



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



YÜKSEK LİSANS TEZİ

**KONUTLARDA ENERJİ TÜKETİMİ KESTİRİMİ İÇİN DERİN
ÖĞRENME VE MAKİNE ÖĞRENME YÖNTEMLERİNİN
KARŞILAŞTIRILMASI**

Erol YAVUZ

**DANIŞMAN
Doç. Dr. Aysel ERSOY YILMAZ**

Elektrik-Elektronik Mühendisliği Anabilim Dalı


Elektrik-Elektronik Mühendisliği Programı

İSTANBUL-2020

Bu çalışma, 6.03.2020 tarihinde aşığıdaki jüri tarafından Elektrik-Elektronik Mühendisliğı Anabilim Dalı, Elektrik-Elektronik Mühendisliğı Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi


Doç. Dr. Aysel ERSOY YILMAZ (Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi


Dr. Öğr. Üyesi Emrah DOKUR
Bilecik Şeyh Edebali Üniversitesi
Mühendislik Fakültesi


Dr. Öğr. Üyesi Abdurrahim AKGÜNDOĞDU
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi



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

ÖNSÖZ

Tez çalışmam boyunca her türlü konuda bana yardımcı olan ve desteğini esirgemeyen değerli hocam Doç. Dr. Aysel ERSOY YILMAZ'a sonsuz teşekkürlerimi sunarım.

Hayatımın her anında olduğu gibi, eğitim hayatım boyunca da beni destekledikleri ve yanımda oldukları için değerli anneme ve babama çok teşekkür ederim. Ayrıca zorlu süreçlerde her zaman yanımda olarak desteğini eksik etmeyen eşim Meryem YAVUZ'a teşekkür ederim.

Erol YAVUZ

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ.....	ix
ÖZET	xi
SUMMARY	xiii
1. GİRİŞ	1
2. GENEL KISIMLAR	3
2.1. AKILLI ŞEBEKE	3
2.1.1. Akıllı Şebekelerinin Faydaları.....	3
2.1.2. Akıllı Şebekelerde Olması Gereken Özellikler	4
2.1.3. Akıllı Şebekelerin Amaçları	4
2.1.4. Geleneksel Şebeke ve Akıllı Şebekenin Karşılaştırılması.....	5
2.1.5. Akıllı Şebekelerin Modellemesinde Kullanılan Yöntemleri	6
2.1.6. Akıllı Şebekelerin Haberleşmesinde Kullanılan Yöntemler	7
2.2. LİTERATÜR TARAMASI.....	8
2.3. ENERJİ TÜKETİMİ HESAPLAMALARI	12
2.4. MAKİNE ÖĞRENME	14
2.4.1. Makine Öğrenmenin Tarihçesi	15
2.4.2. Denetimli Öğrenme	16
2.4.3. Denetimsiz Öğrenme	16
2.4.4. Yarı Denetimli Öğrenme	17
2.4.5. Takviyeli Öğrenme	17
2.5. DERİN ÖĞRENME	17
2.5.1. Derin Öğrenmenin Tarihçesi	18
2.5.2. Derin Öğrenme Mimarileri.....	20
2.5.2.1. Evrişimli Sinir Ağları.....	20
2.5.2.2. Tekrarlayan Sinir Ağları.....	21
2.5.2.3. Kısıtlı Boltzman Makineleri	22

2.5.2.4. Derin Oto-Kodlayıcılar	23
2.5.3. Derin Öğrenme Kullanım Alanları	23
3. MALZEME VE YÖNTEM.....	25
3.1. VERİ SETİ.....	25
3.2. MAKİNE ÖĞRENME ALGORİTMALARININ UYGULANMASI.....	29
3.2.1. Rastgele Orman (Random Forest, RF) Algoritmasının Uygulanması.....	29
3.2.2. K-En Yakın Komşular Regresyonu (K-Nearest Neighbours Regression, KNN) Algoritmasının Uygulanması.....	30
3.2.3. Doğrusal Regresyon (Linear Regression, LR) Algoritmasının Uygulanması.....	30
3.3. DERİN ÖĞRENME ALGORİTMALARININ UYGULANMASI.....	31
3.3.1. CNN Algoritmasının Uygulanması	31
3.3.2. LSTM Ağı Algoritmasının Uygulanması.....	32
3.4. DEĞERLENDİRME ÖLÇÜTLERİ.....	33
3.4.1. Kök Ortalama Hata Karesi (RMSE).....	33
3.4.2. Ortalama Hata Karesi (MSE)	33
3.4.3. Doğruluk Oranı (Accuracy).....	33
4. BULGULAR.....	34
5. TARTIŞMA VE SONUÇ	40
KAYNAKLAR.....	43
ÖZGEÇMİŞ	49

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1: Akıllı Sistemler	3
Şekil 2.2: Makine Öğrenmesi [35].	15
Şekil 2.3: Derin Öğrenme, Makine Öğrenmesi ve Yapay Z. Arasındaki İlişki [39].	18
Şekil 2.4: Ivankhnenko A. tarafından eğitilen bilinen ilk derin ağ mimarisi [41].	18
Şekil 2.5: Evrişimli Sinir Ağları Mimarisi [50].	20
Şekil 2.6: Tekrarlayan Sinir Ağları Mimarisi [52].	21
Şekil 2.7: Kısıtlı Boltzman Makinelerinin Mimarisi [54].	22
Şekil 2.8: Derin Oto-Kodlayıcı Algoritma Şeması [55].	23
Şekil 3.1: Veri Önizleme Aşamasından Sonraki Gerçek Günlük Elektrik Güç Tüketim Grafiği.....	26
Şekil 3.2: CNN Modelinin Katmanları.....	32
Şekil 3.3: LSTM Modelinin Katmanları	32
Şekil 4.1: LSTM Modeli Kayıp Oranı Grafiği	38
Şekil 4.2: Gerçek Veri ile LSTM Tahmin Değerlerinin Karşılaştırılması.	38
Şekil 4.3: Gerçek Veri ile KNN Tahmin (Haftalık) Değerlerinin Karşılaştırılması.....	39
Şekil 4.4: 10 Katlı Çapraz Doğrulama İşleminin Elde Edilen Doğruluk Oranları	39

TABLO LİSTESİ

	Sayfa No
Tablo 2.1: Geleneksel ve Akıllı Şebekelerin Karşılaştırılması [12].....	5
Tablo 2.2: Akıllı Şebekelerde Kullanılan Haberleşme Teknolojileri [6].	7
Tablo 2.3: Elektrik İç Tesisleri Yönetmeliğine Göre Eşzamanlılık Katsayıları.....	13
Tablo 3.1. Veri setindeki verilerin max., min. ve ortalama değerleri.....	26
Tablo 3.2: Veri Setinin Özellikleri	27
Tablo 3.3: ADF Testi Sonuçları	29
Tablo 4.1: %90 Eğitim -%10 Test İşlemine Göre Algoritmaların Kıyaslaması.....	34
Tablo 4.2: %80 Eğitim -%20 Test İşlemine Göre Algoritmaların Kıyaslaması.....	35
Tablo 4.3: %67 Eğitim -%33 Test İşlemine Göre Algoritmaların Kıyaslaması.....	36
Tablo 4.4: On katlı Çapraz Doğrulama ile Yapılan İşlemlere Göre Algoritmaların Kıyaslaması	37
Tablo 5.1: Veri Seti Aynı Olan Diğer Makaleler	41

SİMGE VE KISALTMA LİSTESİ

Simgeler

Açıklama

GHz	: Gigahertz frekans
Hz	: Hertz frekans
km	: Kilometre
kW	: Kilowatt
m	: Metre
MHz	: Mikrohertz frekans
MSE	: Kareseel ortalama hata
RMSE	: Kareseel ortalama hatanın karakökü

Kisaltmalar

Açıklama

ANN	: Yapay Sinir Ağı (Artificial Neural Network)
BPNN	: Geri Yayılım Sinir Ağı (Back Propagation Neural Network)
CNN	: Konvolüsyonel Sinir Ağı (Convolutional Neural Network)
CRBM	: Evrişimli Sınırlı Boltzman Makinesi (Convolutional Restricted Boltzmann Machine)
ELM	: Aşırı Makine Öğrenmesi (Extreme Learning of Machine)
FCRBM	: Faktörlü Evrişimli Sınırlı Boltzman Makinesi (Factored Convolutional Restricted Boltzmann Machine)
GRBFNN	: Granüler Radyan Temelli Fonksiyon Sinir Ağı (Granular Radial Basis Function Neural Network)
IoT	: Nesnelerin İnterneti (Internet of Things)

KNN	: K-En Yakın Komşular Regresyonu (K-Nearest Neighbours Regression)
LR	: Doğrusal Regresyon (Linear Regression)
LSTM	: Uzun-Kısa Süreli Bellek (Long- Short Term Memory)
MCMC	: Markov Chain Monte Carlo
MLR	: R Makine Öğrenmesi (Machine Learning in R)
MLP	: Çok Katmanlı Algılayıcı (Multilayer Perceptron)
RF	: Rassal Orman Bağlanım (Random Forest)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SAE	: Seyrek Otomatik Kodlayıcı (Sparse Autoencoder)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
SVR	: Vektör Regresyon Desteği (Support Vector Regression)

ÖZET

KONUTLARDA ENERJİ TÜKETİMİNİN KESTİRİMİ İÇİN DERİN ÖĞRENME VE MAKİNE ÖĞRENME YÖNTEMLERİNİN KARŞILAŞTIRILMASI

YÜKSEK LİSANS TEZİ

Erol YAVUZ

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman : Doç. Dr. Aysel E. YILMAZ

Günümüzde teknoloji gelişmesi ile beraber enerji ihtiyacı gittikçe artmaktadır. Bu enerji talebi artışı doğrultusunda yenilenebilir enerji üretimine önem verilmektedir. Bu yenilenebilir enerjilerin ürettikleri enerjiyi daha kolay sisteme aktarılması gereklidir. Bu yüzden yeni nesil güç sistemleri ile akıllı elektrik şebeke kavramı ortaya çıkmıştır. Akıllı şebekelerde nesnelerin interneti ile birlikte birçok veri elde edilebilmektedir. Akıllı şebekede elde edilen bu büyük veriler, uygun kullanım ve veri çıkarım yapmak için makine öğrenme yöntemleri ve derin öğrenme yöntemleri ile analiz edilmesi gerekmektedir.

Son yıllarda akıllı şebekelerdeki verilerin üzerine makine öğrenme ve derin öğrenme yöntemleri kullanılması hakkında araştırmalar yapılmaya başlamıştır. Bu çalışmalar makine öğrenme ve derin öğrenme yöntemlerinin gerçekten akıllı şebekelerin yönetiminde veya değerlendirilmesinde daha verimli olabileceğini göstermiştir.

Enerji tüketimini tahmin etmek; üretilmesi gereken enerji miktarını, depolanması gereken enerji miktarını hesaplar iken rahatlık sağlayacaktır. Ayrıca nereye, ne zaman ve ne kadar maliyet gerektiğini öngörülmesini sağlayacağından enerji yönetiminde kolaylık sağlayacaktır. Gerekli olduğu zaman tasarruf yöntemleri de daha kolay işleme sokulacaktır. Planlamalar daha sağlıklı ve daha güvenilir olacaktır.

Bu çalışmada temel hedef talep faktörünün düzenlenmesi olmayıp sadece buna yönelik uygulamalarda makine öğrenme ve derin öğrenme yöntemlerinden hangisinin daha verimli olduğunu kestirmeye çalışmaktır. Derin öğrenme algoritması olarak Konvolüsyonel Sinir Ağı ve yapay sinir ağı algoritması olarak Uzun Kısa Süreli Bellek algoritması kullanılmıştır. Makine öğrenme olarak ise Rastgele Orman, K-En Yakın Komşular Regresyonu ve Doğrusal Regresyon algoritmaları kullanılmıştır. Sonuç olarak bu yöntemler kıyaslanarak yapay sinir ağı algoritması olan LSTM, en başarılı olduğu gözlenmiştir.

Mart 2020 64 sayfa.

Anahtar kelimeler: Akıllı sistemler, derin öğrenme, makine öğrenme, enerji tüketimi, yapay sinir ağı

SUMMARY

COMPARISON OF DEEP LEARNING AND MACHINE LEARNING METHODS FOR ESTIMATING ENERGY CONSUMPTION IN HOUSES

M.Sc. THESIS

Erol YAVUZ

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Electrical and Electronic Engineering

Supervisor : Assoc. Prof. Dr. Aysel E. YILMAZ

Energy consumption is increasing by the development of technology. Renewable energy production has regarded more because of increase in energy consumption. It is necessary to transfer easiler to the energy system of the energy produced by renewable energies. So the new generation power systems and smart grid terms have emerged. A lot of data can be obtained with Internet of Things in smart grids. These data need to be analyzed with machine learning methods and deep learning methods to data extraction.

In recent years, researches that use of machine learning and deep learning methods for smart grid has been started. These researches have been showed that the machine learning and the deep learning methods are more efficient for management or evaluation of smart grids.

Estimating of energy consumption will provide comfort while it is calculating the amount of energy production or the amount of stored energy. It will provide convenience in management of energy. Saving methods will be easier. Plans will be healthier and more reliable.

The main objective of this study is not regulation of demand factor but only it is tried to understand which is more effective between machine and deep learning algorithms for applications that being regulation of demand factor. Convolutional Neural Network and Long-Short Term Memory have been used, which are deep learning algorithm and artificial neural networks. So Random Forest, K-Nearest Neighbours Regression and Linear Regression have been used, which are machine learning algorithms. As a result, when these algorithms are classified each other, it is observed that LSTM that is better than others.

March 2020 64 pages

Keywords: Smart grids, machine learning, deep learning, energy consumption, artificial neural networks

1. GİRİŞ

Günümüzde konut ve ticari binalar toplam enerji talebinin %30-%40'nı oluşturmaktadır [1]. Mevcut eğilimler gelecekte bu oranın daha da artacağını göstermektedir. Enerji talebi artışı doğrultusunda yenilenebilir enerji üretimine ayrıca önem verilmektedir. Bu yenilenebilir enerjilerin ürettikleri enerjiyi daha kolay sisteme aktarılması gereklidir [2]. Bu yüzden mevcut araştırmalar da toplumsal gereklilikleri yerine getirmek için akıllı elektrik şebekelerine odaklanılmıştır. Akıllı şebeke, üretici ile tüketici arasında olan iletişimin daha kolay ve daha hızlı olmasını sağlayan sistemlerdir. [3]. Bu şebekeler ile güç izlenebilir, tahmin edilebilir, zamanlanabilir, öğrenilebilir ve yerel enerji tüketimine göre üretimde karar verilebilir hale gelecektir. Bu şebekeler hem çevresel olarak hem de ekonomik açıdan olumlu sonuçlar ortaya çıkaracaktır. Bu şebekelerin sağladığı başlıca faydalar; elektrik iletim hatları daha kısa olduğu için enerji kaybı olmadan daha verimli elektrik iletimi sağlanması, elektrik kesintilerinde hızlı bir şekilde çözüm bulunması, güvenlik anlamında sabotajlara karşı daha korunaklı olması, yenilenebilir enerji kaynaklarının sisteme entegrasyonu kolaylığı, elektrik arızalarının tespiti ve onarımı sırasında maliyet azalacağından dolayı enerji tüketim birim fiyatının daha az olması vb. dir [4].

Elektrik şebekelerin yönetiminde yapay zekâ kullanılması planlamaların ve sürekli değişen güç kaynağının gerçek zamanlı kontrolünün yönetimini kolaylaştıracaktır. Bu sebeple son zamanlarda bu konu hakkında daha çok çalışma yapılmaktadır [5]. Ayrıca derin öğrenme ve makine öğrenme uygulamaları ile enerji tüketimini tahmin edilmesi üzerine de incelemeler mevcuttur. Bu çalışmalar sayesinde gelecekteki elektrik şebekelerinin belirli bir zamanda enerji tüketimini tahmin etme özelliği olacaktır. Yalnızca toplam talebi değil bina bazlı tüketimi tahmin etmek kullanıcılara enerji tasarrufu imkânı doğuracaktır. Geleneksel olarak tahmin 4 kategoride toplanır:

- 1- Çok kısa vadeli tahminler (1 günden kısa)
- 2- Kısa vadeli tahminler (1 gün - 1 hafta arası)
- 3- Orta vadeli tahminler (1 hafta - 1 yıl arası)
- 4- Uzun vadeli tahminler (1 yıldan uzun)

Binaların enerji tahmini çok sayıda farklı etken (iklim koşulları, tüketicinin kullandığı cihazlar, kullanım sıklığı, vb.) bağımlı olduğu için zor bir problemdir. Binanın enerji davranışının karmaşıklığı ve etkileyen faktörlerdeki belirsizlik, sık sık dalgalanmalara neden olur. Bu dalgalanmalar bina mimarisinden de kaynaklanmaktadır. Binalarda kullanılan malzemelerin fiziksel özellikleri ve davranışları, iklim şartları, aydınlatmalar ve havalandırma sistemleri gibi birçok etken bulunmaktadır. Enerjinin doğru ve sağlam bir şekilde tahmin edilmesi için literatür de birçok yaklaşım vardır. Genel olarak iki çeşide ayrılabilir. İlk tip fiziksel prensiplere yani binadaki ısı dinamikleri ve enerji davranışına göre ortaya koyan yaklaşımdır. Bu yaklaşımda; klima, fotovoltaik sistemler, insanların davranışları, iç-dış mekân iklimi, fiyat duyarlılığı vb. İkinci tip istatistiksel yöntemlere dayanmaktadır. Bu yöntemler bina enerji tüketimlerini ilişkilendirerek tahmin etmek için kullanılan yöntemdir. Hava durumu ve enerji fiyatları gibi değişkenler kullanılır [4].

Enerji tüketimini tahmin etmek; üretilmesi gereken enerji miktarını, depolanması gereken enerji miktarını hesaplar iken kolaylık sağlayacaktır. Ayrıca nereye, ne zaman ve ne kadar maliyet gerektiğinin öngörülmesini sağlayacağından enerji yönetiminde hızlı kararlar alınmasına olanak verecektir. Bu şekilde zaman tasarruf yöntemleri de daha kolay işleme sokulacaktır. Geleceğe yönelik programlamalar daha sağlıklı ve daha güvenilir olacaktır.


Bu çalışmada akıllı sistemlerin kullanıldığı bir konutun açık veri olarak paylaşılan ölçüm değerleri kullanılmak suretiyle enerji tüketim tahmini derin öğrenme ve makine öğrenme yöntemleri ile karşılaştırmalı olarak incelenmiştir. Bu çalışmada ki motivasyonumuz talep faktörü bulmak değildir. Tüketim kestirimi yapmak için tüketim verilerini kullanarak en verimli yöntemi ortaya koymaktır.

2. GENEL KISIMLAR

2.1. AKILLI ŐEBEKE

Yarı iletken teknolojilerinde, haberleşme ve kontrol alanlarındaki çalışmalar mevcuttaki elektrik şebekelerin dijital bir yapıya dönüşmesine yardımcı olmuştur. Böylece elektrik enerjisinin üretiminden son kullanıcı dağıtım noktasına kadar elektrik şebekesinin her aşamasında gelişen teknolojiler kullanılarak daha verimli, daha güvenilir, daha temiz ve daha yönetilebilir olan akıllı şebeke kavramını doğurmuştur. [6].

Akıllı şebeke, üretici ile tüketici arasında olan iletişimin daha kolay ve daha hızlı olmasını sağlayan sistemlerdir [3]. Akıllı şebeke, akıllı sayaçlar, akıllı cihazlar, yenilenebilir enerji kaynakları ve enerji verimli kaynaklar dahil olmak üzere çeşitli işletme ve enerji önlemleri içeren bir elektrik şebekesidir [7,8].



Őekil 2.1: Akıllı Sistemler

2.1.1. Akıllı Őebekelerinin Faydaları

Yeni şebeke sistemi geleneksel şebeke sistemine göre birçok fayda sağlamaktadır. Hem çevresel hem de ekonomik açıdan son derece faydalıdır. Akıllı şebekenin sağladığı temel faydalar şunlardır [9].

- Enerji kayıpları, iletim hatlarının daha kısa olmasından dolayı yok denecek kadar azdır.
- Elektrik kesintilerinden sonra sistemin daha hızlı iyileşmesi sağlanır.
- Elektrik arızalarının tespiti ile onarımı geleneksel şebekelere göre daha hızlıdır.
- Azalan enerji talebi sebebiyle elektrik fiyatlarının daha düşük olmasını sağlar.
- Yenilenebilir enerji sistemlerinin entegrasyonu geleneksel şebekelere göre daha kolaydır.
- Geleneksel şebekelere göre daha güvenlidir. Sabotajlara karşı sistemi kapatarak kendini koruyabilmektedir.

2.1.2. Akıllı Şebekelerde Olması Gereken Özellikler

Kendini İyileştirme: Şebekedeki elektrik bozukluklarını hızlı bir şekilde denetlemeli ve cevaplamalıdır.

İletişim: Tüketici ve şebeke arasında iki yönlü enerji ve bilgi akışı olmasını sağlamalıdır.

Güvenlik: Şebekedeki güvenliği artırmak için siber ve fiziksel saldırılara karşı daha hızlı cevap vermeli ve insan kaynaklı hataları, doğal felaketleri, güvenlik hataları ve açıklıkları hızlıca belirlemelidir.

Optimizasyon: Yapılan işlemlerde ve bakım maliyetlerinde azalma sağlamalıdır.

Uyumluluk: Merkezi, dağıtık ve yenilenebilir enerji üretimi sağlayan sistemler ve enerji depolama sistemleri ile uyumluluk maksimum olmalıdır [10].

2.1.3. Akıllı Şebekelerin Amaçları

- Dijital bilgi ve sistem elemanlarının daha fazla yer alması
- Dağıtık enerji kaynakların yaygınlaşması, yenilenebilir enerji kaynakların şebekede yer alması
- Akıllı ev aletlerinin şebekenin sistemi ile haberleşmesinin sağlanması
- Depolama akıllı teknolojilerin sisteme dahil edilmesi
- Temiz enerji kaynakları ile enerjinin üretiminin sağlanması
- Tüketici taleplerinde maksimum verim ile sağlanması [11].

2.1.4. Geleneksel Şebeke ve Akıllı Şebekenin Karşılaştırılması

Tablo 2.1: Geleneksel ve Akıllı Şebekelerin Karşılaştırılması [12].

ÖZELLİK	GELENEKSEL ŞEBEKE	AKILLI ŞEBEKE
Kendi Kendine Tamir Özelliği	Daha fazla hasarı önlemek için tepki verir. Odak varlıkların korunması üzerinedir.	Online izleme sağlar ve otomatik sorunlara tepki verir.
Son Kullanıcı İçerme	Son kullanıcılar güç sisteminde söz sahibi değildir.	Son kullanıcılar bilgilendirilir, sisteme dahil edilir ve aktiftir.
Saldırıya Karşı Durumu	Ataklara ve doğal felaketlere karşı korumasızdır.	Ataklara ve doğal felaketlere karşı korunaklıdır.
21.yüzyıl İhtiyaçları için Güç Kalitesi Sağlaması	Kesinti sorunları güç kalitesi sorunlarına göre daha önemli sorunlardır.	Güç kalitesi endüstri standartlarını sağlamaktadır.
Üretim ve Depolama Seçeneklerin Barındırması	Sistemler küçüktür.	Üretim ve depolamada çok fazla çeşitlilik vardır.
Pazar Sağlaması	Pazar durumu kısıtlıdır ve iletimdeki tıkanıklık ve kısıtlamalar mevcuttur.	Pazar durumu iyi durumdadır ve iletimdeki tıkanıklık ve kısıtlamalar en aza indirir.
Varlıkların Optimize ve Verimli Çalışması	Varlığın entegrasyonu, yönetim süreçleri ve teknolojiler sınırlıdır. Zamana dayalı bakım mevcuttur.	Varlığın entegrasyonu, yönetim süreçleri ve teknolojiler derindir. Şartlara dayalı bakım mevcuttur.

Çoğu karşıt fikirler akıllı sayaçlar ve onların sağladığı sistemler üzerinde odaklanmıştır. Tüketicinin mahremiyet konusundaki endişeler vardır. Bu endişeleri önlemek için kullanım verilerinin izinsiz kullanımı kanun ile yasaklanmalıdır. Ayrıca elektriğin adil mevcudiyeti hakkında sosyal endişeler de mevcuttur.

Diğer endişelerde aşağıdaki gibidir:

-Karmaşık oran sistemlerinin netliği ve hesap verilebilirliğin ortadan kalkacağı endişesi vardır.

-Akıllı sayaçlara entegre edilmiş, uzaktan kontrol edilebilir sonlandırma anahtarı ile ilgili endişeler mevcuttur.

-Akıllı sayaçlardan gelen RF sinyalleri ile ilgili endişeler mevcuttur.

-Tüm güç kullanım faaliyetlerinin kullanımını kontrol etmek için hükümet mekanizmalarının verilmesiyle ilgili endişeler mevcuttur [13].

2.1.5. Akıllı Şebekelerin Modellemesinde Kullanılan Yöntemleri

Akıllı güç şebekelerini modellemek için birçok farklı yöntem kullanılmıştır. Modellemede kullanılan yöntemler aşağıdaki gibidir [14].

a) Kendilerini doğrulayan ve denetleyen koruma sistemleri:

Pelqim Spahiu ve Ian R.Evans, çalışmalarında trafo bazlı akıllı koruma ve hibrit ünitesi kavramını ortaya koymuştur [15,16]. Yaptıkları çalışmada kontrol ve koruma sisteminin sahip olması gereken bazı önemli tasarım özelliklerini vurgulamışlardır. Aynı zamanda genel proje maliyetini azaltmaya amaçlamışlardır.

b) Kuramoto Osilatörleri:

Kuramoto modeli iyi çalışılmış bir sistemdir. Elektrik şebekesi de bu bağlamda tanımlanmıştır. Amaç, sistemi dengede tutmak veya faz senkronizasyonunu sağlamaktır [17,18].

c) Biyosistemler:

Elektrik şebekeleri, diğer birçok bağlamda biyolojik sistemler ile ilişkilendirilmiştir. Bir çalışmada, elektrik şebekeleri yunus sosyal ağları ile karşılaştırılmıştır [19].

d) Akıllı Şebeke İletişim Ağı:

Ağ simülatörleri, ağ iletişim etkilerini simule etmek için kullanılır. Akıllı ağ aygıtları, uygulamalar ile bir simülatör laboratuvarı kurmayı içerir [20].

e) Nöral Ağlar:

Enerji şebekesi yönetimi için de sinir ağları göz bulunarak bulunmuştur.

f) Maksimum Entropi:

Bu yöntem Shannon'un iletişim ağlarını inceleyen birçok araştırmacının fikirlerine dayanmaktadır [21].

2.1.6. Akıllı Şebekelerin Haberleşmesinde Kullanılan Yöntemler

Akıllı şebekelerin haberleşmesinde kullanılan yöntemler Tablo 2.2. de gösterilmiştir. Bu tabloda bulunan çalışma frekansı hangi teknolojinin hangi frekanslarda çalıştığını belirtmektedir. Tabloda bulunan menzil verisi de kullanılan teknolojinin hangi uzaklıklarda çalıştığına göstermektedir.

Tablo 2.2: Akıllı Şebekelerde Kullanılan Haberleşme Teknolojileri [6].

<i>Teknoloji</i>	<i>Çalışma Frekansı</i>	<i>Veri Hızı</i>	<i>Menzil</i>
GSM	900-1800 MHz	14.4 Kbps'e kadar	1-10 km
GPRS	900-1800 MHz	170 Kbps'e kadar	1-10 km
3G	1.92-1.98 GHz 2.11-2.17 GHz	384 Kbps - 2Mbps	1-10 km
WIMAX	2.5 GHz, 3.5 GHz, 5.8 GHz	75 Mbps'e kadar	10-50km (LOS)

			1-5km (NLOS)
PLC	1-30 MHz	2-3 Mbps	1-3 km
ZigBee	2.4 GHz-868-915 MHz	250 Kbps	30 – 50 m
Z-Wave	868-908 MHz	40 Kbps'e kadar	30 m(iç) 100m(dış)
EnOcen	315-868 MHz	125 Kbps	30 m(iç) 100m(dış)
6loWPAN	868 Mhz- 2.4 Ghz	250 Kbps	10-100m

2.2. LİTERATÜR TARAMASI

Elena Mocanu ve arkadaşları 2015 yılında binalarda enerji tüketiminin derin öğrenme ile hesaplanması hakkında bir makale yayımlamışlardır[4]. Bu çalışmada, enerji tüketiminin tahmini için yeni geliştirilen stokastik modelleri Evrişimli Sınırlı Boltzman Makinesi (CRBM) ve Faktörlü Evrişimli Sınırlı Boltzman Makinesi (FCRBM) kullanılmıştır. Çalışmalar, 1 dakikalık periyotlar ile 4 yıllık süreçte ölçülen bireysel konut müşterisinin veri seti üzerinden yapılmıştır. Tahminlerini 7 farklı senaryo ile uygulamışlardır. Bu senaryolarda Artificial Neural Networks (ANN), Support Vector Machine (SVM), Recurrent Neural Network (RNN), CRBM, FCRBM metotları kullanılmıştır. Senaryolar aşağıdaki gibidir:

Senaryo-1: 1 dakikalık çözüm ile derin öğrenme modellemesi yapılarak 15 dklık enerji tüketiminin tahmin edilmesi.

Senaryo-2: 1 dakikalık çözüm ile derin öğrenme modellemesi yapılarak 1 saatlik enerji tüketiminin tahmin edilmesi.

Senaryo-3: 1 dakikalık çözüm ile derin öğrenme modellemesi yapılarak 1 günlük enerji tüketiminin tahmin edilmesi.

Senaryo-4: 15 dakikalık çözüm ile derin öğrenme modellemesi yapılarak 1 günlük enerji tüketiminin tahmin edilmesi.

Senaryo-5: 15 dakikalık çözüm ile derin öğrenme modellemesi yapılarak 1 haftalık enerji tüketiminin tahmin edilmesi.

Senaryo-6: 1 saatlik çözüm ile derin öğrenme modellemesi yapılarak 1 haftalık enerji tüketiminin tahmin edilmesi.

Senaryo-7: 1 haftalık çözüm ile derin öğrenme modellemesi yapılarak 1 yıllık enerji tüketiminin tahmin edilmesi.

Sonuç olarak; FCRBM son teknoloji tahmin yöntemlerinden (ANN, SVM, RNN, CRBM) daha iyi performans göstermiştir. Yatayda tahmin artırıldığı zaman FCRBM ve CRBM daha güçlü gözükmektedir. Bu metodların hata oranları, ANN metodunun hata oranının yarısı kadardır. İncelenen metodlar karşılaştırılabilir bir veri sunmaktadır ve bu metodları ev ve bina otomasyon sistemlerinde gerçek zamanlı uygulamalarda kullanılabileceği görülmüştür. Toplam aktif gücün tahmininden çok; alt ölçümlerin tahmini yapıp toplayarak toplam aktif ölçüme ulaşmanın daha verimli olduğu gözlemlenmiştir.

Aykut Çakır ve arkadaşları tarafından 2018 yılında “Konutların Günlük Elektrik Güç Tüketimi Tahmini için Uygun Model Seçimi” isimli makale yayımlanmıştır [22]. Bu çalışmada zamana göre farklılık gösteren elektrik güç tüketimini tahmin etmek için mevsimsel etki ve tatil günlerindeki farklılık gösteren enerji tüketimlerini de dikkate alarak makine öğrenme ve yapay sinir ağları yöntemleri kullanılmıştır. Bu makalede kullanılan veride; İngiltere'nin Londra kendinde bulunan 30 farklı eve ait yaklaşık 3 yıllık enerji güç tüketimi bulundurmaktadır. Çalışmanın amacı; bu verileri kullanarak uygun kısa vadeli tüketim tahmin modelini makine öğrenmesi ile bulmaktır. Rassal Orman Bağlanım (RF), Uzun-Kısa Vadeli Bellek (LSTM), yapay sinir ağlarından R-Kare, düzeltilmiş R-Kare kendi aralarında ortalama mutlak hata oranı ile karşılaştırılmıştır. RF en iyi yöntem olduğu gözlemlenmiştir. SVM ve LSTM yöntemleri de umut verici sonuçlar vermesine rağmen RF'ye kıyasla oldukça düşük seviyelerdedir. LSTM zaman serilerinde genel geçer bir yaklaşım olmadığı bu çalışmada gösterilmiştir.

Xiaoou Monica Zhang ve arkadaşları tarafından 2018 yılında “Forecasting Residential Energy Consumption Using Support Vektor Regressions” adlı bir çalışma yapılmıştır [23]. Bu makalede tahmin algoritması olarak SVM modelleme yaklaşımı kullanılmıştır. 15 farklı bireysel kullanıcıların elektrik tüketimleri SVM ile saatlik ve günlük olarak iki çeşit tahmini

yapılmıştır. Bu çalışmada kullanılan elektrik veri seti onbeş farklı haneden alınmış 2014-2016 yıllarına aittir. Özellik seçimi ve veri görselleştirme için keşif veri analizi kullanılmıştır. Elde edilen analizler, konut enerji tüketimini hava durumu, takvim ve kullanım süresi fiyatına göre tahmin etmenin, bazı bireysel konut kullanımları için günlük ve saatlik tahminlerde yeterli doğrulukla uygulanabilir ve güvenilir olduğunu göstermiştir.

Chengdong Li ve arkadaşları 2017 yılında aşırı derin öğrenme yaklaşımı ile binada enerji tüketiminin tahmini isimli bir makale yayımlamışlardır [24]. Daha iyi bina enerji tüketimi tahmin doğruluğu elde etmek için, bu makalede aşırı derin öğrenme yaklaşımı sunulmaktadır. Önerilen yaklaşım, özelliklerinden yararlanmak için SAE ile ELM birleştirilmiştir. ELM doğru tahmin sonuçlarını elde etmek için bir belirleyici iken SAE, bina enerji tüketim özelliklerini çıkarmak için kullanılır. Ayrıca bu çalışmada, birçok popüler makine öğrenme methodları (BPNN, SVR, GRBFNN, MLR gibi) karşılaştırılmıştır. Deneysel sonuçlar ışığında önerilen yöntemin bina enerji tüketiminin farklı durumlarında en iyi tahmin performansına sahip olduğu anlaşılmıştır.

Y.Xu ve arkadaşları 2010 yılında aşırı makine öğrenme kullanarak gerçek zamanlı geçişi kararlılık değerlendirme modeli isimli bir makale yayımlamışlardır [25]. Bu çalışmada ELM modeli sunulmuş ve ELM tabanlı ulaştırma güvenlik kurumu modeli geliştirilmiştir. Önerilen model İngiltere’de 39 otobüs test sistemi üzerinde incelenmiş ve son teknolojiye sahip üç yaklaşımla karşılaştırılmıştır. Similasyon çalışmalarını MATLAB kullanılarak yapılmıştır. Similasyon sonuçları kilobayt zenginleştirmenin yararlarını göstermiştir. Testlerdeki yanlış sınıflandırılmış örnekler incelenmiştir ve makale ayrıca, pratik mühendislik uygulaması sırasında yanlış sınıflandırma riskini azaltmak için de tartışmıştır.

Bei Li ve arkadaşları 2011 yılında akıllı şebeke ortamları için makine öğrenme kullanarak kullanıcı konfor seviyesini tahmin etme isimli bir makale yayımlamışlardır [26]. Bu çalışmada kullanıcıların tercihleri ve alışkanlıklarına göre konfor seviyelerini tahmin etmek için bir metod ortaya atılmıştır. Denetimli makine öğreniminin bu görevle başa çıkmak için uygun olduğu gözlemlenmiştir. Üç algoritmanın performansı karşılaştırılmıştır. SVM, kullanıcıların konfor düzeyini diğerlerinden daha doğru tahmin edebildiği görülmüştür. Proje yönetiminin performansı SVM’nin performansına yakın olduğu gözlenmiştir. SVM, nispeten az miktarda eğitim numunesiyle daha yüksek bir tahmin doğruluğuna ulaşırken, çok katmanlı algılayıcı aynı doğruluk seviyesine ulaşmak için daha fazla eğitim numunesine gerektiği

gözenlenmiştir. Farklı konular için tamin doğruluğu varyansı da karşılaştırılmıştır. SVM ve MLP için tahmin doğruluğunun varyansı yüksek başlayıp sonra daha fazla eğitim örneği eklendiğinde hızla düştüğü görülmüştür.

Mehmet Demirtaş ve arkadaşları 2019 yılında akıllı şebekelerde güneş enerjisi üretiminin zamana bağlı olasılıksal tahmini isimli bir makale yayımlamışlardır [27]. Bu çalışmada araştırmacılar için açık ve ücretsiz bir platform sunan bir proje üzerinden Hollanda için hazırlanmış veri setleri kullanılmıştır. Ülkedeki bütün santrallerden alınan toplam enerji üretimi ve ülke genelindeki meteorolojik ölçüler kullanıldığı için standart sapma artmış ve tahmin edilme aralığı yükselmiştir. Toplamda 361 gün için, saatlik beş farklı ölçüm noktasından elde edilen 43320 veri üzerinde çalışarak analiz yapılmıştır. Panda, numpy, matplotlib, seaborn ve Markov Chain Monte Carlo gibi farklı kütüphaneler ve Python program dili kullanılmıştır. Atmosferik ölçüm verisinde bulut kapalılık oranı, yağış durumu, nem ve çığ gibi bilgileri içermemektedir. Çoklu doğrusal regresyon, Powell optimizasyonu ve Markov Chain Monte Carlo (MCMC) simülasyonlarına dayanan olasılıklı programlama gibi çeşitli yöntemler kullanılmış ve tahmin yetenekleri birbirleriyle karşılaştırılmıştır. Enerji üretimi analitik yaklaşımda %80 doğrulukla tahmin edilmiş ve olasılıksal yaklaşımla %95 doğrulukla tahmin edilmiştir.

Eklas Hossain ve arkadaşları 2019 yılında Akıllı şebekede büyük veri ve makine öğreniminin uygulanması ve ilişkili güvenlik endişeleri isimli bir makele yayımlamışlardır [28]. Bu çalışmada, yeni nesil güç sistemleri ile ortaya çıkan elektrik şebekelerin büyük veri ve makine öğrenmesi konularında detaylı çalışma yapılmıştır. Nesnelerin interneti (IoT) bu elektrik şebekelerin merkezinde yer almaktadır. Nesnelerin internetinden alınan veriler makine öğrenmesi için gayet yeterli verilerdir ve bu verileri elde etmek daha verimli hale gelmektedir. Sonuç olarak; Elektrik şebekelerinin IoT tabanlı akıllı sistemler haline gelmesi büyük faydalar sağlamanın yanında bu zamana kadar olmamış endişelerde ortaya çıkarmaktadır. Akıllı şebekede üretilen büyük veriler, uygun kullanım ve veri çıkarım yapmak için makine öğrenme yöntemleri gibi yöntemler ile analiz yapılması gerekmektedir. Bağlı cihazlar ve ürettikleri veriler de uygun korumanın vazgeçilmez gerekliliklerini ortaya koymaktadır.

Erkan Güneş 2019 yılında İstanbul Üniversitesi-Cerrahpaşa Fen Bilimleri Enstitüsünde Enerji dağıtım sistemleri için tüketicilerin talep faktörünün belirlenmesi isimli bir tez yazmıştır [29]. Bu tezde, Türkiye’de elektrik dağıtım sektöründe, çeşitli hesaplarda kullanılan eşzamanlılık

katsayısının en uygun olan değerini belirlemek için, ölçüm ve analizler ile beraber bir algoritma oluşturulmuştur ve eşzamanlılık katsayısı için yeni bir yöntem önerilmiştir.

Osman Emin Erdem 2019 yılında Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsünde “Makine Öğrenme Teknikleri ile Türkiye’nin Doğalgaz Enerji Tüketiminin Tahminlemesi” isimli bir tez yazmıştır [30]. Bu çalışmada 2010 – 2018 yılları arasında Türkiye’nin aylık olarak doğalgaz tüketimi verisi kullanılmıştır. Bu tüketim verileri kullanarak makine öğrenme yöntemleri ile gelecekte Türkiye’nin ne kadar doğalgaz tüketimi yapacağı tahmin edilmiştir. Yapay sinir ağları, rastgele orman ağacı, regresyon ve zaman serisi isimli yöntemler kendi aralarında karşılaştırılmıştır. En iyi yöntemin yapay sinir ağları olduğu gözlemlenmiştir. Bu yöntemlerin arasında en iyi ikinci yöntem ise regresyon tekniği olarak bulunmuştur. En başarısız olan yöntem ise zaman serileri olduğu elde edilmiştir.

Gürhan Mamaklıoğlu 2019 yılında İstanbul Üniversitesi-Cerrahpaşa Fen Bilimleri Enstitüsünde “Binaların Enerji Tüketiminde Kullanıcı Davranışlarının Modellenmesi” isimli bir tez yazmıştır [31]. Bu çalışmada kullanıcıların davranışları ile farklılaşan enerji tüketimi değerlerini bir matematiksel model oluşturarak tahmin edilmiştir.

Musa Peker ve arkadaşları 2017 yılında “Enerji Tasarflu Bina Tasarımı için Isıtma ve Soğutma Yüklerini Regresyon Tabanlı Makine Öğrenmesi Algoritmaları ile Modelleme” isimli makale yayımlamıştır [32]. Bu çalışmada amaç; konutlardaki ısıtma ve soğutma işlemleri için harcanan yükü tahmin edebilmektir. Sekiz giriş değeri ve iki çıkış değeri olan bir veri seti kullanarak makine öğrenme algoritmaları kullanılmıştır. Makine öğrenme algoritmaları olarak Destek Vektör Makinesi Regresyonu (SVR), Rastgele Orman Regresyonu, En Yakın Komşu Regresyonu, doğrusal regresyon kullanılmıştır ve bu algoritmalar karşılaştırılmıştır. Sonuç olarak kullanılan veri seti için en iyi tahmin eden algoritma Rastgele Orman Regresyonu olduğu gözlemlenmiştir.

2.3. ENERJİ TÜKETİMİ HESAPLAMALARI

Mevcut tüketim hesaplamaları elektrik iç tesisleri yönetmeliğinin 57. maddesine göre yapılmaktadır. Bu yönetmelikte eşzamanlı yükün belirlenmesi aşağıdaki gibi ele alınmıştır.

Eşzamanlı güç, kurulu güç değeri eşzamanlılık katsayısı ile çarpılarak bulunur. Konutlarda kurulu güç aydınlatma gücü, priz gücü ve ev aletlerinin gücünden oluşur.

Konutlardaki kurulu gücün eşzamanlı yükünün belirlenmesinde eşzamanlılık katsayıları aşağıdaki gibidir [29].

-8 kilowatta kadar olan kurulu güç katsayısı: %60

-Geri kalan kısım için katsayı: %40 'tır.

Tablo 2.3: Elektrik İç Tesisleri Yönetmeliğine Göre Eşzamanlılık Katsayıları

Daire Sayısı %	Eş Zamanlı Katsayısı
3-5	45
5-10	43
11-15	41
16-20	39
21-25	36
26-30	34
31-35	31
36-40	29
41-45	28
46-50	26
51-55	25
56-61	24
62 ve 62+	23

Mevcut yönetmeliğe bakıldığı zaman daire eşzamanlılık yükünün belirlenmesinde mesken tüketicilerinin kurulu gücün 8 kilowatta kadar olan %60 ile geri kalanı ise %40 lık bir ön hesap öngörülmüştür.

Örnek olarak 18 kilowatt kurulu güce sahip bir konutun toplam talep gücü aşağıdaki gibi hesaplanır.

Toplam Talep Gücü : $(8 \text{ kilowatt} * 0.6) + (10 \text{ kilowatt} * 0.4) = 8.8 \text{ kilowatt}$ 'tır.

Binadaki daire sayısında 10 olduğu düşünüldüğü zaman Tablo 2.3 de görüldüğü gibi 10 olan kısım %43 ile çarpılır. Bunun sonucunda;

8.8 kilowatt * 0.43=3.784 kilowatttır. 10 daire için toplam talep güç 37.84 kilowatttır.

Bu çalışmada temel hedef talep faktörünün düzenlenmesi olmayıp sadece buna yönelik uygulamalarda makine öğrenme ve derin öğrenme yöntemlerinden hangisinin daha verimli olduğunu kestirmeye çalışmaktır.

2.4. MAKİNE ÖĞRENME

Makine Öğrenmesi; bilgisayarların insanlar gibi öğrenmelerini, davranmalarını ve kendilerini geliştirmelerini sağlayan bilim dalıdır [33]. Makine öğrenmesi ile bilgisayara daha önceki örneklerden edinilmiş tecrübelerin öğretilmesi sağlanmaktadır. Bu sebeple bu olay, tecrübelerden öğrenme olarak nitelendirilebilmektedir. Günümüzde makine öğrenmesi birçok değişik alanda (otomotiv sektörü, eğlence sektörü, pazarlama sektörü, fen bilimleri ve tıp) kullanılmaktadır [34].

Makine öğrenmesinde çözülmek istenen bir problem karşısında takip edilmesi gereken belli başlı temel adımlar bulunmaktadır. Var olan problemin istenilen zamanda ve başarılı bir şekilde çözümlenebilmesi için bu adımları uygulamak önemlidir. Bu süreçte uygulanması gereken adımlar aşağıdaki gibidir [34].

-Problemin Tanımlanması

-Veri Analizi

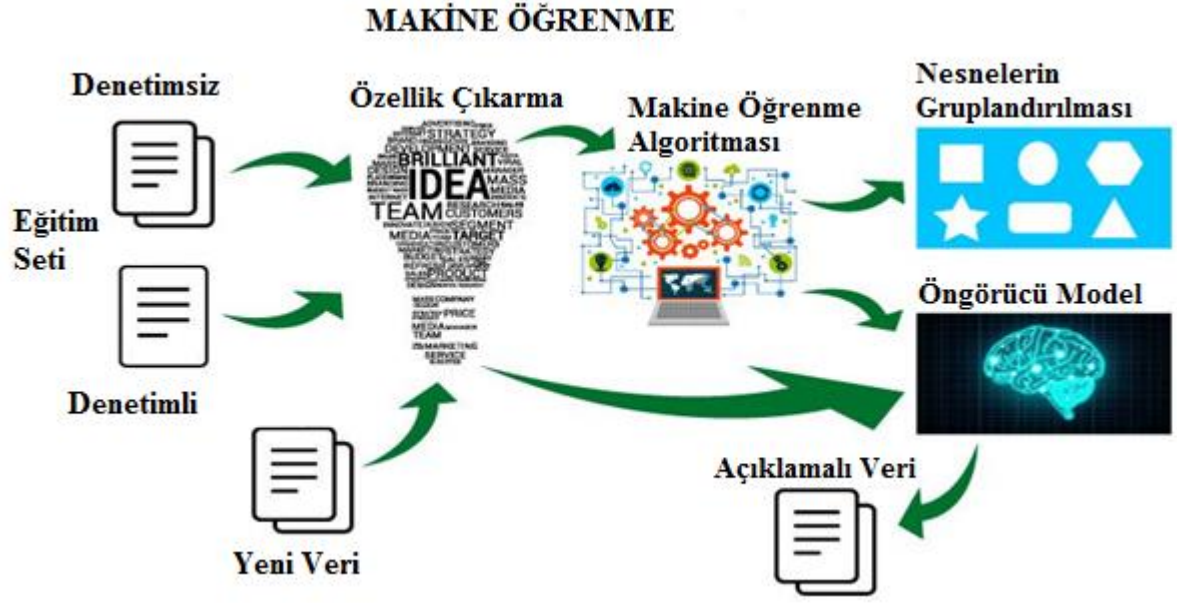
-Verilerin Hazırlanması

-Modelin Kurulması

-Modelin Değerlendirilmesi

-Modelin Kullanılması

Literatürde makine öğrenmesi yöntemleri birçok farklı şekilde sınıflandırılmıştır. Makine öğrenme yöntemleri başta denetimli ve denetimsiz öğrenme olarak ikiye ayrılır iken daha sonra yarı denetimli ve takviyeli öğrenmede eklenerek ana hatlarıyla makine öğrenme yöntemlerinin sınıflandırılması oluşmuştur.



Şekil 2.2: Makine Öğrenmesi [35].

2.4.1. Makine Öğrenmenin Tarihçesi

Sinir ağlarının ilk örneği, 1943'te nörofizyolog Warren McCulloch ve matematikçi Walter Pitts'in nöronlar ve nasıl çalıştıkları hakkında bir yazı yazmasıdır. Bir elektrik devresi kullanarak model oluşturmaya karar vermişler ve makine öğrenmenin temeli olan sinir ağını oluşturmuşlardır.

1950 yılında Alan Turing dünyaca ünlü olan Turing Testini oluşturmuştur. Bu test oldukça basit kurgulanmıştır. Bir bilgisayar bu testi geçebilmesi için, bir insanı bilgisayar olduğuna ikna edebilmelidir.

1952 yılında Arthur Samuel kendi kendine dama oynayan bir bilgisayar programı geliştirdi. 1958 yılında Frank Rosenblatt temel amacı şekil tanıma olan Perceptron adlı ilk yapay sinir ağını tasarladı. Sinir ağının diğer bir örneği ise 1959 yılında Bernard Widrow ve Marcian Hoff iki model tasarladılar. İlki ADELİN olarak adlandırılıyordu ve ikili kalıpları tespit edebiliyordu. Örneğin; bir bit akışında, bir bitten sonra hangi bitin geleceğinin tahmin edilmesidir. Bu modelleme geliştirilerek yeni nesil MADELINE olarak adlandırıldı. Bu modelleme sayesinde telefon hatlarında yankıyı ortadan kaldırabiliyordu ve günümüzde halen bu modelleme kullanılmaktadır.

1982 yılı sinirsel ağılarda ilginin tekrar artmaya başladığı bir yıldır. John Hopfield nöronların çalışma mantığına benzer çift yönlü ağ kurmaya çalıştı. Ayrıca bu yılda Japonya, bölgede daha fazla araştırma yapılan daha gelişmiş sinir ağlarını odaklanıldığını açıkladı. Yapay sinir ağları, gelişmiş sinir ağlarının geri yayılımını kullanır. Bu önemli adım, 1986 yılında Stanford psikoloji bölümünden olan üç araştırmacı tarafından 1962 yılında oluşturulan algoritmayı genişleterek elde edilmiştir. Sinir ağında kullanılacak katmanlar, yavaş öğrenerek ve uzun bir sürede öğrenmektedir.

1980'lerin sonu ve 1990'lerin başında çalışmalar yok denecek kadar azdı. 1997 yılında, satranç oynayan bir bilgisayar olan IBM bilgisayarı Deep Blue, dünya satranç şampiyonunu yendi. O zamandan beri, bu alanda birçok ilerleme kaydedilmiştir [36].

2.4.2. Denetimli Öğrenme

Denetimli Öğrenme; sisteme eğitim veri seti ve test veri setinin yüklenmesi, her bir veri üzerinde gerekli gruplandırmaları yapılması ve bu sayede giren veri seti çıkan veri seti arasında bağlantı kurulmasına dayanan öğrenme yöntemine denir. Temel amacı sonuçları bilinen veri seti sınıflandırarak sonuçları bilinmeyen veri seti üzerinde tahminler bulunmasıdır [37]. Karar ağaçları, destek vektör makineleri, en yakın k-komşu, yapay sinir ağları, genetik algoritmalar, bayes sınıflandırıcılar denetimli öğrenme yöntemlerine örnek olarak verilebilir [34].

Denetimli Öğrenme problemleri iki tür olabilir [38]:

Sınıflandırma: Kategoriler halinde çıktı değişkenlerinin olduğu durumun sonucunu öngörmektir. Örn: Kız – Erkek, Genç – Yaşlı

Regresyon: Verilen değişkenin gerçek değerler biçiminde olduğu belirli bir örneğin sonucunu öngörmektir. Örn: Bir bölgenin yağış miktarı

2.4.3. Denetimsiz Öğrenme

Denetimsiz öğrenme problemlerinde yalnızca girdi değişkenleri vardır, çıktı değişkenleri bulunmaz. Verileri bu yapıya modellemek için kategorisi bulunmayan veri setleri kullanılır. Korelasyon analizi, faktör analizi, kümeleme analizi, kendini düzenleyen haritalar, k-ortalama denetimsiz öğrenmeye örnek olarak verilebilir [34].

Denetimsiz Öğrenme problemleri üç tür olabilir [34].

Birleştirme: Herhangi bir alanda farklı bileşenlerin bir arada olma ihtimali üzerine çalışmalar yapılır. Örneğin; bir müşteri içecek aldıysa %50 ihtimalle çerez alacaktır.

Kümeleme: İlgisiz olan kümedeki örnekleri ayırıp birbirine yakın olan örnekler ile bir araya getirmeye denir.

Boyut Azaltma: Önemli bilgilerin kaybedilmeden veri kümesindeki değişkenlerin sayısını azaltmak anlamına gelir.

2.4.4. Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, eğitim için etiketlenmemiş veriler ile az da olsa etiketlenmiş verileri kullanıp denetimsiz öğrenmeye göre verimi artırılmaya çalışan bir öğrenme sınıfıdır. Çalışmalar sonucunda elde edilen verilere göre denetimsiz öğrenme verileri sınıflandırılmış veri ile ilişkilendirildiğinde öğrenme doğruluğunda önemli iyileşmeler gözlemlenmiştir. Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme arasındadır [34].

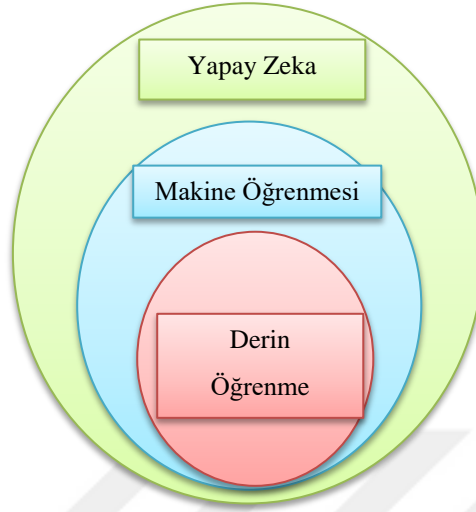
2.4.5. Takviyeli Öğrenme

Birden fazla yöntemi kullanarak mevcut durumdaki en etkili işlemi belirleyip onunla makine öğrenme işlemleri yapılan yöntemdir. Yazılan kodlar, deneme yanılma yöntemleri ile en iyi işlemi öğrenirler. Genel olarak robotik alanda kullanılmaktadır. Örneğin; bir robot engele çarptıktan sonra o alanı öğrenip bir daha ki işlemlerde o alana çarpmaktan kaçınma işlemi takviyeli öğrenmeye örnektir.

2.5. DERİN ÖĞRENME

Derin öğrenme, makinelerin dünyayı algılamasında ve anlamasında kullanılan bir teknolojik gelişmedir. Derin öğrenme, insan beyninin veri işleme ve karar vermede kullanmak için modeller oluşturmadaki çalışmalarını taklit eden yapay bir zeka işlevidir. Derin öğrenme yapay zekanın yapılandırılmamış veya etiketlenmemiş verilerden öğrenebilecek ağlara sahip bir makine öğrenme yöntemidir. Derin sinir öğrenme veya derin sinir ağı olarak da bilinir. Yapay zekanın günümüzde kullanılması için derin öğrenme algoritmaları ile mümkündür. Yapay zekayı eğitmek için hem denetimli hem de denetimsiz öğrenme kullanılabilir. Yapay

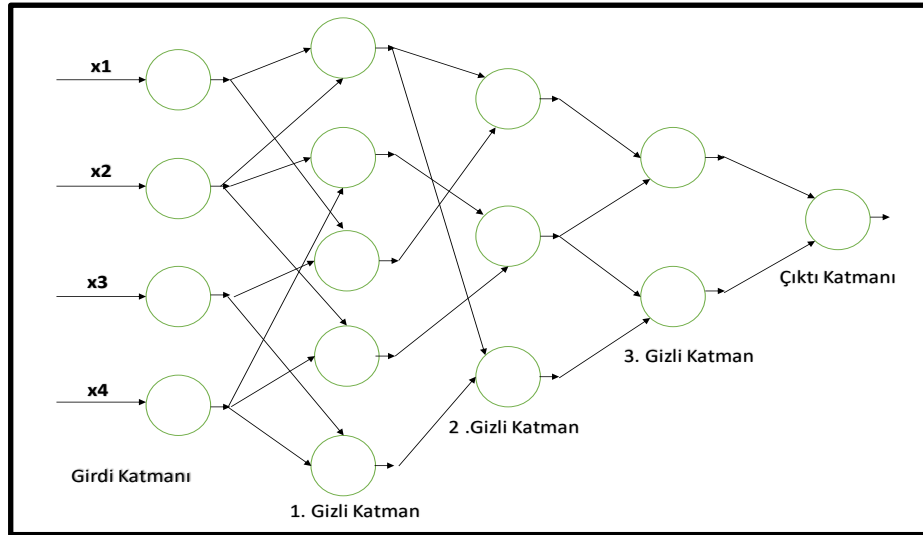
zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki şekildeki gibi görselleştirilebilir [39].



Şekil 2.3: Derin Öğrenme, Makine Öğrenmesi ve Yapay Z. Arasındaki İlişki [39].

2.5.1. Derin Öğrenmenin Tarihçesi

Denetimli derin beslemeli çok katmanlı sinir ağları 1965 yılında Ivahknenko ve Lapa tarafında yayınlanmıştır. Ağlarını uçtan uca eğitmek için geri yayılım kullanılmamış, en küçük kareler yöntemi kullanılmıştır. [40,41].



Şekil 2.4: Ivankhnenko A. tarafından eğitilen bilinen ilk derin ağ mimarisi [41]

Daha sonra “Neokognitron” adlı derin öğrenme mimarisi 1979 yılında Fukushima [42] tarafında ortaya atılmıştır. Bu çalışmada, modern ağlara benzer çoklu bükülme ve havuz katmanlarını içermektedir.

Geri yayılım algoritması başarılı olarak Yann LeCun ve arkadaşları tarafından posta kutusu yazıları üzerinde geliştirmişlerdir. Bu çalışmada, eğitimin üç gün sürmesinden dolayı pratikte uygun olmadığı gözlenmiştir. Bu çalışmadan sonra yine Yann LeCun LeNet ağı ve kıvrımlı ağları kullanarak el yazısı rakamları sınıflandırmıştır.

1995 yılında Brendan Frey, Peter Dayan ve Geoffrey Hinton geliştirdikleri uyanık-uyku algoritmasını kullanarak yüzlerce gizli katman içeren bir ağı, iki günde sürse de eğitilmesi mümkün olduğu gözlemlenmiştir.

1997 yılında Hochreiter ve Schmidhuber’in [43] ortaya attığı tekrarlayan sinir ağları için Uzun Kısa Vadeli Bellek gibi bazı önemli gelişmeler görülmüştür. Destek vektör makineleri gibi probleme özgü çalışan basit modeller, 1990’lı yıllardan 2000’li yıllara kadar daha çok tercih edilmiştir.

2006 yılında Geoffrey Hinton [44], çok katmanlı ileri beslemeli bir sinir ağının her iterasyonda nasıl eğitebildiğini ve denetimli bir geri yayılım yöntemi ile ince ayar yapabileceklerini göstermiştir.

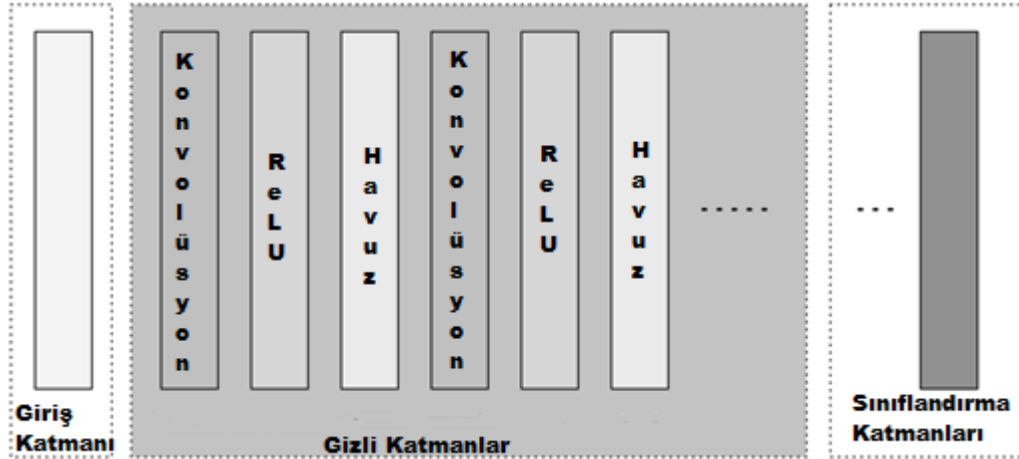
Crisan ve arkadaşları tarafından derin ağların ön-eğitim olmaksızın eğitilebilmesi ile trafik işaretleri, karakter tanıma gibi uygulamalar yapılmıştır. Krizhevsky, Sutskever ve Hinton 2012’de benzer mimariler tasarlamışlardır. Bu çalışmada Grafik işlemci birimi (GPU) destekli çalışmalarda ezberlemeyi azaltmak için dropout normalleştirme yöntemi kullanılmıştır. Dropout yöntemi, ILSVRC-2012 ImageNet yarışmasında olağanüstü sonuçlar göstermiştir.

Bu çalışmalardan sonra Google, Facebook ve Microsoft derin öğrenme konusunda yatırımlar yapmaya başlamışlardır [40].

2.5.2. Derin Öğrenme Mimarileri

2.5.2.1. Evrişimli Sinir Ağları

Izgaraya benzer yapıda olan topolojiye sahip verileri işlemede uzmanlaşmış bir sinir ağı türüdür. Evrişimli sinir ağlarının geçmişi, sayısal modeli oluşmadan önce sinir bilimi deneylerine dayanmaktadır. David Hubel ve Torsten Wiesel tarafından memeli hayvanların görme sistemi hakkındaki çalışmaları evrişimli sinir ağları modelinin en temeli olarak görülmektedir [45]. Evrişimli Sinir Ağı, canlıların görme mekanizmasına benzerliği ile tanınan bir mimaridir [46]. Derin öğrenme algoritmalarından en popülerlerinden biri olan evrişimli sinir ağı; resim, metin, ses ve video verilerini sınıflandırmasını gerçekleştiren bir makine öğrenmesidir [47]. Konvolüsyonel Sinir Ağı (CNN) mimarileri girdi olarak iki boyuta sahip veriler ile çalışmaktadır. Katman tipi olarak üç ana katman kullanılır. Bunlar; evrişimli katmanlar, tamamen bağlı katmanlar ve havuzlama katmanlarıdır [48]. Evrişimli Sinir Ağları mimarisi genel olarak havuzlama katmanı, evrişimli katman, normalizasyon katmanı, tamamen bağlı katmanlar ve aktivasyon katmanından oluşmaktadır. Evrişimli sinir ağlarının öğretilmesinde birçok parametre ile yapılır. Konvolüsyonel Sinir Ağı'nın eğitimi geleneksel geri yayılım algoritması ile yapılır [49].



Şekil 2.5: Evrişimli Sinir Ağları Mimarisi [50].

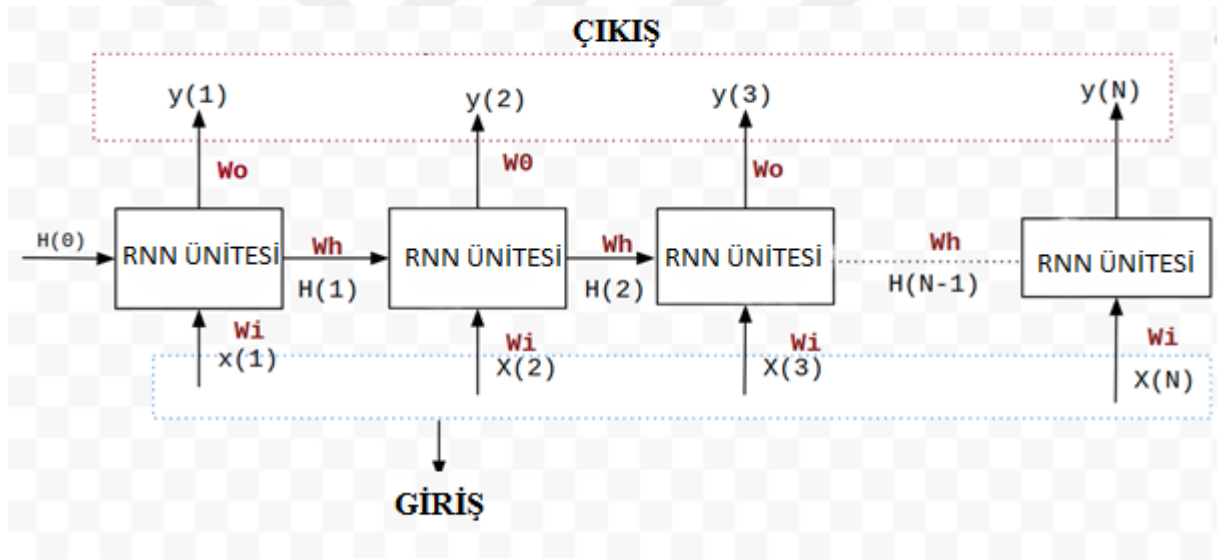
Evrişimli katmanında kullanılan önemli kavramlarından bazıları şunlardır:

- Adım Değeri: Girdi verisi üzerinde çalışırken filtre matrisinin kaç adım kayacağını belirleyen değerdir.

- Çıktı Boyutu: Girdi verisine filtreler uyguladıktan sonra elde edilen çıktı sayısını veren veya gösteren değerdir.
- Filtre Boyutu: Çoğunlukla kare matris olarak seçilen girdi verisi üzerinde uygulanması istenen filtrenin genişlik ve yükseklik değerleridir.
- Dış Boşluk Sayısı: Filtre uygulandıktan sonra girdi ile çıktı boyunu aynı kalmasını sağlamak için 0'lerden oluşan değer sayısını gösterir.
- Kanal Sayısı: Girdi ve filtrenin kaçar kanaldan oluştuklarını gösteren değerdir [51].

2.5.2.2. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları (RNN), giriş dizilerini işlemek için kullanan sinir ağıdır. Bilgilerin tutulmasına izin veren ağlar içlerinde mevcuttur.



Şekil 2.6: Tekrarlayan Sinir Ağları Mimarisi [52].

Şekil 2.6'da görüldüğü gibi, bir tekrarlayan sinir ağları (RNN) ünitesinin çıktısının sadece mevcut girdiye değil, aynı zamanda geçmiş bilgiyi taşıyan önceki gizli durumuna da bağlı olduğu görülecektir. Geçmiş öğrenir ve bağlamı daha iyi anlamasını sağlar. RNN nin bazı sınırları vardır. Bu sınırları aşmak için 2 farklı çeşidi ortaya çıkmıştır. Bunlar; uzun-kısa süreli bellek ve kapılı tekrarlayan birimdir [52].

RNN'nin 3 tipi bulunmaktadır. Bunlar;

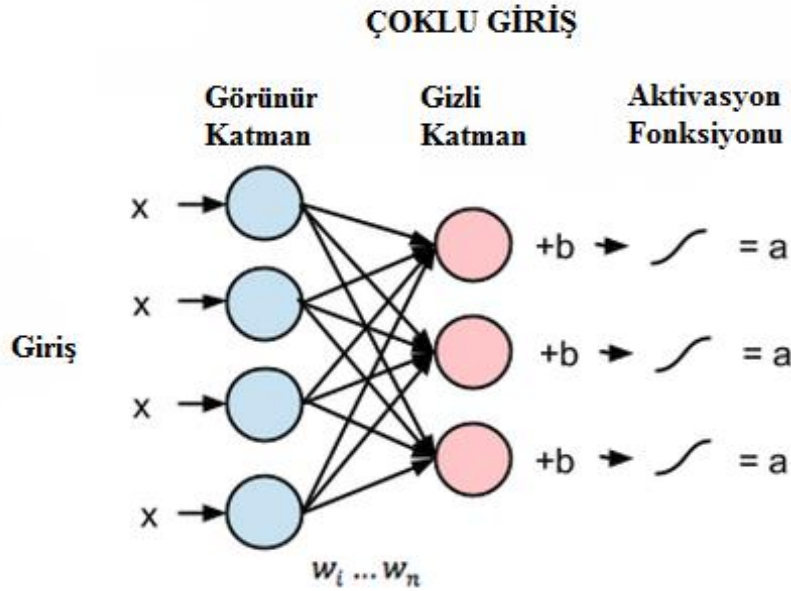
1-Çoktan Aza: Bu tip; uzun veya kısa metinli epostaları analiz ettikten sonra oluşturulan model ile epostanın spam olup olmadığı hakkında karar vermesi gerektiği durumlarda spam filtreleme gibi uygulamalar için kullanılır.

2-Çoktan Çoğa: Bu tip; soru cevaplama, girişin bir dizi olduğu gibi girdilerde çıktının da dizi olarak elde edildiği uygulamalarda kullanılır.

3-Azdan Çoğa: Bu tip; yaygınlıkla şiir üretmek için kullanılan uygulamalarda kullanılır.

2.5.2.3. Kısıtlı Boltzman Makineleri

Kısıtlı Boltzman Makineleri (RBM), girdiler üzerinde olasılık dağılımını öğrenebilen üretken bir sinir ağıdır. RBM, Boltzman makineleri ve Markov rastgele alanlarının özel bir durumudur [53]. Görünür ve gizli birimler arasındaki bağlantılar açısından kısıtlıdır. Bu yüzden kısıtlı boltzman makineleri diye adlandırılmıştır. İki katmanlı bir sinir ağıdır ve bu iki tamamen birbirine bağlıdır [54].




Şekil 2.7: Kısıtlı Boltzman Makinelerinin Mimarisi [54].

Yukarıdaki şekilde çok girdi ile RBM'nin öğrenmesinin ilk adımı görülmektedir. Girişler ağırlıklarla çarpılır ve önyargıya eklenir. Ağırlıklar; giriş sayısı, satır sayısı ve gizli düğüm

sayısı için sütun sayısı olarak bir matris olacaktır. Sonuç daha sonra sigmoid aktivasyon fonksiyonundan geçirilir ve çıkış, gizli durumun aktif edilip edilmeyeceğini belirler [54].

2.5.2.4. Derin Oto-Kodlayıcılar

Hinto ve PDP grup tarafından 1980'li yıllarda ortaya atılan derin oto-kodlayıcılar; girdi verisi olarak aldıkları veriyi çıktı verisi olarak üretmeye çalışan, birden fazla katmana sahip bir sinir ağıdır. Bu sinir ağının amacı; verilen girdiye en yakın çıktı verisini üretecek olan veriye ait önemli yapısal bilgileri içeren fonksiyonun bulunmasıdır. Derin oto-kodlayıcılar, girdi, çıktı ve gizli olmak üzere 3 katmandan oluşmaktadır. Girdi katmanı ile çıktı katmanı yakın olması istenildiği için girdi ve çıktı katmandaki nöronların sayısı eşittir. Gizli katmandaki bulunan nöron sayısı algoritmanın performansını etkilemektedir. Bu nöron sayısı performansa göre istenildiği gibi değiştirilebilir [55].



Şekil 2.8: Derin Oto-Kodlayıcı Algoritma Şeması [55].

2.5.3. Derin Öğrenme Kullanım Alanları

Teknolojinin gelişmesi ile derin öğrenme nerdeyse bütün alanlarda kullanılmaya başlamıştır. Teknoloji geliştikçe derin öğrenme de bu oranla daha çok gelişmektedir. Günümüzde derin öğrenmenin en yaygın uygulamaları aşağıdaki gibidir [56]:

Yüz tanıma: Akıllı telefonlarda kullanılan, yüz tanıma ile kilit açma ve sosyal medyada fotoğrafları etiketlenecek kişinin program ile seçilmesi gibi uygulamalar bu alanda derin öğrenme örnekleridir [56].

Ses tanıma: Telefon bankacılığında, ses algılanarak otomatik olarak hizmetlere yönlendirme işlemleri ses tanıma örneğidir. Bu özellik uzun vadede düşünüldüğünde, elektronik cihazları ile insanlar arasındaki iletişim; ses tanıma özelliği ile devamlı olacağı ve maximum seviyelere çıkacağı öngörülmektedir

Araçlarda kullanım: Otomatik pilot özelliği dışında; şerit tanıma özelliği gibi özellikler de derin öğrenmenin kullanıldığı alanlardan birisidir [56].

Savunma ve güvenlik alanlarında kullanım: Video tanıma özelliği sayesinde güvenlik ve savunma alanlarında çalışan firmalara kolaylık sağlar. Kamera kayıtlarını sürekli kontrol etmek yerine, kayıtları yazılı hale getirip derin öğrenme ile sınıflandırılabilir [56].

Sağlık alanında kullanım: Sağlık sektöründe derin öğrenme kullanımı son 10 yılın uygulama başlıkları arasındadır. Kanseri araştırmalarında, zaman kaybını ortadan kaldırmak için kullanılmaktadır. Kanseri hücre örneklerinin tanıtıldığı derin öğrenme algoritmaları, yeni hücrelerde kanseri olup olmadığını daha hızlı hem de daha başarılı sonuçlar ile ortaya çıkarmaktadır [56].

Enerji sektöründe kullanım: Derin öğrenme ile enerji üretimi veya enerji tüketimini tahmin edilmesine yönelik örnek araştırmalar mevcuttur.

3. MALZEME VE YÖNTEM

Teknolojik gelişmeler sayesinde arařtırmacılar her alanı daha verimli hale getirmek için çalışmalar yapmaktadır. Enerji sektörünü geliřtirmek için de birçok çalışma vardır. Bu çalışmalardan biri olan akıllı řebekeler enerji dağıtımı, yönetimi ve yenilenebilir enerji kaynaklarını üretime eklemesi konusunda kolaylıklar sağlamaktadır.

Bu çalışmanın amacı; derin öğrenme ve makine öğrenmesi ile enerji tüketiminin tahmini yapılarak gelecekteki harcanacak enerji tüketimi hakkında bilgi sahibi olmaktır. Bununla beraber belirlenecek olan model ile enerji tüketiminde tasarruf edilmesine ve hanehalkı harcamalarının planlanmasına katkı sağlanacaktır.

3.1. VERİ SETİ

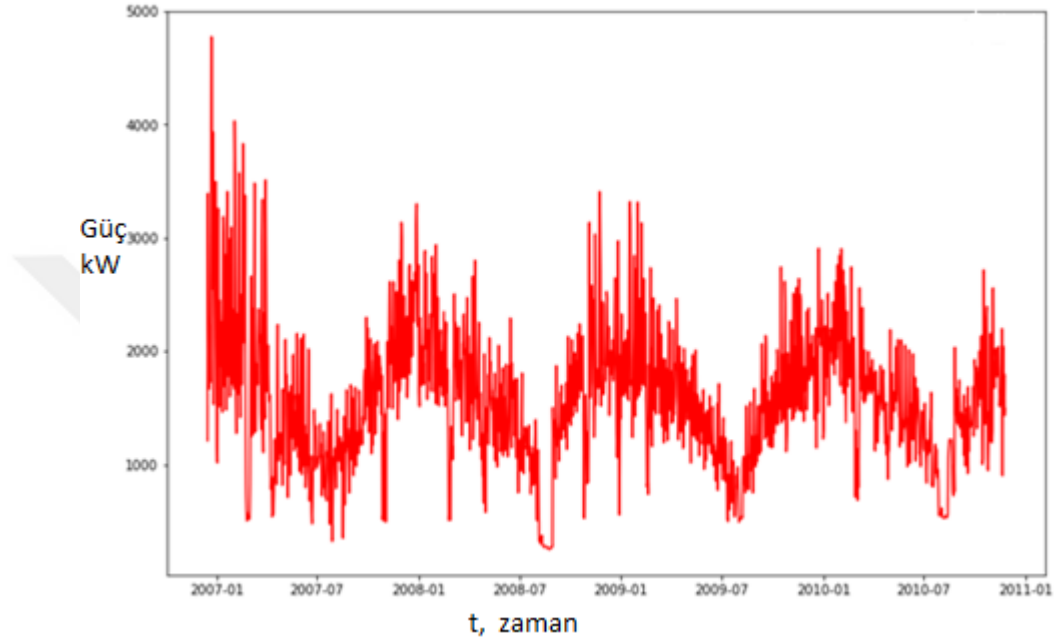
Bu çalışmada kullanılan veriler *UCI Machine Learning Repository* veri tabanından alınan bireysel hane halkı elektrik güç tüketimi (Individual Household Electric Power Consumption) veri kümesine aittir. Veriler, Aralık 2006 ile Kasım 2010 (47 ay) zaman aralığında ve her dakikada bir olacak şekilde Fransa'da bulunan bir evin KW saat türünden elektrik güç tüketimi kayıtları olarak toplanmıştır. Veri seti 2.075.259 adet ölçümü içeren bir zaman serisidir. Bu veriler, gelecekteki elektrik tüketimini modellemek ve aynı zamanda tahmin etmek için kullanılacak zamana bağılı güçle ilgili deęişkenleri temsil eder. Yedi ayrı deęişkenden oluşan bu veri setinden sadece *Global_active_power* olarak adlandırılan hanehalkı tarafından tüketilen toplam aktif güç ölçüm deęerleri (kilowatt) alınmıştır.

Veri setini makine öğrenmesi ve derin öğrenme algoritmaları ile çalışmaya hazır hale getirmek için kullanılacak verinin bir önışlemeden geçirilerek uygun formata dönüřtürülmesi gerekir. Hane halkı elektrik güç tüketimi veri seti ölçümlerde bazı eksik deęerler içermektedir. Örneęin, veri kümesi 28 Nisan 2007'de eksik deęerler göstermektedir. Bu sorunu çözmek için, eksik deęerleri dięer yıllardan gelen dakikalar için güç tüketiminin ortalama deęerleri ile doldurulmuştur ve yeni veri seti olarak kaydedilmiştir.

Veri önışleminin son adımında ise dakikada bir olarak ölçülmüş olan gözlemler kW saat türünden günlük elektrik güç tüketim miktarlarına dönüřtürülmüştür. Yani günlük tahminlerin

yapılması amaçlandığı için güç tüketiminin dakikadaki gözlemleri günlük toplamlara indirgenmiştir. Veri seti toplam 1442 günlük gözlem değerlerinden oluşmaktadır.

Veri önizleme aşamasından sonraki gerçek günlük elektrik güç tüketimleri KW saat cinsinden Şekil 3.1’de gösterilmektedir.



Şekil 3.1: Veri Önizleme Aşamasından Sonraki Gerçek Günlük Elektrik Güç Tüketim Grafiği

Veri setindeki verilerin maximum, minimum ve ortalama değerleri Tablo 3.1’de gösterilmektedir.

Tablo 3.1. Veri setindeki verilerin max., min. ve ortalama değerleri

	Maximum Değer	Minimum Değer	Ortalama Değer
Aktif Güç	11,122	0,122	0,574
Reaktif Güç	1,39	0	0,124
Voltaj	254,15	223,2	240,85
Akım	48,4	0,2	4,62
Alt Ölçüm 1	88	0	1,12

Alt Ölçüm 2	80	0	1,29
Alt Ölçüm 3	31	0	6,45
Alt Ölçüm 4	124,83	-2,4	9,29

Veri setinin günlük değerlere çevirdikten sonraki aktif güç verisinin özellikleri Tablo 3.2’de gösterilmektedir.

Tablo 3.2: Veri Setinin Özellikleri

Veri Seti	1442
Ortalama	1567,839069
Std	597,306856
Minimum	250,298000
25%	1176,195000
50%	1543,253000
75%	1894,467500
Maksimum	4773,386000

Zaman serileri analiz edilirken ilk olarak serinin durağan olup olmadığı kontrol edilmelidir. Zaman serisindeki gözlemlerin ortalaması ve varyansının zaman içinde tutarlı olması yani zamana göre değişmemesi o serinin durağan olduğunu gösterir. Durağan bir zaman serisinde belli bir eğilim veya mevsimsellik yoktur. Bir zaman serisi durağan olduğunda modellemesi daha kolay olabilmektedir. İstatistiksel modelleme yöntemleri, zaman serilerinin etkili olması için durağan olduğunu kabul eder veya gerektirir. Durağan olmayan bir zaman serisinden yapılan gözlemler mevsimsel etkiler, eğilimler ve zaman indeksine bağlı diğer yapıları gösterir. Ortalama ve varyans gibi özet istatistikler zamanla değişebilir ve bir modelin yakalamaya çalıştığı kavramlarda bir kayma sağlar. Klasik zaman serisi analizi ve tahmin yöntemleri, trendleri tanımlayıp kaldırarak ve mevsimsel etkileri kaldırarak durağan olmayan zaman serisi verilerininin sabit kalması ile ilgilidir. Bir zaman serisinin olup olmadığını kontrol etmek için pek çok yöntem vardır.

Grafik: Verilerin zaman serisi grafiđi incelenebilir ve belirgin bir eğilim veya mevsimsellik olup olmadığı görsel olarak kontrol edilebilir.

Özet İstatistikler: Mevsimler veya rastgele bölümler için verilerin özet istatistikleri gözden geçirilebilir ve belirgin veya önemli farklılıklar kontrol edilebilir.

İstatistiksel Testler: Durađanlık beklentilerinin karşılanıp karşılanmadığının kontrol edilmesi için istatistiksel testler kullanılabilir.

İstatistiksel testler veriler hakkında güçlü varsayımlarda bulunur. Bununla birlikte, zaman serilerinin durađan veya durađan olmadığına dair hızlı bir kontrol ve doğrulayıcı kanıt sağlamaktadırlar. Bu çalışmada zaman serisinin durađanlığının kontrolü için Artırılmış Dickey-Fuller testi (Augmented Dickey-Fuller test, ADF) uygulanmıştır. ADF testi, birim kök testi olarak adlandırılan bir tür istatistiksel testtir. Çok sayıda birim kök testi vardır ve ADF testi daha yaygın olarak kullanılanlardan biridir. Bu test otoregresif bir model kullanır ve birden fazla farklı gecikme değerleri arasında bir bilgi kriterini optimize eder.

Testin Sıfır Hipotezi (H0), zaman serilerinin bir birim kökü ile temsil edilebildiđini ve durađan olmadığını göstermektedir. Alternatif hipotez (H1) boş hipotezi reddeder. Zaman serilerinin bir birim kökü ile temsil edilmediđini, yani durađan olduğunu göstermektedir [57].

Bu sonuç testteki p-deđeri ile yorumlanmaktadır. Bir eđiđin altındaki p-deđeri (%5 veya %1 gibi) boş hipotezin reddedildiđini gösterir. Aksi takdirde eđiđin üzerindeki p-deđeri boş hipotezin reddedilmediđini gösterir.

- p-deđeri $> 0,05$: Boş hipotez (H0) reddedilmemektedir, verilerin bir birim kökü vardır ve durađan deđildir.
- p-deđeri $\leq 0,05$: Boş hipotez (H0) reddedilmektedir, verilerin birim kökü yoktur ve durađandır.

Yapılan ADF testi sonuçları Tablo 3.3'de gösterilmektedir. Sonuçlara göre ADF test istatistiđi -3,697385 deđerini vermiştir. Bu istatistik ne kadar olumsuz olursa, sıfır hipotezini reddetme olasılıđı o kadar yüksek olmaktadır. ADF deđeri, %1'lik kritik deđerinden düşük olduđu görülmüştür. Bu, sıfır hipotezinin %1'den daha az anlamlılık düzeyiyle reddedileceđini göstermektedir. Bununla birlikte p-deđerile $\leq 0,05$ olduđundan boş hipotez reddedilir ve bu da

zaman serisinin durağan olduğu ya da zamana bağlı bir yapıya sahip olmadığı anlamına gelmektedir.

Tablo 3.3: ADF Testi Sonuçları

ADF İstatistiği	-3,697385
p-değeri	0,004150
Kritik Değerler	
1%	-3,435
5%	-2,864
10%	-2,568

3.2. MAKİNE ÖĞRENME ALGORİTMALARININ UYGULANMASI

Çalışmada öğrenme algoritmalarının başarısını farklı eğitim ve test verilerinin sayılarına göre karşılaştırabilmek için; veri seti hold-out (%90 eğitim-%10 test), hold-out(%80 eğitim-%20 test) ve %67 eğitim-%33 test olarak üç ayrı bölme yöntemi ile ayrılarak model uygulanmıştır. Ayrıca 10 katlı çapraz doğrulama yöntemi uygulanmıştır. Önerilen modellerin uygulanması Python 3.6 programlama dili kullanılarak Tensorflow arka planlı Keras 2.2.4 versiyonunda gerçekleştirilmiştir.

Zaman serisi tahmin görevlerinde makine öğrenme algoritmalarından Rastgele Orman (Random Forest, RF) , K-En Yakın Komşular Regresyonu (K-Nearest Neighbours Regression, KNN) ve Doğrusal Regresyon (Linear Regression, LR) algoritmaları çalışmada kullanılmak üzere belirlenmiştir.

3.2.1. Rastgele Orman (Random Forest, RF) Algoritmasının Uygulanması

Rastgele orman algoritması; topluluk olarak çalışan çok sayıda karar ağacından oluşur. Bu algorithmada her bir ağaç bir sınıf tahmininde bulunmaktadır en fazla oy alan sınıf modelin öngörüsü haline gelmektedir. [54]

$$RF_{fii} = \frac{\sum_{j \in all\ trees} norm_{fij}}{T} \quad (1)$$

RF_{fii} = RF algoritmasında tüm ağaçlardan hesaplanan özelliğin önemi

$normf_{ij} = j$ ağacında i için normalize edilmiş katsayısı

T= Toplam karar ağacı sayısı

RF algoritmasında kaç tane karar ağacının çizileceğini gösteren “ $n_estimators$ ” parametresi 10 olarak alınmıştır.

3.2.2. K-En Yakın Komşular Regresyonu (K-Nearest Neighbours Regression, KNN) Algoritmasının Uygulanması

KNN algoritması genellikle çıktıyı yorumlama kolaylığı, hesaplama süresi ve tahmini güç konulu uygulamalarda kullanılmaktadır. KNN algoritmasının formülleri aşağıdaki gibidir.

$$Euklid = \sqrt{\sum_{i=1}^k (X_i - Y_i)^2} \quad (2)$$

$$Manhattan = \sum_{i=1}^k |X_i - Y_i| \quad (3)$$

KNN algoritmasındaki komşu sayısı olan k değerini belirten $n_neighbors$ parametresi 3 olarak alınmıştır.

3.2.3. Doğrusal Regresyon (Linear Regression, LR) Algoritmasının Uygulanması

Doğrusal Regresyon, makine öğrenimi en basit modellerden birisidir. Bir veya daha fazla tahmin değişkeni ve sonuç değişkeni arasındaki ilişkiyi ölçmektedir. Kestirimci analiz ve modelleme için doğrusal regresyon kullanılır. Doğrusal regresyon, çoklu regresyon, çok değişkenli regresyon, normal en küçük kareler ve regresyon olarak da bilinir.

$$y = ax + b \quad (4)$$

y = bağımlı değişken

x = bağımsız değişken

b = çizginin eğimi

a = y çizgisinin kesme noktası

3.3. DERİN ÖĞRENME ALGORİTMALARININ UYGULANMASI

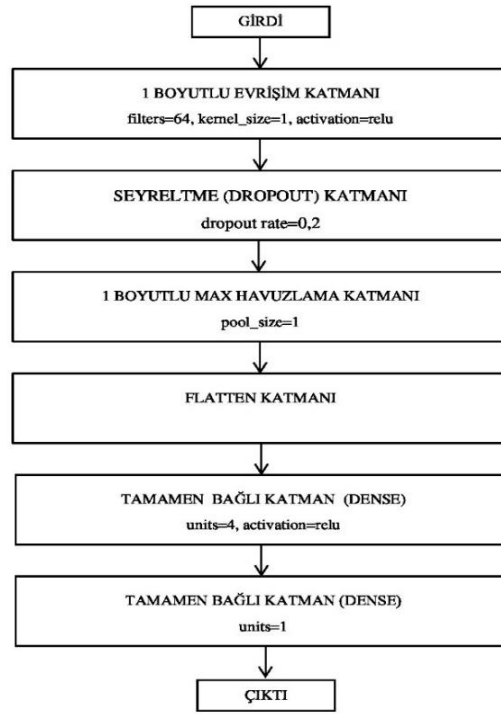
Geleneksel olarak, zaman serisi tahminlerinde doğrusal yöntemler kullanılmaktadır, çünkü birçok basit tahmin probleminde iyi anlaşılır ve etkilidirler. Derin öğrenme yöntemleri, girdilerden çıktılara rasgele karmaşık eşlemeleri otomatik olarak öğrenebilir ve çoklu girdi ve çıktıları destekleyebilir.

CNN'ler, görüntü verilerini verimli bir şekilde işlemek için tasarlanmış bir tür sinir ağıdır. CNN'lerin ham girdi verilerinden karmaşık özellikleri öğrenme ve otomatik olarak çıkarma yeteneği, zaman serisi tahmin problemlerine uygulanabilmektedir. LSTM ağı gibi tekrarlayan sinir ağları ise, girdi verilerinin çoklu paralel dizileri boyunca doğrudan öğrenme yeteneğine sahiptir.

Bu bilgiler doğrultusunda zaman serisi tahmin görevlerinde kullanımı etkili olduğu kanıtlanan CNN ve LSTM yöntemleri çalışmada kullanılmak üzere belirlenmiştir.

3.3.1. CNN Algoritmasının Uygulanması


Önerilen CNN modelinde; 1 boyutlu evrişim (convolution) katmanı, bir seyreltme (dropout) katmanı, 1 boyutlu maksimum havuzlama (pooling) katmanı, bir flatten katmanı, bir tamamen bağlı katman (gizli katman) ve çıktı için bir tamamen bağlı katman kullanılmıştır. Modelin katmanları parametre değerleri ile birlikte Şekil 3.2'de gösterilmektedir.



Şekil 3.2: CNN Modelinin Katmanları

3.3.2. LSTM Ağı Algoritmasının Uygulanması

Önerilen BLSTM modelinde; bir LSTM katmanı ve çıktı için bir tamamen bağlı katman kullanılmıştır. Modelin katmanları parametre değerleri ile birlikte Şekil 3.3.'de gösterilmektedir.



Şekil 3.3: LSTM Modelinin Katmanları

3.4. DEĞERLENDİRME ÖLÇÜTLERİ

3.4.1. Kök Ortalama Hata Karesi (RMSE)

RMSE iki veri kümesi arasındaki hata oranını ölçmeye yaramaktadır. Başka bir deyişle tahmini değer ile gözlenen değeri karşılaştırır. RMSE değeri ne kadar küçük olursa tahmin edilen değer ile gözlemlenen değerler birbirine yakın olur.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2} \quad (5)$$

RMSE Formülü

f = beklenen değerler

o = gözlemlenen değerler

n = örnek sayısı

3.4.2. Ortalama Hata Karesi (MSE)

MSE, hata oranlarının ortalamasının karesidir. RMSE ölçüt biriminden farklı olarak formülünde kök alınmamıştır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - o_i)^2 \quad (6)$$

MSE Formülü

f = beklenen değerler

o = gözlemlenen değerler

n = örnek sayısı

3.4.3. Doğruluk Oranı (Accuracy)

Doğruluk Oranı, doğru tahminlerin sayısının toplam tahminlerin sayısına oranıdır.

$$\text{Doğruluk Oranı} = \frac{\sum (f_i - \bar{f})(o_i - \bar{o})}{\sqrt{\sum (f_i - \bar{f})^2 \sum (o_i - \bar{o})^2}} \quad (7)$$

4. BULGULAR

Bu bölümde en iyilenmiş parametre değerleri ile uygulanan algoritmaların, sırasıyla hold-out (%90 eğitim-%10 test), hold-out (%80 eğitim-%20 test) , hold-out (%67 eğitim-%33 test) yöntemleri ile eğitim ve test verileri oluşturulmuş veri seti için performans analizi sonuçları sunulmuştur. Ayrıca 10 katlı çapraz sorgulama ile KNN, RF ve LR algoritmalarının tahmin sonuçları bulunmuştur.

Hold-out (%90 eğitim - %10) bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan algoritmaların günlük ve haftalık veri tahmini yapılarak performans ölçütleri açısından değerlendirmeleri Tablo 4.1’de gösterilmektedir.

Tablo 4.1: %90 Eğitim -%10 Test İşlemine Göre Algoritmaların Kıyaslaması

Algoritmalar	MSE	RMSE	Doğruluk Oranı
CNN (Günlük)	0,0056	0,0750	0,9944
CNN (Haftalık)	0,01	0,100	0,9899
LSTM (Günlük)	0,0054	0,0748	0,9946
LSTM (Haftalık)	0,010	0,1022	0,9896
RF (Günlük)	0,0066	0,0816	0,9933
RF (Haftalık)	0,015	0,122	0,9849
KNN (Günlük)	0,0073	0,0856	0,9927
KNN (Haftalık)	0,0085	0,0919	0,9915
LR (Günlük)	0,0058	0,0765	0,9941
LR (Haftalık)	0,0090	0,0949	0,9909

Tablo 4.1'deki sonuçlara göre LSTM modelinin 0,0055 değeri ile en küçük MSE değerini veren model olduğu görülmüştür. Diğer yöntemlerin MSE değerleri incelendiğinde; sırasıyla CNN algoritması 0,0056 , RF algoritması 0,0066 , KNN algoritması 0,0073 MSE ve LR algoritması 0,0058 MSE değerleri ile performans sergilemiştir.

Hold-out (%80 eğitim-%20 test) yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan algoritmaların günlük ve haftalık olarak veri tahmini yapılmasındaki performans ölçütleri açısından değerlendirmeleri Tablo 4.2'de gösterilmiştir.

Tablo 4.2: %80 Eğitim -%20 Test İşlemine Göre Algoritmaların Kıyaslaması

Algoritmalar	MSE	RMSE	Doğruluk Oranı
CNN (Günlük)	0,0057	0,0760	0,9943
CNN (Haftalık)	0,0068	0,0828	0,9931
LSTM (Günlük)	0,0056	0,0753	0,9944
LSTM (Haftalık)	0,0075	0,0866	0,9925
RF (Günlük)	0,0072	0,0851	0,9927
RF (Haftalık)	0,0098	0,0988	0,9902
KNN (Günlük)	0,0084	0,0921	0,9915
KNN (Haftalık)	0,0067	0,0825	0,9932
LR (Günlük)	0,0055	0,0745	0,9945
LR (Haftalık)	0,0073	0,084	0,9927

Tablo 4.2'deki sonuçlara göre Doğrusal Regresyon modelinin 0,0055 değeri ile en küçük MSE değerini veren model olduğu görülmüştür. Diğer yöntemlerin MSE değerleri incelendiğinde; sırasıyla CNN algoritması 0,0057, LSTM algoritması 0,0056, RF algoritması 0,0072 ve KNN algoritması 0,0084 MSE değerleri ile performans sergilemiştir.

Hold-out (%67 eğitim - %33 test) yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan algoritmaların günlük ve haftalık olarak veri tahmini yapılmasındaki performans ölçütleri açısından değerlendirmeleri Tablo 4.3'te gösterilmiştir.

Tablo 4.3: %67 Eğitim -%33 Test İşlemine Göre Algoritmaların Kıyaslaması

Algoritmalar	MSE	RMSE	Doğruluk Oranı
CNN (Günlük)	0,0061	0,0785	0,9939
CNN (Haftalık)	0,0084	0,0919	0,9916
LSTM (Günlük)	0,0059	0,0774	0,9941
LSTM (Haftalık)	0,0089	0,0944	0,9910
RF (Günlük)	0,0075	0,0868	0,9924
RF (Haftalık)	0,010	0,10	0,9891
KNN (Günlük)	0,0094	0,0973	0,9905
KNN (Haftalık)	0,012	0,1122	0,9874
LR (Günlük)	0,0062	0,0786	0,9938
LR (Haftalık)	0,0088	0,094	0,9911


Tablo 4.3'teki sonuçlara göre LSTM modelinin 0,0059 değeri ile en küçük MSE değerini veren model olduğu görülmüştür. Diğer yöntemlerin MSE değerleri incelendiğinde; sırasıyla

CNN algoritması 0,0061, RF algoritması 0,0075 , KNN algoritması 0,0094 ve LR 0,0062 MSE değerleri ile performans sergilemiştir.

Tablo 4.4: On katlı Çapraz Doğrulama ile Yapılan İşlemlere Göre Algoritmaların Kıyaslaması


Algoritmalar	MSE	RMSE	Doğruluk Oranı
RF (Günlük)	0,00601	0,0775	0,99399
RF (Haftalık)	0,01384	0,1176	0,98616
KNN (Günlük)	0,0312	0,1766	0,9688
KNN (Haftalık)	0,1181	0,3437	0,8819
LR (Günlük)	0	0	1,0
LR (Haftalık)	0	0	1,0

Yapılan karşılaştırmalara göre hold-out (%90 eğitim-%10 test) yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanmış en iyi performansa sahip model olan LSTM modelinin kayıp oranı grafiği aşağıda gösterilmektedir.




Şekil 4.1: LSTM Modeli Kayıp Oranı Grafiği

Hold-out (%90 eğitim-%10 test) yöntemi ile eğitim ve test verileri oluşturulmuş veri seti üzerinde LSTM modeli ile yapılan tahminlerin gerçek gözlemler ile karşılaştırıldığı grafik aşağıda gösterilmektedir.

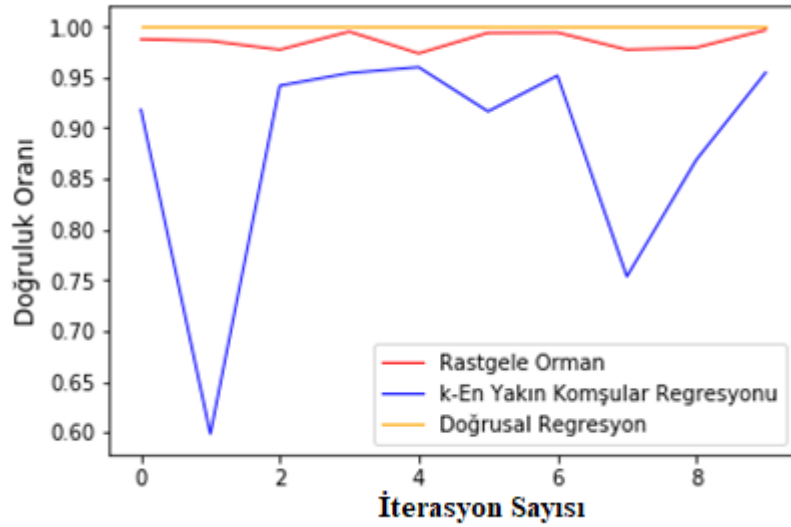


Şekil 4.2: Gerçek Veri ile LSTM Tahmin Değerlerinin Karşılaştırılması.

Haftalık tüketim değerini tahmin etme işleminde en başarılı Hold-out (%80 eğitim - %20 test) yöntemi kullanan KNN algoritmasının gerçek değerler ile tahmin değerlerinin karşılaştırıldığı grafik aşağıdaki gibidir.



Şekil 4.3: Gerçek Veri ile KNN Tahmin (Haftalık) Değerlerinin Karşılaştırılması



Şekil 4.4: 10 Katlı Çapraz Doğrulama İşleminin Elde Edilen Doğruluk Oranları

5. TARTIŞMA VE SONUÇ

Akıllı elektrik şebekelerinin artışı ve elektrik üretim teknolojisinin yaygın olarak benimsenmesi göz önüne alındığında; enerji kullanımının ölçülmesi ve gerekli tasarruf planlamalarının yapılması önem kazanmıştır. Tüketimin birçok yöntemle tahmin edilmesi ile ilgili literatürde birçok çalışma yapılmaktadır. Çünkü gelecekteki elektrik tüketimini modellemek ve tahmin etmek ciddi enerji tasarrufu imkânı verecektir.

Bu çalışmada asıl amaçlanan, derin öğrenme ve makine öğrenmesi yöntemleri ile enerji tüketiminin tahmini için bir model belirleyerek gelecekteki harcanacak enerji tüketimi hakkında bilgi sahibi olunabilecek bir altyapı oluşturmaktır. Bununla beraber belirlenecek olan model ile enerji tüketiminde tasarruf edilmesine ve hanehalkı harcamalarının planlanmasına katkı sağlamaktır. Ayrıca ne kadar üretim yapılması gerektiği hakkında bilgi sahibi olunmuş olacaktır.

Tez kapsamında uygulanan CNN, LSTM, RF, KNN ve Doğrusal Regresyon yöntemleri ile elektrik güç tüketiminin tahmin edilmesinde başarılı sonuçlar elde edilmiştir. Yapılan karşılaştırmalara göre günlük tahminlerde 0,0054 olan en düşük MSE değeri ile LSTM modeli en iyi performansı sergileyen model olmuştur. Haftalık tahminlere göre ise 0,0067 MSE değeri ile KNN algoritması en başarılı olduğu gözlemlenmiştir. Günlük enerji tüketiminin tahmin edilme işlemi haftalık enerji tüketiminin tahmin edilme işlemine göre daha başarılı olduğu gözlemlenmiştir. Ayrıca bu çalışmada 10 Katlı Çapraz Doğrulama işlemi yapıldığında Doğrusal Regresyon algoritması veri setini ezberleyerek doğruluk oranı 1.0 olarak bulunmuştur.

Geliştirilen LSTM modeli uygulanan diğer yöntemlerle karşılaştırıldığında akıllı şebekelerin yönetiminde veya değerlendirilmesinde daha verimli olabileceğini göstermiştir. Bu yaklaşımla yapılan tahminler sayesinde tasarruf planlamaları kolaylıkla yapılabilecek ve aynı zamanda daha güvenilir olacaktır.

LSTM modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %90 eğitim - %10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan LSTM modeli ile diğer bölme yöntemlerine göre daha

yüksek başarı oranı elde edilmiştir. CNN modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan CNN modeli ile diğer bölme yöntemlerine göre daha yüksek başarı oranı elde edilmiştir. RF modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan RF modeli ile diğer bölme yöntemlerine göre daha yüksek başarı oranı elde edilmiştir. KNN modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %90 eğitim-%10 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan KNN modeli ile diğer bölme yöntemlerine göre daha yüksek başarı oranı elde edilmiştir. Doğrusal Regresyon modellerinin performansları kendi arasında bölme yöntemlerine göre karşılaştırıldığında; %80 eğitim-%20 test bölme yöntemi ile eğitim ve test verileri oluşturulmuş veri seti için uygulanan Doğrusal Regresyon modeli ile diğer bölme yöntemlerine göre daha yüksek başarı oranı elde edilmiştir. Doğrusal Regresyon diğer algoritmalarından farklı olarak eğitim serisi ile doğru orantılı olarak daha verimli çalışmadığı gözlemlenmiştir.

Tablo 5.1: Veri Seti Aynı Olan Diğer Makaleler

Makale	Günlük (RMSE)	Haftalık(RMSE)	Sonuç
Sustainable Energy, Grids and Networks (Elena Mocanu ve arkadaşları)	ANN – 0,9072	ANN – 1,8679	FCRBM algoritması diğer algoritmalara göre daha başarılı olduğu görülmüştür.
	SVM – 1,3446	SVM – 1,5598	
	RNN – 1,0092	RNN – 2,8074	
	CRBM – 1,0305	CRBM – 0,9513	
	FCRBM – 0,8995	FCRBM – 0,7971	
Improving Electric Energy Consumption Prediction Using CNN and Bi-LSTM (Tuong Le ve arkadaşları)	LR – 0,503	LR – 0,385	EECP-CBL algoritması diğer algoritmalara göre daha başarılı olduğu görülmüştür.
	LSTM – 0,491	LSTM – 0,324	
	CNN-LSTM – 0,322	CNN-LSTM – 0,309	
	EECP-CBL – 0,255	EECP-CBL – 0,220	
Predicting residential energy consumption using CNN-LSTM neural network (Tae-Young Kim ve	LR – 0,503	LR – 0,384	CNN-LSTM algoritması diğer algoritmalara göre daha

arkadaşları)	LSTM – 0,490 CNN-LSTM – 0,322	LSTM – 0,323 CNN-LSTM – 0,309	başarılı olduğu görülmüştür.
--------------	----------------------------------	----------------------------------	---------------------------------

Eğitim ve test verisini bölme yöntemlerinin önerilen modellerin performansları üzerindeki etkisi incelenecek olursa; kullanılan bölme yöntemlerinde eğitim seti arttıkça her iki model için de tahmin performansının iyi yönde arttığı gözlemlenmiştir. Bu sonuç göstermektedir ki veri seti genişledikçe geliştirilen model çok daha iyi eğitilebilecek ve tahminler daha tutarlı olacaktır.

Gelecekteki çalışmalar için veri seti sayısı artırılarak farklı derin öğrenme modelleri ile tahminler geliştirilebilir.

KAYNAKLAR

- [1]. Costa A., Keane M.M., Tornes J.I., Corry E., 2013, Building operation and energy performance: Monitoring, analysis and optimisation toolkit, *Appl. Energy* 101, 310-316
- [2]. Yang L., Yan H., Lam J.C., 2014, Thermal comfort and building energy consumption Implications - A review, *Appl. Energy* 115 , 164–173.
- [3]. Prowmesadmin, 2018, *Akıllı Şebeke Nedir?*, <http://www.prowmes.com/blog/akilli-sebeke-nedir/>, [Ziyaret tarihi: 15 Ekim 2019].
- [4]. Mocanu E., Nguyen P.H., Gibescu M., King W.L., 2016, Deep learning for estimating building energy consumption, *Sustainable Energy, Grids and Networks*, 91-99
- [5]. Bakirtzis E.A., Simoglou C.K., Biskas P.N., Labridis D.P., Bakirtzis A.G., 2015, Comparison of advanced power system operations models for large-scale renewable integration, *Electr. Power Syst. Res.* 128 , 90–99.
- [6]. Akçin M., Alagöz B. B., Keleş C., Karabiber A. ve Kaygusuz A., Dağıtık Kontrol ile Akıllı Şebekelerde Geniş-Alan Yönetimi ve Geleceğe Dönük Projeksiyonlar, *Sak. Univ. J. Sci.*, 17:3 (2013) 457-470.
- [7]. Cappers P., Goldman C. Kathan D., 2009, Assessment of Demand Response & Advanced Metering, *United States Federal Energy Regulatory Commission*. 14 p.
- [8]. Saleh, M. S., Althaibani, A., Esa, Y., Mhandi, Y., Mohamed, A. A., 2015, Impact of clustering microgrids on their stability and resilience during blackouts. *2015 International Conference on Smart Grid and Clean Energy Technologies (ICSGCE)*. pp. 195–200. doi:10.1109/ICSGCE.2015.7454295. ISBN 978-1-4673-8732-3.
- [9]. Prowmesadmin, 2018, *Akıllı Şebeke Nedir?*, <http://www.prowmes.com/blog/akilli-sebeke-nedir/>, [Ziyaret tarihi: 12 Eylül 2019].
- [10]. Steve, G., Hauserve, K., 2012, Smart Grid Is a Lot More than Just Technology, *Elsevier*, 3-28.

- [11]. Bruinenberg J., Colton L., Darmais E., Dorn J., 2012, Smart Grid Coordination Group Smart Grid Reference Architecture, *Cen-Cenelec-Etsi*, 1-216
- [12]. Pierce E.R., 2013, *Working to Modernize the Nation's Electric Grid*, www.energy.gov
- [13]. Pusung F.F., 2011, *Smart Grid*, PediaPress GmbH, Mainz-Germany, 285 s.
- [14]. Bourguine P., Chavalarias D., Perrier E., Amblard F., Arlabosse F., Auger P., Baillon J.P., Barreteau O., Baudot P., 2009, *French Roadmap for complex Systems 2008–2009*
- [15]. Spahiu P., Evans I.R., 2011, Protection Systems that verify and supervise themselves, *2011 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies*, 5 - 7 December 2011 Manchester, ISBN: 9781457714221
- [16]. Spahiu P., Uppal N., 2010, IED based Protection & Control equipment with Non-Standard primary system arrangements – An approach to application,– *10th IET International Conference on DPSP in Manchester*, 29 March-1 April 2010, ISBN: 978-1-84919-212-5
- [17]. Filatrella G, Nielsen A.H., Pedersen N.F., 2008, Analysis of a power grid using the Kuramoto-like model, *European Physical Journal B*. 61 (4): 485–491.
- [18]. Dorfler F. Bullo F., 2010, Synchronization and Transient Stability in Power Networks and Non-Uniform Kuramoto Oscillators, *2010 American Control Conference Marriott Waterfront*, June 30- July 02 2010, Baltimore , 930-937
- [19]. Lusseau D., 2003, The emergent properties of a dolphin social network, *Proceedings of the Royal Society of London B*. 270 (Suppl 2): S186–S188.
- [20]. Montazerolghaem, A., Yaghmaee, M. H., Leon-Garcia, A. ,2017, OpenAMI: Software-Defined AMI Load Balancing, *IEEE Internet of Things Journal*. PP (99): 206–218.
- [21]. Ahmad S.H., Liu M., Wu Y. 2009, Congestion games with resource reuse and applications in spectrum sharing, *2009 International Conference on Game Theory for Networks*, 13-15 May 2009, İstanbul, 171-179

- [22]. Çakır A., Yenidoğan I., Dağ H., 2018, Konutların Günlük Elektrik Güç Tüketimi Tahmini için Uygun Model Seçimi, *Fırat Üniv. Müh. Bil. Dergisi*, Cilt:30, Sayı 3, 15-21
- [23]. Zhang X. M., Grolinger K., Capretz M. A. M., 2018, Forecasting Residential Energy Consumption Using Support Vektor Regressions, *Proc. Of the IEEE International Conference on Machine Learning and Applications*, 17-20 December 2018, Orlando, FL, 110-117
- [24]. Li C., Ding Z., Zhao D., Yi J., Zhang G., 2017, Building Energy Consumption Prediction: An Extreme Deep Learning Approach, *Energies*
- [25]. Xu Y., Dong Z.Y., Meng K., Zhang R., Wong K.P., 2011, Real-time transient stability assessment model using extreme learning machine, *The Institution of Engineering and Technology*, Vol.5, Iss. 3, s:314-322
- [26]. Li B., Gangadhar S., Pramode S.C., K.Verma, 2011, *Predicting user comfort level using machine learning for smart grid environment*, ISGT, 2011- ieeexplore.ieee.org
- [27]. Demirtaş M., Akkoyun N., Akkoyun E. , Çetinbaş İ., 2019, Akıllı Şebekelerde Güneş Enerjisi Üretiminin Zamana Bağlı Olasılıksal Tahmini, *GU J Sci*, 411-424
- [28]. Hossain E., Khan I., Un-noor F., Sikander S.S., 2019, *Application of Big Data and Machine Learning in Smart Grid and Associated Security Concerns: A Review*, IEEE , 13960-13988
- [29]. Güneş E., 2019, *Enerji Dağıtım Sistemleri için Tüketicilerin Talep Faktörünün Belirlenmesi*, Yüksek Lisans Tezi, İstanbul Üniversitesi-Cerrahpaşa, Fen Bilimleri Enstitüsü
- [30]. Erdem O. E., 2019, *Makine Öğrenme Teknikleri ile Türkiye'nin Doğalgaz Enerji Tüketiminin Tahminlemesi*, Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü
- [31]. Mamaklıoğlu G., 2019, Binaların Enerji Tüketiminde Kullanıcı Davranışlarının Modellenmesi, Yüksek Lisans Tezi, İstanbul Üniversitesi-Cerrahpaşa, Fen Bilimleri Enstitüsü
- [32]. Peker M., Özkaraca O., Kesimal B., 2017, Enerji Tasarufllu Bina Tasarımı için Isıtma ve Soğutma Yüklerini Regresyon Tabanlı Makine Öğrenmesi Algoritmaları ile Modelleme, *Bilişim Teknoloji Dergisi*, Cilt:10,Sayı 4, 443-339

- [33]. Faggella D., 2019, *What is Machine Learning*, <https://emerj.com/ai-glossary-terms/what-is-machine-learning/>, [Ziyaret tarihi: 12 Eylül 2019].
- [34]. Sarıcaoğlu, C. 2019, *Sözcüksel Analiz Kullanarak Kötü Niyetli Url'leri Derin Öğrenme Teknikleri ile Tespit Etme*, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü
- [35]. Ağraz M., 2019, *Makine Öğrenmesi (Machine Learning)*, <https://www.kodexbilisim.com/makine-ogrenmesi-nedir.html>, [Ziyaret tarihi: 15 Kasım 2019].
- [36]. Mayo H., Punchihewa H., Emile J., and Morrison J., 2018, *Histry of Machine Learning*, <https://www.doc.ic.ac.uk/~jce317/history-machine-learning.html>
- [37]. Kızılkaya Y. M., Oğuzlar A., 2018, Bazı Denetimli Öğrenme Algoritmalarının R programlama dili ile kıyaslanması , *Karadeniz*, 37, s:90-98
- [38]. Cerebro, 2018, *Yeni Başlayanlar için Makine Öğrenmesi Algoritmaları*, <https://medium.com/türkiye/yeni-başlayanlar-için-makine-öğrenmesi-algoritmaları-ae22f794af2f> , [Ziyaret tarihi: 13 Eylül 2019].
- [39]. Goodfellow, I., Bengio, Y. ve Courville, A., 2016, *Deep Learning*, The Mit Press, ISBN: 0262035618.
- [40]. Şeker A., Diri B., Balık H.H., 2017, Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi*, s. 47-64
- [41]. Ivakhnenko, A.G. ve Lapa,V.G., 1965, *Cybernetic predicting devices*, N.Y. CCM Information Corp., New York.
- [42]. Fukushima, K., 1988, Neocognitron: A hierarchical neural network capable of visual pattern recognition, *Neural Networks*, 1 (2), 119-130.
- [43]. Hochreiter, S. ve Schmidhuber, J., 1997, Long Short-Term Memory, *Neural Computation*, 9 (8), 1735-1780.
- [44]. Hinton, G.E. VE Salakhutdinov, R., 2006, Reducing the Dimensionality of Data with Neural Networks, *Science*, 313 (5786), 504-507.

- [45]. Hubel, D.H. ve Wiesel, T. N., 1962, Receptive Fields, Binocular Interaction and Functional Architecture in the Cat's Visual Cortex, *Journal of Physiology*, 160 (1), 106-154.
- [46]. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J. ve Chen, T., 2018, Recent Advances in Convolutional Neural Networks, *Pattern Recognition*, 77, 354-377.
- [47]. MathWorks, 2017, *Convolutional Neural Network: 3 Things You Need to Know*, <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>, [Ziyaret tarihi: 18 Eylül 2019].
- [48]. Ranganathan, S., Gribskov, M.R. ve Nakai, K., 2019, *Encyclopedia of Bioinformatics and Computational Biology*, Elsevier Science Publishing Co., ISBN: 978-012-811414-8.
- [49]. Deniz, E., Şengür, A. ve Kadiroğlu, Z., 2018, Transfer Learning Based Histopathologic Image Classification for Breast Cancer Detection, *Health Information Science and Systems*, 6 (18), 1-7.
- [50]. Gibson A., Patterson J., 2016, *Deep Learning: A Practitioner's Approach*, O'Reilly Media, Sebastopol, ISBN: 978-1-4919-1425-0.
- [51]. Karasu E., 2019, *Metin Madenciliği Tekniklerini Kullanarak Faaliyet Bazlı Proje Yönetiminde Bilgi Yönetimi Süreçleri İçin Derin Öğrenme Modeli*, Yüksek Lisans Tezi, İstanbul Üniversitesi-Cerrahpaşa, Fen Bilimleri Enstitüsü
- [52]. Singh S., 2016, *What is RNN*, <https://www.quora.com/What-is-RNN>. [Ziyaret tarihi: 5 Eylül 2019].
- [53]. Sutskever I., Tielema T., 2010, On the convergence properties of contrastive divergence , *Proceedings of the 13th International Conference on Technology in Mathematics Teaching*, 3-6 Temmuz 2017, Lyon, 789-795
- [54]. Sharma A., 2018, *Restricted Boltzman Machines-Simplified*, <https://towardsdatascience.com/restricted-boltzman-machines-simplified-eab1e5878976>, [Ziyaret tarihi: 6 Eylül 2019].

[55]. Süzen A.A.,Kayaalp K., 2018, *Derin Öğrenme ve Türkiye’de ki Uygulamaları*, IKSAD Yayınevi,Türkiye, ISBN: 978-605-7510-53-2


[56]. Admin, 2019, *Deep Learning(derin öğrenme)nedir?*, <https://biart.com.tr/deep-learning-derin-ogrenme-nedir/>, [Ziyaret tarihi: 6 Eylül 2019].

[57]. Brownlee J., 2016, *How to check if time series data is stationary with python*, <https://machinelearningmastery.com/time-series-data-stationary-python/>, [Ziyaret tarihi: 20 Kasım 2019].



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Erol YAVUZ
Doğum Yeri	İstanbul/Şişli
Doğum Tarihi	25.11.1992
Uyruğu	<input checked="" type="checkbox"/> T.C. <input type="checkbox"/> Diğer:
E-Posta Adresi	erolyvuz@gmail.com



Eğitim Bilgileri	
Lisans	
Üniversite	Karabük Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Elektrik-Elektronik Mühendisliği (%100 ing)
Mezuniyet Yılı	2015

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Elektrik-Elektronik Mühendisliği Anabilim Dalı
Programı	Elektrik-Elektronik Mühendisliği Programı

İş Deneyimleri	
2016.11-2017.02	Vispartners Danışmanlık Şirketi - IT Uzmanı
2017.02-Devam Ediyor	Tübitak Kamu Sertifikasyon Merkezi - Araştırmacı

