları	44
5. SONUÇLAR	45
6. KAYNAKLAR	46
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Derin Öğrenme Tabanlı Elektrik Dağıtım Trafo Merkezlerinde Yük tahmini: Azerbaycan Örneği” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

...../...../20....

Vusal ISAYEV

İmzası

SİMGELER VE KISALTMALAR

Simgeler

A	: amper
AC	: Alternatif Akım
ASC	: Anonim Sanayi Şirketi
DC	: Sabit Akım
kWh	: kilo Watt saat
P	:Aktif Güç
R	:Reaktif Güç
S	: Görünen Güç
V	: Gerilimin Birimi
W	: Waat

Kısaltmalar

Azerışiq	: Azərbaycan Elektrik Dağıtım Şirketi
IoT	: Nesnelerin İnterneti
LSTM	: Uzun Kısa süreli Bellek
MAE	: Ortalama Mutlak Hata
MSE	: Ortalama Karesel Hata
OBIS	: Object Identification System
RNN	: Yinelemeli Sinir Ağı
PCA	: Temel Bileşen Analizi
YSA	: Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 1.1. Enerjinin Kaynakları.....	1
Şekil 2.1. İndirgeme Merkezi	7
Şekil 2.2. Eski Mekanik Sayaç	10
Şekil 2.3. Luna Elektrik Sayacı	12
Şekil 2.4. Örnek OBIS Kodları, A1xxx ALPHA - Elektrik Sayaçları OBIS (IEC) Kodları	14
Şekil 2.5. RS485 Bağlantı Şeması	17
Şekil 3.1. Model Eğitimin Akış Diyagramı	20
Şekil 3.2. Aykırılık Tahlili.....	22
Şekil 3.3. Özelik Seçimi	24
Şekil 3.4. Veri setinin Yeni Hali.....	24
Şekil 3.5. Sıralı Verilerin Formatı	28
Şekil 3.6. train_test_split Görseli.....	30
Şekil 3.7. LSTM ve GRU Yapısı.....	33
Şekil 3.8. LSTM&GRU Model Mimarisi.....	34
Şekil 3.9. Eğitim Hata Grafiği	34
Şekil 3.10. Gerçek ve Tahmin Sonuçları	35
Şekil 3.11. Aykırılık Analizi Diyagramı.....	36
Şekil 3.12. Verimli ve Aykırı Tüketim Grafiği	38
Şekil 3.13. Voltage Aykırılık Görselleştirilmesi	39
Şekil 3.14. Arızalı Trafo Voltage Aykırılık Görselleştirilmesi.....	39
Şekil 3.15. Current Aykırılık Görselleştirilmesi	40
Şekil 3.16. Arızalı Trafo Current Aykırılık Görselleştirilmesi	40
Şekil 4.1. Kopuk kablo kesiti.....	44

ÇİZELGE DİZİNİ

Çizelge 3.1. Veri Seti.....	20
Çizelge 3.2. Uygulanmış Veriseti	25
Çizelge 3.3. Normalize Edilmiş Veriseti	27
Çizelge 3.4. series_to_supervised Uygulanmış Veri seti.....	28
Çizelge 3.5. Veri Seti.....	36
Çizelge 3.6. Verimli Tüketim	37
Çizelge 4.1. Trafo için Model Eğitim Grafiği ve Kayıp Grafiği	41
Çizelge 4.2. Her Modelin RMSE ve R2 Skoru.....	43




1. GİRİŞ

1.1. Çalışmanın Amaç ve Kapsamı

Gelişmiş ülkelerin rekabetlerdeki en önemli unsurlardan biri olan enerji günümüzün en vazgeçilmez kaynağı olmuştur. Sanayi, askeri savunma ve birçok sektörlerde de zorunlu hale gelmektedir. Elektrik enerjisi yalnızca üretilen ülkenin ihtiyacını karşılamak değil aynı zamanda ülkenin refah seviyesinin yükseltilmesinde aracı olan ekonomik, sosyal kalkınma potansiyelini yansıtan temel göstergedir. Günümüzde, dünyada hızla artan nüfus artışı, sanayilerin büyümesi ile beraber enerjiye olan talep günden güne talebin arttığını görüyoruz (Ahmad 2020).

Devletlerin gelişmişlik seviyelerinin belirlenmesinde önemli rol oynayan enerjinin, öz kaynakları doğada bulunduğu haliyle kullanışlarına göre yenilenebilir ve yenilenemez enerji kaynakları olarak çeşitlilik şekil 1.1’de (Ülkü 2021) gösterilmektedir. Bu öz kaynakların herhangi bir değişim görmemiş hali birincil enerji kaynağı olarak ifade edilirken uygun yöntemler kullanılarak birincil enerji kaynaklarının dönüştürülmesi sonucu elde edilen enerji kaynakların görülse de üstünlüğünü koruduğu ve gelecekte de koruyacağı ikinci bölümde enerjinin durumu adı altında verilen istatistiki bilgilerde de gözlenmektedir.



Şekil 1.1. Enerjinin Kaynakları

Enerji, modern yaşamın temel unsurlarından biridir ve küresel düzeyde endüstriyel üretimden ısınma, aydınlatma ve ulaşım gibi birçok alanda hayati bir rol oynamaktadır (Yılmaz 2022). Enerji talebi, nüfus artışı, sanayileşme ve teknolojik gelişmeler gibi faktörlerin etkisiyle sürekli artmaktadır. Bu durum, enerji sektörünü ve enerji kaynaklarını daha etkili bir şekilde yönetmeyi, enerji güvenliğini sağlamayı ve sürdürülebilirlik hedeflerini gerçekleştirmeyi zorunlu hale getirmektedir.

Enerji sektörünün karmaşıklığı, değişkenliği, enerji tahmin süreçlerini önemli kılmaktadır. Kısa dönemli enerji tahmini, genellikle birkaç hafta ila birkaç gün sonrasına kadar olan dönemi kapsar ve enerji talebinin ve arzının gelecekteki durumunu tahmin etmek amacıyla kullanılır. Bu tahminler, çok sayıda değişkeni hesaba katarak gelecekteki enerji ihtiyacını, enerji fiyatlarını ve tüketim örüntüleri öngörme konusunda temel bir rol oynamaktadır.

Kısa dönemli enerji tahmininin uygulama alanları oldukça geniştir. Enerji şirketleri, elektrik dağıtım şirketleri, enerji pazarı düzenleyici hükümetler, enerji üretimini, dağıtımını ve tüketimini daha iyi yönetmek için bu tahminlere dayanmaktadır. Ayrıca, enerji maliyetlerini ve kararlarını etkileyen birçok önemli faktörün belirlenmesine yardımcı olurlar.

1.2. Azerbaycan Cumhuriyeti Devleti Elektrik Şebekesi Tarihçesi

Azerbaycan'ın enerji kaynakları arasında hidroelektrik enerji de önemli bir rol oynamaktadır. Azerbaycan'ın enerji sektörü, bu doğal kaynakların yanı sıra kömür, doğalgaz ve nükleer enerji gibi diğer kaynakları da kullanmaktadır. Ancak, yenilenebilir enerji kaynaklarına yönelik artan ilgi, Azerbaycan'ın enerji bağımsızlığını artırmak ve sürdürülebilir enerji geleceğine doğru adım atmaya yardımcı olmaktadır.

Azerbaycan Devletinin elektrik şebekesini tarihçesi 1895 yılında Bakü'de ilk elektrik santrali Bayıl Şosesi üzerindeki Bakü tersanelerin de kurulmuştur. Azerbaycan Cumhuriyeti Devlet Tarihi Arşivinin belgelerine göre akım, Alman yapımı "Algemayne" sisteminin dinamo-makinasından sağlanmıştır. 1898-1899 yıllarında şehirde "Elektriçeskaya sila" (Elektrik Gücü) adlı Ortaklık Şirketi'nin Bakü şubesi kuruldu. Bu Şirket, kendi sırasında, "Siemens ve Halske" firmasının 1886 yılında kurulan "Elektrik Aydınlatma Şirketi"nin bir filialı idi.

1900 yılında "Siemens ve Halske" firması Bibiheybet'te - Bayıl burnunda ve Kara şehirde (şimdiki Beyaz şehir) ikinci elektrik santralini kurulmasına başlandı. 1901 yılının Temmuz ayının başında Bibiheybet elektrik santrali denemelerden geçirildi, bir hafta sonra ise santral daimi kullanıma verildi. 1902 yılında ise Kara şehirde elektrik santrali işletmeye alındı. 1903 yılında elektrik santrallerinin sayısı zaten 70'e ulaşmıştı. 1906 yılının Mart ayında ilk defa elektrik enerjisinin iletimine başlandı. Kara şehirdeki elektrik yarı istasyonundan Balakhana petrol madenlerine 8,1 km uzunluğunda 20 kV gerilimli iki elektrik hava hattı çekildi. Sonraki gelişim 1909-1920 yıllarında gerçekleşti. Balakhana, Ramana ve Surakhany bölgelerinde 60'tan fazla transformator istasyonu inşa edildi. 1920 yılında cumhuriyetin sınırları içinde yer alan enerji tesisleri millileştirildi ve bunların temelinde "Elektrotok" adlı yönetim kuruldu.

Bakü Elektrik Şebekesi 1920 yılından itibaren bir dizi kuruluşun bünyesinde faaliyet göstermiştir. 1929 yılına kadar Azneft'in "Elektrotok" yönetiminin bünyesinde olmuş, 1929 yılında SSCB Merkezi Yürütme Komitesinin Kararı ile Bakü Şehir Elektrik

Şebekesi (BŞEŞ), Bakü Şehir Sovyetinin bünyesine verilmiştir. Azerbaycan Cumhuriyeti Bakanlar Soveti'nin Kararı ile 1963 yılında Enerji ve Elektrifikasyon Baş İdaresinin bünyesinde olmuştur. 1969 yılından 2000 yılına kadar ise Bakü Şehir Yürütme Komitesi'nin, Bakü Şehir Yürütme otoritesinin bünyesinde faaliyet göstermiştir.

Büyük yarı istasyonların, üretim tesislerinin ve elektrik hatlarının inşası yalnızca geçen yüzyılın 70'li yıllarında geniş ölçüde başladı. O zaman bu işlerin öncüsü cumhuriyete yeni atanan lider ulusal lider Haydar Aliyev idi.

Azerbaycan Cumhuriyeti Cumhurbaşkanı'nın 2000 yılı 14 Haziran tarihli kararnamesi ile başkentin elektrik şebekesinin faaliyetinin sağlamlaştırılması ve şehrin elektrik enerjisi ile teminatının iyileştirilmesi amacıyla "Baku elektrikşebek" Açık Tip Ortaklık Şirketi kuruldu. 02.01.2002 tarihinden 03.07.2006 tarihine kadar Türkiye'nin "Barmek Holding A.Ş." şirketine yönetim verilmiştir. Azerbaycan Cumhuriyeti Cumhurbaşkanı'nın 10.08.2006 tarihli kararnamesi ile "Baku elektrikşebek" AŞ'nin faaliyeti yeniden başlatıldıktan sonra yenileme ve yatırım işlerinin yapılması amacıyla Cumhurbaşkanı'nın rezerv fonundan maddi yardım ayrılması hakkında ilgili karar verilmiştir. Haydar Aliyev siyasi kursunun layığıyla devam ettiricisi Azerbaycan Cumhuriyeti Cumhurbaşkanı sayın İlham Aliyev tarafından ülkemizin diğer alanları gibi elektroenerji alanına da sürekli dikkat ve özen gösterilmektedir.

Azerbaycan Cumhuriyeti Cumhurbaşkanı sayın İlham Aliyev'in 10 Şubat 2015 tarihli kararnamesi ile "Baku elektrik şebek" AŞ'nin adı değiştirilerek "Azerişiq" AŞ adlandırılmakla Azerbaycan Cumhuriyeti topraklarında (Nahçıvan Özerk Cumhuriyeti hariç) tüketicilerin güvenilir, güvenli ve verimli şekilde elektrik enerjisi ile tedarik edilmesi "Azerişiq ASC" ye devredilmiştir.

2. KAYNAK TARAMASI

2.1. Elektrik Tüketim Tahmini Yapılan Çalışmalar

Elektrik enerjisinin tüketimini tahmin etmek son yıllarda literatür de birçok çalışma yer almaktadır. Yapay zekâ algoritmalarından önce enerji tüketim tahmini için zaman serisi veya regresyon modelleri kullanılmıştır (Deb 2017). İstatiksel yöntemler iyi performans gösterirler ama yapay zekâ algoritmaları kadar öğrenme yetenekleri geniş olmadıkları gibi, büyük veri kümelerinin de ve karmaşık problemlerde yapay zeka algoritmaları kadar başarı gösterememektedirler. Yapay zekâ algoritmaları, veriden öğrenme, daha karmaşık problemleri çözme yeteneği ve farklı alanlardaki etkin kullanımı nedeni ile elektrik tüketimin tahmini için literatürde birçok çalışma gerçekleştirilmiştir.

Kocadayi (2017) de Zonguldak, Karabük, Bartın bölgesin de yıllık elektrik tüketimi yapay sinir ağları (YSA) 2002-2014 yıllarından nüfus, bina, ithalat ve ihracat verileri YSA nın girdileri olarak elektrik tüketim verileri YSA modeli geliştirmişler. YSA nın performansını Ortalama Karesel Hata (MSE), Ortalama Mutlak Hata(MAE), Korrelasyon katsayısı (R2) ile ölçülmüş olup, %90,55 doğruluk oranı ile tahmin geliştirmişlerdir.

Haliloğlu (2018) çalışmasından Türkiye için kısa vadeli elektrik tahmin Ocak 2012- Nisan 2018 elektrik tüketimi, sıcaklık verilerinde tüketim üzerinde etkisi gösterilmiş olup, aynı şekil de bayram günlerin de elektrik tüketim de belirgin bir değişimi olduğu gösterildiğinden bu verilerle veri seti oluşturularak en küçük kareler (EKK) yöntemi ile model geliştirilmiştir.

Addoos ve arkadaşları (2015) yaptıkları çalışmada kısa vadeli yük tahmini için önceki günlerin yükü ve sıcaklık verilerini kullanarak yeni bir hibrit yöntem önermişlerdir. Gereksiz verilerin elenmesi için özellik seçimi yöntemi kullanarak öğrenme sürecini hızlandırmak ve tahmin genellemesi artırmak için kullanılmıştır. Hafta içi ve hafta sonu elektrik yükü tahmini için iki ayrı model geliştirilmiştir. Karşılaştırmalı sonuçla, önerilen yöntemin öngörü açısından önceliği gösterilmiştir.

Torres ve ard (2022) çalışmalarından 2007'den 2016'ya kadar İspanya'nın elektrik verilerinden oluşan zaman serisini sürdürebilir ve güvenli akıllı şebekeler için derin sinir ağı modeli önerilmiştir. İlk olarak hiper parametreler için en uygun değerler belirlenmiş bir uzun kısa süreli bellek (LSTM) mimarisi geliştirilmiş. %1.5 altından bir tahmin hatası elde edilmiştir.

Shaikh (2022), akıllı şebekeler için, binlerce müşteriden gelen tüketim verilerini işleyen bir model geliştirmişlerdir. 169 müşterinin enerji tüketiminden oluşan büyük veri kümesi üzerin de sinirsel Tabanlı Genişleyen Analiz Yöntemi (N-Beats) modeli geliştirilmiştir. Önerilen modeli doğrulamak için LSTM, GRU, TCN modelleri kıyaslanmıştır. N-BEATS modeli 1,2,4 ve 4 haftalık tahmin modeli 1 gün önceden enerji tüketimi tahmini daha iyi bir sonuç ortaya koyduğunu belirtmişlerdir.

Ngo (2022), binalarda bir gün öncesinde enerji tüketim 30 dakikalık aralıkla tahmin etmek için hibrit bir yapay zekâ modeli önermişlerdir. Altı binadan 30 dakikalık tüketim verileri ile hava durumu verileri ile SAMFOR (Support Vector Regression) modeli geliştirmişlerdir. %9.56 mutlak yüzde hatası (MAPE) bir gün öncesinde enerji tüketimin etkili olduğu gösterilmiştir.

Mishra (2024), Binalarda enerji tüketimi tahmin yapmak için hava durumu verileri ile LSTM ile geliştirilmiştir. Bu model, doğrusal regresyon, kara ağaçları gibi modellerle kıyaslandığında 0.97 R2 değeri iyi bir performans ile enerji tahminin de katkıda bulunmuştur.

Mikayilov (2017) çalışmasında, Azerbaycan'daki elektrik talebinin zaman içinde gelir ve fiyat değişikliklerine nasıl tepki verdiğini ileri ekonometrik metodlar kullanarak araştırıyor. Çalışma, özellikle yararlı olan zaman değişkenli katsayı eşbütünleşme yöntemini kullanıyor. Bu yöntemle, gelir esnekliğinin incelenen dönem boyunca önemli ölçüde değiştiği gözlemlenmiş, bu değişim yüzde 0.48 ile yüzde 0.56 arasında değişen oranlarda saptanmış. Araştırma, Azerbaycan'daki elektrik tüketiminin gelir ve fiyat yönleriyle ilgili faydalı politika önerileri sunuyor.

Hasanov (2017) çalışmasında, STIRPAT çerçevesi içinde Azerbaycan'da 0-14, 15-64 ve 65 ve üstü yaş gruplarının konut elektrik tüketimi üzerindeki etkilerini incelemişler. Daha önce yapılan birçok STIRPAT çalışmasından farklı olarak, bu etkiyi, kullanılan durağan olmayan verilerden kaynaklanabilecek olası yanıltıcı tahmin sonuçlarını ortadan kaldırmak için eş bütünleşme ve hata düzeltme yöntemi kullanarak analiz ettik. Küçük örneklem durumlarında alternatifler arasında tercih edilen yöntem olan Otoregresif Dağıtılmış Gecikmeler Sınır Testi yaklaşımından elde edilen sonuçlar, refah düzeyi ile birlikte yaş gruplarının Azerbaycan'daki konut elektrik tüketimi üzerinde önemli bir etkiye sahip olduğunu ve en büyük etkinin çalışma çağındaki 15-64 yaş grubundan geldiğini gösterdi. Çalışmanın bir diğer bulgusu ise, sistemi başlangıçta etkileyen herhangi bir (ekonomik, sosyal, çevresel vb.) şoka karşı, tüm şokun sistem tarafından bir yıldan daha kısa sürede absorbe edileceğidir. Çalışmanın bulguları, konut elektrik tüketimi alanında uygun kararlar alınmasında faydalı olabilir.

Akbarov (2023), “Azerbaycan Elektrik Enerjisi Tüketiminin Yapay Zeka Yöntemleri ile Analiz ve Tahmini” başlıklı tezinde ise 2000-2021 yılları arasında Azerbaycan'da kullanılan enerji miktarına dair veriler incelenmiş ve geleceğe yönelik tahminler yapılmıştır. ARIMA, LSTM ve Prophet modelleri kullanılarak zaman serisi analizi gerçekleştirilmiştir. Bu modeller performans kriterlerine göre değerlendirilmiş, veriler %80 eğitim ve %20 test olarak ayrılmıştır. Sonuçlara göre en iyi uyumu ve tahmin başarısını gösteren model Prophet olarak belirlenmiştir. Prophet modeli, bu veri seti için en uygun model olarak seçilmiş ve 2027 yılına kadar elektrik tüketim tahmini yapılmıştır. LSTM modelinin daha büyük ve daha karmaşık veri setleri için tercih edilmesi beklenmektedir, çünkü bu modelin iyi sonuçlar verebileceği öngörülmektedir.

Hasanov (2016) diğ er bir “Modeling and Forecasting Electricity Demand in Azerbaijan Using Cointegration Techniques” makalesinde, gelişmekte olan ve geçiş ekonomilerindeki politika yapıcılar, hızla artan enerji tüketiminin nedenlerini anlamak ve gelecekteki enerji talebini tahmin etmek için sağlam modellere ihtiyaç duyarlar. Bu makale, Azerbaycan'daki elektrik talebini modellemeyi ve geleceğe yönelik tahmin senaryoları sunmayı amaçlamaktadır. Bildiğimiz kadarıyla, bu Azerbaycan için kapsamlı bir modelleme çerçevesi kullanılarak yapılan ilk girişimdir. 1995 ile 2013 yılları arasında, Azerbaycan'da elektrik tüketimi önemli ölçüde artmış ve azalmıştır; 1995'ten 2006'ya kadar yıllık ortalama yaklaşık %4 artmış, 2006'dan 2010'a kadar ise yıllık ortalama yaklaşık %2 azalmış ve sonrasında tekrar artmıştır. Bu nedenle, Azerbaycanlı planlayıcıların ve politika yapıcılarının elektrik talebini neyin yönlendirdiğini anlamaları ve gelecekteki büyümesini tahmin edebilmeleri hayati önem taşımaktadır. Ancak, böyle bir ülke için elektrik talebini modellemek birçok zorluk içerir. Azerbaycan enerji kaynakları bakımından zengindir ve bu nedenle GSYİH büyük ölçüde petrol fiyatlarından etkilenir; bu yüzden bu araştırmada gerçek petrol dışı GSYİH, faaliyet sürücüsü olarak kullanılmıştır. Ayrıca, elektrik fiyatları piyasa odaklı değil, idari olarak belirlenmektedir. Bu nedenle, Azerbaycan için kişi başına düşen birkaç elektrik talebi modeli tahmin etmek ve 2025'e kadar tahmin senaryoları üretmek için farklı eşbütünleşme ve hata düzeltme teknikleri kullanılmıştır. Elde edilen tahmini modeller ve Azerbaycan için 2025 elektrik talebi tahminleri, katsayılar açısından çok benzer sonuçlar vermiştir; işlerin her zamanki gibi devam etmesi durumunda tahminler yaklaşık 19,5 ila 21 TWh arasında değişmektedir.

Rajbhandari (2021) çalışmalarında, elektrik talebi ve sıcaklık arasındaki ilişkiyi analiz ederek kısa vadeli yük tahminleri üzerindeki etkilerini incelemişler. Çalışma, sıcaklık değişikliklerinin elektrik yükü üzerindeki etkisini, hafta içi ve hafta sonu yük varyasyonlarını ve önceki günlerin yük verilerinin tahminler üzerindeki rolünü ele alıyor. Analizler, yıl boyunca önceki günün talep ve sıcaklık verilerini kullanarak hafta içi ve hafta sonları için kısa vadeli yük tahminleri yapılmasını sağlamış. Araştırma, zaman serisi modelleri ve ileri beslemeli yapay sinir ağlarını (FF-ANN) kullanarak, ortalama mutlak yüzde hata (MAPE) açısından daha iyi performans gösterdiğini ortaya koymuştur; hafta içi %0.34 ve hafta sonu %8.04 oranında iyileşme sağlamıştır.

Yildiriz (2022) çalışmalarında yük profil katsayıları (YPK), elektrik enerjisi tüketicileri için günlük ve yıllık elektrik kullanım modelini temsil eder. Elektrik Enerji Piyasası'ndaki dengesizlik maliyetlerini en aza indirmek için YPK'ları doğru ve güvenilir bir şekilde belirlemek önemlidir. Doğru tahminler yapabilmek için güvenilir yöntemler ve yeterli ölçüm verisi gereklidir. Yerel dağıtım şirketi, Türkiye'de meteorolojik ölçümler olmadan tüketimlerin ortalamasını alarak profil katsayılarını hesaplamaktadır. YDŞ, tüketicilerden doğrudan saatlik tüketim verileri alarak YPK'ları belirler. Bu makalede, Türkiye'deki Düzce için çoklu regresyon analizi yöntemi kullanılarak ilk kez matematiksel tahmin modelleri üretilmiştir. İlk olarak, bazı belirlenmiş konut abonelerinde saatlik elektrik enerjisi tüketimi ve meteorolojik sıcaklıklar ölçülmüştür.

Ölçülen veriler kullanılarak MTM'ler üretilmiş ve ardından MTM'ler kullanılarak YPK'lar belirlenmiştir. Belirlenen YPK'lar kullanılarak elektrik enerjisi tüketimleri tahmin edilmiş ve tahmin sonuçları ölçüm verileriyle karşılaştırılmıştır. MTM'ler, literatürde kabul edilen uygunluk testlerine tabi tutulmuş ve modellerin performansları doğrulanmıştır. Elde edilen sonuçlara göre, MTM'lerin, gelecekteki değişen meteorolojik koşullara bağlı olarak %96'ya varan bir doğrulukla yükleri tahmin edebileceği görülmüş ve YPK hesaplaması için hızlı ve pratik bir yöntem olarak önerilmiştir. Makale, üretilen MTM'lerin Türkiye'nin Düzce bölgesi için enerji tüketimi tahmininde tatmin edici sonuçlar sağladığını göstermektedir.

2.2. İndirgeme ve Trafo Merkezi

Elektrik enerjisinde indirgeme merkezleri, yüksek gerilim seviyesinde iletilen elektriği, kullanım için uygun daha düşük gerilim seviyelerine dönüştüren tesislerdir. Bu merkezler, enerji iletim ve dağıtım sisteminin kritik bir parçasıdır. İndirgeme merkezlerinin temel işlevi, yüksek gerilimdeki elektriği (genellikle yüzlerce kilovolt) alıp, daha düşük gerilimlere (genellikle onlarca kilovolt) dönüştürmektir. Bu işlem, büyük güç transformatörleri kullanılarak yapılır.

Şekil 2.1 indirgeme merkezlerinde gerilim düşümü, esas olarak transformatörler aracılığıyla gerçekleştirilir. Bu süreç, elektrik enerjisini yüksek gerilim seviyelerinden alıcıya uygun daha düşük gerilim seviyelerine indirmek için tasarlanmıştır.



Şekil 2.1. İndirgeme Merkezi

İndirgeme merkezine ilk olarak yüksek gerilimde elektrik enerjisi girer. Bu enerji, genellikle uzak enerji üretim tesislerinden gelir ve yüksek gerilim, enerjinin uzun mesafeler boyunca daha az kayıpla iletilmesini sağlar. Merkezdeki transformatörler,

gelen yüksek gerilimi daha düşük bir gerilime dönüştürmek için kullanılır. Bir transformatör, iki bobinden oluşur: birincil (yüksek gerilim) ve ikincil (düşük gerilim). Bu bobinler manyetik bir alan aracılığıyla enerjiyi birbirlerine aktarır, ancak elektriksel olarak birbirinden izole edilmiştir. Transformatördeki birincil bobine uygulanan yüksek gerilim, manyetik alan oluşturur. Bu manyetik alan, ikincil bobinde bir akım indükler ve bu akım, daha düşük bir gerilimde olur. Transformatörün tasarımı (bobinlerin sargı sayısı oranı), giriş ve çıkış gerilim seviyelerini belirler. Gerilim dönüşümü sırasında, enerjinin frekansı değişmez ve enerji kalitesi korunur. Transformatörler, enerji verimliliği yüksek cihazlardır ve dönüşüm sürecinde minimum enerji kaybıyla çalışırlar. Dönüştürülen düşük gerilim, daha sonra yerel elektrik dağıtım şebekelerine aktarılır. Bu şebekeler, elektriği son kullanıcılara (evler, iş yerleri vb.) ulaştırır. Transformatörler, indirgeme merkezlerindeki gerilim düşümünün temel bileşenidir ve elektrik enerjisinin güvenli, verimli ve kullanışlı bir şekilde tüketicilere ulaştırılmasında kritik bir rol oynarlar. Bu cihazlar, modern elektrik dağıtım sistemlerinin temel taşlarından biridir. Elektrik enerjisi, verimliliği artırmak için genellikle yüksek gerilimde iletilir. İndirgeme merkezleri, bu yüksek gerilimli elektriği alır ve yerel dağıtım ağları için uygun gerilim seviyelerine indirir. Bu, hem enerji kaybını azaltır hem de güvenli kullanım sağlar. İndirgeme merkezleri, genellikle ulusal veya bölgesel elektrik şebekelerine bağlıdır. Bu sayede, enerji üretim noktalarından tüketim alanlarına kadar enerji akışını etkin bir şekilde yönetirler. Güvenlik önlemleri bu merkezlerin temel bileşenlerindendir. Aşırı akım koruması, arıza tespiti ve acil durum kesinti sistemleri gibi özellikler, sistem güvenliğini ve sürekli çalışmasını sağlar.

Trafo merkezleri, elektrik enerjisini farklı voltaj seviyelerine dönüştüren ve enerji dağıtımının temel parçalarından biri olan tesislerdir. Trafo merkezlerinin enerji tüketimi konusuna geniş bir bakış açısıyla yaklaşmak gerekirse, şu noktaları ele alabiliriz:

1. Enerji Dönüşümü ve Verimlilik:

- Trafo merkezleri, genellikle yüksek voltajlı elektrik enerjisini daha düşük voltajlı seviyelere dönüştürmek için kullanılır. Bu dönüşüm, elektrik enerjisinin endüstriyel, ticari ve konut alanlarında kullanılabilir hale getirilmesini sağlar.
- Dönüşüm süreci sırasında, trafolar bazı enerjiyi kaybeder. Bu kayıplar genellikle ısı şeklinde ortaya çıkar ve trafonun verimliliğine bağlıdır.
- Verimlilik, trafo tasarımı, malzeme kalitesi ve bakım durumu gibi faktörlere bağlı olarak değişir. Yüksek verimlilik oranlarına sahip trafolar, daha az enerji kaybı anlamına gelir.

2. Enerji Kayıpları:

- Enerji kayıpları, trafonun verimliliği ve yük durumu ile doğrudan ilişkilidir. Trafoların verimlilik oranları genellikle %95-99 arasında değişir, ancak bu oran trafonun tipine ve kalitesine bağlı olarak değişebilir.
- Trafoların tasarımında kullanılan malzemeler (örneğin, çelik ve bakır) ve yapısal özellikleri, kayıp oranlarını etkiler. İyi tasarlanmış ve iyi malzemelerle yapılan trafolar daha az enerji kaybeder.
- Enerji kayıpları hem trafonun kendisinden hem de elektrik iletim hatlarından kaynaklanabilir.

3. Yük Yönetimi:

- Trafo merkezlerinin enerji tüketimi, elektrik talebine bağlı olarak değişir. Zirve yük saatlerinde (genellikle sabah ve akşam saatlerinde) trafolar daha fazla enerji tüketir.
- Yük yönetimi, enerji tüketimini optimize etmek için önemlidir. Düşük talep dönemlerinde trafoların daha az yüklenmesi, enerji verimliliğini artırır.
- Akıllı şebeke teknolojileri ve talep yanıtı yönetimi, yük yönetiminde önemli rol oynayarak enerji tüketimini dengelemeye yardımcı olur.

4. Bakım ve İşletim Giderleri:

- Trafo merkezlerinin bakımı, enerji tüketimini doğrudan etkileyebilir. Düzenli bakım, trafoların daha verimli çalışmasını ve enerji kayıplarını azaltmasını sağlar.
- Soğutma sistemleri, aydınlatma, kontrol odaları ve güvenlik sistemleri gibi yardımcı ekipmanlar da enerji tüketir. Bu sistemlerin verimli çalışması, toplam enerji tüketimini azaltmada önemli bir faktördür.

5. Yenilikler ve Geliştirmeler:

- Enerji verimliliğini artırmak için sürekli teknolojik gelişmeler yapılmaktadır. Bu yenilikler, daha az enerji kaybı sağlayan trafoların geliştirilmesini içerir.
- Akıllı şebeke teknolojileri, enerji tüketimini daha iyi yönetmek ve optimize etmek için kullanılır. Bu teknolojiler, enerji talebinin gerçek zamanlı izlenmesini ve buna göre ayarlamalar yapılmasını sağlar.
- Yenilenebilir enerji kaynaklarıyla entegrasyon, enerji tüketimini dengeler ve çevresel etkiyi azaltır.

2.3. Akıllı Elektrik Sayaçları

Elektrik sayaçlarının tarihi, elektriğin yaygın kullanımının başlangıcına kadar uzanır. Şekil 2.2’de gibi elektrik sayaçları, tüketicilerin elektrik kullanımını ölçmek ve bu kullanıma göre faturalandırma yapmak için tasarlanmıştır. İlk elektrik sayaçları, 19. yüzyılın sonlarında geliştirildi. Bu sayaçlar, dönen diskler kullanarak elektrik tüketimini ölçerdi ve mekanik olarak çalışırdı. 20. yüzyılın ortalarına doğru, elektrik sayaçları daha sofistike hale geldi ve elektronik özellikler eklenmeye başlandı. Bu gelişmeler, daha doğru ölçümler ve uzaktan okuma gibi yeniliklerin yolunu açtı. Günümüzde, akıllı elektrik sayaçları yaygınlaşmış durumda. Bu sayaçlar, gerçek zamanlı veri aktarımı yapabilen, tüketim analizleri sunabilen ve hatta bazı durumlarda tüketiciye enerji kullanımı üzerinde daha fazla kontrol sağlayan teknolojilere sahiptir. Elektrik sayaçları, elektriğin evlere ve iş yerlerine ulaştırılmasında önemli bir rol oynar. Enerji tüketiminin doğru bir şekilde ölçülmesi, hem tüketicilerin faturalarının adil olmasını sağlar hem de enerji tedarikçilerinin kaynaklarını daha etkin bir şekilde yönetmesine yardımcı olur. Bu sayede, enerji verimliliği ve sürdürülebilir enerji kullanımı konularında da önemli adımlar atılabilir. Son yıllarda, elektrik sayaçları internete bağlı cihazlar ve akıllı ev sistemleriyle entegre edilerek daha da işlevsel hale getirilmektedir. Bu gelişmeler, tüketicilere enerji kullanımlarını daha iyi anlama ve yönetme imkânı sunarken, enerji sağlayıcılarına da daha verimli ve esnek hizmet sunma fırsatı veriyor.



Şekil 2.2. Eski Mekanik Sayaç

Luna Smart Elektrik Sayaçları, modern elektrik ölçüm ihtiyaçlarına yönelik geliştirilmiş cihazlardır ve hem monofaze hem de trifaze versiyonları bulunmaktadır.

Luna Trifaze Elektrik Sayacı Özellikleri:

- 3 fazlı 4 telli yapı.
- Aktif / Import-Export ölçüm özellikleri.
- Direkt bağlantı imkanı (trafo gerektirmez).
- Anma Akımı: 3x0.25-5(100)A.
- Anma Gerilimi: 3x230/400V AC.
- Sayaç sabiti: 1000 imp/kWh – 1000 imp/kVArh.
- Çalışma Sıcaklık Aralığı: -40°C...+70°C.
- IP54 koruma sınıfı.
- 188 segment LCD ekran.
- Optik port ile haberleşme.

Luna Monofaze Elektrik Sayacı Özellikleri:

- Genellikle mesken ve aydınlatma tipi aboneliklerde kullanılan tek fazlı sayaç.
- Nominal Gerilimi (AC) 220V.
- Nominal Akımı 5(100)A.
- Nominal Frekans Hz 50 Hz $\pm$ %2.
- Minimum Akım 0,25A.
- Başlangıç Akımı mA 20mA.
- Sayaç Sabiti 1000 imp/kWh.
- Doğruluk Sınıfı B.
- Mekanik/Elektromanyetik Sınıf M1/E2.
- LCD Ekran 5 tam, 3 ondalık.
- Koruma Sınıfı IP54 Bina Dışı.
- Çalışma Sıcaklık Aralığı: -40 °C...+70 °C.

Bu sayaçlar, elektrik tüketiminin doğru ve verimli bir şekilde ölçülmesi, kontrol altında tutulması ve raporlanması için kullanılır. Hem monofaze hem de trifaze sayaçlar, farklı uygulama alanlarına ve kullanım gereksinimlerine göre tasarlanmıştır. Luna Smart Elektrik Sayaçları, elektrik ölçümünde güvenilirlik ve verimlilik açısından tercih edilen seçenekler arasında yer alıyor.



Şekil 2.3. Luna Elektrik Sayacı

Viko, elektrik sektöründe önemli bir yer tutan ve geniş bir ürün yelpazesine sahip bir markadır. Viko'nun elektrik sayaçları, özellikle akıllı şebeke çözümlerinin kritik bir parçası olarak ön plana çıkmaktadır. İşte Viko Smart Elektrik Sayaçları hakkında detaylı bilgiler aşağıda verilmiştir:

- 2G Modem Entegrasyonu: GSM 900 ve GSM 1800 frekans bantlarında çalışabilen bu modemler, geniş bir besleme kaynağı aralığına (58...230VAC) sahiptir.
- Çoklu Montaj Olanakları: Ölçü panolarının bulunduğu noktalarda raya montaj, askı kulaklığı ile montaj veya yapıştırma gibi çeşitli montaj seçenekleri sunar.
- Haberleşme Durumu Göstergesi: Cihaz üzerindeki LED, haberleşme durumu hakkında bilgi verir.
- Seri Haberleşme Kanalı: RS485 veri yolu ile maksimum 32 elektronik elektrik sayacına bağlanabilir.
- Su ve Toza Karşı Dayanıklılık: IP54 koruma sınıfına sahip olan sayaçlar, dış etkenlere karşı dayanıklıdır.
- Yazılım Güncelleme İmkânı: GSM veya seri kanal (RS485) üzerinden yazılım güncellemesi yapılabilir.

Günümüzdeki elektrik sayaçları, teknolojinin gelişmesiyle birlikte önemli ölçüde evrim geçirmiştir. Modern sayaçlar, eski mekanik modellerin yerini alarak daha sofistike, dijital ve akıllı özellikler sunmaktadır. Dijital Gösterge: Çoğu modern elektrik sayacı, tüketilen elektriği dijital bir ekranda gösterir. Bu, kullanıcıların enerji tüketimini kolayca okuyabilmesini sağlar. Akıllı Sayaçlar: Akıllı sayaçlar, enerji tüketim verilerini otomatik olarak enerji sağlayıcılarına gönderir. Bu, manuel okuma ihtiyacını ortadan kaldırır ve daha doğru faturalandırma sağlar. Ayrıca, kullanıcıların enerji tüketimini gerçek zamanlı olarak takip etmelerine olanak tanır. Enerji Yönetimi: Bazı akıllı sayaçlar, kullanıcıların

enerji kullanımını daha verimli hale getirmelerine yardımcı olacak analiz ve raporlama özellikleri sunar. Bu, enerji tasarrufu yapmalarına ve maliyetleri azaltmalarına olanak tanır. Uzaktan İzleme ve Kontrol: Akıllı sayaçlar, enerji sağlayıcılarının tüketim verilerini uzaktan izlemesine imkân tanır. Bu, arıza tespiti ve çözümünde hızlı hareket etmeyi, ayrıca enerji arzının daha etkin yönetilmesini sağlar. Talep Yanıtı ve Yük Yönetimi: Bazı gelişmiş akıllı sayaçlar, enerji talebinin yüksek olduğu zamanlarda enerji kullanımını düzenleyerek ağın istikrarını korumaya yardımcı olur. Çok Fonksiyonlu Kullanım: Günümüz sayaçları, elektrik dışında su ve gaz gibi diğer hizmetlerin ölçümü için de kullanılabilir hale gelmiştir. Güvenlik ve Gizlilik: Akıllı sayaçlar, veri iletiminde güvenlik ve gizlilik konularına özel önem verir. Bu, kullanıcı verilerinin korunmasını ve sistemin güvenliğini sağlar. Entegrasyon ve Uyumluluk: Yeni nesil sayaçlar, çeşitli akıllı ev cihazları ve yönetim sistemleriyle entegre edilebilir, böylece kullanıcılar tüm enerji yönetimini merkezi bir sistem üzerinden kontrol edebilir.

Bu özellikler, günümüz elektrik sayaçlarını sadece tüketim ölçüm araçları olmaktan çıkarıp, enerji yönetiminin önemli bir parçası haline getirmiştir. Hem tüketiciler hem de enerji sağlayıcılar için daha fazla verimlilik, tasarruf ve esneklik sunmaktadır.

Tüketim hesabı yapma süreci, elektrik akımının ve voltajın ölçümüne dayanır. Akım ve Voltaj Ölçümü: Elektrik sayacı, elektrik devresinden geçen akımı (amper cinsinden) ve devreye uygulanan voltajı (volt cinsinden) sürekli olarak ölçer. Bu iki değer, elektrik enerjisinin tüketimini belirlemede temel bileşenlerdir. Güç Hesaplama: Elektrik enerjisi tüketimi genellikle kilowatt-saat (kWh) cinsinden ifade edilir. Bir cihazın tükettiği güç (watt cinsinden), akım (amper) ile voltaj (volt) çarpılarak hesaplanır. Yani, Güç (W) = Akım (A) × Voltaj (V). Enerji Tüketimi Ölçümü: Toplam enerji tüketimi, gücün zamanla çarpılmasıyla hesaplanır. Örneğin, bir cihaz 100 watt güç tüketiyorsa ve bu cihaz 1 saat boyunca çalıştırılıyorsa, tüketilen enerji 100 watt-saat olur. 1 kilowatt-saat (kWh), 1000 watt-saat'e eşittir. Sürekli Kayıt: Elektrik sayacı, ölçülen akım ve voltaj değerlerini sürekli olarak kaydeder ve bu verileri kullanarak toplam enerji tüketimini hesaplar. Bu hesaplama, genellikle sayacın içindeki bir mikroişlemci tarafından otomatik olarak yapılır. Gösterge veya İletişim: Modern dijital ve akıllı sayaçlar, ölçülen tüketimi dijital bir ekranda gösterir. Akıllı sayaçlar ayrıca, bu tüketim verilerini enerji sağlayıcıya kablosuz ağlar aracılığıyla otomatik olarak gönderebilir. Faturalandırma: Enerji sağlayıcılar, sayacın kaydettiği tüketim verilerini kullanarak tüketicilerin elektrik faturalarını hesaplar. Bazı akıllı sayaçlar, zaman tabanlı fiyatlandırmayı destekleyerek, günün farklı zamanlarında farklı tarifeler uygulanmasına olanak tanır. Sayaçların doğru şekilde çalışması, tüketicilerin adil bir şekilde faturalandırılması ve enerji tedarikçilerinin enerji tüketimini etkin bir şekilde yönetmesi için önemlidir.

OBIS (Object Identification System), elektrik enerjisi ölçümü ve veri toplama süreçlerinde kullanılan bir kodlama sistemidir. Bu sistem, enerji verilerini standartlaştırmak ve farklı cihazlar arasında veri alışverişini kolaylaştırmak amacıyla

geliştirilmiştir. Elektrik sayaçlarında, şekil 2.4’de gibi OBIS kodları ölçüm yapılan çeşitli enerji parametrelerini tanımlar.

OBIS - Kodu					Açıklama
A-BB	CC	DD	T	VV	
Tanımlama					
1-1:	0	0	0		Dağıtım şirketi tanımı-1 (ASCII)
1-1:	0	0	1		Dağıtım şirketi tanımı-2 (ASCII)
1-1:	0	0	2		Dağıtım şirketi tanımı-3 (ASCII)
1-1:	0	0	3		Dağıtım şirketi tanımı-4 (ASCII)
1-1:	0	0	4		Dağıtım şirketi tanımı-5 (ASCII)
1-1:	0	0	5		Dağıtım şirketi tanımı-6 (ASCII)
1-1:	0	0	4		Parametre ayar tanımlaması
1-1:	0	0	5		Program no değiştirme zamanı
1-1:	C	1	0		Seri numarası
1-1:	0	2	1		Parametre toplam kontrolü
1-1:	0	2	2		Tarife program numarası
1-1:	0	2	0		Temel yazılım toplam kontrolü
1-1:	C	65			Konf. parametre toplam kontrolü
Saat / tarih					
1-1:	0	9	1		Gerçek zaman
1-1:	0	9	2		Gerçek tarih
1-1:	0	51			Mevcut mevsim
1-1:	0	9	5		Mevcut haftanın günü
1-1:	C	63			Zaman periyotunda kalan süre
Pulse sabiti / trafo oranı					
1-1:	0	3	0		Pulse sabiti R_p , aktif enerji
1-1:	0	3	1		Pulse sabiti R_p , reaktif enerji
1-1:	0	3	3		Pulse sabiti R_p , aktif enerji
1-1:	0	3	4		Pulse sabiti R_p , reaktif enerji
1-1:	0	4	2		Akım trafosu oranı
1-1:	0	4	3		Gerilim trafosu oranı
Demant reset					
1-1:	0	1	0		Demant reset sayıcısı
1-1:	C	70			Tarife kaynağı
1-1:	0	1	2	xx	Demant reset tarihi
1-1:	0	1	3	xx	Demant reset saati
1-1:	0	9	0		MD resetten sonraki gün sayısı
1-1:	C	61			Son demant reset tarihi
1-1:	C	63			Demant periyodunda kalan süre
Demant ölçümü					
1-1:	0	8	0		Demant periyodu
1-1:	1	4	0		+P, anlık maksimum demant M0
1-1:	1	5	0		+P, son periyottaki demant M0
1-1:	1	6	1	xx	+P, saat/tarih etiketli MD reset, M1
1-1:	1	2	1	xx	+P, kümülatif demant, M1
1-1:	1	6	1	xx	+P, saat/tarih etiketli MD reset, M2
Enerji ölçümü					
1-1:	1	8	0	xx	+A, toplam aktif enerji, T0
1-1:	1	8	1	xx	+A, aktif enerji, T1
1-1:	1	8	2	xx	+A, aktif enerji, T2
1-1:	1	8	3	xx	+A, aktif enerji, T3
1-1:	1	8	4	xx	+A, aktif enerji, T4
1-1:	2	8	0	xx	-A, toplam aktif enerji, T0
1-1:	2	8	1	xx	-A, aktif enerji, T1

Şekil 2.4. Örnek OBIS Kodları, A1xxx ALPHA - Elektrik Sayaçları OBIS (IEC) Kodları

OBIS kodları, belirli bir enerji parametresini veya ölçümü tanımlayan bir numaralandırma sistemine sahiptir. Tipik bir OBIS kodu şu şekildedir:

- Grup-Üretici (A:) Belirli bir sektörü veya uygulamayı tanımlar. Elektrik sayaçları için genellikle "1" kullanılır.

- Özellik (B:)Grup içinde belirli bir özelliği tanımlar. Örneğin, enerji tüketimi, reaktif enerji, akım, gerilim gibi.
- Düğme (C:) Belirli bir özelliğin altında daha spesifik bir parametreyi ifade eder. Örneğin, anlık değerler, toplam enerji tüketimi, reaktif enerji tüketimi gibi.
- Veri Tipi (D:) Ölçülen değerin birimi ve nitelikleri hakkında daha fazla bilgi sağlar. Örneğin, enerji birimi (kWh), akım birimi (Amper), gerilim birimi (Volt) gibi.

Elektrik sayaçlarında kullanılan OBIS kodları, elektrik tüketimi ve ölçümü ile ilgili verilerin standart bir formatta ifade edilmesini sağlar. Bu kodlar, uluslararası bir standart olan IEC 62056-61 standardına göre düzenlenmiştir ve genellikle elektrik sayaçlarının veri okuma ve yönetim sistemlerinde kullanılır.

OBIS kodları, altı grup halinde düzenlenmiştir ve her grup belirli bir veri türünü temsil eder:

1. A Grubu (Ortam Bilgisi): Sayaç yerleşim yeri, hava durumu gibi çevresel faktörleri temsil eder.
2. B Grubu (Ekipman Kimliği): Sayaç modeli, seri numarası gibi ekipman bilgilerini içerir.
3. C Grubu (Ölçüm Değerleri): Aktif ve reaktif enerji, güç, voltaj gibi ölçüm değerlerini içerir.
4. D Grubu (Enerji Kaynakları ve Yükler): Enerji kaynakları ve yüklerle ilgili bilgileri içerir.
5. E Grubu (Hata ve Uyarılar): Sistem hataları, uyarılar ve güvenlik ihlalleri gibi durumları temsil eder.
6. F Grubu (Diğer): Diğer genel bilgileri içerir.

Her OBIS kodu, bu altı grup içindeki özel bir veri noktasını tanımlar. Örneğin, bir OBIS kodu aktif enerji tüketimini, diğeri ise gerilim düzeyini gösterebilir.

1. 1-0:0.2.0: Sayaç yazılım versiyonu
2. 1-0:1.8.0: Toplam aktif enerji tüketimi (kWh)
3. 1-0:2.8.0: Toplam aktif enerji üretimi (kWh)
4. 1-0:3.8.0: Toplam reaktif enerji tüketimi (kvarh)
5. 1-0:32.7.0: Anlık voltaj (V)
6. 1-0:52.7.0: Anlık akım (A)
7. 1-0:1.7.0: Anlık aktif güç tüketimi (kW)
8. 1-0:2.7.0: Anlık aktif güç üretimi (kW)
9. 1-0:3.7.0: Anlık reaktif güç tüketimi (kvar)
10. 1-0:4.7.0: Anlık reaktif güç üretimi (kvar)

OBIS kodları, enerji sayaçlarından alınan verileri standartlaştırmak ve bu verilerin anlamını kolaylaştırmak için kullanılır. Elektrik şebekesindeki farklı cihazlar arasında veri alışverişini standardize etmek için bu kodlama sistemine başvurulur.


Her OBIS kodu, belirli bir enerji parametresini temsil eder ve bu sayede enerji tüketimi, güç faktörü, gerilim, akım gibi değerlerin anlamı genel bir standart üzerinden yorumlanabilir.

Bu bilgiler, elektrik sayaçları ve enerji ölçümü ile ilgilenen kişiler için önemlidir ve bu alandaki standartların anlaşılmasına katkı sağlar.

Elektrik sayaçlarının uzaktan okuma teknolojisi, enerji yönetimi ve faturalandırmada devrim yaratan bir gelişmedir. Bu teknoloji, elektrik sağlayıcılarının müşterilerin elektrik kullanımını uzaktan ve otomatik olarak takip etmelerini sağlar. Uzaktan okuma teknolojisi, genellikle kablosuz ağlar üzerinden çalışır. Bunlar arasında Wi-Fi, GSM, 3G, 4G, 5G (mobil ağlar) ve özel radyo frekansı ağları bulunabilir. Bazı sistemler, elektrik iletim hatları üzerinden veri iletimi sağlayan Power Line Communication (PLC) teknolojisini de kullanır. Otomatik sayaç okuma (AMR) teknolojisi, sayaçların periyodik olarak kablosuz ağlar üzerinden enerji kullanım verilerini otomatik olarak göndermelerini sağlar. Bu işlem genellikle günlük veya saatlik aralıklarla yapılır. Gelişmiş ölçüm altyapısı, AMR'den daha sofistike bir sistemdir. AMI, iki yönlü iletişim kurabilen akıllı sayaçlar kullanır ve gerçek zamanlı veri iletimi, talep yanıtı yönetimi ve uzaktan sayaç yönetimi gibi işlevleri destekler. Toplanan veriler, enerji sağlayıcısının veri merkezlerine iletdikten sonra işlenir. Bu işlem, enerji tüketimini analiz etmek, faturalandırma bilgilerini hazırlamak ve ağ yönetim stratejileri geliştirmek için kullanılır. Gerçek Zamanlı Tüketim İzleme hem enerji sağlayıcılarının hem de son kullanıcıların gerçek zamanlı enerji tüketim verilerine erişimini sağlar. Kullanıcılar, çevrimiçi portallar veya mobil uygulamalar aracılığıyla kendi tüketim verilerini görebilirler. Enerji Verimliliği ve Yönetimi enerji tedarikçilerine ağına daha verimli yönetilmesi için gerekli verileri sağlar. Ayrıca, kullanıcıların enerji tüketim alışkanlıklarını anlamalarına ve daha enerji verimli kararlar almalarına yardımcı olur. Güvenlik ve Gizlilik veri güvenliği ve gizlilik konusunda yüksek standartlar gerektirir. İletilen verilerin güvenliği ve korunması hem kullanıcıların gizliliği hem de ağına güvenliği için kritik önem taşır. Tespiti ve Yönetimi: arızaların ve anormal tüketim kalıplarının hızlı bir şekilde tespit edilmesini sağlar. Böylece, hizmet kesintileri ve diğer sorunlar daha hızlı çözülebilir.

RS485, elektrik sayaçlarının uzaktan okunmasında kullanılan popüler bir iletişim standardıdır. Bu teknoloji, özellikle endüstriyel ve ticari uygulamalarda yaygın olarak kullanılır. RS485, birçok cihazın bir iletişim hattı üzerinden veri alışverişini yapabilmesini sağlayan bir seri iletişim protokolüdür. Diferansiyel Sinyal İletimi veri iletimi için diferansiyel sinyal kullanır. Bu, iletişim hattındaki iki tel üzerinde zıt voltajlar kullanılarak veri iletilmesi anlamına gelir. Diferansiyel sinyal iletimi, elektromanyetik girişimlere (EMI) karşı daha dayanıklıdır ve uzun mesafelerde daha güvenilir iletişim

sağlar. Çoklu Cihaz Bağlantısı: bir iletişim hattına birden fazla cihazın (genellikle 32'ye kadar, bazen daha fazla) bağlanmasına olanak tanır. Bu, bir ağ üzerinde birçok elektrik sayacının birbirine ve merkezi bir kontrol noktasına bağlanmasını sağlar. Uzun Mesafe İletişimi: birkaç kilometreye kadar uzanan mesafelerde veri iletimini destekler. Bu, büyük tesislerde veya geniş alanlarda elektrik sayaçlarının verilerinin toplanması için idealdir. Yüksek Veri Aktarım Hızları Bu teknoloji, saniyede birkaç megabit hıza kadar veri aktarımı sağlayabilir. Aktarım hızı, iletişim mesafesine göre değişebilir; mesafe uzadıkça hız genellikle azalır. Esnek Topoloji: çeşitli topolojilerde kurulabilir, örneğin yıldız, zincir veya halka şeklinde. Bu, farklı uygulama gereksinimlerine göre esnek bir ağ kurulumu sunar. Standart ve Uyumluluk: endüstri standardı bir protokol olduğu için, farklı üreticilerin cihazları arasında uyumluluk sağlar. Bu, farklı markaların elektrik sayaçlarının ve kontrol sistemlerinin bir arada kullanılmasını kolaylaştırır. Adreslenebilirlik: RS485 protokolü, ağdaki her cihazın benzersiz bir adrese sahip olmasını sağlar, böylece veriler doğru cihaza yönlendirilebilir. Güvenilirlik ve Dayanıklılık: endüstriyel ortamlardaki zorlu koşullara dayanıklıdır. Gürültülü ortamlarda bile güvenilir veri iletimi sağlar. RS485, elektrik sayaçları için uzaktan okuma uygulamalarında, güvenilir, esnek ve genişletilebilir bir iletişim çözümü sunar. Bu teknoloji, özellikle endüstriyel ve ticari alanlarda, enerji yönetimi ve otomasyon sistemlerinde yaygın olarak kullanılmaktadır.



Şekil 2.5. RS485 Bağlantı Şeması

Elektrik gatewaylerinin tarihi, geniş bant internetin yaygınlaşması, ağ teknolojilerindeki ilerlemeler ve akıllı ev cihazlarının artan kullanımıyla paralel olarak gelişmiştir. Bu cihazlar, özellikle akıllı elektrik sayaçlarının ve akıllı şebeke (smart grid) teknolojilerinin gelişimiyle birlikte önem kazanmıştır. İşte bu tarihsel gelişimin ana hatları belirtilmiştir. 1990'ların sonlarında internetin yaygınlaşması, evlerde ve iş yerlerinde ağ bağlantılı cihazların kullanımını artırdı. Bu dönemde, ağ geçitleri (network gateways) temel olarak farklı ağlar arasında iletişim kurmak için kullanılmaya başlandı. 2000'lerin başlarında, akıllı ev teknolojileri ve otomasyon sistemleri daha popüler hale

gelmeye başladı. Bu, ev aletlerinin, güvenlik sistemlerinin ve diğer cihazların internet üzerinden kontrol edilmesi ve yönetilmesi anlamına geliyordu. Bu süreçte, gateway'ler bu cihazların internete bağlanmasında kilit rol oynamaya başladı. 2000'lerin ortalarından itibaren, elektrik şebekelerinin verimliliğini ve güvenilirliğini artırmak için akıllı şebeke teknolojileri geliştirildi. Bu teknolojiler, elektrik tüketiminin gerçek zamanlı olarak izlenmesi, yönetilmesi ve optimize edilmesi için tasarlandı. Akıllı elektrik sayaçları, enerji tüketimini daha doğru ve verimli bir şekilde ölçmek ve yönetmek için tasarlandı. Bu sayaçlar, tüketim verilerini toplayıp iletmek için gateway'lerle entegre edildi. Zamanla, elektrik gatewayleri farklı iletişim standartları ve protokollerini destekleyecek şekilde geliştirildi. RS485, Wi-Fi, ZigBee, Z-Wave ve GSM gibi teknolojiler, gatewaylerin farklı türdeki cihazlarla uyumlu olmasını sağladı. Bugün, elektrik gatewayleri, enerji verimliliği, uzaktan izleme ve kontrol, talep yanıtı yönetimi gibi özellikleriyle akıllı şebeke çözümlerinin önemli bir parçasıdır. Ayrıca, IoT (İnternet Nesneleri) ve büyük veri analitiğiyle entegrasyonları, enerji yönetim sistemlerinin daha da akıllanmasını sağlamaktadır. Elektrik gatewaylerinin tarihi, teknolojik ilerlemeler ve kullanıcı ihtiyaçlarının değişimiyle şekillenmiştir ve bu cihazlar, modern enerji sistemlerinin vazgeçilmez bir bileşeni haline gelmiştir.


3. MATERYAL VE METOT

Bu çalışmada, Azerbaycan Devletinin Şirvan bölgesin deki bir indirgeme ve altı trafo merkezin de akıllı sayaçlar ile her 15 dk okunan veriler ve hava durumu verileri ile her trafo ve indirme merkezi için derin öğrenme tabanlı bir tahmin modeli geliştirilmiştir. Çalışmamızın başlangıcında, detaylı ve geniş kapsamlı sıcaklık verilerini, çeşitli coğrafi konumlardaki hava durumu istasyonlarından ve güvenilir meteoroloji veri tabanlarından sağlanmıştır. Bu toplanan veriler, eksik veri noktalarını doldurma ve veri setini bir bütün olarak normalizasyon gibi kapsamlı ön işleme adımlarından geçirilmiştir, böylece veri kalitesi artırılarak modelin eğitimi için uygun hale getirilmiştir.

Çalışmada kullanılan derin öğrenme modeli olarak, özellikle tahmin doğruluğu ve zaman serisi verileriyle uyumluluğu yüksek olan gelişmiş bir derin öğrenme modeli tercih edilmiştir. Bu model, belirlenen spesifik hiperparametre ayarları altında eğitilmiş ve çeşitli optimizasyon algoritmalarıyla geliştirilmiştir. Modelin eğitimi sırasında, zaman serisi analizine uygun bir yapıda düzenlenmiş ve büyük veri seti kullanılmıştır, bu sayede modelin öğrenme kapasitesi maksimize edilmiştir. Modelin doğruluğunu ve genelleştirme kapasitesini değerlendirmek amacıyla, eğitim setinden farklı, bağımsız bir test veri seti kullanılmıştır.

Derin öğrenme modelin geliştirilmesi şekil 3.1'deki akış diyagramına göre dokuz ara işlem geliştirilmiştir. Bir indirgeme ve altı trafo merkezi Azerişiq ASC şirketinin sunucularında kayıt altından tutulmaktadır. Bu veriler tez kapsamında Azerişiq ASC şirketi tarafından sağlanmıştır. Hava durumu verisi elektrik tüketimin etkisini literatürde ortaya konulduğundan dolayı bu verilerde dahil edilerek derin öğrenme tabanlı model için yeni birleşen oluşturularak modelin tahmin performansı aktırılması sağlanmıştır. Veri setimiz, elektrik tüketim ve hava verileri oluşmuştur. Böylelikle veri setimiz bir çok birleşenden oluşmuştur.

Modelin performans değerlendirmesi, tahmin edilen değerlerin gerçek verilerle olan uyumunun ölçülmesi ve çeşitli istatistiksel hata metriklerinin detaylı bir şekilde incelenmesi yoluyla yapılmıştır. Bu değerlendirme sürecinde, modelin tahmin doğruluğu ve güvenilirliği, çalışmanın başarısını belirleyen temel ölçütler olarak ön plana çıkmıştır. Sonuç itibariyle, bu çalışma, sıcaklık verilerini kullanarak indirgeme ve trafo merkezindeki elektrik tüketimi tahminleri yapmak için etkili ve yenilikçi bir derin öğrenme tabanlı metodoloji sunulmuştur.



Şekil 3.1. Model Eğitimin Akış Diyagramı

3.1. Veri Bileşenleri

Çizelge 3.1. de olan tablo veri setimizin ilk 5 gözlemini örneklemiştir. Bu çalışmada kullanılan veri seti, enerji verimliliği ve tüketim analizi için çeşitli bileşenleri içermektedir. Aşağıda, veri setinde bulunan temel bileşenler ve eklenen yeni bileşenler detaylı bir şekilde açıklanmıştır:

Çizelge 3.1. Veri Seti

	VoltageR	VoltageS	VoltageT	CurrentR	CurrentS	CurrentT	CosR	CosS	CosT	RC	RI	IndexT	cosf	tanf
OXUNMA VAXTI														
2022-01-07 00:25:15	62.9	63.3	62.5	1.304	1.328	1.235	0.93	0.90	0.90	0.0	60.0	136.8	0.905349	0.438596
2022-01-07 00:40:30	62.9	63.3	62.4	1.280	1.302	1.254	0.92	0.89	0.90	0.0	60.0	136.8	0.905349	0.438596
2022-01-07 00:55:45	62.9	63.3	62.5	1.264	1.259	1.198	0.92	0.88	0.90	0.0	60.0	132.0	0.898461	0.454545
2022-01-07 01:11:00	62.9	63.3	62.5	1.215	1.259	1.190	0.91	0.89	0.89	0.0	60.0	127.2	0.890798	0.471698
2022-01-07 01:26:11	62.9	63.4	62.5	1.186	1.189	1.123	0.90	0.87	0.89	0.0	60.0	124.8	0.886639	0.480769

Temel Bileşenler :

- VoltageR, VoltageS, VoltageT : R,S,T fazındaki gerilimi temsil eder.
- CurrentR, CurrentS, CurrentT : R,S,T fazındaki akımı temsil eder.
- CosR, CosS , CosT (Cos ϕ): R,S,T fazındaki güç faktörünü temsil eder.

Temel Bileşen Açıklamaları:

- Voltage (Gerilim): Elektrik devresindeki gerilim, enerji tüketiminin temel bir ölçüsüdür.
- Current (Akım): Elektrik devresindeki akım, enerji transferinin bir göstergesidir.
- Cos ϕ (Güç Faktörü): Güç faktörü, tüketilen enerjinin ne kadarının gerçek güce dönüştürüldüğünü gösterir.
- Tanf: Yeni eklenen bileşen, Reaktans İndeksi (RI) ile Tüketim (IndexT) bileşenlerinin oranını temsil eder. Denklem 3.1göre tanf in formülüne edilip, yeni bileşen hesaplanmıştır.

$$Tanf = \frac{RI}{IndexT} \quad 3.1$$


- True_cosf: Güç faktörü (cosf) değerinin düzeltilmiş hali olarak tanımlanır. Yeni güç faktörü, orijinal güç faktörünün tanf ile düzeltilmiş hali olarak hesaplanır. Denklem 3.2 true_cosf birleşeni hesaplanmıştır.

$$True_cosf = \frac{1}{\sqrt{1+tanf^2(cosf)}} \quad 3.2$$

- RC (Resistans): Sistemin toplam direncini temsil eder. Yüksek direnç, enerji kayıplarına neden olabilir.
- RI (Reaktans İndeksi): Sistemin reaktansını temsil eder. Reaktans, endüktif veya kapasitif olabilir ve enerji akışını etkileyebilir.
- IndexT (Tüketim İndeksi): Tüketim bileşenini temsil eder. Bu bileşen, enerji tüketiminin ölçüldüğü ana odaklanan bir gösterge olarak kullanılmıştır.

Bu bileşenler, enerji verimliliği ve tüketim analizi için temel göstergeler sağlamaktadır. Derin öğrenme modeli, özellikle IndexT üzerinde eğitilerek, tüketim üzerindeki etkileri anlamak ve tahmin etmek için kullanılmıştır.

Aykırı değerler, genellikle diğer veri noktalarından önemli ölçüde farklı olan ve istatistiksel modellemeyi olumsuz etkileyebilecek değerlerdir. IQR (Interquartile Range) ile aykırılık tespiti şekil 3.2 de gösterilmiştir ve işlem basamaklarını detaylandırmak için; Bu analiz, veri setindeki potansiyel aykırı değerleri belirlemek ve bu değerlerin model performansına olan etkisini değerlendirmek amacıyla gerçekleştirilmiştir. Aykırı değer tespiti için IQR yöntemi tercih edilmiştir. IQR, bir veri setindeki çeyrekler arası aralığı ifade eder. Q1 ve Q3 çeyrekler arası aralığın alt ve üst sınırları belirlendikten sonra, bu sınırlar dışında kalan değerler aykırı değer olarak kabul edilir. IQR kullanımı, veri setindeki istatistiksel olarak anormal değerleri belirlemek için güçlü bir yöntemdir (Domański 2020).



Şekil 3.2. Aykırılık Tahlili

Bu analizde, her bir özellik için IQR kullanılarak alt ve üst sınır değerleri belirlenmiş ve bu sınırlar dışında kalan değerler aykırı değer olarak tanımlanmıştır. Aykırı değerler, belirlenen sınırların dışında kalan veri noktaları olarak saptanmış ve bu değerler tespit edilerek işleme alınmıştır. Analiz sonuçlarına göre belirlenen aykırı değerler, veri setinden çıkarılmıştır. Bu işlem, model eğitimi sürecindeki yanıltıcı etkileri azaltmayı ve modelin daha genel bir şekilde öğrenmesini sağlamayı amaçlamaktadır. Aykırı değer analizi, IQR yöntemi kullanılarak gerçekleştirilmiştir. Bu yöntem, veri setinin istatistiksel olarak anormal değerleri belirleme konusunda güçlü bir araç sağlamıştır. Analizin ardından, modelin güvenilirliği ve tahmin performansındaki potansiyel iyileştirmeler değerlendirilmiştir. Aykırı değer analizi ve işleme süreci, modelin daha güvenilir ve stabil bir şekilde çalışmasına katkıda bulunmayı hedeflemektedir.

3.1.1. Hava Durumu Verileri


Hava Durumu verileri, elektrik tüketim verilerini daha kapsamlı ve doğru bir şekilde analiz etmeye literatürde birçok çalışmaya ortaya konmuştur. Tez kapsamında kullanılan hava durumu verileri, WeatherAPI websitesinden temin edilmiştir (Anonymous 2). 2022-06-21 ile 2023-09-29 tarihleri arasında indirgeme ve trafo merkezinin bulunduğu bölgenin verileri web sitesinden temin edilmiştir.

Çeşitli meteorolojik bileşenleri içermektedir. Bu bileşenler, projenin genel bağlamında önemli olan hava durumu özelliklerini tanımlamaktadır. 2022-06-21 ile 2023-09-29 tarihleri arasında elde ettiğimiz hava durumu verilerindeki bileşenler ve tanımlamalar şu şekildedir:

time	Tarih ve saat bilgisini içerir.
temp_f	Fahrenheit cinsinden sıcaklık.
feelslike_c	Celsius cinsinden hissedilen sıcaklık.
feelslike_f	Fahrenheit cinsinden hissedilen sıcaklık.
windchill_c	Celsius cinsinden rüzgar hissi sıcaklık.
windchill_f	Fahrenheit cinsinden rüzgar hissi sıcaklık.
heatindex_c	Celsius cinsinden hissedilen sıcaklık endeksi.
heatindex_f	Fahrenheit cinsinden hissedilen sıcaklık endeksi.
dewpoint_c	Celsius cinsinden çiy noktası sıcaklığı.
dewpoint_f	Fahrenheit cinsinden çiy noktası sıcaklığı
wind_mph	Mil/saat cinsinden maksimum rüzgar hızı.
wind_kph	Km/saat cinsinden maksimum rüzgar hızı.
wind_degree	Rüzgar yönü derece cinsinden.
humidity	Nem oranı yüzde cinsinden.
precip_mm	Milimetre cinsinden yağış miktarı.
precip_in	İnç cinsinden yağış miktarı.
vis_km	Kilometre cinsinden görünürlük.
vis_miles	Mil cinsinden görünürlük.
uv	UV endeksi.
is_day	Gündüz veya gece olduğunu belirten 1 veya 0 değeri.
gust_mph	Mil/saat cinsinden rüzgar şiddeti.
gust_kph	Km/saat cinsinden rüzgar şiddeti.

Bu bileşenler, hava durumu verisinin genel özelliklerini temsil etmekte ve tez kapsamındaki analizlere katkı sağlamaktadır. Bu çerçevede, RandomForestRegressor modeli kullanarak bu bileşenler ile feature_importances_ kısmına ayrı bir parantez açarak özellik seçimi(feature selection) işlemi gerçekleştirildi ve tüketim bileşenine en uygun hava durumu bileşenleri seçilmiştir. Bu bileşenler, şekil 3.3 de görüldüğü gibi bileşenler

ve bileşenlerin katkı değerleri gösterilmektedir. İlk değer 0.05 seçildiği taktirde sırasıyla 'temp_f', 'is_day', 'heatindex_c', 'dewpoint_f', 'feelslike_f' bileşenleri seçilmiştir.



Şekil 3.3. Özelik Seçimi

	IndexT	temp_f	is_day	feelslike_f	heatindex_c	dewpoint_f
2022-06-24 16:00:00	14.64	86.4	1.0	86.0	30.0	56.8
2022-06-24 18:00:00	12.36	87.3	1.0	87.0	30.6	57.7
2022-06-24 19:00:00	11.52	84.6	1.0	85.0	29.4	59.1
2022-06-24 20:00:00	11.64	82.3	1.0	83.1	28.4	59.8
2022-06-24 21:00:00	11.82	80.0	0.0	81.1	27.3	60.0

Şekil 3.4. Veri setinin Yeni Hali

Şekil 3.4'te, yeni veri setinin yapısını gösteren bir tablo bulunmaktadır. Bu tablo bileşen seçimi sonrasında oluşturulan yeni veri setini temsil eder. Oluşturulan bu yeni veri setinde sadece tüketim ve seçilen hava durumu bileşenleri yer almaktadır.

3.2. Temel Bileşen Analizi

Temel Bileşen Analizi (PCA), genellikle bilimsel ve veri analizi alanlarında kullanılan yaygın bir tekniktir. PCA, bir veri setindeki değişkenler arasındaki ilişkileri anlamak, veriyi daha az boyutta ifade etmek ve veri setindeki gizli yapıları ortaya çıkarmak için kullanılır. PCA'nın başlıca amaçlarından biri, veri setindeki karmaşıklığı

azaltarak veriyi daha anlaşılır hale getirmektir. Boyut azaltma, veri sıkıştırma, özellik çıkarma ve veri görselleştirme gibi çeşitli uygulamaları vardır (Kurita 2019). Hava durumu bileşenlerinin boyutunu azaltmak ve elektrik tüketimiyle olan ilişkilerini daha iyi anlamak amacıyla PCA uygulanmıştır. PCA uygulama aşamaları aşağıdaki gibidir.

- a) Veri Ölçeklendirme: PCA öncesinde, veri setindeki bileşenlerin ölçeklerini standartlaştırmak önemlidir. Bu adım, her bir bileşenin varyansının etkisini dengelemeye yardımcı olur.
- b) Kovaryans Matrisi Hesaplama: Standartlaştırılmış veri seti kullanılarak kovaryans matrisi hesaplanır. Bu matris, veri setindeki bileşenler arasındaki ilişkiyi gösterir.
- c) Özdeğer ve Özvektörlerin Hesaplanması: Kovaryans matrisinin özdeğerleri ve özvektörleri hesaplanır. Özdeğerler, veri setindeki varyansın büyüklüğünü gösterirken, özvektörler ise veri setindeki temel yapıları temsil eder.
- d) Bileşen Seçimi: Özdeğerlerin büyüklük sırasına göre dizilmesiyle, en büyük özdeğerlere karşılık gelen özvektörler seçilir. Bu seçilen özvektörler, veri setindeki temel yapıları ifade eder.
- e) Veri Dönüşümü: Seçilen özvektörler kullanılarak veri seti dönüştürülür. Yeni veri setinde, orijinal veri setindeki bileşenlerin lineer kombinasyonlarıyla oluşturulan yeni bileşenler bulunur.

Çizelge 3.2'de PCA sonucunda oluşturulmuş yeni veriseti tablosu gösterilmektedir. Bu tabloya bakıldığında PCA sonucunda seçilen 5 hava durumu bileşeni tek bileşene indirgenmiştir. PCA ile hava durumu bileşenlerinin boyutunu azaltarak, elektrik tüketimiyle olan ilişkilerini daha iyi anlama fırsatı elde edilmiştir.

Çizelge 3.2. Uygulanmış Veriseti

	IndexT	pca
2022-06-24 16:00:00	14.64	-38.870436
2022-06-24 18:00:00	12.36	-40.568374
2022-06-24 19:00:00	11.52	-37.811227
2022-06-24 20:00:00	11.64	-35.164500
2022-06-24 21:00:00	11.82	-32.233505

3.2.1. Normalizasyon

Veri setindeki ölçeklerin dengelenmesi ve veri setinin daha iyi performans göstermesi, optimizasyon işlemleri kolaylaştırılması, aşırı öğrenmeyi azaltmak için yapılan ön işleme adımdır. Veri normalleştirilmesi için kullanılan yöntem, Min-Max

normalizasyonu kullanılmıştır. Bu yöntem, veri集中的 her bir $[0, 1]$ aralıđına ölçeklendirir. Bu ölçeklendirme işlemi, veri集中的 değeriñ orijinal aralıđını korurken, modelin öğrenme sürecini optimize etmeye yardımcı olur (Darbeheshti 2023).


Min-Max normalizasyonu, denklem 3.3 göre hesaplanır:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.3)$$

Denklemde bulunan formülde:

- X , orijinal değeri
- X_{min} , minimum değeri
- X_{max} , maksimum değeri

Bu normalleştirme işlemi şekil 3.3’de olduđu gibi, tüm veri setinde uygulanarak, her bir özelliğinin değeriñ belirli bir aralıđına çekilmiştir. Bu sayede, modelin öğrenme süreci daha istikrarlı ve hızlı bir şekilde gerçekleştirilebilir.



Şekil 3.4. MinMaxScaler(Anonim 1)

Çizelge 3.3. Normalize Edilmiş Veriseti

	IndexT	pca
2022-06-24 16:00:00	0.770370	0.161166
2022-06-24 18:00:00	0.488889	0.147371
2022-06-24 19:00:00	0.385185	0.169771
2022-06-24 20:00:00	0.400000	0.191274
2022-06-24 21:00:00	0.422222	0.215087

Çizelge 3.1 deki PCA Uygulanmış Verisetini Min Max Scaler fonksiyonu ile çizelge 3-2’de gözüktüğü gibi sayısal değerlerin 0 ile 1 arasında normalize edilmiştir. Bu normalleştirme işlemi, veri setindeki büyük değer farklılıklarını dengeleyerek, modelin genel performansını artırmayı amaçlamaktadır. Normalleştirilmiş veri seti, daha dengeli ve genelde daha iyi sonuçlar elde etmeye yönelik olarak kullanılmıştır.

3.2.2. Zaman Serisini Denetimli Öğrenmeye Dönüştürme


Series_to_supervised fonksiyonu, zaman serisi verilerini denetimli öğrenme formatına dönüştürmek için kullanılır ve bu dönüşümde "lag" değeri oldukça önemlidir. Lag değeri, mevcut zaman adımından önceki zaman adımlarının sayısını belirtir ve bu sayede geçmiş veri noktalarıyla mevcut veri noktası arasındaki ilişkiyi belirler.

Örneğin, bir zaman serisi veri setinde lag değeri 1 olarak belirlenirse, her mevcut veri noktası, bir önceki zaman adımındaki veri noktasıyla birlikte denetimli öğrenme için kullanılır. Bu, modelin zaman içindeki değişiklikleri anlamasına ve öğrenmesine yardımcı olur.

series_to_supervised işleminin özellikle kullanıldığı durumlar şunlardır:

- **Denetimli Öğrenme Modelleri:** Zaman serisi verileri üzerinde çalışan modeller genellikle bir dizi önceki zaman adımını kullanarak gelecekteki değerleri tahmin etmeye çalışır. Bu nedenle, veriyi uygun bir şekilde düzenlemek, bu modellerin geçmişle gelecek arasındaki ilişkiyi öğrenmesine yardımcı olur.
- **Giriş-Çıkış İlişkisinin Belirlenmesi:** Zaman serisi veri setini denetimli öğrenme formatına dönüştürmek, giriş ve çıkış değişkenleri arasındaki ilişkiyi anlamak için yapılan analizleri kolaylaştırır. Bu, veri setindeki desenleri ve etkileşimleri daha iyi anlamak için kullanılabilir.
- **Makine Öğrenimi Modelinin Eğitimi:** Zaman serisi veri setini uygun bir şekilde düzenleyerek, makine öğrenimi modelini eğitmek daha etkili olabilir. Giriş ve çıkış verilerinin doğru bir şekilde belirlenmesi, modelin daha iyi performans göstermesine katkıda bulunabilir.

Bu nedenlerle, zaman serisi verilerini denetimli öğrenme modelleri için hazırlamak amacıyla `series_to_supervised` işlemi kullanılır. Şekil 3.5’da(Kotriwala 2018) görüldüğü gibi `series_to_supervised` ile `lags`(gecikme) belirleniyor, ve bunu kayan pencere işlemi ile yapıyor. Bu, veriyi daha iyi anlamak, modelin doğru öğrenmesini sağlamak ve gelecekteki değerleri tahmin etmek için önemlidir. Verimizdeki bileşenler için gecikmek sayısı 17 olarak belirlenmiş. Bu değer deneme yanılmaya dayalı oluşturulmuştur.



Şekil 3.5. Sıralı Verilerin Formatı

Çizelge 3.4. `series_to_supervised` Uygulanmış Veri seti

	var1(t-2)	var2(t-2)	var1(t-1)	var2(t-1)	var1(t)	var2(t)
2022-06-24 19:00:00	0.770370	0.161166	0.488889	0.147371	0.385185	0.169771
2022-06-24 20:00:00	0.488889	0.147371	0.385185	0.169771	0.400000	0.191274
2022-06-24 21:00:00	0.385185	0.169771	0.400000	0.191274	0.422222	0.215087
2022-06-24 22:00:00	0.400000	0.191274	0.422222	0.215087	0.348148	0.218631
2022-06-24 23:00:00	0.422222	0.215087	0.348148	0.218631	0.385185	0.258609

	var1(t-2)	var2(t-2)	var1(t-1)	var2(t-1)	var1(t)	var2(t)
2022-06-24 19:00:00	0.770370	0.161166	0.488889	0.147371	0.385185	0.169771
2022-06-24 20:00:00	0.488889	0.147371	0.385185	0.169771	0.400000	0.191274
2022-06-24 21:00:00	0.385185	0.169771	0.400000	0.191274	0.422222	0.215087
2022-06-24 22:00:00	0.400000	0.191274	0.422222	0.215087	0.348148	0.218631
2022-06-24 23:00:00	0.422222	0.215087	0.348148	0.218631	0.385185	0.258609

Şekil 3.7. da series_to_supervised fonksiyonundan bahsedilmiştir ve fonksiyonun veri setine uygulandıktan sonraki tablo çıktısı Çizelge 3.3. de görülmektedir. Gecikme sayısı 17 olarak belirlenmiştir ancak tabloda referans görüntü olarak gecikme sayısı 2 seçilerek çıktı alınmıştır.

Uygun Giriş Formatı: Veri setini sinir ağı modeline uygun bir formata getirmek önemlidir, özellikle LSTM gibi reküran sinir ağı modelleri için. Bu modeller genellikle 3D bir giriş formatı bekler, bu nedenle veri setini numpy kullanarak uygun bir şekilde yeniden boyutlandırmak gereklidir (McKinney 2012).

Zaman Serisi Veri İçin, zaman serisi veri setlerinde, önceki zaman adımlarının kullanılabilmesi için veri setinin uygun bir şekilde düzenlenmesi önemlidir. 3D format, zaman serisi verilerinin geçmiş değerlerini içerecek şekilde düzenlenir. Bu işlemler, modelin doğru bir şekilde eğitilmesini ve performansının doğru bir şekilde değerlendirilmesini sağlar. Veri setinin ayrılması, modelin gerçek dünya verileri üzerindeki başarısını daha güvenilir bir şekilde değerlendirmemize ve aşırı uyum riskini azaltmamıza yardımcı olur. Ayrıca, veri setinin boyutlandırılması, sinir ağı modeline girişin uygun bir şekilde yapılmasını sağlar, bu da modelin daha etkili öğrenmesini sağlar.


3.2.3. Train Test Split

Veri Setinin Performans Değerlendirmesi: Train-test split, modelin performansını değerlendirmek için kullanılır. Şekil 3.8’de görüldüğü gibi veri seti, eğitim verisi ve test verisi olarak iki kısma ayrılır. Bunun nedeni model eğitilirken kullanılan veri seti üzerinde başarılı sonuçlar alabilir, ancak gerçek dünya performansını değerlendirmek için ayrılan test verisi kullanılır.

Aşırı uyum ve geneleme kontrolü için modelin genelleme yeteneğini artırmak ve aşırı uyum yapmamasını sağlamak için önemlidir. Eğer model, eğitim verisindeki performansı test verisinden belirgin şekilde yüksekse, aşırı uyum riskiyle karşı karşıya olabilir. Train-test split, bu durumu kontrol etmek ve modelin gerçek dünya verileri üzerindeki performansını değerlendirmek için kullanılır (Kramer 2016).

Örneğin, bir model eğitim verisinde %90 doğruluk elde ederken, test verisinde %80 doğruluk elde ediyorsa, modelin aşırı uyum yapma eğiliminde olduğu ve genelleme yeteneğinin daha iyi olabileceği düşünülebilir.

Train-test split işlemi, veri seti üzerinde yapılan işlemlerin güvenilirliğini artırır ve modelin gerçek dünya verilerine nasıl genelleşeceğini tahmin etmede yardımcı olur. Bu nedenle, modelin eğitim ve test verileri üzerindeki performansı dikkatlice incelenmelidir. Verinin %80 i eğitim, %20 si test ve eğitim verilerinin %20 sini doğrulama veri seti olarak ayrılmıştır.



Şekil 3.6. train_test_split Görseli

3.3. Derin Öğrenme

3.3.1. Yinelemeli Sinir Ağı

Tekrarlayan Sinir Ağı (RNN), ilk kez 1982 yılında Saratha Sathasivam tarafından önerilen Hopfield ağından türetilmiştir. Geleneksel makine öğrenimi algoritmaları genellikle manuel özellik çıkarımına dayanır; bu durum, özellikle görüntü tanıma, konuşma tanıma ve doğal dil işlemede özellik çıkarımını kısıtlayabilir (Hopfield 1982).

Tamamen bağlantılı sinir ağları, çok sayıda parametre içerir ve zaman serisi verilerindeki bilgilerin işlenmesinde kısıtlılıklar yaşanabilir. RNN'lerin gelişimi, veri madenciliğinde sıralı bilgilerin ve anlamsal yapıların daha etkin bir şekilde kullanılmasını sağlamıştır. Bu sayede RNN modelleri, konuşma tanıma, makine çevirisi ve zamanlama analizi gibi alanlarda önemli ilerlemeler kaydetmiştir (Rius1998).

Zaman serisi analizi, gelecekteki değerleri mevcut ve geçmiş verilere dayanarak tahmin etmeyi amaçlar. Bu alanda RNN, önemli bir sinir ağı modelidir. Diğer sinir ağı türleriyle karşılaştırıldığında, RNN'ler önceki adımlarla ilişkili olan bilgileri korur. Bu özellik, RNN'yi zaman serisi verilerinde etkili kılar. Ancak, uzun vadeli bağımlılıkların işlenmesi sırasında RNN eğitiminde karşılaşılan gradyan kaybı ve patlama gibi sorunlar ortaya çıkabilir (Wang 2022).

RNN ailesi, sıralı veri analizi ve modelleme için tasarlanmış katmanlar içerir. Bu aile içinde yer alan Long Short-Term Memory (LSTM) ve Gated Recurrent Unit (GRU) gibi özel katmanlar, standart RNN'lere kıyasla daha gelişmiş ve etkili hale getirilmiştir.

3.2.2 Long-Short-Term Memory (LSTM)

1997 yılında Schmidhuber ve Hochreiter tarafından tanıtıldı. LSTM uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türüdür. Çok çeşitli problemlerde çok iyi çalışmaları için günümüzde çok yaygın şekilde kullanılıyor. Boşluk uzunluğuna göreceli duyarsızlık, alternatif RNN'ler, gizli Markov modelleri ve sayısız uygulamadaki diğer dizi öğrenme yöntemlerine kıyasla LSTM'ye bir avantaj sağlamaktadır. LSTM, RNN'nin eğitim sürecindeki gradyan kaybolması ve patlaması sorunlarını iyi bir şekilde hafifletebilir. LSTM, üç ana kapı (giriş, çıkış ve unutma) ile donatılmış bir hücre yapısına sahiptir. Bu kapılar, bilgilerin hafızaya eklenmesi, okunması ve silinmesi süreçlerini kontrol eder. Bu sayede şekil 3.7'de görünen LSTM yapısı uzun vadeli bağımlılıkları daha etkili bir şekilde öğrenebilir.

Giriş Kapısı: Giriş kapısı, mevcut girişten ve önceki adımdan gelen kısa süreli hafızadan elde edilen bilgilerle uzun vadeli hafızada saklanacak bilgileri belirler. Bu kapı, gereksiz bilgileri filtreleyerek yararlı bilgileri korur.

Unutma Kapısı: Unutma kapısı, uzun vadeli bellekten hangi bilgilerin korunacağına veya silineceğine karar verir. Bu karar, gelen uzun vadeli belleğin, mevcut giriş ve önceki kısa vadeli bellekten oluşturulan bir unutma vektörüyle çarpılmasıyla yapılır.

Çıkış Kapısı: Çıkış kapısı, yeni kısa vadeli belleği üretmek için mevcut girişi, önceki kısa vadeli belleği ve hesaplanan uzun vadeli belleği kullanır. Bu kapı ayrıca mevcut zaman adımının çıktısını da alabilir.

Cho tarafından geliştirilen ve unutma geçidini ve giriş kapısını birleştiren güncelleme geçidini içeren GRU, LSTM'nin önemli bir türüdür. GRU, LSTM ile karşılaştırıldığında daha az parametreye sahiptir ve daha basit bir yapıya sahiptir (Gers 2000).

3.3.2. Gated Recurrent Unit (GRU)

Cho ve diğer araştırmacılar, basit RNN'lerdeki gradyan kaybı sorununu çözmek için Kapılı Tekrarlayan Birim (GRU) adını verdikleri bir model önerdiler. GRU, LSTM'ye oldukça benzer bir yapıya sahiptir. Her ikisi de bilgi akışını kontrol etmek için kapılı bir yapı kullanır, ancak GRU, hafıza hücresine ihtiyaç duymadan bilgi akışını kontrol eden geçit birimlerine sahiptir. GRU'nun iki ana geçidi vardır: güncelleme geçidi (z) ve sıfırlama geçidi (r). Genel olarak, GRU'nun yapısı Şekil 3.12'te gösterilmiştir. GRU'nun güncelleme geçidi, LSTM'in giriş ve unutma kapılarının bir kombinasyonu olarak düşünülebilir (Cho 2014).

GRU, LSTM'e benzer bir şekilde uzun vadeli bağımlılıkları öğrenmeye odaklanan bir RNN türüdür. Ancak, LSTM'den daha basit bir yapıya sahiptir. GRU, reset, güncelleme ve hafıza kapılarını içerir. GRU'nun en önemli özelliklerinden biri, daha az parametre içermesi ve daha hızlı eğitilebilmesidir. Şekil 3.7. da(Lazar) GRU yapısını ve içindeki kapıları görebiliyoruz.


Güncelleme Kapısı: Güncelleme kapısı, hücrenin bir sonraki duruma geçmesi gereken önceki bilgi miktarını belirler. Bu özellik, modelin geçmişteki tüm bilgileri kopyalamaya karar vermesini engelleyerek eğimin kaybolma riskini azaltır.

Sıfırlama Kapısı: Sıfırlama kapısı, geçmiş bilgilerin ne kadarının unutulması gerektiğini belirler. Yani, hücrenin önceki durumunun önemli olup olmadığına karar verir.

Bu kapı ilk olarak, geçmiş zaman adımından gelen ilgili bilgileri yeni hafıza içeriğine depolar. Ardından, giriş vektörü ve gizli durumun ağırlıklarıyla çarpım işlemi gerçekleştirir. Daha sonra, sıfırlama kapısı ve daha önce gizli olan durum arasındaki eleman bazında çarpımı hesaplar. Bu adımların sonunda doğrusal olmayan aktivasyon fonksiyonu uygulanarak bir sonraki durum oluşturulur.

GRU ve LSTM arasındaki farklar şu şekildedir:

GRU'nun iki kapısı vardır, LSTM'nin üç kapısı vardır. GRU'da sıfırlama ve güncelleme kapıları bulunurken, LSTM'de bunlara ek olarak unutma kapısı vardır. GRU'nun içinde gizli bir durum (hidden state) ve hücre durumu (cell state) olmak üzere iki bileşen vardır. LSTM'de ise bu bileşenler ayrıdır: gizli durum LSTM'in çıkışıdır, hücre durumu ise içeride tutulan bellektir. GRU, daha basit bir yapıya sahip olup daha az parametre içerir, bu nedenle eğitimi daha hızlıdır. LSTM ise daha karmaşık bir yapıya sahiptir ve daha fazla parametre içerir, bu da daha uzun eğitim süreleri gerektirebilir. GRU, unutma kapısı olmadığından bazı durumlarda daha hızlı öğrenme sağlayabilir. Ancak, LSTM daha karmaşık ilişkileri öğrenebilir ve daha uzun süreli bağımlılıkları işleyebilir. GRU'nun sıfırlama kapısı ve güncelleme kapısı, LSTM'deki unutma, giriş ve çıkış kapılarına benzer işlevleri yerine getirir. Bu kapılar, geçmiş bilgileri unutmak, yeni bilgileri eklemek ve mevcut bilgileri güncellemek için kullanılır. GRU ve LSTM, farklı problemlere ve veri setlerine göre farklı performanslar gösterebilir. Bu nedenle, hangi modelin kullanılacağı genellikle deney ve testlerle belirlenir.



Şekil 3.7. LSTM ve GRU Yapısı


3.3.3. Model Tanımı ve Metriklerin Belirlenmesi

LSTM ve GRU modelleri için giriş verilerinin üç boyutlu olması gerekmektedir. Bu üç boyutlu vektörde birinci boyut toplam örnek sayısını, ikinci boyut zaman adımlarının sayısını ve üçüncü boyut ise özellik sayısını göstermektedir. Eğitim verileri için zaman gecikmeleri olarak 17 zaman adımı atılmıştır. Şekil 3.8’de görüldüğü gibi veri setimizdeki bileşen sayısı ikidir bu yüzden veri setinin boyutu (None, 35, 1)’dir. Şekil 3.8’de kurulan model mimarisi temsil edilmiştir.

LSTM ve GRU katmanlarında bulunan nöron sayısı, bu katmanların karmaşıklığını ve öğrenme kapasitesini belirler. Nöron Sayısı: Daha fazla nöron, modelin daha karmaşık öğrenme işlevlerini öğrenme kapasitesini artırabilir, ancak aynı zamanda modelin eğitim süresini ve hesaplama yükünü de artırabilir. Hiper parametreler, modelin performansını ve genel öğrenme yeteneklerini büyük ölçüde etkiler. Optimal hiper parametre seçimi, belirli bir görev veya veri setine bağlı olarak dikkatlice yapılmalıdır.

Modeli eğitmek için her gizli LSTM ve GRU katmanı için 100 nöron birimi alınmıştır. LSTM ve GRU modellerinde bir giriş katmanı, iki gizli katman ve bir çıkış katmanı bulunmaktadır. Yoğun ağ nedeniyle aşırı uyum sorununu önlemek için modelde bırakma katmanlarının alınması da önemlidir. Bu nedenle, her gizli LSTM ve GRU katmanından sonra, sinir ağının geri yayılım sürecinde ölebileceği için herhangi bir nörona tamamen güvenmemesini sağlayan bir bırakma katmanı vardır. Bu nedenle, geriye yayılımdaki ağırlıkları ve ofset hatasını düzelterek aşırı uyumu önler.


Modelin performansını değerlendirmek için MSE kayıp fonksiyonu ve MAE metriği kullanılmıştır. Bu metrikler, modelin tahminlerini gerçek değerlerle karşılaştırarak modelin performansını değerlendirmeye yardımcı olur. Optimize edici olarak Adam kullanılmıştır ve öğrenme oranı 0.001 olarak belirlenmiştir.



Şekil 3.8. LSTM&GRU Model Mimarisi

3.4. Model Eğitim ve Değerlendirilmesi


Modelimizin eğitim süresi boyunca eğitim ve doğruluk hata değerlerini şekil 3.9'de görselleştirildi. Bu grafikte eğitim ve doğruluk hata değerlerinin birbirini takip ettiğini ve 0 a yaklaştığını gözlemlendi. Epochs sayısının daha fazla olması ise overfitting e neden olabileceğini ön görüldü. Oluşturulan model ve veriseti özelinde 10 epoch yeterli görüldü.



Şekil 3.9. Eğitim Hata Grafiği

Tüm bu değerlendirmeler test verileri üzerinde yapıldı. Modelin önceki görmediği verilerle nasıl başa çıktığını ve genelleme yeteneği değerlendirildi. Test verileri, modelin gerçek dünya senaryolarında ne kadar iyi performans gösterdiğini belirlememize yardımcı oldu.

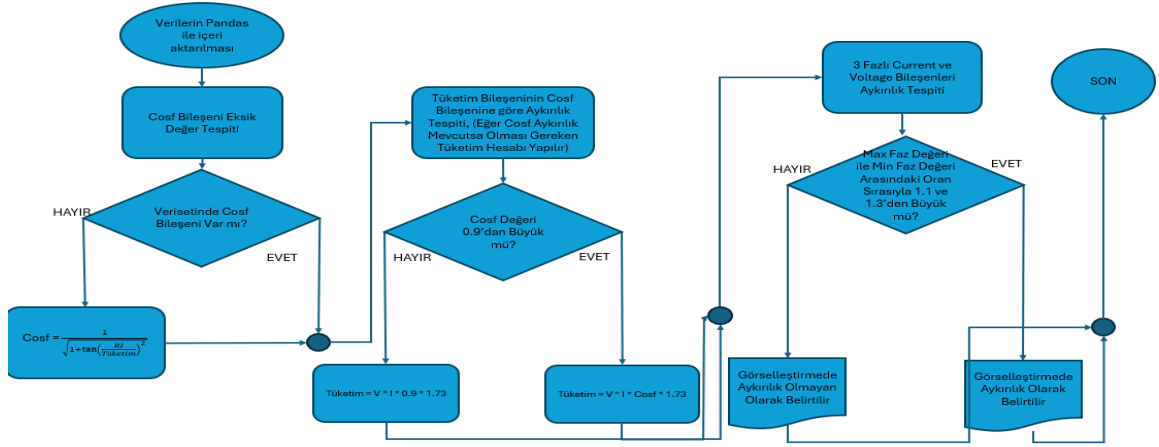
Bu aşamada elde ettiğimiz sonuçlar şekil 3.10’de görüldüğü gibi modelin tahmin yeteneğini değerlendirmek ve olası iyileştirmeler için bir temel oluşturmak adına kritik öneme sahiptir.



Şekil 3.10. Gerçek ve Tahmin Sonuçları

Model Değerlendirme Metrik Sonuçları RMSE 0.02 ve R^2 skoru 0.96 olarak hesaplanmıştır. Bu sonuçlar bir sıralı veri için gayet başarılı gözükmemekte. Grafik üzerindeki mavi kısımlar gerçek değerleri ifade ederken turuncu kısımlar ise tahmin değerlerini ifade ediyor. Bu iki grafiğin birbirini çok yakından takip ettiğini görebiliyoruz.

3.4.1. Aykırılık Analizi



Şekil 3.11. Aykırılık Analizi Diyagramı

Aykırı değerler, genellikle diğer veri noktalarından belirgin şekilde farklı olan veya beklenen desenlerden sapma gösteren veri noktaları olarak tanımlanır. Bu değerler, ölçüm hatalarından, veri girişi hatalarından veya gerçek dünyadaki nadir olaylardan kaynaklanabilir. Aykırı değerlerin doğru bir şekilde tanımlanması ve ele alınması, veri analizinin doğruluğunu ve güvenilirliğini önemli ölçüde artırabilir.

Şekil 3.13 de Aykırılık Analizi Diyagramı verilmiştir. Bu diyagram doğrultusunda Verisetimizdeki Cos, Voltage, Current, Tüketim bileşenleri için geniş çerçevede aykırılık analizi ve görselleştirilmesi yapılmıştır.

Çizelge 3.5. Veri Seti

	VoltageR	VoltageS	VoltageT	CurrentR	CurrentS	CurrentT	CosR	CosS	CosT	RC	RI	IndexT	cosf	tanf
OXUNMA VAXTI														
2022-01-07 00:25:15	62.9	63.3	62.5	1.304	1.328	1.235	0.93	0.90	0.90	0.0	60.0	136.8	0.905349	0.438596
2022-01-07 00:40:30	62.9	63.3	62.4	1.280	1.302	1.254	0.92	0.89	0.90	0.0	60.0	136.8	0.905349	0.438596
2022-01-07 00:55:45	62.9	63.3	62.5	1.264	1.259	1.198	0.92	0.88	0.90	0.0	60.0	132.0	0.898461	0.454545
2022-01-07 01:11:00	62.9	63.3	62.5	1.215	1.259	1.190	0.91	0.89	0.89	0.0	60.0	127.2	0.890798	0.471698
2022-01-07 01:26:11	62.9	63.4	62.5	1.186	1.189	1.123	0.90	0.87	0.89	0.0	60.0	124.8	0.886639	0.480769

3.4.2. Cosf Bileşeni Aykırılık Analizi

Denklem (4.3) ile hesaplanan Cosf bileşeni, Çizelge 3.4'deki Veri Seti Tablosu'na eklenmiştir. Cosf bileşeni için 0.9 değeri ve üzeri verimli kabul edilirken, 0.9'dan düşük değerler aykırı olarak belirlenmiştir. Tabloda, Cosf bileşeninin 0.9'dan yüksek ve düşük değerlere sahip gözlemleri bulunmaktadır.

$$\text{Cosf} = \frac{1}{\sqrt{1 + \tan^2\left(\frac{RI}{T_{\text{tüketim}}}\right)^2}} \quad (4.3)$$

3.4.3. Tüketim Bileşeni Aykırılık Analizi

Tüketim aykırılığı analizi için öncelikle Cosf bileşenine bakılmalıdır. Denklem 4.4, tüketim bileşeninin hesaplanma şeklini açıklamaktadır. Eğer bir gözlemin Cosf değeri 0.9'dan küçükse, Cosf bileşeninde aykırılık olduğu ve dolayısıyla tüketimde de aykırılık olduğu söylenebilir. Bu durumu tespit etmek için öncelikle Cosf değerinin 0.9 olması gerekmektedir. Sonrasında, Denklem 4.5 ile tüketim hesaplanmalıdır.


$$Tüketim = V \times I \times Cosf \times 1.73 \quad (4.4)$$

$$Tüketim = V \times I \times 0.9 \times 1.73 \quad (4.5)$$

Çizelge 3.6. Verimli Tüketim

	cosf	IndexT	true_cosf	true_IndexT
OXUNMA VAXTI				
2022-01-07 00:25:15	0.905349	136.8	0.905349	136.800000
2022-01-07 00:40:30	0.905349	136.8	0.905349	136.800000
2022-01-07 00:55:45	0.898461	132.0	0.900000	132.226152
2022-01-07 01:11:00	0.890798	127.2	0.900000	128.513991
2022-01-07 01:26:11	0.886639	124.8	0.900000	126.680581

Çizelge 3.5'teki tabloda yeni eklenen true_cosf ve true_IndexT bileşenleri bulunmaktadır. true_cosf bileşeni, olması gereken cosf değerini temsil ederken, true_IndexT bileşeni ise verimli true_cosf değerine göre hesaplanmış olması gereken tüketim değerlerini ifade eder. Bu şekilde, trafolardaki kaybı hesaplanmış oluyoruz.



Şekil 3.12. Verimli ve Aykırı Tüketim Grafiği

Şekil 3.13'daki grafik, aykırılık ve verimlilikle ilgili bilgi vermektedir. Grafikteki mavi çizgiler aykırılığı temsil ederken, turuncu çizgiler ise olması gereken tüketim değerlerini göstermektedir. Şekil 3.15 grafiği, Şekil 3.14'te gösterilen tablodaki IndexT ve true_IndexT bileşenlerinin görselleştirilmiş halidir.


3.4.4. Voltage ve Current Tüketim Bileşeni Aykırılık Analizi

Veri setimizdeki Voltage ve Current bileşenleri R, S ve T fazları olmak üzere 3 fazlı bir yapıdadır. Her bir gözlemde 3 faz bilgisi bulunmaktadır. Voltage ve Current bileşenleri için belirlenen aykırılık analizi koşulu şu şekildedir:

Denklem 4.4'de belirtildiği gibi, bir gözlemdeki 3 fazdan, maksimum faz değeri ve minimum faz değerleri tespit edildikten sonra, Voltage için Oran değeri 1.1'den büyükse, Current için Oran değeri 1.3'ten büyükse, bu durumu aykırılık olarak tanımlanır.


$$Oran = \frac{Max_{faz}}{Min_{faz}} \quad (4.6)$$

Şekil 3.13 80058003 numaralı trafo için Voltage bileşeni aykırılık analizi sonucu olan görselleştirilmedir. Kırmızı noktalar aykırılık bulunan gözlemler olup, yeşil alanlar ise olması gereken değerlerdir.




Şekil 3.13. Voltage Aykırılık Görselleştirilmesi

Şekil 3.13, 80058003 numaralı trafonun Voltage bileşeni için yapılan aykırılık analizi sonuçlarını göstermektedir. Kırmızı noktalar, aykırılık tespit edilen gözlemleri temsil ederken, yeşil alanlar ise verimli olan bölgeleri göstermektedir. Grafikte, çoğunlukla verimli bölgelerde yoğunluk olduğu görülmektedir, ancak bazı gözlemlerde aykırılık belirtileri gözlenmektedir. Bu aykırı değerler, trafonun belirli zaman dilimlerinde normalden sapma gösterdiğini ve bu durumun özellikle belirli koşullarda daha sık gerçekleştiğini gösterebilir. Aykırı değerlerin analizi, trafo üzerinde potansiyel sorunları tespit etmede ve bakım planlarının oluşturulmasında önemli bir rol oynayabilir. Bu nedenle, aykırılık analizi sonuçlarına dayanarak belirlenen bölgelerde daha detaylı incelemeler yapılabilir ve trafo performansının optimize edilmesine yönelik stratejiler geliştirilebilir.




Şekil 3.14. Arızalı Trafo Voltage Aykırılık Görselleştirilmesi

Şekil 3.15 grafiği ile Şekil 3.13 grafiği karşılaştırıldığında, kırmızı bölgelerin yani aykırı durumların Şekil 3.14'da daha fazla olduğu gözükmemektedir. Bu durum, trafonun belirli bir dönemde daha fazla aykırılık gösterdiğini ve bu durumun saha analizi ile doğrulandığını göstermektedir. Saha analizi sonucunda trafonun R fazının yenilendiği belirlenmiştir. Bu iki grafik arasındaki karşılaştırma, aykırılık analizinin trafonun sağlığı ve performansı üzerindeki önemini daha net bir şekilde ortaya koymaktadır. Aykırılıkların tespiti ve zamanında müdahale, trafonun güvenilirliğini artırabilir ve bakım maliyetlerini azaltabilir.



Şekil 3.15. Current Aykırılık Görselleştirilmesi



Şekil 3.16. Arızalı Trafo Current Aykırılık Görselleştirilmesi

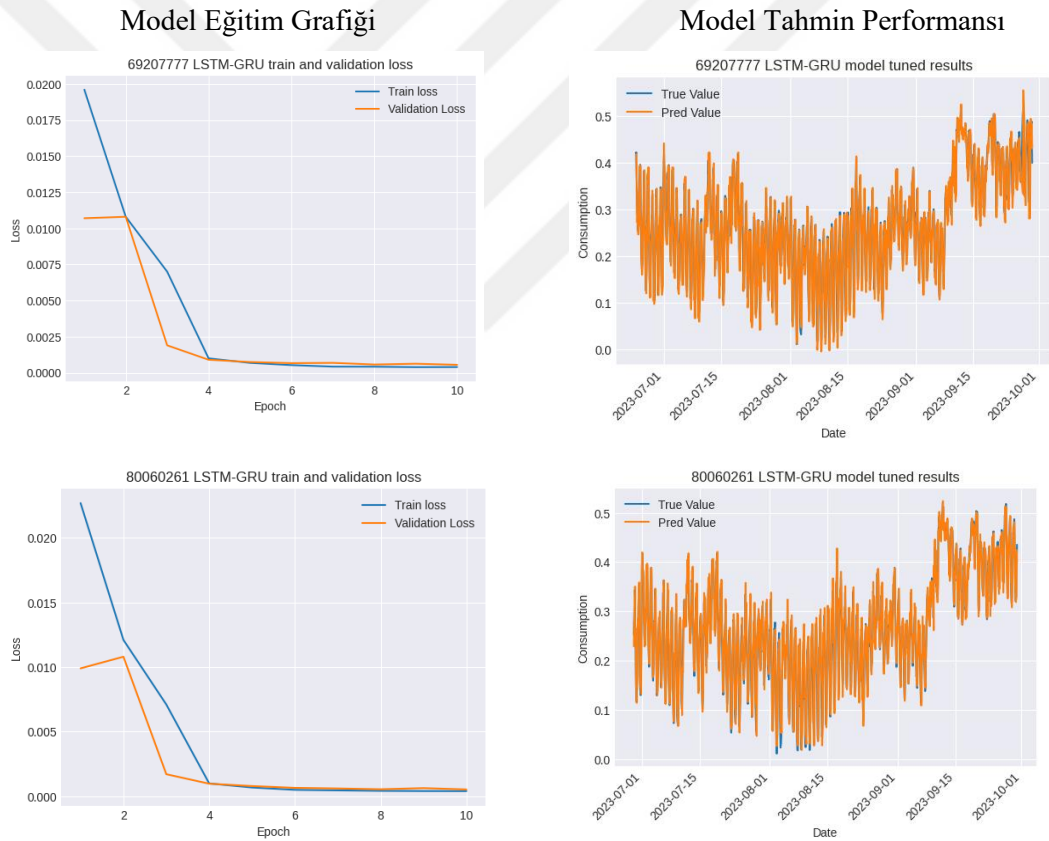
Şekil 3.16, 69207777 numaralı trafonun Current bileşeni için yapılan aykırılık analizine ilişkin sonuçları göstermektedir. Grafikte, kırmızı noktalar aykırılık tespit edilen gözlemleri temsil ederken, yeşil alanlar olması gereken değerleri göstermektedir. Veriler incelendiğinde, genellikle verimli bölgelerde yoğunluk olduğu görülmektedir. Ancak Şekil 3.15 'e bakıldığında aykırılık görselleştirilmesiyle beraber arızalı trafonun kırmızı bölgeleri yani aykırı durumları çok daha fazladır.







4. BULGULAR VE TARTIŞMA


4.1. Derin Öğrenme Modelin Çıktıları

Model eğitiminde kullanılan LSTM-GRU mimarisi, farklı trafoların saatlik elektrik tüketimlerini tahmin etmek için başarılı bir şekilde uygulanmıştır. İndirgeme Merkezi Numarası 69207777 ve trafo numaraları, 80060261, 80059990, 80059918, 80059900, 80058003 ve 02800859 olarak belirlenmiştir. Çizelge'deki görüldüğü üzere eğitim sürecinde, her bir trafo için 10 epoch boyunca modelin eğitimi gerçekleştirilmiştir. Eğitim ve doğrulama kayıpları (loss) ile ortalama mutlak hata (MAE) değerleri göz önünde bulundurulduğunda, modelin öğrenme sürecinin başarılı olduğu ve genel olarak iyi bir performans sergilediği görülmektedir. Bu sonuçlar, LSTM-GRU modelinin elektrik tüketimi tahmini için etkili bir yöntem olduğunu göstermektedir.

Çizelge 4.1. Trafo için Model Eğitim Grafiği ve Kayıp Grafiği







Saatlik elektrik tüketimi tahminleri, LSTM-GRU modelinin farklı trafolar için başarılı bir şekilde uygulandığını göstermektedir. Her bir trafonun (69207777, 80060261, 80059990, 80059918, 80059900, 80058003, 02800859) saatlik elektrik tüketim tahminlerinin gerçek değerlerle karşılaştırılması, modelin genel doğruluğunu ve güvenilirliğini göstermektedir. Görseller, modelin eğitiminde kullanılan verilerin gerçek dünya verilerini ne kadar iyi yakaladığını görsel olarak göstermektedir.

Modelimizin performansını değerlendirmek için Root Mean Squared Error (RMSE) ve R-squared (R2) skorlarını kullanıldı. RMSE, modelin gerçek değerlerle tahminleri arasındaki ortalama hata miktarını ölçerken, R2 skoru modelin verileri ne kadar iyi açıkladığını gösterir. Tablomuzda, her bir trafo için elde edilen RMSE ve R2 skorları bulunmaktadır. Düşük RMSE değerleri ve yüksek R2 skorları, modelin başarılı bir şekilde elektrik tüketim tahminleri yapabildiğini göstermektedir.

Çizelge 4.2. Her Modelin RMSE ve R2 Skoru

Trafo Numarası	RMSE	R2 Skoru
69207777	0.0238	0.9481
80060261	0.0207	0.9612
80059990	0.0218	0.9552
80059918	0.0183	0.9719
80059900	0.0198	0.9658
80058003	0.0202	0.9615
02800859	0.0232	0.9515

4.2. Aykırı Değer Tespiti Sonuçları

Aykırlık Değer analizi veri görselleştirme üzerinden değerlendirilmiştir. Her trafo da yapılan analizler sonucu 80059990 nolu trafo merkezi gidilip yerinde inceleme yapılmıştır. Şekil 4.1’de görüldüğü üzere kablo kesitinin koptuğu gözlenmiştir.



Şekil 4.1. Kopuk kablo kesiti

5. SONUÇLAR

Bu tez çalışması, elektrik trafolarından elde edilen verilerin detaylı bir analizi ve derin öğrenme modelleriyle elektrik tüketimi tahminleme üzerine odaklanmıştır. Yapılan analizlerde, Voltage, Current, Cosf gibi kritik bileşenler üzerinde derinlemesine bir inceleme gerçekleştirilmiş ve bu bileşenlerdeki aykırı davranan gözlemler başarılı bir şekilde tespit edilmiştir. Bu tespitler, elektrik hatlarında olası sorunlar ve düzeltilebilecek noktalar hakkında değerli bilgiler sunmaktadır.

Elektrik tüketim bileşeni için gerçekleştirilen ileriye yönelik tahminleme çalışması, veri setine hava durumu bileşenlerinin eklenmesiyle daha kapsamlı bir boyut kazanmıştır. Hava durumu verileri, elektrik tüketimini etkileyen önemli faktörlerden biridir ve bu durumun göz önüne alınması, tahminleme modelinin daha güvenilir ve doğru sonuçlar üretmesine olanak sağlamıştır.

Derin öğrenme modeli olarak LSTM ve GRU katmanları kullanılarak eğitilen model, elde edilen tahminlerde gerçek değerlere son derece yakın sonuçlar elde etmiştir. şekil 3.8'deki görselleştirmeler, modelin yüksek doğruluk seviyesini gözler önüne sermektedir. Modelin performansını kesinleştirmek adına RMSE ve R2_score gibi metriklerle yapılan değerlendirmeler, modelin veri seti üzerinde %96'lık bir doğruluk sağladığını göstermektedir. Bu durum, elde edilen sonuçların güvenilir ve genel geçerli olduğunu gösterirken, bu başarı gelecekteki enerji planlamaları ve yönetimi için önemli bir temel oluşturmaktadır.

Bu çalışma, elektrik tüketimi tahminleme alanında derin öğrenme modellerinin etkili bir şekilde kullanılmasının yanı sıra, enerji sektöründe veri analizi ve modelleme konularında yeni kapılar açmaktadır. Elde edilen bulgular, enerji sektöründeki uzmanlara, karar alıcılara ve araştırmacılara değerli bir perspektif sunmaktadır.

6. KAYNAKLAR

- Abdoos, A., Hemmati, M., & Abdoos, A. A. 2015. Short term load forecasting using a hybrid intelligent method. *Knowledge-Based Systems*, 76, 139-147.
- Ahmad, T., & Zhang, D. (2020). A critical review of comparative global historical energy consumption and future demand: The story told so far. *Energy Reports*, 6, 1973-1991.
- Akbarov, İ. 2023. Azerbaycan'da Elektrik Enerjisi Tüketimin Yapıya Zeka Yöntemleri ile Analizi ve Tahmini. Yüksek Lisans Tezi, İstanbul Üniversitesi-Cerrahpaşa
- Anonymous 1: <https://www.geeksforgeeks.org/interquartile-range-to-detect-outliers-in-data/> [Son erişim Tarihi: 02.02.2024]
- Anonymous 2: Weather Api online. <https://www.weatherapi.com/> [Son erişim tarihi: 01.05.2024]
- Burçak Polat, Yenilenebilir Enerji Tüketimi ve Karbon Emisyonu İlişkisi, *Euroasis Journal of Social Sciences & Humanities*, 2022
- Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y. “On the properties of neural machine translation: encoder-decoder approaches”. *arXiv preprint arXiv:1409.1259*.
- Darbeheshi, N., & Moradi, E. 2023. LSTM-Based Forecasting Model for GRACE Accelerometer Data. *arXiv preprint arXiv:2308.08621*
- Domański, P. D. 2020. Study on statistical outlier detection and labelling. *International Journal of Automation and Computing*, 17(6), 788-811.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10), 2451-2471.
- Hasanov, F. J., Hunt, L. C., & Mikayilov, C. I. 2016. Modeling and forecasting electricity demand in Azerbaijan using cointegration techniques. *Energies*, 9(12), 1045.
- Hasanov, F. J., & Mikayilov, J. I. 2017. The impact of age groups on consumption of residential electricity in Azerbaijan. *Communist and Post-Communist Studies*, 50(4), 339-351.
- Hopfield, J. J. 1982. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558
- Jeyhun I. Mikayilov Fakhri J. Hasanov , Carlo A. Bollino ve Ceyhun Mahmudlu Modeling of Electricity Demand for Azerbaijan: Time-Varying Coefficient Cointegration Approach, *Energies dergisi* 2017
- Kotriwala, A. M., Hernandez-Leal, P., & Kaisers, M. 2018, October. Load classification and forecasting for temporary power installations. In *2018 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)* (pp. 1-6). IEEE
- Kramer, O., & Kramer, O. 2016. Scikit-learn. *Machine learning for evolution strategies*, 45-53.

- Kurita, T. 2019. Principal component analysis (PCA). Computer Vision: A Reference Guide, 1-4.
- Lazar, D. Character-level Deep Language Model with GRU/LSTM units using TensorFlow <https://medium.com/nabla-squared/character-level-deep-language-model-with-gru-lstm-units-using-tensorflow-ec419fe692cd> [Son erişim tarihi: 05.12.2023]
- Melike Ç. Ve Şeyma Ş.K Türkiyede Yenilenebilir Enerji Tüketimi ve çevresel Sürdürülebilirliği Ekonomik Büyüme Üzerine Etkisi, Journal of Empirical Economics and Social Sciences, Mart 2022
- McKinney, W. (2012). Python for data analysis: Data wrangling with Pandas, NumPy, and IPython. " O'Reilly Media, Inc.".Nabiyev, V. V.
- Mikayilov, J. I., Hasanov, F. J., Bollino, C. A., & Mahmudlu, C. (2017). Modeling of electricity demand for Azerbaijan: time-varying coefficient cointegration approach. *Energies*, 10(11), 1918.
- Mishra, A., Lone, H. R., & Mishra, A. 2024. DECODE: Data-driven energy consumption prediction leveraging historical data and environmental factors in buildings. *Energy and Buildings*, 307, 113950.
- Ngo, N. T., Pham, A. D., Truong, T. T. H., Truong, N. S., & Huynh, N. T. 2022. Developing a hybrid time-series artificial intelligence model to forecast energy use in buildings. *Scientific Reports*, 12(1), 15775.
- Rajbhandari, Y., Marahatta, A., Ghimire, B., Shrestha, A., Gachhadar, A., Thapa, A., ... & Korba, P. (2021). Impact study of temperature on the time series electricity demand of urban nepal for short-term load forecasting. *Applied System Innovation*, 4(3), 43.
- Rius, A., Ruisanchez, I., Callao, M. P., & Rius, F. X. (1998). Reliability of analytical systems: use of control charts, time series models and recurrent neural networks (RNN). *Chemometrics and Intelligent Laboratory Systems*, 40(1), 1-18.
- Shaikh, A. K., Nazir, A., Khan, I., & Shah, A. S. 2022. Short term energy consumption forecasting using neural basis expansion analysis for interpretable time series. *Scientific reports*, 12(1), 22562.
- Ülkü, H., & Yalpir, Ş. (2021). Enerji talep tahmini için metodoloji geliştirme: 2030 yılı Türkiye örneği. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 188-201.
- Wang, J., Li, X., Li, J., Sun, Q., & Wang, H. (2022). NGCU: A new RNN model for time-series data prediction. *Big Data Research*, 27, 100296.
- Yılmaz, E., & Cowley, P. P. 2022. Enerji Tüketimi ve Ekonomik Büyüme İlişkisine Ekonometrik Yaklaşım. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 14(26), 59-74.
- Yildiriz, G., & Öztürk, A. 2022. Electrical energy consumption forecasting using regression method considering temperature effect for distribution network. *Electrical Engineering*, 104(5), 3465-3476

ÖZGEÇMİŞ

VUSAL ISAYEV

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2021-2024	Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Antalya
Lisans	Trakya Üniversitesi
2006-2012	Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Edirne

MESLEKİ VE İDARİ GÖREVLER

Azerishiq A.S İnformasiya ve Teknolojiya	Direktör Yardımcısı
2015-Devam Ediyor	Bakü