

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI
ELEKTRİK ELEKTRONİK MÜHENDİSLİĐİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**BİR İLİN ELEKTRİK TÜKETİM VERİLERİNİN MAKİNE ÖĐRENMESİ
YÖNTEMLERİ İLE ANALİZİ**

HAZIRLAYAN

KADİR ÇAĐRI GEZMEZ

YÜKSEK LİSANS TEZİ

ANKARA – 2022

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI
ELEKTRİK ELEKTRONİK MÜHENDİSLİĐİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**BİR İLİN ELEKTRİK TÜKETİM VERİLERİNİN MAKİNE ÖĐRENMESİ
YÖNTEMLERİ İLE ANALİZİ**

HAZIRLAYAN

KADİR ÇAĐRI GEZMEZ

YÜKSEK LİSANS TEZİ

TEZ DANIŐMANI

DR. ÖĐR. ÜYESİ SELDA GÜNEY

ANKARA – 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektrik-Elektronik Mühendisliği Tezli Yüksek Lisans / Doktora Programı çerçevesinde Kadir Çağrı Gezmez tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans / Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 23 / 08 / 2022

Tez Adı: Bir İlin Elektrik Tüketim Verilerinin Makine Öğrenmesi Yöntemleri ile Analizi

Tez Jüri Üyeleri (Unvanı, Adı- Soyadı, Kurumu)

İmza

Prof. Dr. Necmi Altın, Gazi Üniversitesi

.....

Prof. Dr. Sedat Nazlıbilek, Başkent Üniversitesi

.....

Dr. Öğr. Üyesi Selda Güney, Başkent Üniversitesi

.....

ONAY

Prof. Dr. Ömer Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü

Tarih : ... / ... / 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS / DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: ... / ... / 20...

Öğrencinin Adı, Soyadı : Kadir Çağrı Gezmez

Öğrencinin Numarası : 21920098

Anabilim Dalı : Elektrik-Elektronik Mühendisliği

Programı : Tezli Yüksek Lisans

Danışmanın Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Selda Güney

Tez Başlığı : Bir İlin Elektrik Tüketim Verilerinin Makine Öğrenmesi Yöntemleri ile Analizi

Yukarıda başlığı belirtilen Yüksek Lisans/Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 62 sayfalık kısmına ilişkin, 02 / 09 / 2022 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 12'dir. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:.....

Onay

Tarih: 02 / 09 / 2022

Dr. Öğr. Üyesi Selda Güney

TEŐEKKÜR

Tez alıőmamın gerekleőtirilmesinde, bilgilerini her zaman benimle paylaőan, kıymetli zamanını ayırıp, sabırla ve büyük bir ilgiyle faydalı olabilmek için elinden geleni sunan, güler yüzünü ve samimiyetini asla esirgemeyen ve gelecekteki hayatımda hem mesleki hem de hayata dair verdiđi deđerli bilgilerinden faydalanabileceđimi düőündüđüm kıymetli danıőman hocam Dr. Öđr. Üyesi Selda Güney ‘e teőekkürü bir bor biliyor ve őükranlarımı sunuyorum. Ayrıca eđitim ve öđretim hayatım boyunca, kıymetli bilgilerini benimle her zaman paylaőan ve yardımcı olmayı esirgemeyen, deđerli Baőkent Üniversitesi öđretmenlerime saygılarımı ve teőekkürlerimi sunarım. Yine alıőmamda desteklerini ve bana olan güvenlerini hiçbir zaman esirgemeyen ve her zaman yanımda olan, baőtta sevgili anneme ve aileme, dostlarıma teőekkürlerimi ve sevgilerimi sunarım. Son olarak her zaman arkamda olarak, bu alıőmamı sonulandırmam için beni her zaman cesaretlendiren sevgili Burcu Karakaya’ ya sonsuz teőekkürlerimi, sevgilerimi ve őükranlarımı sunuyorum. İyi ki varsınız.

Kadir ađrı GEZMEZ

AđUSTOS 2022

ANKARA

ÖZET

Kadir Çağrı GEZMEZ

BİR İLİN ELEKTRİK TÜKETİM VERİLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE ANALİZİ

Başkent Üniversitesi, Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2022

Elektrik dağıtım şirketleri, sahip oldukları abonelerine, elektriksel tüketimlerini “Piyasa Yönetim Sistemi” aracılığıyla bildirmekle yükümlüdür. Elektrik dağıtım şirketleri, ay sonu tüketim değerleri olmayan, yani okuma verisi bulunmayan tüketicilerine, tüketim değerlerini tahmin metotlarıyla bildirmektedirler.

Bu tezin amacı, Enerji Piyasası Düzenleme Kurumu’nun belirlemiş olduğu ve hala kullanılmakta olan tüketim tahminleme metodolojisinin yanı sıra makine öğrenmesi yöntemleri ile tahminleme yapmaktır. Bu çalışmada, makine öğrenmesi yöntemleri kullanılarak, doğrusal regresyon ve uzun-kısa süreli bellek (LSTM) yöntemleriyle, MATLAB ortamında analizler yapılmıştır. Başarı kriteri olarak Kök Ortalama Kare Hatası (Root Mean Square Error, RMSE), kriter olarak belirlenmiş ve kullanılan yöntemlerden en başarılı sonucu doğrusal regresyon analizi yöntemi sağlamıştır.

Bu kapsamda yapılan çalışmalar ile doğrusal regresyon, uzun-kısa süreli bellek ve Enerji Piyasası Düzenleme Kurumu’nun Tahminleme Metodolojisi yöntemlerinin karşılaştırması yapılmış olup, tutarlı ve başarılı sonuçlar elde edildiği gözlemlenmiştir.

ANAHTAR KELİMELER: Derin Öğrenme Algoritması, Yapay Zekâ, Yapay Sinir Ağı, Tüketim Tahminleme, Elektrik Tüketimi, Elektrik Dağıtım

ABSTRACT

Kadir Çağrı GEZMEZ

ANALYSIS OF A CITY'S ELECTRICITY CONSUMPTION DATA WITH MACHINE LEARNING METHODS

Baskent University, Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

2022

Electricity distribution companies are obliged to inform their subscribers about their electricity consumption through the “Market Management System”. Electricity distribution companies inform their consumers who do not have consumption values at the end of the month, that is, they do not have reading data, by estimating consumption values.

The aim of this thesis is to make estimations with machine learning methods as well as the consumption forecasting methodology determined by the Energy Market Regulatory Authority and which is still being used. In this study, analyses were performed using machine learning methods, linear regression and long-short-term memory (LSTM) methods in MATLAB environment. Root Mean Square Error (RMSE) method was determined as the success criterion and linear regression analysis method provided the most successful result of the methods used.

In this context, the studies of linear regression long short term memory and Energy Market Regulatory Authority's methodology, a comparison of estimation methods is made, and observed that consistent and successful results are obtained.

KEYWORDS: Deep Learning Algorithm, Artificial Intelligence, Artificial Neural Network, Consumption Forecasting, Electricity Consumption, Electricity Distribution

İÇİNDEKİLER

TEŞEKKÜR	i
ÖZET	ii
ABSTRACT.....	iii
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
SİMGELER VE KISALTMALAR.....	viii
1. GİRİŞ.....	1
1.1. Çalışmanın Konusu	1
1.2. Tez Çalışmasının Önemi	2
1.3. Literatür Araştırması.....	2
2. KURAMSAL TEMELLER	4
2.1. Elektriğin Tarihçesi.....	4
2.2. Türkiye ve Elektrik Üretimi.....	5
2.3. Elektriğin İletimi ve Dağıtımı	6
2.4. Türkiye Elektrik Dağıtım A.Ş (TEDAŞ) ve Dağıtım Şirketleri	7
2.5. Günümüzde Elektrik Tüketimi.....	8
2.6. EPDK Tahminleme Metodolojisi	9
3. MATERYAL VE METOT	13
3.1. Veri Seti	13
3.2. Yapay Zeka.....	14
3.2.1. Yapay Zeka' nın Tarihi.....	14
3.3. Makine Öğrenimi	16
3.4. Yapay Sinir Ağları.....	17
3.5. Derin Öğrenme	19
3.6. Regresyon Analizi.....	22
3.7. Yinelemeli Sinir Ağları (RNN)	26
3.8. Uzun-Kısa Süreli Bellek (LSTM).....	27
3.10. Veri Setinin Oluşturulması.....	33
3.11. Kök Ortalama Kare Hatası (RMSE).....	36

4. DENEYSEL ÇALIŞMA VE SONUÇLAR.....	37
5. SONUÇ	56
6. KAYNAKLAR.....	58

TABLULAR LİSTESİ

Sayfa

Tablo 3.1. Veri Setlerinin Aylara Göre Bölünmüş Hali – Örnek Yapı.....	13
Tablo 3.2. Veri Setleri Klasik Normalizasyon – Örnek Yapı.....	31
Tablo 3.3. Veri Setleri Maksimum Normalizasyon – Örnek Yapı.....	32
Tablo 3.4. Ev Aletlerinin 1 Saatlik Enerji Tüketimi (kWh).....	33
Tablo 4.1. A Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri.....	38
Tablo 4.2. A Veri Setinin LSTM Sonucundaki RMSE Değerleri.....	40
Tablo 4.3. A Veri Setinin Göre Regresyon ve LSTM/Regresyon Karşılaştırılması.....	41
Tablo 4.4. B Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri.....	43
Tablo 4.5. B Veri Setinin LSTM Sonucundaki RMSE Değerleri.....	44
Tablo 4.6. B Veri Setine Göre Regresyon ve LSTM/Regresyon Karşılaştırılması.....	45
Tablo 4.7. C Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri.....	47
Tablo 4.8. C Veri Setinin LSTM Sonucundaki RMSE Değerleri.....	48
Tablo 4.9. C Veri Setine Göre Regresyon ve LSTM/Regresyon Karşılaştırılması.....	49
Tablo 4.10. D Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri.....	51
Tablo 4.11. D Veri Setinin LSTM Sonucundaki RMSE Değerleri.....	52
Tablo 4.12. D Veri Setine Göre Regresyon ve LSTM/Regresyon Karşılaştırılması.....	53
Tablo 4.13. Regresyon Analizi – LSTM Analizi ve EPDK Tahminleme Metodolojisi Karşılaştırma Tablosu.....	54
Tablo 4.14. Regresyon Analizi – LSTM Analizi – Literatür ve EPDK Tahminleme Metodolojisi Başarı Yüzdesi Karşılaştırma Tablosu.....	55

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. Üretim,İletim ve Dağıtım Şebekeleri.....	6
Şekil 2.2. 2013 Yılı Türkiye Enterkonekte Şebeke Haritası.....	7
Şekil 2.3. Türkiye Elektrik Dağıtım Şirketleri Coğrafi Dağılımı Haritası.....	8
Şekil 2.4. Tahminleme Metodolojisi ‘ne dayanan Endeks-Zaman Eğrisi.....	10
Şekil 3.1. Yapay Zeka’ nın Gelişimi.....	15
Şekil 3.2. Gözetimli Makine Öğrenimi Modeli.....	16
Şekil 3.3. Gözetimsiz Makine Öğrenimi Modeli.....	17
Şekil 3.4. Biyolojik Sinir Hücresi.....	18
Şekil 3.5. Bir Sinir Hücresinin Matematiksel Modeli.....	18
Şekil 3.6. Yapay Sinir Ağı Yapısı.....	19
Şekil 3.7. Yapay Sinir Ağı Yapısı Örneği.....	19
Şekil 3.8. Derin Öğrenme Gelişimi.....	20
Şekil 3.9. Makine Öğrenmesi ve Derin Öğrenme Arasındaki Fark.....	21
Şekil 3.10. Regresyon Analizi	22
Şekil 3.11. Linear Regresyon.....	23
Şekil 3.12. Multiple Linear Regresyon.....	24
Şekil 3.13. Non-Linear Regresyon.....	25
Şekil 3.14. Regresyon Analizi – Underfitted / Overfitted.....	26
Şekil 3.15. Yinelemeli Sinir Ağı Diagramı.....	27
Şekil 3.16. LSTM Yapısal Diagramı.....	28
Şekil 3.17. Uzun-Kısa Süreli Bellek Yapısı-1.....	29
Şekil 3.18. Uzun-Kısa Süreli Bellek Yapısı-2.....	30
Şekil 4.1. Deneysel Çalışmaya Ait Blok Diagram Yapısı.....	37

SİMGELER VE KISALTMALAR

EPDK	Elektrik Piyasası Düzenleme Kurumu
TEDAŞ	Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
TEK	Türkiye Elektrik Kurumu
PYS	Piyasa Yönetim Sistemi
YSA	Yapay Sinir Ağları
KCETAŞ	Kayseri ve Civarı Elektrik Türk Anonim Şirketi
AI	Artificial Intelligence (Yapay Zeka)
RNN	Recurrent Neural Network (Tekrarlamalı Sinir Ağı)
LSTM	Long-Short Term Memory (Uzun-Kısa Süreli Bellek)
GRU	Gated Recurrent Units (Kapı Özyinelemeli Geçitler)
RMSE	Root Mean Square Error
BLSTM	Bidirectional LSTM (Çift Yönlü LSTM)

1. GİRİŞ

1.1.Çalışmanın Konusu

Elektrik enerjisi, hayatımızı kolaylaştıran en temel faktörlerden biridir. Günümüzde çeşitli şekillerde üretiliyor olsa da tüketilebilecek şekilde meskenlere kadar ulaşmaktadır. Dağıtım şirketleri sayesinde, meskenlere ulaşan elektrik enerjisinin, tüketilebilmesi için, meskenlerin, abonelik sahibi olması gerekmektedir. Elektrik dağıtım şirketlerinden alınan izinler ve aboneliği ifade eden numaralar sayesinde üretilen bu elektrik tüketilebilmektedir. Abonelerin kullandıkları elektrik tüketimleri sonucunda, aylık olarak tespit edilen tüketim değerleri, tüketicilere faturalandırılmaktadır. Bu tüketim değerleri, dağıtım şirketleri tarafından, abonelik sayaçlarından yapılan okumalar sayesinde belirlenir. Dağıtım şirketleri ise, perakende şirketleri aracılığıyla sahip oldukları abonelere ait, bir ayı kapsayan (1-30 gün periyodunda) tüketimlere göre elektrik tüketim faturası kesmektedir. Abonelik tüketim değeri, abonenin son endeksinden, bir önceki ay endeksinin farkının alınması ile elde edilir ve abonenin o aya ait ne kadar elektrik tüketiminin olduğunu gösterir.

Türkiye 'de bulunan dağıtım şirketleri, bazı bölgelerinde, sayaçlardan uzaktan okuma yapabilirken bazı bölgelerinde ise saha ortamında manuel şekilde okuma yapabilmektedir. Ancak ne şekilde gerçekleşirse gerçekleşsin ay sonu değerinin bilinmesi ve bunun akıbetinde de aylık tüketiminin belirlenmesi gerekmektedir. Her zaman sayaçlardan bir okuma veya doğru bir okuma gerçekleşmemektedir. Bu sebepten dolayı, tüketicilerin ay sonu endeks değerlerinin tahmin yoluyla belirlenebilmesi için, EPDK tarafından yayımlanan tahminleme yöntemi kullanılmaktadır.

Bu tahminleme yöntemine göre; tahmini yapılacak tarih ile en son okuma yapılan tarihin farkı alınmaktadır. Bu sonuç değeri güç değişim katsayısı, endeks ilerleme eğilimi ve mevsimsellik katsayısı ile çarpılarak, o aya ait bir tahmini tüketim değeri hesaplanmış olur. Ancak tahminlenen bu tüketim değerleri, her zaman doğru sonuçlar verememektedir. Belli sapmalara ve hata oranlarına maruz kalan bu yöntemin iyileştirilmesi için, çalışmalar gerçekleştirilmiştir.

Bu tez çalışmasında, EPDK 'nın yayımlanmış olduğu mevcut tahminleme yaklaşımına istinaden makine öğrenmesi yöntemleri kullanılarak daha iyi çözümler önerilmiştir. Bu amaçla, makine öğrenmesi algoritmaları yardımı ile tahminleme yapılmıştır. Abonelere ait elektrik tüketim değerlerinin, makine öğrenmesi yöntemleri ile başarımları, bir sonraki bölümlerde incelenmiştir.

1.2. Tez Çalışmasının Önemi

Bu tez çalışmasında 1.1. bölümde de bahsedilmiş olan, EPDK 'nın belirlemiş olduğu tahmin metodolojisinin yanı sıra, makine öğrenmesi algoritmaları ile daha doğru tüketim değerlerine yakınsama yapmak amaçlanmaktadır.

EPDK yayımlamış olduğu tahmin metodolojisini 01.01.2019 tarihine kadar zorunlu olarak kullanımını amaçlamış ve bu tarihten sonraki süreçlerde de inisiyatifi elektrik dağıtım şirketlerine bırakmıştır. 01.01.2019 tarihinden sonra ise dağıtım şirketleri ister kendi tahmin yöntemlerini kullanabilecek isterlerse de EPDK 'nın belirlemiş olduğu mevcut tahmin metodolojisini kullanmaya devam edebileceklerdir. Ancak kendi yöntemlerini kullanabilmeleri için EPDK' ya kendi yöntemlerini raporlamak zorundadırlar, onaylanması durumunda ise, ilgili bölgeleri için önerdikleri yöntemleri kullanabileceklerdir.

Bu tez çalışması sayesinde, tüketicilerin sayaçlarından okuma yapılamaması durumunda, gerçeğe daha yakın değerlerle tahminleme yapılabilecektir. Bu sayede, hem dağıtım şirketlerine ait, hem de abonelere ait tüketim belirleme hatası azaltılacaktır. Önerilen yöntemin EPDK' ya sunulması ve onaylanması taktirinde, dağıtım şirketlerince bir önceki paragrafta bahsedildiği üzere kullanılabilir.

1.3. Literatür Araştırması

Bu tez çalışmasının amacı, ay sonu elektriksel tüketim değeri belirlenemeyen tüketicilerin ay sonu tüketimlerini, EPDK 'nın yayımlamış olduğu tahminleme metodolojisine ek olarak farklı yöntemlerle belirlemek ve gerçeğe en yakın tüketim değerlerine göre hesaplamaktır.

Literatür araştırması sonucunda, elektrik tüketimi tahmini konusu üzerinde yoğunlaşıp farklı yöntemlerin kullanıldığı gözlemlenmiştir. Örnek olarak, kısa-orta ve uzun vadeli elektriksel tüketim tahminleri üzerinde çalışılmış ve yapay sinir ağları yöntemleri kullanılmıştır.

V. Ateş (2019) 'daki çalışmalarında "Türkiye'nin Kısa Dönemli Saatlik Bazda Elektrik Tüketiminin Yapay Zeka Teknikleri Kullanılarak Tahmin Edilmesi" üzerinde çalışmalar gerçekleştirmiştir. Bulanık Tahmin ile tahminleme yaparak, Karınca Kolonisi Algoritması ile optimizasyon gerçekleştirmiştir. Önerilen modellerin başarıları, MAPE yöntemi kullanılarak ölçülmüştür. [15][1]

E. Doruk (2019) çalışmalarında "Sakarya Bölgesi Hanehalkı Elektrik Tüketiminin Dinamik Lineer Model ile Tahmini" üzerinde çalışmalar gerçekleştirmiştir. Yöntem olarak, zaman serisi

yöntemlerinden ARIMA modelleri ve Dinamik Lineer Modeller ile çalışmıştır. 1 aylık veriler üzerinde çalışılmıştır (2017 Aralık). Ek olarak Kalman Filtresi uygulaması yapılmıştır. [16][2]

Y. Şahin (2020) çalışmalarında “Gelecek Dönemlere Ait Türkiye Elektrik Tüketimi Tahmininde Yapay Sinir Ağları Modelinin Kullanılması“ üzerinde çalışmalar gerçekleştirmiştir. Tahmin yöntemi olarak YSA modeli seçilmiştir. Oluşturulan ağın eğitimi için 1980-2017 yılları arasındaki veriler kullanılmış ve 2018 yılına ait Türkiye elektrik tüketim miktarı tahmin edilmeye çalışılmıştır. Tahmin eğerleri yüksek doğruluk ile performanslı sonuçların verdiği gözlemlenmiştir. [17][3]

T. Akman (2018) çalışmalarında “Yapay Zeka Modelleri Kullanarak Ankara Bölgesinin Kısa Dönem Elektrik Enerjisi Yük Tahmini” üzerinde çalışmıştır. Kısa dönem elektrik yük tahmini için YSA ve genetik algoritma tabanlı adaptif bir hibrid sistem modeli üzerinde çalışılmıştır. Geliştirilen modelin yük tahmini performansı ortalama mutlak yüzdesi hatası (MAPE) şeklinde hesaplanmıştır. [18][4]

Literatür araştırmaları arasında, bu tez çalışmasıyla benzer şekilde çalışmalar gerçekleştirmiş olan G. Özlü (2018), çalışmalarında “Yapay Arı Kolonisi Algoritması ile Kayseri ve Civarı Elektrik Tüketim Verilerinin Analizi” üzerinde çalışmıştır. Tez konusu itibarıyla, spesifik bir il için çalışmalar gerçekleştirerek, aynı problem üzerinde çalışmalar gerçekleştirmiştir. KCETAŞ (Kayseri ve Civarı Elektrik Türk Anonim Şirketi) bölgesi için, farklı bir tahminleme metodolojisi ile çalışılmış ve YSA ile Zaman Serisi tahminlemesi yapılmıştır. Ayrıca abonelere ait “aylık endeks” bilgileri kullanılmıştır. Yapay Arı Kolonisi optimizasyonu uygulanarak gözlemlenen bir başarı sağlanmıştır. YSA ve genetik algoritma temelli bir yöntemin mevcut EPDK tahminleme metodolojisinden daha iyi sonuçlar verdiği gözlemlenmiştir. [19][5]

2. KURAMSAL TEMELLER

2.1. Elektriğin Tarihçesi

Elektrik, atom altı parçacıklarının birbiriyle olan etkileşimleri sonucunda ortaya çıkan ve bir dizi fiziksel durum oluşturan enerji türüdür. Elektrik doğada pek çok farklı şekilde var olabilir. Örneğin, durgun (statik) elektrik, yıldırım ve şimşekler, elektromanyetik indüksiyon ve elektrik akımları elektriğin var olma biçimleridir.

Elektrik kavramının ilk olarak incelenmesi Milet'li Thales tarafından olduğu düşünülmektedir. MÖ 546-624 yılları arasında, Thales, doğa ile ilgili çalışmalar gerçekleştirirken kehribarın yüne sürtüldüğünde tüy ve saman gibi hafif nesnelere kendine doğru çektiğini gözlemlemiştir [1]. Tales' in Antik Yunan döneminde ilgilendiği bu gözlem bugün statik elektrik olarak adlandırılmaktadır.

“Kehribar” anlamına gelen elektron sözcüğü, Latince diline “electro” olarak geçmiştir. 1600 yılında W. Gilbert, “De Magnete” adlı eserinde electricus kelimesini “kehribar gibi cisimleri kendine çeken” anlamında kullanmıştır. 1634 yılında ise İngiliz Sir Thomas Browne tarafından ilk kez elektrik sözcüğü kullanılmıştır [1]. Alessandro Volta'nın yaptığı deneyler sonucunda da statik elektrik kavramına ek olarak akan elektrik keşfi başlamıştır. Bu keşifleri sonucunda Volta, ilk elektrik pilini ve bundan da ilk elektrik akımını elde etmeyi başarmıştır. [2]

“Elektrik Nedir?” sorusu her zaman merak konusu olmuş ve bu soru, modern atom teorisinin ortaya atılmasından sonra, günümüz dünyasında cevap bulabilmiştir. Elektrik akımı bugün şu şekilde açıklanabilir: Serbest elektronlar, rastgele ve serbestçe komşu atoma hareket edebilen elektronlar olarak tanımlanır. Hareketleri rastgele olduğundan dolayı, herhangi bir dış etkiye maruz kalmadıkları sürece, bir yöne hareket eden elektronların sayısının, zıt yöne hareket eden elektronların sayısına eşit kabul edilir. Ancak dış sebeplerden dolayı, iletkenin zıt yönlerinde “elektron sayısı” farklılıkları oluşabilir ve bu iletken içindeki serbest elektronlar elektrostatik kuvvete maruz kalırlar. Bunlar pozitif ucuna (elektron eksikliği olan uç) doğru çekme kuvveti ve negatif uçtan (elektron fazlalığı olan uç) öteye doğru bir itme kuvvetidir. Bu itme ve çekme kuvveti bize elektrik akımı tanımını yapabileme imkanı sağlar ve birim zaman içindeki akan ortalama elektron miktarı da elektrik akımının birimini oluşturur. [3]

Michael Faraday, 19. Yüzyılın başlarında, büyük gözlemler ve araştırmalar sayesinde elektrik üretimi ile ilgili büyük keşiflerde bulunmuştur. Elektrik, bakır gibi iletken bir telin manyetik bir alan içinde hareket ettirilmesi ile üretilebileceği teorisini ortaya atan ve deneylerle bunu ispatlayan Faraday, zaman içinde gerçekleştirdiği çalışmalar itibariyle elektrik jeneratörü tanımlamasını yapmıştır. Bugün elektrik jeneratörünün mekanik etki ile elektrik enerjisi üretebilmesi için birçok kaynak kullanılmaktadır. Doğal gaz, kömür, uranyum (nükleer santraller de), petrol bu kaynaklardan bazılarıdır. Temel amaç, suyu buhara çevirecek bir yakıtın olması ve ısı enerjisini hareket enerjisine çevirerek motorların mekanik dönüşünü gerçekleştirebilmesidir. Bu sayede meskenlerin, işyerlerinin ve endüstriyel fabrikaların, ihtiyaç duydukları elektrik enerjisi kullanabilecek duruma gelir [4].

2.2.Türkiye ve Elektrik Üretimi

1878 yılında ilk defa, elektrik enerjisi günlük hayata dahil olmuş ve bu tarihi takiben elektrik üretimi için 1882 yılında ilk elektrik santrali inşa edilmiştir. Türkiye 'de ilk elektrik üretimi, 1902 yılında Tarsus iline tesis edilen 2 kW gücündeki küçük bir su türbini ile gerçekleşmiştir ve elektrik altyapısı 1906 yılında kurulmaya başlanmıştır. 1910 yılına gelindiğinde, Tarsus Belediyesi, şehrin elektrik alt yapısını kurarak devreye almıştır. Kurulan bu hidroelektrik santrali şehre iki kilometre uzaklıkta bulunan, Berdan nehrinin hemen yanına kurulmuştur. Bu tesis, 75 kW elektrik üretebilmekteydi. Günümüzdeki kadar profesyonel şekilde gerçekleşme de aynı yöntemle, önce yüksek sonra da alçak gerilim ile abonelere elektrik iletimi sağlanmıştır. İlk zamanlar da elektrik altyapısının bütün idaresi Tarsus Belediye' sine ait olsa da sonraki yıllarda, bu elektriksel altyapı yönetimi, 1922/1923' de, Tarsus Elektrik Komandit Şirketi'ne devredilmiştir. Elektrik ücretlerinde ise, abonelerin niteliğine göre farklı tarifeler uygulanmıştır. Postane, cami, okul ve kışla gibi resmî kurumlardan mevcut ücretin yarısı alınmıştır. 1914 yılında Silahtarağa Termik Santrali hizmete girmiştir. 14 Şubat 1914' de açılan bu tesis, içindeki elektriksel altyapı ve şalt malzemelerinin, ekonomik ömrünü tamamlamasına kadar, yani 1983 yılına kadar hizmet vermiştir. [5]


1923 yılında kurulan Türkiye Cumhuriyeti'ne kadar kurulu güç 33 MW iken, bugün 1228 kat artarak 40.519 MW' a ulaşmıştır. 1923 yılında 45 milyon kWh olan elektrik üretimi ise 3904 kat artarak 175,69 milyar kWh' a kadar ulaşmıştır. [6]

01.10.2021 tarihi incelendiği zaman, Türkiye Cumhuriyeti 'ne ait elektrik enerjisi üretimi 275.588 GWh iken, ekim ayı sonu toplam elektrik enerjisinin kurulu gücü, 98.789 MW 'dır. [7]

2.3.Elektriğin İletimi ve Dağıtımı

Elektriğin iletimi ve dağıtımı, elektriğin üretilmesinden sonra, son kullanıcıya kadar ulaştırılmasıdır. Bu süreç boyunca üç kapsam bulunmaktadır. Bunlar; üretim, iletim ve dağıtım kapsamlarından oluşmaktadır. Elektrik enerjisinin, üretimden tüketime doğru iletilerek dağıtılması gerekmektedir.

Santrallerde üretilen elektrik enerjisinin, meskenlerde ve iş yerlerinde kullanılabilmesi için, iletim ve dağıtım aşamalarının koordineli bir çalışma gerçekleştirmesi gerekmektedir. Üretilen elektrik enerjisi ilk üretildiğinde yükseltici transformatörler ile çok yüksek gerilim seviyelerine dönüştürülür. Bunun sebebi elektrik enerjisinin uzun mesafelerdeki kaybını engellemektir. Bu yüksek gerilimin taşınmasında iletim şebekeleri görev almaktadır. Daha sonra ise iletim şebekeleriyle taşınan yüksek gerilimin, tüketicinin kullanabileceği seviyeye indirilmesi gerekmektedir. Gerilimin bu seviyeye indirilmesi işlemi ise indirici transformatör merkezleri sağlamaktadır. Gerilimin kullanılabilir seviyeye düşürülmesinden sonra ise iletim hatlarıyla tekrar taşınması gerçekleştirilir. Dağıtım transformatörleri ve dağıtım şebekesi sayesinde ise meskenlere ve iş yerlerine kadar iletimi gerçekleştirilir.



Şekil 2.1. Üretim,İletim ve Dağıtım Şebekeleri [4]



Şekil 2.2. 2013 Yılı Türkiye Enterkonnekte Şebeke Haritası [8]

2.4. Türkiye Elektrik Dağıtım A.Ş (TEDAŞ) ve Dağıtım Şirketleri

15 Temmuz 1970 tarihinde çıkarılan kanunla, Türkiye Cumhuriyeti' ne ait elektriğin; iletimi, dağıtımı, üretimi ve ticaretini yapmak amacıyla, Türkiye Elektrik Kurumu (TEK) kuruldu. 12 Ağustos 1993 tarihinde ise, Türkiye Elektrik Üretim İletim A.Ş. (TEAŞ) ve Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) adı altında, iki ayrı devlet kurumu olarak yeniden düzenlendi. 1994' de, yapılanmalarının tamamlanmasıyla beraber görev dağılımları gerçekleştirilerek, üretim ve iletim hizmetleri TEAŞ' a, dağıtım hizmetleri ise TEDAŞ' a verildi. [9]

Elektriğin dağıtım ve perakende satışının yapılabilmesi adına, bölgesel düzenlemelerin de tamamlanmasıyla beraber, 02.04.2004 tarihi ve 2004/22 sayılı Özelleştirme Yüksek Kurulu Kararı ile TEDAŞ 'ı özelleştirme çalışmalarına başlanmıştır. Dağıtım bölgeleri yeniden çizilip haritalandırılarak, Türkiye Cumhuriyeti, 21 dağıtım bölgesine ayrılmıştır. 31.08.2013 tarihiyle de TEDAŞ 'ın özelleştirilme çalışmaları tamamlanarak, 21 dağıtım bölgesine ayrılması ve hisse devirleri tamamlanmıştır [10].

Günümüz itibariyle, Türkiye Cumhuriyeti 'nde 21 dağıtım şirketi bulunmaktadır. Elektrik dağıtım şirketlerinin mülkiyeti ve denetimi TEDAŞ' a bağlıdır. Elektrik dağıtım şirketi; belirlenmiş bir bölgede, elektrik dağıtım hizmet hakkını, EPDK tarafından verilen lisans ile devralan tüzel kişiliktir. Dağıtım şirketleri, lisansında belirtilen bölgedeki dağıtım sistemini, elektrik enerjisi üretimini, elektrik satışındaki rekabet ortamını düzenlemekle yükümlüdür. Ayrıca mevcut elektrik tesislerini yenilemek, kapasite ikamesini sağlamak ve kapasite artırım yatırımlarını oluşturmak

zorundadır. Son olarak, dağıtım sistemine bağlı veya bağlanacak olan tüm dağıtım sistemi kullanıcılarına, mevzuat hükümleri doğrultusunda, ayırım gözetmeksizin, hizmet sunmakla yükümlüdür. [11]



Şekil 2.3. Türkiye Elektrik Dağıtım Şirketleri - Coğrafi Dağılımı Haritası [12]

2.5.Günümüzde Elektrik Tüketimi

Günümüzde elektrik enerjisine ihtiyaç duyan tüzel veya gerçek kişiler, bölgesinde bulunan dağıtım şirketine yazılı dilekçeyle veya e-Devlet kapısı aracılığıyla başvuruda bulunur. Başvuru sonrasında ise, onaylanması halinde, bu başvuru sahipleri, başvurmuş oldukları dağıtım şirketinin tüketicisi yani “abonesi” olmuş olur. Bunun akabinde ise, bağlı oldukları dağıtım şirketleri tarafından abonelik numaralarına sahip olurlar.

Abonelerin elektrik sayaçları, en az 25 en fazla 35 günlük dönemlerle dağıtım şirketi tarafından her takvim ayında bir defa okunur. Bu okuma, aylık okuma olarak değerlendirilir [13]. Aylık tüketim miktarının belirlenmesi ilk olarak, okuma yapılacak aya ait son okuma tarihindeki, sayaçta gözlemlenen endeks değerine göre belirlenir. Bu okuma son endeks değeri olarak tanımlanır. Gözlemlenmiş bu endeks değeri, sayacın mekaniksel olarak (veya dijital olarak) ileri yöndeki hareketi sonucunda belirlenir. Bunun akabinde son okunan endeks değerinden, bir önceki aya ait endeks değerinin çıkarılmasıyla o aya ait tüketim miktarı belirlenmiş olur.

Aboneye ait okuma bilgileri (tüketim değerleri, okuma tarihi, vb.), dağıtım şirketleri tarafından, PYS (Piyasa Yönetim Sistemi) sistemi olarak adlandırılan, sisteme kaydedilir. Dağıtım şirketleri, abone sayaçlarından yaptıkları okuma bilgisi sonucunda ortaya çıkan fatura tutarlarını, abonelerine bildirmekle yükümlüdür. Bu bildiriye, (abone tarafından talep edilmesi doğrultusunda) elektronik ortamda, e-posta yoluyla veya kısa mesaj yoluyla bildirebilir [13].

2.6.EPDK Tahminleme Metodolojisi

Günümüzde her tüketici, PYS sistemi sayesinde son ayki endeks değeri bilgisine ulaşabilir. Çünkü ay sonu endeks değerinin, tüketiciye bildirilmesi zorunludur. Ancak tüketim endeks değeri, mücbir sebeplerden dolayı okunamamış abonenin son aya ait endeks değeri, EPDK tarafından yayımlanan, Tahmini Tüketim Değeri Belirleme Metodolojisi çerçevesinde belirlenerek, PYS sistemi aracılığıyla tüketiciye bildirilir.

Reaktif tüketim değerinin belirlenmesinde kullanılmayıp, sadece aktif tüketim değerlerinin belirlenmesinde kullanılan bu metodolojinin amacı; bir önceki okuma döneminde, abone sayacından okuma gerçekleşmemesi sonucunda, tahmini bir tüketim ortaya çıkarabilmektir. [14]

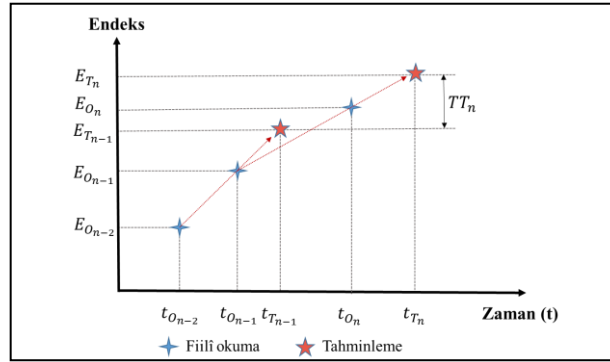
Tahmini tüketim değerinin hesaplanması, aşamalı olarak şu şekilde belirlenmektedir;

- E_{T_n} : Tahmin edilecek endeks değerini,
- $E_{T_{n-1}}$: Bir önceki döneme ait endeks değerini,
- E_{O_n} : Aboneye ait okuma yapılmış güncel tarihli, gerçek endeks değerini,
- $E_{O_{n-1}}$: Aboneye ait okuma yapılmış bir önceki güncel tarihli, bir önceki gerçek endeks değerini,
- t_{O_n} : Gerçek okumanın yapılabildiği tarihi (gün),
- $t_{O_{n-1}}$: Gerçek okumanın yapılabildiği bir önceki tarihi (gün),
- t_{T_n} : Tahmin yapılacak tarihi (gün),
- TT_n : Tahmin edilecek güne ait tahmini tüketim değerini (kWh),
- ζ_E : Endeks çarpan katsayısı (kWh),
- GD_n : Tahmin edilecek tarih ile bir önceki tarih arasındaki bağlantı gücündeki değişim oranını (değişim varsa),
- M_t : Mevsimsellik katsayısı (Dağıtım şirketinin inisiyatifine bırakılmıştır, 1 kabul edilebilir.)
- BG_n : Bağlantı gücünü (kW),
- BG_{n-1} : Bir önceki bağlantı gücünü (kW)

$$E_{T_n} = GD_n * M_t * \frac{E_{O_n} - E_{O_{n-1}}}{t_{O_n} - t_{O_{n-1}}} * (t_{T_n} - t_{O_{n-1}}) + E_{O_{n-1}} \quad (2.1)$$

$$TT_n = \zeta_E * (E_{t_n} - E_{T_{n-1}}) \quad (2.2)$$

$$GD_n = \frac{BG_n}{BG_{n-1}} \quad (2.3)$$



Şekil 2.4. Tahminleme Metodolojisine Dayanan Endeks-Zaman Eğrisi [14]

Tahmin değerinin hesaplanması sonucunda; tahmin edilen tarihteki tüketim değeri, bir önceki fatura dönemi tahmini endeks değerinden küçükse ($E_{T_n} < E_{T_{n-1}}$) geçmiş dönemdeki tüketim değeri ile aynı kabul edilir ($E_{T_n} = E_{T_{n-1}}$). Yani o aya ait aylık tüketim değeri sıfır olarak kabul edilir.

Mevsimsellik katsayısı değeri için herhangi spesifik değer olarak bulunmamaktadır. Bu değer elektrik dağıtım şirketinin insiyatifine bırakılmıştır.

Eğer ki bir abonenin geçmiş tüketim değeri bulunmuyorsa, aynı lokasyonda bulunan, aynı tüketici tipine sahip (mesken, iş yeri, fabrika, vb.) ve aynı trafo gücüne sahip (yaklaşık olarak) olan bir başka abonenin tüketimi baz alınabilir.

İlgili elektrik dağıtım şirketi, hesaplanan tahmini tüketim değerinin metodolojiye uygun olarak hazırlandığını, talep edilmesi halinde kurumuna, tedarikçisine detaylı açıklamalı olarak ibraz edebilmelidir. [14]

EPDK 'nın yayımlamış olduğu tahminleme meteorolojisi formülleri ((1) - (2) - (3) numaralı formüller) şu şekilde de sadeleştirilebilir;

$$E_{T_n} = GD_n * M_n * tg\alpha_n * (TT_n - TO_{n-1}) + EO_{n-1} \quad (2.4)$$

- **GD_n**: (4) numaralı formüle göre: Bağlantı gücü değişimi olarak tanımlanan “**GD_n**” değeri, tahmin edilecek tarih ile bir önceki tarih arasındaki bağlantı gücündeki değişim oranını temsil eder. Yani tüketim değeri tahmin edilecek abonenin bağlı olduğu trafonun, okuma yapılacak tarih ile en son okuması yapılan gerçek ve güncel tarihinin arasındaki süre zarfı boyunca, bağlı olduğu o trafonun güç değişimi gerçekleşmemişse, “**GD_n**” değeri “**1**” kabul edilebilir.
- **M_n**: (4) numaralı formüle göre: Mevsimsellik değişimi kat sayısı olarak tanımlanan “**M_n**” değeri için herhangi bir sabit değer bulunmamaktadır. Bu değer, tüketim değeri tahmin edilecek abonenin bağlı olduğu dağıtım şirketinin insiyatifine bırakılmıştır ve genelde “**1**” kabul edilir. Ancak mevsimsellik değerinin formülde hesaba katılması, tahminleme işleminin, gerçek tüketim değerine daha yakın sonuç elde edilmesine sebebiyet verir. Ayrıca mevsimsellik katsayısı değeri hesaplanabilmesi için, tahmini tüketimi bulunacak abonenin son 3 yıla ait abone tüketim verilerinin bulunması gerekmektedir.

Örnek olarak herhangi bir abonenin, Nisan 2021 tarihindeki mevsimsellik katsayısı oranı;

$$M_{NİSAN2021} = ([2020 \text{ Nisan} / 2020 \text{ Mart}] + [2019 \text{ Nisan} / 2019 \text{ Mart}])/2 \quad (2.5)$$

Şeklinde hesaplanmaktadır.

- **tga_n**: (4) numaralı formüle göre: Günlük endeks ilerleme değeri olarak tanımlanan “**tgan**” değeri, tüketim tahmini yapılacak aboneye ait okuma yapılmış en güncel tarihli gerçek endeks değerinden, aboneye ait okuma yapılmış bir önceki güncel tarihli gerçek endeks değerinin farkının alınmasından sonra, bu iki tarihin fark değerine bölünmesiyle hesaplanmaktadır. Yani günlük endeks ilerleme değerinin 2021 Nisan tarihi için değeri;

$$tga_{NİSAN2021} = [(2021 \text{ Mart} - 2021 \text{ Şubat}) / (31.03.2021 - 28.02.2021)] \quad (2.6)$$

Şeklinde hesaplanmaktadır.

- **TTn:** (4) numaralı formüle göre: Tahminleme yapılacak tarih değeridir. Yani örnek olan 2021 Nisan ayı için, 30.04.2021 tarihidir.
- **TOn:** (4) numaralı formüle göre: Sayacın saha ortamında veya uzaktan şekilde okunabildiği en güncel tarihtir. Yani 30.04.2021 tarihi için, 31.03.2021 tarih değeridir.
- **TOn-1:** (4) numaralı formüle göre: Sayacın saha ortamında veya uzaktan şekilde okunabildiği en güncel tarihten bir önceki okuması yapılabilen endeks tarihidir. Yani 31.04.2021 tarihi için, 28.02.2021 tarih değeridir.
- **EOn-1:** (4) numaralı formüle göre: Tahmini tüketimi hesaplanacak olan aboneye ait, tahmin yapılacak tarihe göre en güncel okuma yapılan tarihten bir önceki okuma yapılabilen gerçek tüketim değeridir. Örnek olarak ele alınan 2021 Nisan tarihi için 28.02.2021 tarihindeki endeks değeridir.

3. MATERYAL VE METOT

3.1. Veri Seti

Bu çalışmada veri setimiz, özel bir ile bağlı olan, elektrik dağıtım şirketinin geçmiş yıllara ait verilerinden oluşmaktadır. Veriler, 2020 ve 2021 yıllarına dair okuma bilgilerine göre oluşturulmuştur. Güncel olarak, abonelere ait okumalar günümüzde de aylık olarak yapıldığından dolayı, veri seti de 12 ‘şer aylara bölünerek oluşturulmuştur.

Toplamda 2 yıl içeren ve aylara göre bölünmüş olan veri seti, bağlı olduğu trafoya ait, o ay ki son tüketim değerini barındırmaktadır. Toplamda 90 adet trafo ve bu 90 adet trafoya bağlı olan 30.930 aboneden veri alınmıştır. Örnek olarak gözlemlenebilmesi adına, rastgele değerlere göre oluşturulmuş ve rastgele aylara göre bölünmüş Tablo-1 yapısı gözlemlenebilir.

Tablo 3.1. Veri Setlerinin Aylara Göre Bölünmüş Hali – Örnek Yapı

Abone Numarası	Ocak/2020 (kWh)	Şubat/2020 (kWh)	Mart/2020 (kWh)	Haziran/2021 (kWh)	Temmuz/2021 (kWh)	Ağustos/2021 (kWh)
1	162	107	173	274	163	244
2	103	144	123	168	207	210
3	321	186	235	362	215	204
4	260	48	102	139	95	155
5	210	131	198	177	175	190
6	29	0	16	48	33	26
7	220	98	149	129	107	95
8	172	99	178	167	145	198
9	76	60	90	71	76	100
10	276	114	178	135	141	293
11	91	50	98	67	110	38

Doğrudan kullanılan verilerin, hata oranını yükselttiği ve performansı olumsuz etkilediği, çalışmalar sonucunda ortaya çıkmıştır. Bu sebeple, verilerin daha performanslı çalışabilmesi adına, iki normalizasyon yöntemiyle normalize edilerek “0-1” değerlerine dönüştürülmesi işlemi gerçekleştirilmiştir. İlk yöntem klasik normalizasyon yöntemi ile verilerin yeniden yapılandırılması üzerine dayanmaktadır, ikinci yöntem ise maksimum değere göre normalizasyon işlemi ile veri setinin tekrar yapılandırılmasına dayanmaktadır.

3.2.Yapay Zeka

Yapay zeka, insan zekasını taklit edebilen ve topladığı yeni bilgilerle kendini aşamalı olarak geliştirebilen, iyileştiren, sistemler anlamına gelir. Makinelerin geçmiş verilerden yeni tecrübeler edinebilmesi ve yeni bilgilere uyum sağlamasını, aynı zamanda da kendini geliştirebilmesine olanak sağlar. Bugün bilinen otonom araçlar, satranç oynayan bilgisayarlar, derin öğrenme ve yapay zekaya dayanmaktadır. Bu teknolojileri kullanarak bilgisayarlar, büyük miktarda veri işleyerek ve verilerdeki kalıpları analiz ederek, ilerleme kaydederek kendini eğitebilir.

3.2.1. Yapay Zeka' nın Tarihi

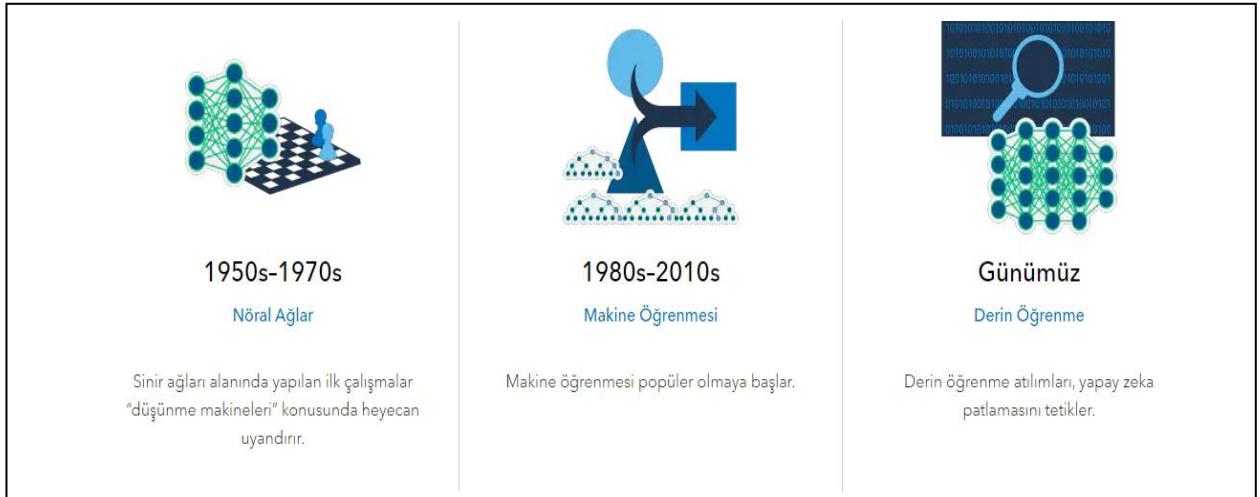
“Yapay İnsan” olgusunun yaklaşımı, yapay zeka tarihindeki ilk hareketliliklerden sayılmaktadır ve bu olgu Eski Yunan Mitolojisine kadar dayanmaktadır. Bu olgunun yapay zeka ile bağdaştırılmasının en temel nedeni mitolojiye göre, mitolojide bahsedilen Daedalus' un (eli her sanata yatkın olan kişilere verilen isimdir.) yapay insan oluşturma arzusu örnek verilebilir. Bu olgu göstermektedir ki, yapay zeka aslında tüm zamanlarda bahsedilen bir kavramdır. Ancak somut adımlara, 19. Yüzyılın sonlarında ve 20. Yüzyılın başlarında rastlanmaktadır. Yapay zeka için 1884 yılı kritik bir dönem olarak kabul edilmektedir. 1884 yılında, C.Babbage, makinelerin bir insanın yapabileceği yetkinliklere sahip olabilmesi adına, makineler üzerinde belli araştırmalar ve çalışmalar gerçekleştirmiştir. Teknolojik yetersizlik ve dönemin şartlarından kaynaklı olarak bu çalışmaların sonucu, makinelerin insan zekası kadar zeki davranışlar sergilemeyeceğine kanaatinde olmuştur. Ancak tarihsel olarak 20. Yüzyıl'a yani 1940 yılına geldiği zaman, bilgisayarların kullanımının artmasıyla beraber (üretimiyle beraber), gerçek yapay zeka kavramı yavaş yavaş oluşmaya başlanmıştır. [20]

Yapay zeka 'nın kurucusu olarak isimlendirilen Alan Turing, günümüz makinelerinin ve bilgisayarının bu denli gelişime maruz kalmasının mucididir. 1950 yılında “Hesaplamalı Makineler ve Zeka” adlı makalede, Alan Turing tarafından kaleme alınmış olan “Turing Testi”, yapay zekanın gelecekte ne kadar gelişeceğinin bir kanıtı niteliğindedir. Bu teste göre bir makine, bir insanla birlikte, sorgulayıcı sıfatına sahip bir gönüllü deneğin görüş alanı dışında bir yerde gizlenir. Sorgulayıcı, bir takım sorular sorar, makine ve insan bu sorulara cevap verir. Ancak bu cevaplar ne sesli ne de görsel şekilde gerçekleşmektedir, bunun yerine bir klavye sisteminde yazılı şekilde sorgulayıcıya bir ekranda gösterilmektedir. Sorgulayıcıyla, bu soru-cevap oturumu

sayesinde elde ettiği bilgiler dışında herhangi bir bilgi paylaşılmaz. Sorgulayıcının bir süre sonra kesin olarak insanı saptayamadığı durumda ise makine Turing Testin ‘ni geçmiş sayılır. [20][21]

Yapay zekanın tarihteki yerini, günümüz tanımlamalarıyla, resmi olarak aldığı zaman dilimi 1950-1960 yıllarına dayanmaktadır. 1956 yılında Dartmouth Konferansında yapay zeka ismi ilk kez ortaya atılmıştır ve bu isim J. McCarthy tarafından dile getirilmiştir. LISP dili de (yani yapay zeka programlamak için ilk defa özel olarak hazırlanan programlama dili) yine McCarthy tarafından, 1957 yılında geliştirilmiştir. LISP dilinin en ilgi çekici ve avantajlı kısmı ise cümle ve kurallarla ilerleme kaydedebilmesidir. Uzun yıllar boyunca da yapay zeka, LISP programlama dili sayesinde programlanabilmiştir. [20][21]

1960 ‘lara gelindiğinde ise ABD Savunma Bakanlığı bu yeni ve popüler olan teknolojiye dikkatlerini çevirerek çalışmalarına başlamıştır. Bu çalışmaların neticelerine bakıldığı zaman, türkçeye çevrilmiş haliyle “Savunma İleri Araştırma Projeleri Ajansı” olan DARPA, 1970’lerde sokak haritalama projelerini yapay zeka ile gelişimini sağlamıştır. DARPA, 2003 yılında, günümüzdeki akıllı telefonlarımızda asistan olarak kullandığımız; Siri, Alexa veya Cortana'nın kullanılmaya başlanmasından önce akıllı kişisel asistanlar geliştirmiştir. DARPA ‘nın bu süreçte gerçekleştirdiği çalışmalar günümüzdeki yapay zeka kavramının yerine oturmasında büyük rol oynamıştır . [21]



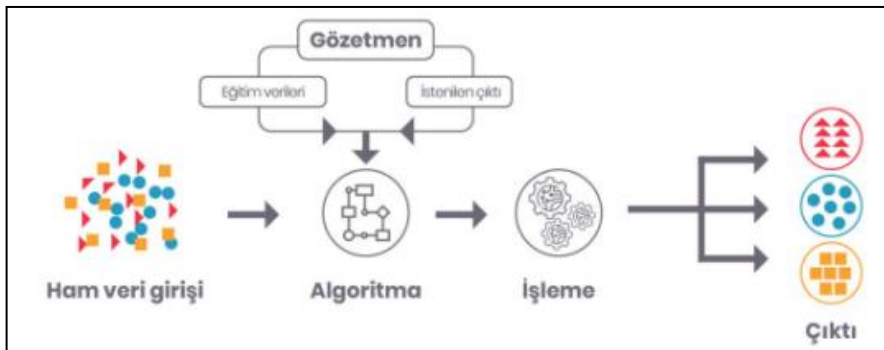
Şekil 3.1. Yapay Zeka’ nın Gelişimi [21]

3.3.Makine Öğrenimi

Bir yapay zeka tekniği olarak da tanımlanabilecek olan makine öğrenmesi, insan zekasını taklit edebilmesi ile bilinmektedir. İnsan zekasını taklit edebilmesi tanımını daha detaylı olarak şu şekilde tanımlayabiliriz ki; makine öğrenmesi doğruluğunu arttırabilmek için kendini kademeli olarak geliştirebilir. İnsanların kendi doğruluklarını arttırabilmeleri için tecrübe elde edebilmesi gibi, makine öğrenmesi de kendi doğruluğunu insanlar gibi deneyimleriyle arttırabilmektedir. Algoritmalarla eğitim gerçekleştirerek, hangi veriler ile çalışacağını algılar ve tahminleme işlemlerini gerçekleştirebilir. Bu tahminlemeler sayesinde deneyim kazanır ve edindiği deneyimlerinden yararlanarak doğruluklarını artırma yoluna gider. Bu algoritmaların daha performanslı çalışabilmesi için, makine öğrenmesine düzenli olarak yeni veriler empoze edilmesi ve deneyimlerini arttırılması hedeflenir. Bu sayede tahminleme, sınıflandırma veya kümeleme işlemleri gerçekleştirerek çeşitli amaçlarda performanslı başarılar sağlamış olur. [22]

Makine öğrenimi gözetimli, gözetimsiz ve takviyeli öğrenme olarak üç ana başlıkta incelenebilir;

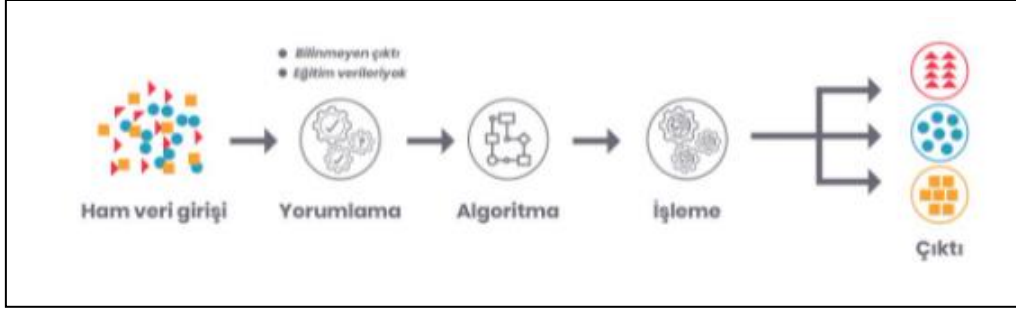
Gözetimli öğrenme, daha önceden varolan bir veri kümesiyle çalışır ve bu veri kümesi eğitim aşamasında kullanılır. Bu eğitimler sonucunda deneyim kazanan makine öğrenimi algoritması istenilen tahminleme yöntemi için kullanılabilir. En çok kullanılan algoritmalar; karar ağaçları, lineer regresyon, destek vektör makineleri ve lojistik regresyondur.



Şekil 3.2 Gözetimli Makine Öğrenimi Modeli [22]

Gözetimsiz öğrenme de ise, gözetimli öğrenmedeki gibi önceden kullanılacak bir veri seti olmadığından, öncesinde bir eğitim gerçekleşmez. Eğitim için kullanılacak bir veri seti olmadığı için, algoritma kendi deneyimlerini oluşturur, süreç içerisinde de daha çok deneyim kazanır ve

bunun akıbetinde tahminlerde bulunmaya başlar. Kümeleme ve boyut indirgeme, gözetimsiz öğrenme algoritmalarındandır.



Şekil 3.3. Gözetimsiz Makine Öğrenimi Modeli [22]


Takviyeli öğrenme yönteminde ise deneme yanılma yöntemi kullanılır. Programcı makinenin uyması gereken kuralları belirler ancak çözüme nasıl ulaşacağı bilgisini vermeyerek, programın deneme yanılma yoluyla sonuca ulaşmasını bekler. Denemeleri rastgele gerçekleştirerek, başarı yüzdesini en üst seviyeye çıkarmak, modele bağlı gelişim gösterebilmektedir. Makine yeni aksiyonlar vererek sonuçlarını gözlemler ve en doğru yola bu denemeler ve tecrübeler ile ulaşır.

3.4.Yapay Sinir Ağları


Yapay sinir ağlarını (YSA) anlayabilmek için öncelikle biyolojik sinir ağının yapısının bilinmesi gerekmektedir. İnsan beynindeki biyolojik sinir ağlarından örnek alınarak tasarlanan yapay sinir ağları da aynen biyolojik sinir ağları gibi nöronlardan oluşur. Biyolojik sinir ağlarında bilgi işleme ve analiz etme görevi üstlenen nöronlar, yapay sinir ağlarında da aynı görevi üstlenmektedir. Yaklaşık olarak beynimizde 200 milyar adet nöron olduğu saptanmaktadır ve bu nöronların hepsi birbiriyle iletişim halinde olup, bilgi alışverişi içindedir. İnsanlarda bulunan biyolojik sinir hücresi çekirdek, aksonlardan ve diğer yapılardan meydana gelmektedir. Aksonlarını amacı elektriksel uyarıları başka sinir hücrelerine iletebilmektir. [25]

Biyolojik sinir ağları öğrenme-hatırlama ve genelleme prensipleri ile çalışır. Yapay sinir ağları tasarlanırken biyolojik sinir ağlarından örnek alınarak tasarlanmıştır. Bu tasarıma göre aynen biyolojik sinir ağında olduğu gibi, öğrenme ile yeni bilgileri türeterek, bu türetilen bilgilerden de yeni bilgiler oluşturur ve yeni yetenekleri açığa çıkarır. Bu süreci tek başına yönetir ve bunun için dışarıdan ayrıca yardım almaz. yapay sinir ağlarında yeni bilgiyi özümseyerek

çalışabilme işlemi yeni örnekler kullanılarak oluşturulur ve bu prosesin gerçekleşmesi sırasında kurallar konularak uyması gereken adımlar belirtilir. Yapay sinir ağları genel olarak sınıflandırma, tahminleme, kontrol, veri ilişkilendirme ve filtreleme gibi alanlarda aktif olarak kullanılır. [25]



Şekil 3.4. Biyolojik Sinir Hücresi [26]




Şekil 3.5. Bir Sinir Hücresinin Matematiksel Modeli [25]

Aksonlar gibi ayrıca bulunan bir yapı da Dentritlerdir. Nöronlardan alınan elektrokimyasal uyarımın hücre gövdesi olan somaya iletilmesini sağlayan yapı denir. Birbiriyle iletişime girecek olan iki nöron arasındaki bilgi alışverişi bu elektriksel yapı ile sinapslar sayesinde dentritlere ulaşır. [25]


Dentrit yapısı boyunca nitelikli bilgi olarak adlandıracağımız ağırlıklarımız mevcuttur ve sembol olarak w_0 'dır. Ayrıca bir başka nöronun dentrit yapısından almış olduğumuz giriş değerimiz x_0 vardır. Giriş değerimiz olan x_0 , dentritteki ağırlığımız w_0 çarpıldıktan sonra $w_0 x_0$ olarak sinir hücresine iletilir. Tüm dentritlerden gelen yeni bilgiler ağırlık katsayısıyla çarpılarak toplanır. Daha sonra ise bir bias (b) ile işleme girerek (toplanarak) aktivasyon fonksiyonundan geçirilir ve çıkışa aktarılır. Çıkışa aktarılmış olan bu bilgi, nihai sonuç olacağı gibi bir başka

nöronla iletişime girmek için oluşmuş olan yeni bilgi de olabilir. Özetle, matematiksel olarak ağırlıklarımız olan w_0 ile giriş değerlerimiz x_0 çarpılır ve bu sonuca ilave olarak bir bias eklenir. Yapay sinir ağları algoritmasının da temel işlemi ve mantığı w_0 ve bias parametrelerinin analizini yapabilmektir. [25]

Bir yapay sinir ağı beş bölümden oluştuğu gibi üç de ana katmandan oluşur. Öncelikli olarak beş bölümümüz; girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılarıdır. Üç ana katmanımız ise; giriş katmanı, gizli katmanlar ve çıkış katmanıdır. Veri girişi, giriş katmanından yapıya dahil olur. Sonrasında bu veriler gizli katmanda işlenerek çıktı katmanına iletilir.



Şekil 3.6. Yapay Sinir Ağı Yapısı [27]



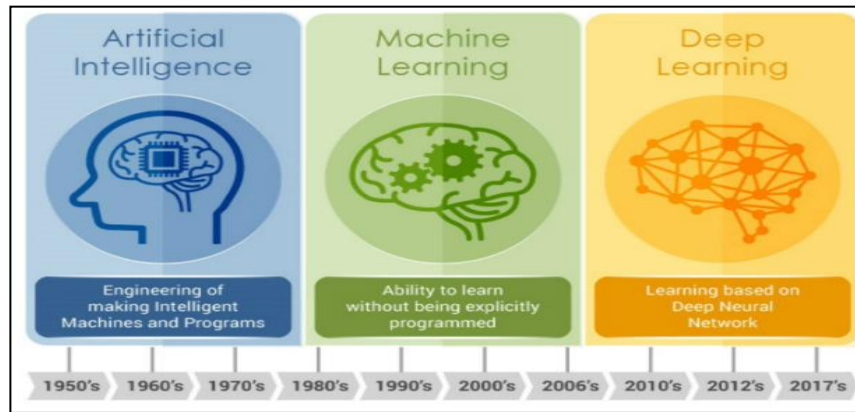
Şekil 3.7. Yapay Sinir Ağı Yapısı Örneği [27]

3.5. Derin Öğrenme

Derin öğrenme bir veya daha fazla gizli katman içeren yapay sinir ağları ve makine öğrenme algoritmalarını içeren teknolojidir. En az bir adet YSA kullanılması ve çeşitli algoritmalar ile programın, mevcut verilerle yeni veriler yaratması işlemidir.

Ivakhnenko ve Lapa tarafından 1965 yılında ilk genel öğrenme algoritması temelleri yayınlanmıştır. Bu çalışmanın içeriğinde geri besleme yöntemi kullanılmayarak, en küçük kareler yöntemi kullanılmıştır. Ivankhnenko'dan sonra ise 1979 yılında Kunihiro Fukushima tarafından ilk derin öğrenme mimarisi "Neokognitron" yöntemi ortaya atılmıştır. Bu yapı, canlıların sinir sistemlerinden esinlenilerek ortaya çıkarılmıştır ve kendi deneyimlerini yaratan "gözetimsiz öğrenme" ile kendi kendini organize eden bir ağ geliştirilmiştir. Ancak süreç içerisinde, daha öncelerden ortaya atılmış olsa da, geri beslemeli bir ağ yapısı algoritmasının daha performanslı olduğu ortaya çıkmıştır. Bu performansı ispatlayan Yann LeCun ve arkadaşları, posta kutusu yazıları üzerinde çalışmışlardır. Yaptıkları çalışmalar sonucunda ağ başarılı olsa da, eğitimin üç gün sürmesi performansı açısından soru işaretleri bırakmış ve neticede pratik açıdan uygun olmadığı kararlaştırılmıştır. [28]

Derin öğrenme 1980'lerde Geoffrey Hinton tarafından kavramsallaştırıldı. Makine öğrenimi tekniklerinin insan beynine olan benzerliğini karşılaştırması Hinton'un derin öğrenmeye en büyük katkısı oldu. Hinton, beyindeki nöronların yapısına benzer şekilde yapılandırılmış bir derin öğrenme algoritması olan "sinir ağı" konseptini oluşturdu. O yıllar da teknolojik yetersizliklerin olması ve veri yetersizliği derin öğrenmenin kavramsallıktan öteye geçememesine yol açtı. Derin öğrenme kavramının yıllar önce ortaya çıkmasına rağmen, günümüze geldiğinde ivme kazanmasının en büyük sebebi teknolojik gelişmelerin yaşanmasıdır. Şuan da Hinton çalışmalarına 2013 yılından beri Google'da devam etmektedir. [29]



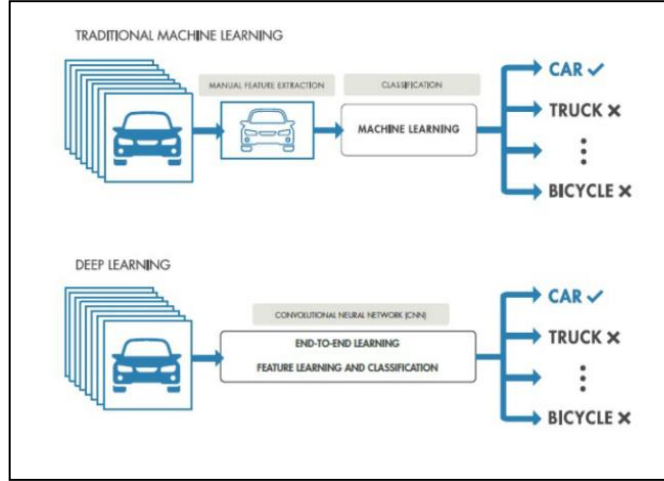
Şekil 3.8. Derin Öğrenme Gelişimi [30]

Derin öğrenme yapısını normal bir yapay zeka algoritmasından ayıran temel farklardan biri şudur ki, bir yapay zeka algoritması yanlış bir tahmin verdiğinde programcı devreye girmeli ve

ayarlamalar yaparak programın tekrar devreye giresine yardımcı olmalıdır. Ancak derin öğrenme modeliyle, bir algoritma, bir tahminin doğru olup olmadığını kendi sinir ağı aracılığıyla belirleyebilir.

Derin öğrenme algoritması ne kadar çok veriyle çalışırsa programın performansı ve doğruluğu o kadar çok artmaktadır. Derin öğrenme ve makine öğrenmesi bu nokta da farklılık göstermektedir. Derin öğrenme de veri sayısı arttıkça performans artarken, makine öğrenmesinde ise bir süre sonra program bir gelişim kaydetmez ve sabit öğrenme yolunu izler.

Derin öğrenme, makine öğreniminin daha özel halidir. Makine öğrenimi kullanıcının manuel olarak görsellerden çıkardığı özellikler ile başlar. Bu özellikler görüntüdeki nesnelere kategorilere ayırmada kullanılmak için kullanılır. Derin öğrenmede ilgili özellikler otomatik olarak görüntülerden çıkarılır [30].



Şekil 3.9. Makine Öğrenmesi ve Derin Öğrenme Arasındaki Fark [30]

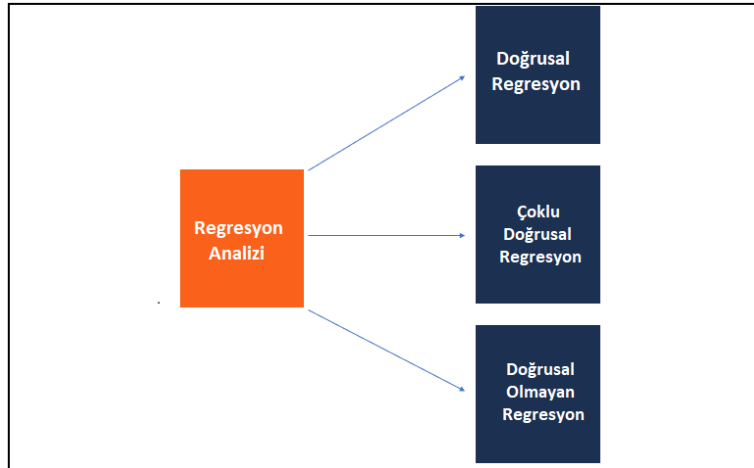
Derin öğrenme, sinir ağı algoritmaları sayesinde işlenmemiş verileri başarılı bir şekilde analiz edebilmektedir. Derin öğrenme yapısı katmanlara ayrılmıştır ve bu katmanlara birbirinden bağımsız görevler verilebilir. Örneğin, bir görüntü tanıma uygulamasında; bir katman gözlük takıp takmadığınızı algılamaya çalışırken, bir diğer katman ise sakalanızdan sizi tanıyabilmek için çalışmalar gerçekleştirir. Ayrıca, üçüncü bir katman, saçınızın yeni modelini hafızasına kazımaya çalışır. Tüm bu bilgiler, önceki katmanlarda öğrenilen bilgiler sayesinde bir ayırt edicilik katarak, parçaları birleştirerek bilgiyi deşifre eder. [31]

3.6.Regresyon Analizi

Regresyon analizi, bir sürecin ortaya çıkardığı bağımlı bir değişken ile sürecin başında bulunan bir veya birden fazla bağımsız değişken arasındaki (birbirine bağlı olarak değişen), oluşabilecek olan ilişkilerin tahmin edilmesi ve değerlendirilmesi için kullanılan bir dizi istatistiksel yöntemdir. Değişkenler arasındaki ilişkinin bağımlılığını irdeleyen ve değerlendiren, aynı zamanda bu ilişkinin gelecekteki durumunu modelleyen bir yöntemdir. Bağımsız değişken veya değişkenler tahmin temelini oluştururken, tahmin edilecek değişken ise bağımlı değişken olarak adlandırılır. [33]

Regresyon Analizi ilk olarak astronomik gözlemler yapılabilmesi ve uyduların genel etrafındaki yörüngelerini saptayabilmek adına, A. Marie Legendre tarafından 17. Yüzyılda ortaya çıkmıştır. Terimsel olarak ilk kullanılışı ise, 19. Yüzyıla gelindiğinde, F.Galton tarafından biyoloji alanında kullanılabilmek için ortaya atılmıştır. [34]

Regresyon analizi, üç temel varyasyon da karşımıza çıkmaktadır. Bunlar; Doğrusal – çoklu doğrusal ve doğrusal olmayan regresyon metodlarıdır. Zaman içinde oluşan bu varyasyonlar, problem yapısına göre kullanılmaktadır. Örnek olarak, doğrusal olmayan regresyon yaklaşımı, bağımlı ve bağımsız değişkenlerin doğrusal olmayan bir ilişki gösterdiği karmaşık veri kümelerinde daha efektif rol oynamaktadır. [33]



Şekil 3.10. Regresyon Analizi Yöntemleri [33]


Temel model gözlemlendiği zaman, regresyon geleceğe dair bir tahmin modeli oluşturmaktadır. Bu tahmin modelini bağımlı değişken ve bağımsız değişken arasında bir gözlem yaparak ortaya çıkarır.

Doğrusal regresyon, rastgele veriler üzerinde çalışma gerçekleştirerek tahmine dayalı bir model ortaya çıkarır. Veri noktalarında gözlemler yaparak istatistiksel bir yapı ortaya koyar ve bir eğim çizgisi oluşturur. Karmaşık veri kümelerinin davranışlarını ve gelecekteki durumlarının anlaşılmasına ve tahmin edilmesine olanak sağlayan doğrusal regresyon, birçok veri modelinin analiz edilmesine olanak sağlar. Ancak verilerin boyutu arttıkça, doğrusal regresyonun performansı düşer. Doğrusal regresyon, aşağıdaki denklem kullanarak ifade edilebilir [33];

$$Y = a + bX + \epsilon$$

- Y: Bağımlı Değişken,
- X: Bağımsız Değişken,
- a: Müdahale,
- b: Eğim,
- ϵ : Hata

Denklemden de anlaşılacağı gibi, doğrusal regresyon, bağımsız bir değişken ile bağımlı bir değişken arasındaki ilişkiyi doğrusal olarak ortaya koyar. [35]



Şekil 3.11. Doğrusal Regresyon [34]

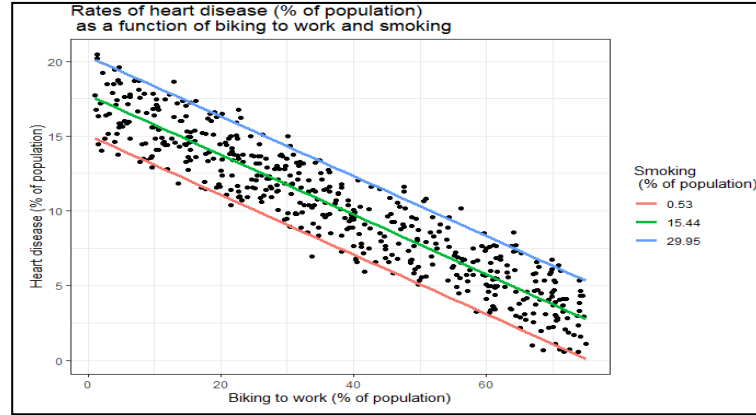
Çoklu doğrusal regresyon yapı olarak doğrusal regresyona benzer. Ancak en temel fark, doğrusal regresyona istinaden birden fazla bağımsız değişken içerebilecek olmasıdır. Bu sebeple

doğrusal regresyondaki dezavantaj olan veri boyutunun büyümesi, çoklu doğrusal regresyonda dezavantaj değildir. Çoklu doğrusal regresyon matematiksel olarak şu şekilde ifade edilebilir;

$$Y = a + bX1 + cX2 + dX3 + \epsilon \quad (3.1)$$

- Y: Bağımlı Değişken,
- X1-X2-X3: Bağımsız Değişkenler,
- a: Müdahale,
- b,c,d: Eğim,
- ϵ : Hata

Çoklu doğrusal regresyonda bir koşul daha vardır. Bu koşul, bağımsız değişkenler arasındaki ilişkiye dayanmaktadır. Eğer bağımsız değişkenler kendi aralarında yüksek düzeyde ilişki barındırıyor, bağımlı ve bağımsız değişken arasındaki ilişkileri değerlendirmek yanlış sonuçlar ortaya çıkaracaktır [33].



Şekil 3.12. Çoklu Doğrusal Regresyon [36]

Doğrusal olmayan regresyon, çoklu doğrusal regresyon gibi birden fazla bağımsız değişken içerir. Adından da anlaşılacağı üzere doğrusal regresyon gibi doğrusal değildir. Bağımsız değişkenler ve bağımlı değişken arasında doğrusal olmayan bir eğri uydurma varyasyonu ortaya çıkarır. Doğrusal olmayan regresyon modelini problem yapısı belirler, örneğin; üstel işlevler, logaritmik problemler, trigonometrik ifadeler, Gauss işlevleri, lorentz dağılımları doğrusal olmayan forma örnek teşkil eder [33]. Matematiksel olarak [38];


$$Y = f(X, \beta) + \epsilon \quad (3.2)$$

- X: P Tahmin Edicilerin Vektörü,
- β : k Parametrelerinin Bir Vektörü,
- F: Bilinen Regresyon Fonksiyonu,
- ϵ : Hata

Alternatif olarak;

$$Y_i = h [x_i(1), x_i(2), \dots, x_i(m); \theta_1, \theta_2, \dots, \theta_p] + E_i \quad (3.3)$$

- Y_i : Değişken,
- h: Fonksiyon,
- x_i : Girdiler,
- θ : Tahmin Edilecek Parametre




Şekil 3.13. Doğrusal Olmayan Regresyon [37]

Regresyon analizi tahmine dayalı bir çalışma tekniğidir ve en az yardımla en çok tahmini gerçekleştirebiliyor olması performansın yüksek olduğunu gözlemlenmesine olanak sağlar. Ancak dikkat edilmesi gereken bir takım unsurlar mevcuttur. Bu unsurları; yetersiz uyum ve aşırı uyum (underfitting - overfitting) olarak adlandırabiliriz.

Tahmin işleminin gerçekleştirilebilmesi için ihtiyacından fazla değişken kullanılması sonucunda, aşırı uyum durumu ile karşılaştırılabilir. Bu unsura dikkat edilmediği takdirde, algoritmanın eğitim

sırasında performanslı olduğu gözlemlenbilir ancak test aşamasına geçildiği zaman yüksek uyum problemi ile karşılaştırılmasına sebebiyet verir. Bu da, algoritmanın problemi ezberleme yoluna gittiğinin, farklı bir değişken ile karşılaştığı zaman ise hata oranının yükselmesine yani tahmin işlemini doğru şekilde gerçekleştirememesine sebebiyet verir.

Bir diğer unsur ise yetersiz uyum problemidir. Bu sorunun oluşmasındaki temel faktör, mevcut verilerin yetersizliğinden kaynaklanmaktadır. Veri yetersizliğinin olması algoritmanın eğitim aşamasında bile performanslı bir eğitim gerçekleştirilememesine sebebiyet verir. Eğitimin gerçekleştirilememesi, test ve sonuç aşamasında hata oranının yükselmesine sebebiyet verir. [39]




Şekil 3.14. Regresyon Analizi – Yetersiz Uyum / Aşırı Uyum [39]

3.7.Yinelemeli Sinir Ağları (RNN)

Yinelemeli Sinir Ağları (Recurrent Neural Network, RNN), hata payını daha çok düşürebilmek için oluşturulmuş bir sinir ağıdır. RNN yapısı, geçmiş bilgilerden bir pay çıkararak çalışma gerçekleştirebilir, yani tecrübelerinden yararlanır. Normal sinir ağlarından farklı olarak RNN yapısı, algoritmadaki daha önceki bilgileri ve gelecekte tanıtılacak bilgileri de kullanır. Kullandığı bu bilgiler sonucundaki yeni kazanımları, eski veriler ile yeni verileri kıyaslayarak ortaya çıkarır. Tahmin ettiği bilgi ile gerçek verileri karşılaştırarak ortaya bir hata oranı çıkarır. Bu hata oranını düşürebilmek için de, programcının belirlemiş olduğu iterasyonlarda sürekli olarak ağırlıkları değiştirerek yeni tahminlerde bulunur. [40]

RNN yapısına Yinelemeli Sinir Ağı denmesinin sebebi şudur ki; yapı itibarıyla, tahmin sonucunda ortaya çıkan hata payının, daha çok indirgenebilmesi için ve bu bilgiden tecrübe kazanabilmesi için tekrar işleme sokulmasından kaynaklanır. [40]



Şekil 3.15. Yinelemeli Sinir Ağı Diagramı [41]

RNN 'e matematiksel bir yaklaşım ile inceleme yaptığımız zaman [42];

$$h_t = f(h_{t-1}, x_t) \quad (3.4)$$

- h_t : Çıktı,
- h_{t-1} : Bir Önceki Çıktı Değeri,
- x_t : Mevcut Girdi Değeri

Aktivasyon fonksiyonu ile çalıştırılmasını istersek;

$$h_t = \tanh(W_{hh}h_{t-1} + W_{xh}x_t) \quad (3.5)$$

- W : Ağırlık,
- h : Gizli Katman,
- W_{hh} : Bir Önceki Gizli Katmanın Ağırlığı,
- W_{xh} : Mevcut Gizli Katmanın Ağırlığı,
- \tanh : Aktivasyon Fonksiyonu


Makine öğrenimi problemlerin de performansı arttırarak, hata oranını düşürebilmek için, üç farklı RNN varyasyonu ile karşılaşırız. Bunlar: Çift Yönlü Tekrarlayan Sinir Ağı (Bidirectional Recurrent Neural Network, BRNN), Kapılı Tekrarlayan Birimler (Gated Recurrent Units, GRU) ve Uzun-Kısa Süreli Bellek (Long Short Term Memory, LSTM) dir.

3.8.Uzun-Kısa Süreli Bellek (LSTM)

1997 yılında S. Hochreiter ve J. Schmidhuber tarafından tanıtılan Uzun Kısa Süreli Bellek (LSTM) yapısı, yapı itibariyle Yinelemeli Sinir Ağı (RNN) yapısından türetilmiş olan bir

varyasyon modelidir. Yani yine bir derin öğrenme alanında kullanılmak için tasarlanmış olan RNN mimarisidir. LSTM ileri beslemeli sinir ağlarına istinaden, geri besleme bağlantılarına sahiptir ve bu sayede bilgiler arası uzun vadeli bağımlılıkları öğrenebilen bir tekrarlayan sinir ağı yapısıdır. En büyük avantajı, tek bir veri yapısını değil tüm veri yapısını işleyebilir. Bu sayede makine çevirisi ve konuşma tanıma gibi yeni teknolojilerde kullanılabilir. [43]

İlk ortaya çıktığı zaman, hücreler-giriş-çıkış yapılarını içeriyor olsa da zaman içinde modifikasyonlara uğramış ve iyileştirilmiştir. Mevcut LSTM yapısına genel anlamda baktığımız zaman; hücre-giriş-çıkış ve unutulacak bilgi kapılarından oluşur. Yapısında bulunan “hafızalara” hücre adı verilir. LSTM hücre yapısına yeni bilgi durumları eklenebilir, hücrelerden bilgi çıkarılabilir ve bu süreç kapılar tarafından koordine edilir. Bu kapılar hücre içine bilgi giriş çıkışı sağlar. Hücre odaları, bir önceki bilgiyi ve (mevcut durumda işlenecek) yeni girdiyi beraber tutar. Algoritmanın da yönetim merkezini bu hücreler ve hücre kapıları oluşturur. Uzun vadeli bağımlılıkları özümseyebilme avantajından kaynaklı olarak LSTM yapısı, zaman serisi analizinde sıkça kullanılır. [46]




Şekil 3.16. Uzun-Kısa Süreki Bellek Yapısal Diagramı [48]

Zaman ilerledikçe gelişime uğrayan LSTM yapısı çift yönlü olarak da karşımıza çıkmaktadır. Her eğitim dizisi, tekrarlayan ağları ayırmak için ileri ve geri beslemeli olarak tekrar işleme sokulur. Bu noktada her iki dizi de çıktı katmanına bağlıdır. Çift yönlü LSTM, normal yapıya göre daha karmaşık olmasına rağmen probleme göre çok daha fazla başarı şansı ortaya çıkarır. Belirli sıradaki her veri yapısı için, önceki ve sonraki her şey hakkında eksiksiz bilgiye sahip olur.


Çift Yönlü LSTM yapısını avantajlı hale getiren en önemli faktör şudur ki; klasik olarak çalışan geleneksel tekrarlayan sinir ağları, bilgi almak için bir önceki noktayı dikkate alırken, Çift Yönlü LSTM yapısında ise bilgiyi almak için, hem çıktı katmanına doğru ilerleyen bir gizli katmandan hemde çıktı katmanından girdi katmanına doğru ilerleyen ikinci bir gizli katmandan çift yönlü olarak bilgi akışını alır. [43]

LSTM yapısının çalışma metodolojini maddeler halinde incelediğimiz zaman [47];

- Unutma kapısı (Forget Gate) olarak adlandırılan yapı, hangi bilginin işe yaradığı veya yaramayarak unutulacağına karar verir. Bir önceki gizli katmandan gelen verilere dayalı bilgiler, güncel bilgiler içeren Sigmoid Fonksiyonundan geçer. Bu bilgilerden ortaya çıkan sonuca bakıldığı zaman, 0'a ne kadar yakınsa unutulacak bilgi kategorisine alınırken, 1'e ne kadar yakınsa mevcut durumda özümzenecek bilgi kategorisine alınarak tutulur.
- Girdi Kapısı (Input Gate)' e geldiği zaman ana amacı Cell State 'i güncellemektir. Unutma kapısında olduğu gibi Sigmoid Fonksiyonu uygulanır ve tutulacak bilgiye karar verilir. Sonraki aşamalarda ağ yönetiminin gerçekleşebilmesi için, "tanh" aktivasyon fonksiyonu yardımıyla -1 / 1 arasına indirgeme işlemi gerçekleşir ve çıkan iki sonuç çarpılır.
- Cell State, hücreler içindeki bilgiyi iletmek ile görevlidir. Ağ üzerinde veri akışını gerçekleştirme görevini içeren Cell Gate, unutma kapısından gelen bilgi ile girdi kapısından gelen bilginin toplamını taşır.
- Çıktı Kapısı (Output Gate), bir sonraki tahmin de kullanılabilmesi için, sonraki katmana iletilecek bilgiye karar verir.



Şekil 3.17. Uzun-Kısa Süreli Bellek Yapısı-1 [47]



Şekil 3.18. Uzun-Kısa Süreli Bellek Yapısı-2 [47]

LSTM yapısının, günümüz teknolojilerinde yadsınamayacak başarıları bulunmaktadır. İleri teknoloji içeren bütün yapay zeka alanlarında performansı yüksek şekilde işlev görmektedir. 2018 ve 2019 yıllarında, popüler ve karmaşık video oyunlarında (Starcraft,Dota 2) üstünlük sağlamak amacıyla derin LSTM yapısı kullanılmıştır. Ayrıca yine 2018 yılında, insan benzeri bir robot elinin el becerilerinin geliştirilmesinde LSTM yapısının eğitimleri büyük başarılarla bulunmuştur. [46]

3.9. Klasik Normalizasyon ve Maksimum Normalizasyon

Klasik normalizasyon işlemi, Tablo-1'e ait değerler dikkate alınarak ve bu değerlerden 1. satır üzerinde çalışılarak, aşağıdaki adımları takip ederek gerçekleştirilmiştir;

(1. Satıra Göre)

- Maksimum değer olan 274 değerinin belirlenmesi,
- Minimum değer olan 107 değerinin belirlenmesi,
- $$\frac{N_{ij} - (\text{Minimum Değer})}{(\text{Maksimum Değer}) - (\text{Minimum Değer})}$$

Yukarıdaki adımları takip ederek klasik normalizasyon işlemine göre herhangi bir satırdaki tüketim değeri, 0-1 değerleri arasına normalize edilmiştir. Örnek olarak (Tablo-1) 'de bulunan ve 1. Aboneye ait Ocak2020 tüketim değerinin klasik normalizasyon yöntemine göre normalize işlemi;

$$\frac{(1 \times \text{Ocak2020}) - (\text{Minimum Değer})}{(\text{Maksimum Değer}) - (\text{Minimum Değer})}$$

Şeklinde gerçekleşecektir. Yani;

$$(162 - 107) / (274 - 107) = 0,329341$$

Değerine denk gelecektir.

Tablo 3.2. Veri Setleri Klasik Normalizasyon – Örnek Yapı

Abone Numarası	Ocak/2020 (kWh)	Şubat/2020 (kWh)	Mart/2020 (kWh)	Haziran/2021 (kWh)	Temmuz/2021 (kWh)	Ağustos/2021 (kWh)
1	0,33	0	0,4	1	0,34	0,82
2	0	0,38	0,2	0,61	0,97	1
3	0,77	0	0,28	1	0,16	0,1
4	1	0	0,25	0,43	0,22	0,5
5	1	0	0,85	0,58	0,55	0,75
6	0,6	0	0,33	1	0,69	0,54
7	1	0,02	0,43	0,27	0,1	0
8	0,74	0	0,80	0,69	0,46	1
9	0,4	0	0,75	0,28	0,4	1
10	0,91	0	0,36	0,12	0,15	1
11	0,74	0,17	0,83	0,40	1	0

Maksimum normalizasyon işlemi, Tablo-1'e ait değerler dikkate alınarak ve bu değerlerden 1. satır üzerinde çalışılarak, aşağıdaki adımları takip ederek gerçekleştirilmiştir;

(1. Satıra Göre)

- Maksimum değer olan 274 değerinin belirlenmesi,

- $$\frac{N_{ij}}{(\text{Maksimum Değer})}$$

Yukarıdaki iki adım takip edilerek, maksimum normalizasyon işlemine göre, herhangi bir satırdaki tüketim değeri, 0-1 değerleri arasına göre normalize edilmiştir. Örnek olarak Tablo-1 'de bulunan ve 1. aboneye ait olan Temmuz2021 tüketim değerinin maksimum normalizasyon yöntemine göre normalize işlemi;

$$\frac{(1x \text{ Temmuz2021})}{(\text{Maksimum Değer})}$$

Şeklinde gerçekleşecektir. Yani;

$$(163) / (274) = 0,59489051$$

Değerine tekabül edecektir.

Tablo 3.3. Veri Setleri Maksimum Normalizasyon – Örnek Yapı

Abone Numarası	Ocak/2020 (kWh)	Şubat/2020 (kWh)	Mart/2020 (kWh)	Haziran/2021 (kWh)	Temmuz/2021 (kWh)	Ağustos/2021 (kWh)
1	0,59	0,39	0,63	1	0,59	0,89
2	0,49	0,69	0,59	0,8	0,99	1
3	0,89	0,51	0,65	1	0,59	0,56
4	1	0,18	0,40	0,53	0,37	0,6
5	1	0,62	0,94	0,84	0,83	0,9
6	0,60	0	0,33	1	0,69	0,54
7	1	0,45	0,68	0,59	0,49	0,43
8	0,87	0,5	0,9	0,84	0,73	1
9	0,76	0,6	0,9	0,71	0,76	1
10	0,94	0,39	0,6	0,46	0,78	1
11	0,23	0,45	0,9	0,61	1	0,35

Normalizasyon yöntemleriyle çalışılarak, algoritmanın daha hızlı çalıştığı ve farklı normalizasyon yöntemlerinin farklı hata oranlarına sahip olduğu gözlemlenmiştir.

3.10. Veri Setinin Oluřturulması

Günümüzde bir abonenin, günlük elektrik tüketimi, kullandığı ev aletlerinin güç tüketimleri dikkate alınarak, ortalama olarak tahmin edilebilir. 24 saatlik zaman dilimi, 12’şer saatlere bölünerek (aydınlık ve karanlık vakitlere göre) gerçeğe yakın bir deęerle tahmin edilebilir. Öznel bir yaklaşımla, ev aletlerinin çalışma süresini de bu ortalama hesaplama da dikkate alabiliriz. Tüm bu öznel yaklaşımlar ve ortalama hesaplar dikkate alınırsa, bir abonenin 1 günlük ortalama tüketimi řu şekilde tespit edilebilir;

Tablo 3.4. Ev Aletlerinin 1 Saatlik Enerji Tüketimi (kWh)

Cihaz	Güç (Watt)	1 Saatlik Enerji Tüketimi (kWh)
Buzdolabı (A+)	44	0,04
Bulaşık Makinesi (A+)	510	0,51
Çamaşır Makinesi (A+)	303	0,3
LCD TV (A+)	98	0,1
Ütü	2600	2,6
Elektrikli Süpürge	2000	2
Fırın	2500	2,5
Klima	2200	2,2
Elektrikli Isıtıcı	3000	3
Akkor Ampul	60	0,06
Enerji Tasarruflu Ampul	12	0,01
LED Lamba	12	0,01
Kettle	2200	2,2
Tost Makinesi	2000	2
Çamaşır Kurutma Makinesi	1000	1
Mikrodalga Fırın	800	0,8
Dizüstü Bilgisayar	90	0,09
Telefon Şarjı	4	0,004

Tablo 3.4 'de enerji tüketimlerini incelediğimiz zaman aşağıdaki yorumları kullanarak önce 24 saatlik, sonra 30 günlük, son olarak da veri setinde olduğu gibi 2 senelik bir ortalama tüketim hesabı gerçekleştirilebilir;

- Buzdolabı (A+) : (0,040 kW) x (24 Saat) = 0,960 kWh,
- Bulaşık Makinesi (A+) : (0,510 kW) x (2 Saat) = 1,020 kWh,
- Çamaşır Makinesi (A+) : (0,300 kW) x (2 Saat) = 0,600 kWh,
- LCD TV (A+) : (0,100 kW) x (5 Saat) = 0,500 kWh,
- Akkor Ampul : (0,060 kW) x (6 Saat) = 0,360 kWh,
- Dizüstü Bilgisayar : (0,090 kW) x (3 Saat) = 0,270 kWh,
- Telefon Şarj Aleti : (0,004 kW) x (2 Saat) = 0,008 kWh,

Yukarıdaki enerji tüketim hesabı öznel olarak oluşturulmuştur. Bu yorumsal hesaplamalara göre;

- Bir abonenin 24 saatlik toplam tüketimi: 3,71800 kWh 'dır,
- Bir abonenin 1 aylık toplam tüketimi: 111,540 kWh 'dır,
- Bir abonenin 2 yıllık toplam tüketimi: 2676,96 kWh 'dır.

Yapılan bu öznel hesaplamalara göre, hata payları da dikkate alınarak, bir abonenin ortalama olarak 2 yıllık enerji tüketiminin 2500 kWh olması gerektiğine kanaat getirilmiştir.

Performansı arttırmak adına, normalizasyon işlemleri gerçekleşmeden evvel, veri setinin daha performanslı çalışabilmesi ve daha gerçekçi bir senaryo ile oluşturabilmek için, veri seti filtreleme işlemlerine tabi tutulmuştur. Bu işlemler sonucunda var olan veri setinden, 3 yeni veri seti oluşturulmuştur. Daha sonra bu veri setleri de kendi içlerinde hem klasik normalizasyon ile hem de maksimum normalizasyon ile normalize edilmiştir. Bu veri setlerine B-C-D veri setleri adı verilmiştir;

- B veri seti: 2 yıllık toplam tüketimi 2500 kWh (Öznel olarak hesaplanmış bir abonenin 2 yıllık enerji tüketimi) altında olan abonelerin tüketimleri veri setine dahil edilmemiştir.

- C veri seti; B veri setindeki filtreleme işlemine ek olarak, 12 ay boyunca elektriksel tüketimi olmayıp, sonraki 12 ay tüketimi olan (veya tam tersi durum için) abonelerin enerji tüketimleri veri setine dahil edilmemiştir.
- D veri seti; C veri setindeki filtreleme işlemine ek olarak, tüketimleri düzensiz olan abonelerin (24 ay çoğunlukla tüketimi olmayan) enerji tüketimleri veri setine dahil edilmemiştir.

Deneysel çalışmalar ham veri seti (ilerleyen kısımlarda “A” veri seti olarak nitelendirilecektir.) ve bu üç veri seti üzerinde gerçekleştirilmiştir.

Normalizasyon işlemlerinden geçmiş veri setleri ile çalışılmadan önce, Tablo-1 ‘deki gibi verilerin ham haliyle analizler gerçekleştirilmiştir. 24 aylık abone enerji tüketimlerini bulunan verilerden 23 ay girdi değeri olarak eğitim aşamasında kullanılırken, 24. ay olan Aralık2021 tarihi, çıktı olarak yani tahmin edilecek ay olarak kullanılmıştır.

Bu aşamada MATLAB programı ile Makine Öğrenmesi - Regresyon Analizi ile çalışılmıştır. A veri seti ile çalışıldığı zaman regresyon analizi verilerin karmaşıklığı ve düzensizliği nedeniyle tahmin miktarında yüksek hatalar elde edilmiştir.

A veri setinin normalize işlemlerinin gerçekleştirilebilmesi için önce klasik normalizasyon sonrasında ise maksimum normalizasyon işlemleri gerçekleştirilmiştir. Normalizasyon işlemleri veri setleri için olumlu sonuçlar yaratmıştır. Hem klasik normalizasyon işlemleri hem de maksimum normalizasyon işlemlerinden sonra tahmin edilecek Aralık2021 tarihi, RMSE değeri olarak 0-1 arasına geriletilerek başarılı sonuçlar vermiştir. Bu çalışma, veri setinin tutarlı bir çalışma gerçekleştirebileceği niteliğindedir.

B-C ve D veri setleri, önce klasik normalizasyon, sonrasında ise maksimum normalizasyon işlemlerine tabii tutulduktan sonra regresyon analizine sokulmuştur. Daha sonra bu veri setleri normalizasyon işlemleriyle normalize edildikten sonra bir derin öğrenme yöntemi olan LSTM analizi yapısı ile tahmin edilmeye çalışılmıştır. LSTM analizi yöntemi ile çalışırken veri setleri, MATLAB programı üzerinde eğitim ve test verileri olarak 2 ‘ye ayrılmıştır. Belli iterasyon sayısında ve belirli gizli nöron sayıları ile çalışan LSTM yapısı sonucunda öznetelik çıkarma işlemleri tamamlanmıştır. Öznetelikler, ilk aşamada olduğu gibi regresyona analizine sokulmuştur. Sonuçlar karşılaştırılarak, elektrik tüketim verilerine göre en iyi tahmin modelinin önerilmesi

amaçlanmıştır. Bu sonuçların gözlemlenmesi Deneysel Çalışma ve Sonuçlar bölümünden incelenebilmektedir.

3.11. Kök Ortalama Kare Hatası (RMSE)

Makine öğrenmesi programlarında hata değerlendirme kriterlerinden biri olarak değerlendirilen Kök Ortalama Kare Hatası (RMSE), algoritmanın tahminleme sonucunda tespit ettiği değerler ile gerçek olan değerler arasındaki sapmanın tespit edilmesi sürecinde kullanılan ve sapmanın ne kadar olduğunu gözlemleyebilen bir metriktir. Tespit edilen tahminleme sonucunun gerçek değerden ne kadar uzak olduğunu ölçüsü olarak da tanımlanabilir. RMSE değeri 0 'dan, sonsuza kadar değişebilir bir ölçümdür [50]. Verilerin en uygun çizgi etrafında ne kadar yoğun olduğunu söyler. Ortalama karekök hatası, deneysel sonuçları doğrulamak için, tahmin ve regresyon analizinde yaygın olarak kullanılır. [51]

$$\text{RMSE}_{fo} = \left[\sum_{i=1}^N (z_{fi} - z_{oi})^2 / N \right]^{1/2} \quad (3.6)$$

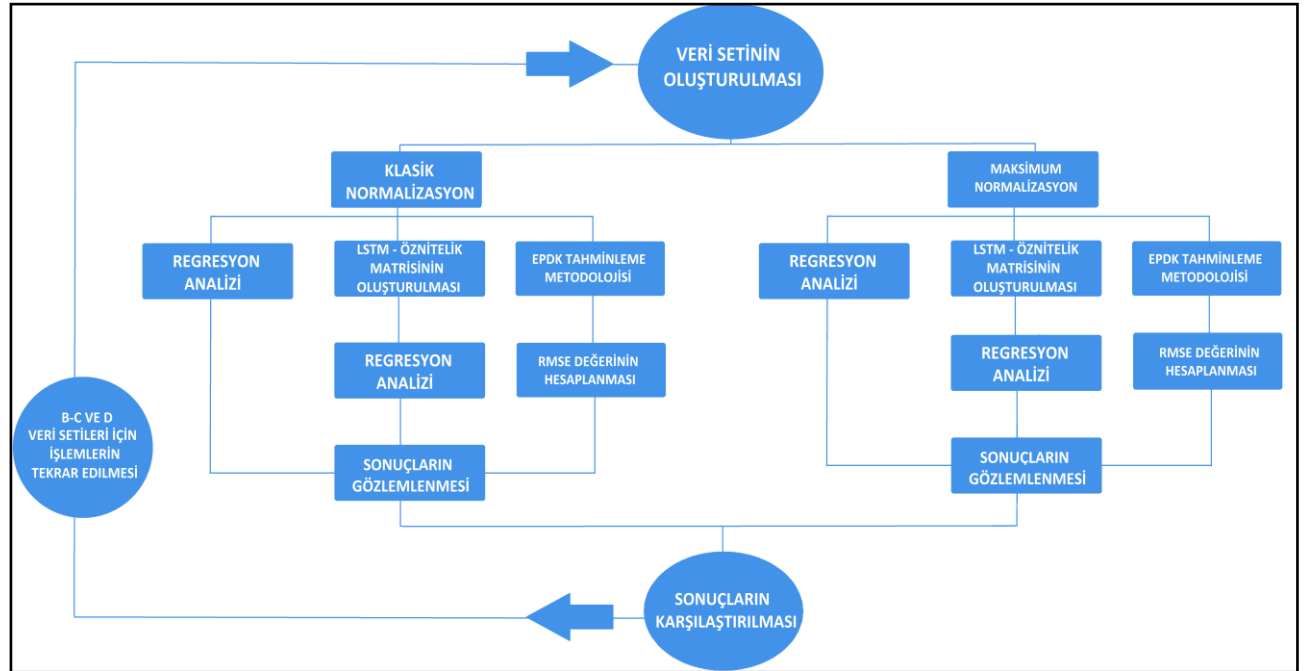
- Z_{fi} : Tahmin Edilen Değer,
- Z_{oi} : Gözlemlenen Değer,
- N : Toplam Veri Sayısı,

Şeklinde matematiksel olarak da hesaplanabilir [51]. RMSE hesaplamaları sonucunda hesaplanan matematiksel değer negatif eğilim gösterdiği sürece başarılı olarak nitelendirilebilir. Bu sebeple algoritma sonucunda hesaplanan RMSE değeri 0 değerine ne kadar yakın ise, algoritmanın RMSE değeri, yani hata oranı o kadar düşüktür şeklinde bir yorum yapılabilir.

4. DENEYSEL ÇALIŞMA VE SONUÇLAR

Bu tez çalışmasında amaç, öncelikle oluşturulan veri setleri üzerinde tek tek aynı işlemler tekrarlanarak ve sonuçlar gözlemlenerek en iyi tahmin modelinin oluşturulmasıdır. İlk aşama olarak kullanılacak mevcut veri setinin, regresyon analizi ile RMSE değerlerinin elde edilmesi olacaktır. İkinci aşama olarak bu veri setinin LSTM analizi yöntemi ile öznitelik matrisinin çıkartılması, çıkartılan bu öznitelik matrisinin tekrar regresyon analizine tabii tutulması ve RMSE değerlerinin elde edilmesi olacaktır. Üçüncü aşama, mevcut veri setlerine göre EPDK tahminleme metodolojisi ile RMSE değerlerinin elde edilmesi olacaktır. Son aşama ise, ilk aşamada elde edilen RMSE değerleri, ikinci aşamada oluşan RMSE değerleri ve EPDK tahminleme metodolojisi ile elde edilen RMSE değerlerinin karşılaştırılmasıdır. Deneysel çalışmalar gerçekleştirilirken verilerin %80 'ni eğitim için kullanılırken, %20 'si test verileri olarak kullanılmıştır. Verilerin hangisinin test, hangisinin eğitim için kullanılacağı çapraz doğrulama ile gerçekleşmiş ve "K" değeri 5 olarak seçilmiştir.

Yukarıda belirtilen bu aşamalar; A, B, C ve D veri setlerine uygulanırken hem klasik normalizasyon üzerinde hem de maksimum normalizasyon içinde gözlemlenmiştir. Böylece en iyi tahmin modeli elde edilirken, normalizasyon yöntemlerinin de başarıya etkisi incelenmiştir.



Şekil 4.1. Deneysel Çalışmaya Ait Blok Diagram Yapısı

Deneyisel çalışmanın ilk kısmında, ilk veri seti olan, A veri setinin normalize edilmesinden sonra regresyon analizi gerçekleştirme işlemi ile başlamıştır. A veri setinin regresyon analizi sonucunda hata değeri olarak ortaya çıkan RMSE değeri, Tablo 4.1 ‘ deki gibi gözlemlenmiştir;

Tablo 4.1. A Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri

A Veri Seti		
Regresyon Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Karar Ağacı – İyi Ağaç (Tree – Fine Tree)	0.29567	0.25993
Karar Ağacı – Ortalama Ağaç (Tree – Medium Tree)	0.26771	0.23753
Karar Ağacı – Kaba Ağaç (Tree – Coarse Tree)	0.25522	0.22892
Doğrusal Regresyon – Doğrusal (Linear Reg. – Linear Regression)	0.26924	0.24711
Doğrusal Regresyon – Etkileşimli (Linear Reg. – Interactions Linear)	0.26394	0.24056
Doğrusal Regresyon – Güçlü (Linear Reg. – Robust Linear)	0.27806	0.26148
Birlik– Arttırılmış Ağaç (Ensemble – Boosted Trees)	0.25152	0.22874
Birlik – Paket Ağaç (Ensemble – Bagged Trees)	0.23116	0.20592
Destek Vektör Makineleri – Doğrusal (Svm – Linear Svm)	0.27745	0.25438
Destek Vektör Makineleri – İyi Gaussian – (Svm – Fine Gaussian Svm)	0.27375	0.24314
Destek Vektör Makineleri – Ortalama Gaussian – (Svm – Medium Gaussian)	0.2243	0.20305
Destek Vektör Makineleri – Kaba Gaussian – (Svm- Coarse Gaussian Svm)	0.26891	0.24716
Sinir Ağı – Kısıtlı (Neural Network – Narrow)	0.25374	0.22794
Sinir Ağı – Ortalama (Neural Network – Medium)	0.24275	0.21825
Sinir Ağı – Kapsamlı (Neural Network – Wide)	0.24332	0.21845
Sinir Ağı – Çift Katmanlı (Neural Network – Bilayered)	0.23982	0.21767
Sinir Ağı – Üç Katmanlı (Neural Network – Trilayered)	0.23975	0.21627

Tablo 4.1 incelendiğinde, A veri setinin regresyon analizi sonucundaki RMSE değerlerinin farklı regresyon analizleriyle tespit edildiğini görülmektedir.

RMSE deęerinin 0-1 arasında olması gerekmektedir ve bu deęer 0'a ne kadar yakınsa regresyon analizi ile tahmin etme iřlemi o kadar bařarılı gerekleřmiřtir anlamına gelmektedir. Tablo 4.1 incelendięinde, hem klasik normalizasyon iin hemde maksimum normalizasyon iin en bařarılı sonu SVM-Medium Gaussian yntemi ile elde edilmiřtir.

Regresyon analizi ile gerekleřtirilen tahmin iřlemleri sonucunda, bir sonraki adım olan LSTM yntemi ile znelik ıkarma iřlemidir. LSTM ile znelik ıkarma iřlemi sonucunda oluřacak znelik matrisinin de daha sonra tekrar regresyon iřlemine tabii tutulması gerekmektedir. Bu sonular Tablo 4.2 'de grlmektedir;

Tablo 4.2. A Veri Setinin LSTM Analizi Sonucundaki RMSE Değerleri

A Veri Seti		
LSTM Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.31261	0.28374
Tree- Medium Tree	0.28439	0.25717
Tree- Coarse Tree	0.266	0.24372
Linear Reg. - Linear	0.27021	0.2572
Linear Reg. - Interactions Linear	0.26344	0.24993
Linear Reg. - Robust Linear	0.27746	0.26681
Ensemble- Boosted Trees	0.26232	0.24073
Ensemble- Bagged Trees	0.24711	0.22493
Svm- Linear Svm	0.28264	0.26343
Svm- Fine Gaussian Svm	0.26198	0.24166
Svm- Medium Gaussian	0.27659	0.25175
Svm- Coarse Gaussian Svm	0.27328	0.26481
Neural Network- Narrow	0.25217	0.23864
Neural Network- Medium	0.25061	0.23462
Neural Network- Wide	0.25096	0.23491
Neural Network- Bilayered	0.24642	0.23158
Neural Network- Trilayered	0.24726	0.22992

Tablo 4.2 incelendiği de, maksimum normalizasyonda en iyi sonuç Ensemble-Boosted Trees yöntemi ile elde edilirken, klasik normalizasyonda ise Neural Network Bilayered yöntemi ile elde edilmiştir.

Öncelikle klasik normalizasyon ve maksimum normalizasyonu karşılaştırıldığında, maksimum normalizasyon sonucunda ortaya çıkan RMSE değerlerinin, klasik normalizasyona ait RMSE değerlerinden daha performanslı sonuçlar verdiği gözlemlenmiştir

Tablo 4.3 'de, regresyon analizi sonucunda en iyi sonuç olarak elde edilen maksimum normalizasyon sonuçları ve LSTM ile öznitelik çıkartılması sonucu, en iyi sonuç olarak elde edilen maksimum normalizasyon değerleri karşılaştırılmıştır. Hem ilk aşama olarak uygulanan regresyon analizinde, hem de LSTM sonucunda oluşan öznitelik matrisinin regresyon işleminde, en iyi performans, maksimum normalizasyon ile elde edilmiştir. Bu karşılaştırma, regresyon analizi ve LSTM analizinin karşılaştırmasını gösterecektir.

Tablo 4.3. A Veri Setine Göre Regresyon ve LSTM Analizi Karşılaştırılması

A Veri Seti		
Regresyon Analizi ve LSTM Analizi Karşılaştırılması		
-	Regresyon Analizi	LSTM Analizi
Tree - Fine Tree	0.25993	0.28374
Tree - Medium Tree	0.23753	0.25717
Tree - Coarse Tree	0.22892	0.24372
Linear Reg. - Linear	0.24711	0.2572
Linear Reg. - Interactions Linear	0.24056	0.24993
Linear Reg. - Robust Linear	0.26148	0.26681
Ensemble - Boosted Trees	0.22874	0.24073
Ensemble - Bagged Trees	0.20592	0.22493
Svm - Linear Svm	0.25438	0.26343
Svm - Fine Gaussian Svm	0.24314	0.24166
Svm - Medium Gaussian	0.20305	0.25175
Svm - Coarse Gaussian Svm	0.24716	0.26481
Neural Network - Narrow	0.22794	0.23864
Neural Network - Medium	0.21825	0.23462
Neural Network - Wide	0.21845	0.23491
Neural Network - Bilayered	0.21767	0.23158
Neural Network - Trilayered	0.21627	0.22992

Tablo 4.3 incelendiğinde, veri setinin regresyon analizine tabii tutulmasından sonra ortaya çıkan RMSE değerleri, LSTM sonucunda oluşturulan öznelik matrisinin tekrar regresyon analizine tabii tutulmasından daha başarılı sonuçlar vermiştir. Regresyon analizi sonucunda en başarılı sonuç SVM – Medium Gaussian ile elde edilirken, LSTM sonucunda en başarılı yöntem Ensemble – Bagged Trees olmuştur.

Ayrıca, A veri setinin sonuç tablosu olarak nitelendirilebilecek Tablo 4.3 incelendiği zaman, LSTM yönteminin sadece, SVM – Fine Gaussian yöntemin de, regresyon analizine göre daha başarılı sonuçlar verdiği gözlemlenmiştir.

Performansı arttırabilmek adına ve veri setinde gerçekleştirilen filtreleme işlemlerinden sonra, bir sonraki veri seti olan, B veri seti için de aynı çalışmalar gerçekleştirilmiştir;

Tablo 4.4. B Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri

B Veri Seti		
Regresyon Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.29789	0.24711
Tree- Medium Tree	0.27031	0.2259
Tree- Coarse Tree	0.25157	0.21202
Linear Reg. - Linear	0.2568	0.22159
Linear Reg. - Interactions Linear	0.25074	0.21488
Linear Reg. - Robust Linear	0.26141	0.23128
Ensemble- Boosted Trees	0.24098	0.20343
Ensemble- Bagged Trees	0.22952	0.19221
Svm- Linear Svm	0.26206	0.22605
Svm- Fine Gaussian Svm	0.27418	0.23359
Svm- Medium Gaussian	0.22049	0.18739
Svm- Coarse Gaussian Svm	0.25664	0.22071
Neural Network- Narrow	0.24304	0.20707
Neural Network- Medium	0.2369	0.20156
Neural Network- Wide	0.25349	0.21128
Neural Network- Bilayered	0.23668	0.19892
Neural Network- Trilayered	0.23931	0.20202

Tablo 4.5. B Veri Setinin LSTM Analizi Sonucundaki RMSE Değerleri

B Veri Seti		
LSTM Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.31627	0.26296
Tree- Medium Tree	0.2848	0.24125
Tree- Coarse Tree	0.26794	0.22589
Linear Reg. - Linear	0.25718	0.22161
Linear Reg. - Interactions Linear	0.25101	0.2139
Linear Reg. - Robust Linear	0.26189	0.22947
Ensemble- Boosted Trees	0.25591	0.21907
Ensemble- Bagged Trees	0.24679	0.2089
Svm- Linear Svm	0.26243	0.22605
Svm- Fine Gaussian Svm	0.25057	0.21413
Svm- Medium Gaussian	0.24915	0.21331
Svm- Coarse Gaussian Svm	0.25975	0.22433
Neural Network- Narrow	0.24665	0.20649
Neural Network- Medium	0.24351	0.20498
Neural Network- Wide	0.25198	0.21155
Neural Network- Bilayered	0.24242	0.20411
Neural Network- Trilayered	0.24047	0.20436

Tablo 4.6. B Veri Setine Göre Regresyon ve LSTM Analizi Karşılaştırılması

B Veri Seti		
Regresyon Analizi ve LSTM Analizi Karşılaştırılması		
-	Regresyon Analizi	LSTM Analizi
Tree- Fine Tree	0.24711	0.26296
Tree- Medium Tree	0.2259	0.24125
Tree- Coarse Tree	0.21202	0.22589
Linear Reg. - Linear	0.22159	0.22161
Linear Reg. - Interactions Linear	0.21488	0.2139
Linear Reg. - Robust Linear	0.23128	0.22947
Ensemble- Boosted Trees	0.20343	0.21907
Ensemble- Bagged Trees	0.19221	0.2089
Svm- Linear Svm	0.22605	0.22605
Svm- Fine Gaussian Svm	0.23359	0.21413
Svm- Medium Gaussian	0.18739	0.21331
Svm- Coarse Gaussian Svm	0.22071	0.22433
Neural Network- Narrow	0.20707	0.20649
Neural Network- Medium	0.20156	0.20498
Neural Network- Wide	0.21128	0.21155
Neural Network- Bilayered	0.19892	0.20411
Neural Network- Trilayered	0.20202	0.20436

Tablo 4.4, Tablo 4.5 ve Tablo 4.6 incelendiğinde, öncelikle maksimum normalizasyon işleminin, klasik normalizasyon işlemine göre daha performanslı sonuçlar elde ettiği gözlemlenebilir. İkinci olarak B veri seti için gerçekleştirilmiş olan filtreleme işlemleri sonucunda hem regresyon analizinde hem de LSTM analizi ile oluşturulan öznitelik matrisinin regresyon analizinde performans artışı gerçekleşmiştir. Ancak B veri setinde de, regresyon analizi, LSTM ile oluşturulan öznitelik matrisinden daha performanslı tahmin işlemi gerçekleştirmiştir. Regresyon

analizi sonucunda en başarılı yöntem SVM Medium Gaussian yöntemi iken, LSTM sonucundaki en başarılı yöntem Neural Network- Trilayered yöntemi olmuştur.

Ayrıca B veri setine göre, Tablo 4.6 incelendiği zaman, LSTM yönteminin;

- Linear Regresyon – Interaction Linear,
- SVM – Fine Gaussian SVM,
- Neural Network Narrow,

Yöntemlerinde, regresyon analizine istinaden daha başarılı sonuçlar verdiği gözlemlenmiştir.

Bir sonraki veri seti olan, C veri seti ile çalışıldığı zaman, regresyon analize ait RMSE sonuçları Tablo 4.7 'de gözlemlenebilmektedir;

Tablo 4.7. C Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri

C Veri Seti		
Regresyon Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.29572	0.24569
Tree- Medium Tree	0.27045	0.22506
Tree- Coarse Tree	0.25045	0.21135
Linear Reg. - Linear	0.25594	0.21983
Linear Reg. - Interactions Linear	0.25012	0.21321
Linear Reg. - Robust Linear	0.2603	0.2296
Ensemble- Boosted Trees	0.23996	0.2018
Ensemble- Bagged Trees	0.22926	0.19161
Svm- Linear Svm	0.26069	0.22391
Svm- Fine Gaussian Svm	0.2741	0.23413
Svm- Medium Gaussian	0.2221	0.18816
Svm- Coarse Gaussian Svm	0.25554	0.2187
Neural Network- Narrow	0.24199	0.20524
Neural Network- Medium	0.23935	0.19927
Neural Network- Wide	0.25317	0.2136
Neural Network- Bilayered	0.23408	0.1997
Neural Network- Trilayered	0.23786	0.20324

Tablo 4.8. C Veri Setinin LSTM Analizi Sonucundaki RMSE Değerleri

C Veri Seti		
LSTM Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.31806	0.24753
Tree- Medium Tree	0.2859	0.2262
Tree- Coarse Tree	0.26708	0.21208
Linear Reg. - Linear	0.25695	0.21987
Linear Reg. - Interactions Linear	0.25107	0.21299
Linear Reg. - Robust Linear	0.26095	0.22963
Ensemble- Boosted Trees	0.25612	0.20173
Ensemble- Bagged Trees	0.24821	0.19098
Svm- Linear Svm	0.27832	0.23686
Svm- Fine Gaussian Svm	0.29412	0.25403
Svm- Medium Gaussian	0.23412	0.20357
Svm- Coarse Gaussian Svm	0.26578	0.22269
Neural Network- Narrow	0.24552	0.20486
Neural Network- Medium	0.24387	0.20033
Neural Network- Wide	0.25314	0.20867
Neural Network- Bilayered	0.24425	0.20266
Neural Network- Trilayered	0.24511	0.20276

Tablo 4.9. C Veri Setine Göre Regresyon ve LSTM Analizi Karşılaştırılması

C Veri Seti		
Regresyon Analizi ve LSTM Analizi Karşılaştırılması		
-	Regresyon Analizi	LSTM Analizi
Tree- Fine Tree	0.24569	0.24753
Tree- Medium Tree	0.22506	0.2262
Tree- Coarse Tree	0.21135	0.21208
Linear Reg. - Linear	0.21983	0.21987
Linear Reg. - Interactions Linear	0.21321	0.21299
Linear Reg. - Robust Linear	0.2296	0.22963
Ensemble- Boosted Trees	0.2018	0.20173
Ensemble- Bagged Trees	0.19161	0.19098
Svm- Linear Svm	0.22391	0.23686
Svm- Fine Gaussian Svm	0.23413	0.25403
Svm- Medium Gaussian	0.18816	0.20357
Svm- Coarse Gaussian Svm	0.2187	0.22269
Neural Network- Narrow	0.20524	0.20486
Neural Network- Medium	0.19927	0.20033
Neural Network- Wide	0.2136	0.20867
Neural Network- Bilayered	0.1997	0.20266
Neural Network- Trilayered	0.20324	0.20276

C veri setine göre çalışmalar incelendiği zaman, maksimum normalizasyon işleminin, klasik normalizasyon işleminden daha performanslı sonuçlar verdiği gözlemlenebilir. Ayrıca C veri setinde gerçekleşmiş olan filtreleme işleminin, B veri setinde de olduğu gibi, orantılı şekilde hem regresyon analizinde hem de LSTM analizinde performans artışı gerçekleşmesine sebep olmuştur. Regresyon analizi sonucunda en başarılı yöntem, B veri setinde olduğu gibi, SVM Medium Gaussian yöntemi iken, LSTM sonucundaki en başarılı yöntem Ensemble Bagged Trees yöntemi olarak güncellenmiştir.

Ayrıca C veri seti için, diğer veri setlerine istinaden, “Regresyon Analizi ve LSTM Analizi Karşılaştırması” tablosuna göre (Tablo 4.9); LSTM analizinin, regresyon analizine göre en çok başarı elde ettiği veri seti olmuştur. LSTM analizi yönteminin, regresyon analizi yöntemine göre;

- Linear Regresyon – Interaction Linear,
- Ensemble Boosted Trees,
- Ensemble Bagged Trees,
- Neural Network Narrow,
- Neural Network Trilayered,

Yöntemlerinde daha başarılı sonuçlar verdiği gözlemlenmiştir.

Bir sonraki veri seti olan D veri seti ile gerçekleştirilen çalışmalar sonucunda;

Tablo 4.10. D Veri Setinin Regresyon Analizi Sonucundaki RMSE Değerleri

D Veri Seti		
Regresyon Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.30016	0.20654
Tree- Medium Tree	0.27168	0.18663
Tree- Coarse Tree	0.25323	0.17492
Linear Reg. - Linear	0.25606	0.1883
Linear Reg. - Interactions Linear	0.24996	0.18572
Linear Reg. - Robust Linear	0.26013	0.1974
Ensemble- Boosted Trees	0.24092	0.1681
Ensemble- Bagged Trees	0.22976	0.16026
Svm- Linear Svm	0.26093	0.19424
Svm- Fine Gaussian Svm	0.27591	0.20081
Svm- Medium Gaussian	0.22254	0.16133
Svm- Coarse Gaussian Svm	0.25593	0.18873
Neural Network- Narrow	0.2456	0.17537
Neural Network- Medium	0.23908	0.17379
Neural Network- Wide	0.25883	0.18928
Neural Network- Bilayered	0.24007	0.18382
Neural Network- Trilayered	0.23745	0.18623

Tablo 4.11. D Veri Setine Göre Regresyon Analizi ve LSTM Analizi Karşılaştırılması

D Veri Seti		
LSTM Analizi (RMSE Sonuçları)		
-	Klasik Normalizasyon	Maksimum Normalizasyon
Tree- Fine Tree	0.3196	0.2353
Tree- Medium Tree	0.28813	0.21157
Tree- Coarse Tree	0.26965	0.19695
Linear Reg. - Linear	0.25718	0.18847
Linear Reg. - Interactions Linear	0.25206	0.18462
Linear Reg. - Robust Linear	0.26081	0.19331
Ensemble- Boosted Trees	0.25664	0.19039
Ensemble- Bagged Trees	0.24966	0.18345
Svm- Linear Svm	0.25126	0.19107
Svm- Fine Gaussian Svm	0.25126	0.19005
Svm- Medium Gaussian	0.2499	0.18722
Svm- Coarse Gaussian Svm	0.25896	0.19065
Neural Network- Narrow	0.24769	0.18284
Neural Network- Medium	0.24528	0.18172
Neural Network- Wide	0.25623	0.191
Neural Network- Bilayered	0.24382	0.18156
Neural Network- Trilayered	0.24785	0.18085

Tablo 4.12. D Veri Setine Göre Regresyon Analizi ve LSTM Analizi Karşılaştırılması

D Veri Seti		
Regresyon ve LSTM Karşılaştırılması		
-	Regresyon Analizi	LSTM Analizi
Tree- Fine Tree	0.20654	0.2353
Tree- Medium Tree	0.18663	0.21157
Tree- Coarse Tree	0.17492	0.19695
Linear Reg. - Linear	0.1883	0.18847
Linear Reg. - Interactions Linear	0.18572	0.18462
Linear Reg. - Robust Linear	0.1974	0.19331
Ensemble- Boosted Trees	0.1681	0.19039
Ensemble- Bagged Trees	0.16026	0.18345
Svm- Linear Svm	0.19424	0.19107
Svm- Fine Gaussian Svm	0.20081	0.19005
Svm- Medium Gaussian	0.16133	0.18722
Svm- Coarse Gaussian Svm	0.18873	0.19065
Neural Network- Narrow	0.17537	0.18284
Neural Network- Medium	0.17379	0.18172
Neural Network- Wide	0.18928	0.191
Neural Network- Bilayered	0.18382	0.18156
Neural Network- Trilayered	0.18623	0.18085

Son olarak D veri setinde de diğer veri setlerinde olduğu gibi, maksimum normalizasyon ile gerçekleştirilen çalışmaların daha performanslı olduğu gözlemlenebilir. Ayrıca B-C veri setlerinde olduğu gibi, D veri setinin filtreleme ve düzenlenme işlemlerinden sonra performansta olumlu sonuçlar olduğu gözlemlenebilmektedir. Regresyon analizi sonucunda en başarılı yöntem Ensemble Bagged Trees iken, LSTM analizi sonucundaki en başarılı yöntem Neural Network Trilayered yöntemi olmuştur.

Ayrıca, D veri setine ait Tablo 4.12 incelendiği zaman, LSTM analizinin (regresyon analizine göre) başarılı yöntem sayısı (C veri setine göre) artış göstermiştir. Bu yöntemler;

- Linear Regresyon – Robust Linear,
- Linear Regresyon – Linear,
- SVM – Linear SVM,
- SVM – Fine Gaussian SVM,
- Neural Network – Bilayered,
- Neural Network – Trilayered,

Yöntemleri olmuştur.

Tablo 4.13. Regresyon Analizi – LSTM Analizi ve EPDK Tahminleme Metodolojisi Karşılaştırma Tablosu

-	Regresyon Analizi		LSTM Analizi		EPDK Tahmin Metodu	
	Klasik Norm.	Maksimum Norm.	Klasik Norm.	Maksimum Norm.	Klasik Norm.	Maksimum Norm.
A Veri Seti	0.2243	0.20305	0.24642	0.22493	0.6769	0.70731
B Veri Seti	0.22049	0.18739	0.24047	0.20411	0,7138	0.7569
C Veri Seti	0.2221	0.18816	0.23412	0.19098	0,7138	0.7576
D Veri Seti	0.22254	0.16026	0.24382	0.18085	0.7135	0.7603

RMSE oranlarının karşılaştırılması sonucunda oluşturulmuş olan Tablo 4.13 incelendiği zaman, önerilen modeller olan; Regresyon analizi ve LSTM analizi yöntemlerinin, EPDK Tahminleme Metodolojisine göre daha düşük hata oranları elde ettiği gözlemlenmektedir.

Tablo 4.14 Regresyon Analizi – LSTM Analizi – Literatür ve EPDK Tahminleme Metodolojisi Başarı Yüzdesi Karşılaştırma Tablosu

-	Kullanılan Veri Sayısı Dönemi	Regresyon Analizi
Regresyon Analizi	2 Yıl	84,0%
LSTM Analizi	2 Yıl	82,0%
Literatür	5 Yıl	93,4%
EPDK Tahminleme Metodu	-	32,4%

Tablo 4.14 incelendiği zaman, literatür çalışmasının ve bu tez konusunda önerilen metodlar olarak kullanılan Regresyon analizi ve LSTM analizi metodlarının, EPDK ‘nın yayımlanmış olduğu tahminleme metodolojisine göre daha başarılı sonuçlar elde ettiği gözlemlenmektedir.

Bu tez çalışmasında, literatüre istinaden, abonelere ait güç tüketim değerleri (kWh) kullanmıştır. Önerilen metodların başarı yüzdesinin, literatürdeki başarı yüzdesinden daha düşük sonuçlar elde etmesi; veri setlerinin yapısal farklılıklarından , kullanılan tahminleme metodlarının farklılıklarından kaynaklanmaktadır. Ayrıca literatür çalışmasında gerçekleştirilen çalışmalarda, endeks değerleri üzerinde çalışılmış ve mevsimsellik katsayısı da bulunulan lokasyon itibari ile hesaplamalara dahil edilmiştir.

5. SONUÇ

Günümüzde, abonelerin büyük bir bölümünün tüketim bilgisinin abonelik sayaçlarından, otomatik sayaç okuma sistemi (OSOS) ile uzaktan yapılabildiği ve büyük bir bölümünün de tüketim bilgisinin, elektrik dağıtım personelleri tarafından, manuel bir şekilde sayaçlarından okuma yapılarak tespit edildiği bilinmektedir. Yine büyük bir bölümünün ise, abonelik sayaçlarından okuma yapılamamasından dolayı elektriksel tüketimi tespit edilememektedir.

Buna önlem olarak geliştirilen EPDK tahmin metodolojisine ek olarak, bu tez çalışmasında da bu sorun ele alınmış ve okuma yapılamamış abonelerin tüketim bilgilerinin, makine yöntemleri ile tahmin edilmesi amaçlanmıştır.

Bu tez çalışmasında, hata belirleme faktörü olarak belirlenmiş olan RMSE değerlerine göre elde edilen başarılar kıyaslanmıştır. Makine öğrenmesi yöntemlerinden, regresyon analizi ve LSTM analizi yöntemleri kullanılmış ve en iyi tahmin modelinin elde edilmesi amaçlanmıştır.

Bu tez çalışmasındaki sonuçlar incelendiğinde; veri setlerinde gerçekleştirilen filtreleme işlemleri sonucunda, RMSE değerlerinin hem regresyon analizinde hem de LSTM analizi yöntemi ile oluşturulmuş olan öznelik matrisinin, klasik regresyon yöntemlerinin uygulanması sonucunda, tahmin hatasının giderek "0" değerine daha çok yakınsama eğilimi gösterdiği gözlemlenmiştir. Hem regresyon analizi hem de LSTM analizi yönteminin, kendi içlerinde karşılaştırması yapılırken, aynı zamanda klasik normalizasyon işleminin de maksimum normalizasyon işlemlerinin karşılaştırılması da her veri seti için, ayrıca yapılmıştır. Bu karşılaştırmaya istinaden de, bu veri setleri için maksimum normalizasyon işleminin, klasik normalizasyon işlemine göre daha performanslı olduğu gözlemlenmiştir. Ana veri seti (A veri seti), B, C ve D veri setleri de kendi içlerinde karşılaştırıldığında, veri setlerinde gerçekleştirilen filtreleme işlemlerinin performansı arttırdığı ve LSTM analizi yapısının da, regresyon analizi yapısına göre başarı şansını giderek arttırdığı çalışmalara istinaden gözlemlenmiştir. Ancak veri setlerinde gerçekleştirilebilecek olan ek filtreleme işlemlerinin, veri setinin ana yapısını bozabileceği öngörüsünden kaynaklı olarak ilave filtreleme işlemleri gerçekleştirilmemiştir.

Yapılan çalışmalar sonucunda hem regresyon analizi metodunun hem de LSTM analizi metodunun EPDK 'nın yayımlamış olduğu tahminleme metodolojisi yöntemlerinden daha performanslı tahminlerde bulunduğu ve başarı oranlarının da yüksek olduğu gözlemlenmiştir.

Gelecek alıřmalarda, tüketicileri daha düzenli olan abonelerin seçilmesi ve 2 yıldan fazla sürecin ele alındığı dönemlerin seçilebilmesi, tahminleme işleminin daha başarılı olması sonucunu ortaya çıkarabilir. Mevsimsellik katsayısının, hesaplama işlemlerine dahil edilmesinin, performansın artırılmasına olanak sağlayacağı öngörülmektedir. Bu olanak sayesinde daha hassas ölçümlerin yapılabileceđi ve başarı yüzdesinin artırılabilceđi öngörülmektedir. Ayrıca veri setlerinin mevsimsel dönemlere bölünmesinin, daha performanslı tahminleme işlemi gerçekleřtirebileceđi ve mevsimlere göre tahmin de yapabileceđi öngörülmektedir.

Son olarak, bu tez alıřmasında önerilen tahminleme yöntemlerinin, öncelikle büyük şehirler için kullanılmayıp, pilot bölge olarak belirlenebilecek herhangi bir kırsal alanda veya az sayıda mesken aboneli bulunan bir mahallede (veya sadece okuması daha zor yapılan bölgeler de) uygulanabileceđi, önerilmektedir.

6. KAYNAKLAR

- [1]. Elektrik Nedir? [Online]. Available: elektrikport.com/makale-detay/elektrik-bolum
- [2]. Elektriğin Tarihçesi. [Online]. Available: elektrikrehberiniz.com/eletrik/elektrigin-tarihcesi
- [3]. Elektrik Nedir? [Online]. Available: nedir.com/elektrik
- [4]. Elektrik Evlerimize Nasıl Gelir? [Online]. Available: elektrikinfo.com/elektrik-nasil-uretilir
- [5]. Türkiye’de Elektriğin Tarihi. [Online]. Available: wikipedia.org
- [6]. Türkiye’de Elektrik Enerjisi Gelişiminin Kısa Tarihçesi. [Online]. Available: emo.org.tr
- [7]. Türkiye Elektrik Enerjisi Üretim İstatistikleri: Ekim 2021. [Online]. Available: enerjiportali.com/turkiye-elektrik-enerjisi-uretim-istatistikleri-ekim-2021/
- [8]. Türkiye Enterkonnekte Şebeke Haritası. [Online]. Available: emo.org.tr
- [9]. Türkiye Elektrik Dağıtım. [Online]. Available: wikipedia.org/wiki
- [10]. Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ) [Online]. Available: tedas.gov.tr
- [11]. TEDAŞ Özelleştirilmesi [Online]. Available: dergipark.org.tr/en/download/article-file/201843
- [12]. Elektrik Dağıtım Şirketleri Coğrafi Dağılımı Haritası. [Online]. Available: enerjibes.com/elektrik-dagitim-sirketleri/

- [13]. Tüketici Hizmetleri Yönetmeliği – 20.01.2021 [Online]. Available: [enerjibes.com/ elektrik-dagitim-sirketleri/](http://enerjibes.com/elektrik-dagitim-sirketleri/)
- [14]. Tahmini Tüketim Değeri Belirleme Metodolojisi [Online]. Available: epdk.gov.tr
- [15]. V. ATEŞ, “Türkiye’nin Kısa Dönemli Saatlik Bazda Elektrik Tüketiminin Yapay Zeka Teknikleri Kullanılarak Tahmin Edilmesi”, Doktora Tezi, Kırıkkale Üniversitesi, 2019
- [16]. E. DORUK, “Sakarya Bölgesi Hane Halkı Elektrik Tüketiminin Dinamik Lineer Model ile Tahmini”, Yüksek Lisans Tezi, Sakarya Üniversitesi, 2019
- [17]. Y.ŞAHİN,” Gelecek Dönemlere Ait Türkiye Elektrik Tüketimi Tahmininde Yapay Sinir Ağları Modelinin Kullanılması”, Yüksek Lisans Tezi, Marmara Üniversitesi, 2020
- [18]. T.AKMAN, “Yapay Zeka Modelleri Kullanarak Ankara Bölgesinin Kısa Dönem Elektrik Enerjisi Yük Tahmini, Yüksek Lisans Tezi, Gazi Üniversitesi, 2018
- [19]. G.ÖZLÜ, “Yapay Arı Kolonisi Algoritması İle Kayseri ve Civarı elektrik Tüketim Verilerinin Analizi”, Yüksek Lisans Tezi, Kayseri Erciyes Üniversitesi, 2018
- [20]. Yapay Zeka Nedir 1. Bölüm. [Online]. Available: elektrikport.com/makale-detay/yapay-zeka-nedir-serisi-1-bolum
- [21]. Yapay Zeka. [Online]. Available: sas.com/tr_tr/insights/analytics/yapay-zeka-nedir.html
- [22]. Makine Öğrenmesi. [Online]. Available: turhst.com/blog/makine-ogrenmesi-machine-learning-nedir
- [23]. Hafez Ahmad. (2019). Machine Learning Applications In Oceanography. Aquatic Research Available: academia.edu/Machine_learning_applications_in_oceanography

- [24]. Dr. Erol Eğriođlu, Doç.Dr. Ufuk Yolcu, Doç.Dr. Eren Bař, “Yapay Sinir Ađları Öngör ve Tahmin Uygulamaları”, Türkiye, 2020.
- [25]. Yapay Sinir Ađı (Artificial Neural Network) Nedir? [Online]. Available: veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/
- [26]. Yapay Sinir Ađı ve Biyolojik Sinir Ađı. [Online]. Available medium.com
- [27]. Yapay Sinir Ađı Nedir? [Online]. Available: medium.com
- [28]. Abdulkadir Őeker, Banu Diri, Hasan Hüseyin Balık. (2017). “Derin Öđrenme Yöntemleri ve Uygulamaları Hakkında”. Cumhuriyet Üniversitesi Bilgisayar Mühendisliđi Bölümü Available: dergipark.org.tr
- [29]. Deep Learning? [Online]. Available: turhust.com/blog/deep-learning-nedir/#serp
- [30]. Yapay Zeka, Makine Öđrenimi ve Derin Öđrenme Nedir? [Online]. Available: elektrikport.com/teknik-kutuphane/yapay-zek%C3%A2-makine-ogrenimi-ve-derin-ogrenme-nedir/21774#ad-image-0
- [31]. Derin Öđrenme Yöntemleri ve Uygulamaları – ALİ ONAR. [Online]. Available: alitunacanonar.medium.com/derin-ogrenme-yontemleri-ve-uygulamaları
- [32]. Necmesttin Çarkacı, 2018. “Derin Öđrenme Uygulamalarında En Sık Kullanılan Hiper-Parametreler, Türkiye, [Online]. Available: medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4
- [33]. What Is Regression Analysis? [Online]. Available: corporatefinanceinstitute.com/resources/knowledge/finance/regression-analysis/

- [34]. Regression Analysis. [Online]. Available: wikipedia.org/wiki/Regresyon_analizi
- [35]. Regresyon Nedir, Nerede Kullanılır? [Online]. Available: [bulutistan.com / blog/regresyon](https://bulutistan.com/blog/regresyon)
- [36]. Multiple Linear Regression. [Online]. Available: [scribbr.com /statistics/multiple-linear-regression/](https://scribbr.com/statistics/multiple-linear-regression/)
- [37]. Nonlinear Regression. [Online]. Available: [wikipedia.org/ wiki/ Nonlinear _regrssion](https://wikipedia.org/wiki/Nonlinear_regrssion)
- [38]. What Is Nonlinear Regression? [Online]. Available: [corporatefinanceinstitute.com /resources /knowledge/ other/nonlinear-regression/](https://corporatefinanceinstitute.com/resources/knowledge/other/nonlinear-regression/)
- [39]. Regresyon Analizi II. [Online]. Available: [hosting.com.tr/blog/regresyon-analizi/blog /regresyon-analizi/](https://hosting.com.tr/blog/regresyon-analizi/blog/regresyon-analizi/)
- [40]. Yinelemeli Sinir Ağı (RNN) Nedir? [Online]. Available: [elektrikport.com/teknik-kutuphane/yinelemeli-sinir-aglari-\(rnn\)-nedir/23277#ad-image-0](https://elektrikport.com/teknik-kutuphane/yinelemeli-sinir-aglari-(rnn)-nedir/23277#ad-image-0)
- [41]. Recurrent Neural Networks-RNN(Yinelemeli Sinir Ağları). [Online]. Available: medium.com/recurrent-neural-networks-rnn-yinelemeli-sinir-aglari
- [42]. RNN Nedir? Nasıl Çalışır? [Online]. Available: medium.com
- [43]. What is LSTM? Introduction to Long Short Term Memory. [Online]. Available: intellipaat.com/blog/what-is-lstm/
- [44]. Yinelemeli Sinir Ağları (RNN) Nedir? [Online]. Available: [elektrikport.com/teknik-kutuphane/yinelemeli-sinir-aglari-\(rnn\)-nedir/23277#ad-image-0](https://elektrikport.com/teknik-kutuphane/yinelemeli-sinir-aglari-(rnn)-nedir/23277#ad-image-0)
- [45]. Long-Short Term Memory. [Online]. Available: [wikipedia.org/ wiki/ Uzun_k %C4%B1sa_s%C3%BCreli_bellek](https://wikipedia.org/wiki/Uzun_k%C4%B1sa_s%C3%BCreli_bellek)

- [46]. LSTM Nedir? Nasıl Çalışır? [Online]. Available: [medium.com/lstm-nedir nas%C4%B1l-%C3%A7al%C4%B1%C5%9F%C4%B1r-326866fd8869](https://medium.com/lstm-nedir-nas%C4%B1l-%C3%A7al%C4%B1%C5%9F%C4%B1r-326866fd8869)
- [47]. Structure of The LSTM. [Online]. Available: [researchgate.net/ figure/Structure-of-the-LSTM-cell-and-equations-that-describe-the-gates-of-an-LSTM- cell_fig5_329362532](https://researchgate.net/figure/Structure-of-the-LSTM-cell-and-equations-that-describe-the-gates-of-an-LSTM-cell_fig5_329362532)
- [48]. [RMSE] Kök Ortalama Kare Hata (Root Mean Square Error). [Online]. Available: veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/
- [49]. Root Mean Square Deviation. [Online]. Available: wikipedia.org/wiki/Root-mean-square_deviation
- [50]. What is Root Mean Square Error (RMSE)? [Online]. Available: statisticshowto.com/probability-and-statistics/regression-analysis/rmse-root-mean-square-error/