



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS PROGRAMI

**TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ HASTANESİ İÇİN
HİBRİT DERİN ÖĞRENME (CNN-LSTM) MODELİ İLE ENERJİ
TALEP TAHMİNLEMESİ**

YÜKSEK LİSANS TEZİ

ORHAN YILDIZ

Danışman: Doç. Dr. Zafer DOĞAN

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Zafer DOĞAN danışmanlığında hazırlamış olduğum “Tokat Gaziosmanpaşa Üniversitesi Hastanesi İçin Hibrit Derin Öğrenme (CNN-LSTM) Modeli İle Enerji Talep Tahminlemesi” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../...

Orhan YILDIZ

İmza

X X X X X

JÜRİ KABUL VE ONAY

Orhan YILDIZ tarafından hazırlanan “**Tokat Gaziosmanpaşa Üniversitesi Hastanesi İçin Hibrit Derin Öğrenme (CNN-LSTM) Modeli İle Enerji Talep Tahminlemesi**” adlı tez çalışmasının savunma sınavı 08.11.2024 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan) :Doç. Dr. Cem EMEKSİZ

Üye :Doç. Dr. Zafer DOĞAN

Üye :Dr. Öğr.Üyesi Alişan AYVAZ

ONAY

...../...../.....

Doç. Dr. Yusuf TEMUR

Lisansüstü Eğitim Enstitüsü Müdürü

ÖZET

Tokat Gaziosmanpaşa Üniversitesi Hastanesi İçin Hibrit Derin Öğrenme (CNN-LSTM) Modeli İle Enerji Talep Tahminlemesi

YILDIZ, Orhan

Danışman: Doç. Dr. Zafer DOĞAN

Elektrik Elektronik Mühendisliği

Aralık 2024, xi + 62

Her geçen gün sanayileşme ve büyümeye eşdeğer olarak elektrik üretim ve tüketimin değişeceği görülmektedir. Geleceğe yapılacak olan tüm yatırımlar, planlamalar geleceği doğru tahminlemekle olacaktır. Gelecekteki elektrik tüketimimizin tahmin doğruluğu da, doğru planlamayı destekleyecektir. Elektrik enerjisi planlaması, elektriğin üretiminden son kullanıcıya ulaşana kadar tüm maliyetleri minimize etmeyi, güç sistemlerinin verimliliğini artırmayı, sistemin güvenilirliğini güçlendirmeyi ve elektrik enerjisinin en yüksek kaliteyle tüketiciye sunulmasını sağlamayı amaçlar. Bu süreçlerin önemli bir aşaması, gelecekteki elektrik talebini yüksek doğruluk oranıyla tahmin etmektir.

Bu tez çalışmasında, Tokat Gaziosmanpaşa Üniversitesi Hastanesi'nin son beş yıllık saatlik elektrik tüketim verileri ile sıcaklık ve nem gibi meteorolojik parametreler toplanmıştır. Bu veriler, elektrik talebinin daha doğru bir şekilde tahmin edilmesine yönelik analizlerde kullanılmıştır. Çeşitli istatistiksel analiz, matematiksel analiz, makine öğrenmesi ve onun alt alanı olan derin öğrenme yöntemleri, zaman serisi verilerini analiz etmek ve gelecek tahmini yapabilmek için kullanılmaktadırlar. Giderek popülerliği artan derin öğrenme yöntemi ile zaman serisi problem çözümlerinde geleneksel yöntemlere göre daha başarılı olmuş ve kullanımı artmaktadır. Bu çalışmada, tahmin yöntemlerine odaklanarak Colab kütüphanesi programında derin öğrenme teknikleri kullanılarak kısa dönemli talep tahmini yöntemi geliştirilmiştir. Geliştirilen yöntem Tokat Gaziosmanpaşa Üniversitesi Hastanesi'nde uygulanmış ve elde edilen sonuçlar analiz edilmiştir.

Anahtar Kelimeler: Derin öğrenme, Enerji talep tahmini, Evrişimsel Sinir Ağı, Tekrarlanan Sinir Ağları

ABSTRACT

Energy Demand Forecasting for Tokat Gaziosmanpaşa University Hospital with Hybrid Deep Learning (CNN-LSTM) Model

YILDIZ, Orhan

Thesis Advisor: Doç. Dr. Zafer DOĞAN

Electrical Electronics Engineering

December 2024, xi + 62 pages

It is seen that electricity production and consumption will change day by day, equivalent to industrialization and growth. All investments and planning for the future will be based on accurately predicting the future. The accuracy of forecasting our future electricity consumption will also support accurate planning. Electrical energy planning regulation aims to minimize all costs from the production of electricity until it reaches the end user, to increase the efficiency of power systems, to increase the reliability of the system and to deliver electrical energy to the consumer with the highest quality.

Various statistical analysis, mathematical analysis, machine learning and its subfield, deep learning methods, are used to analyze time series data and make future predictions. With the increasingly popular deep learning method, it has become more successful in time series problem solving than traditional methods and its use is increasing. In this study, a short-term demand forecasting method was developed using deep learning techniques in the Colaboratory program, with a focus on forecasting methods. This developed method was applied to Tokat Gaiosmanpaşa University hospital and the results were analyzed.

Keywords: Deep learning, Energy demand forecasting, Convolutional Neural Network, Recurrent Neural Network

TEŞEKKÜR

Tez çalışmamda desteğini esirgemeyen, çalışmalarımızın planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda yüksek tecrebe ve bilgisinden faydalandığım, yönlendirme ve eğitimiyle çalışmamı bilimsel esaslara ışığında şekillendiren değerli hocalarım Doç. Dr. Zafer Doğan ve Öğr. Gör. Dr. Abdulkadir Gözüoğlu'na sonsuz teşekkürlerimi sunarım.

Eğitim öğretim hayatım boyunca maddi ve manevi desteklerini hiç eksik etmeyen kıymetli aileme, anneme, çocuklarıma ve eşime teşekkürlerimi sunarım.

Orhan YILDIZ

TOKAT 2024

İÇİNDEKİLER

	Sayfa
ETİK SÖZLEŞME.....	i
JÜRİ KABUL VE ONAY	ii
ÖZET	iii
ABSTRACT.....	iv
İTHAF.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ.....	ix
KISALTMALAR VE SİMGELER LİSTESİ	x
1. GİRİŞ	1
1.1. AMAÇ.....	1
1.2. KAPSAM.....	2
1.3. LİTERATÜR ÇALIŞMASI.....	2
2. KURAMSAL TEMELLER	10
2.1. YÜK TALEP TAHMİNİ SINIFLANDIRILMASI	10
2.2. YÜK TAHMİNİ PARAMETRELERİ	11
2.3. YÜK TAHMİN YÖNTEMLERİ.....	13
2.3.1. YAPAY ZEKA TEMELLERİ.....	14
2.3.2. DERİN ÖĞRENME	27
2.4. KULLANILAN PROGRAMLAR	36
3. METARYEL VE YÖNTEM	38
3.1. VERİ TOPLAMA.....	38
3.2. VERİ HAZIRLAMA	40
3.3. MODELLEME SÜRECİ	42
4. BULGULAR.....	45
4.1. SENERYO-1.....	45
4.1.1. CNN MODELİ SONUÇLARI.....	46
4.1.2. LSTM MODELİ SONUÇLARI	48
4.1.3. CNN-LSTM HİBRİT MODELİ SONUÇLARI	49
4.1.4. METEOROLOJİK PARAMETRELERİN TAHMİNLEME ETKİSİ ..	52

4.2. SENERYO-2.....	52
5. SONUÇLAR.....	58
KAYNAKÇA.....	59
ÖZGEÇMİŞ	62



ŞEKİL LİSTESİ

<u>Sekil-No</u>	<u>Sayfa</u>
Şekil 2.1. – Tüketim verilerinin bir haftalık grafiği.....	12
Şekil 2.2. – 22 Aralık – 20 Mart 2023 Arası elektrik yük grafiği.....	13
Şekil 2.3. – Talep tahmin yöntemleri.....	13
Şekil 2.4. – Biyolojik nöron şekli	15
Şekil 2.5. – İki biyolojik nöron arasındaki elektriksel sinyal transferi	15
Şekil 2.6. – Yapay nöronda sinyal toplama ve n sayıda nöron ile sinyal transferi ...	16
Şekil 2.7. – Çok katmanlı yapay sinir ağı mimarisi.....	17
Şekil 2.8. – İleri beslemeli yapay sinir ağı yapısı	18
Şekil 2.9. – Adım aktivasyon grafiği	20
Şekil 2.10. – Doğrusal aktivasyon grafiği.....	20
Şekil 2.11. – Sigmoid aktivasyon grafiği.....	21
Şekil 2.12. – Tanh aktivasyon grafiği	21
Şekil 2.13. – Relu ve LReLU aktivasyon grafiği.....	22
Şekil 2.14. – Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme ilişkisi	27
Şekil 2.15. – Makine öğrenme yaklaşımı.....	28
Şekil 2.16. – Öğrenme teknikleri performansları	28
Şekil 2.17. – Tam bağlantılı asimetrik sinir ağı	29
Şekil 2.18. – Yineleyen ağlarda nöronların bağlantıları	30
Şekil 2.19. – Tensör ve işlem düzeyinde gösterilen LSTM Birimine ait mimari	31
Şekil 2.20. – LSTM birimine ait keep gate mimarisi.....	31
Şekil 2.21. – LSTM birimine ait write gate mimarisi	31
Şekil 2.22. – LSTM birimine ait output gate mimarisi	32
Şekil 2.23. – LSTM ve GRU mimarileri	33
Şekil 2.24. – Genel Bir CNN Mimarisi	33
Şekil 2.25. – 3d Boyutlu giriş katmanı	35
Şekil 2.26. – Giriş ve Çıkış değerlerine sahip konvolüsyonel katman	35
Şekil 3.1. – Elektrik tüketim verisi toplama şeması	38
Şekil 3.2. – Toplanan 5 yıllık elektrik tüketim verisi	39
Şekil 3.3. – 01 Ocak 2019 – 31 Aralık 2023 aralığı nem verisi	39
Şekil 3.4. – 01 Ocak 2019 – 31 Aralık 2023 aralığı sıcaklık verisi	40

Şekil 3.5. – 01 Ocak 2019 – 31 Aralık 2023 aralığı işlenmiş elektrik tüketim verisi	41
Şekil 3.6. – 01 Ocak 2019 – 31 Aralık 2023 aralığı işlenmiş nem verisi	42
Şekil 3.7. – 01 Ocak 2019 – 31 Aralık 2023 aralığı işlenmiş sıcaklık verisi	42
Şekil 4.1. – 5 yıllık eğitim ve test verisi	45
Şekil 4.2. – CNN model grafiği	47
Şekil 4.3. – CNN model son 100 veri grafiği	47
Şekil 4.4. – LSTM model grafiği	48
Şekil 4.5. – LSTM model son 100 veri grafiği	49
Şekil 4.6. – CNN-LSTM model grafiği	51
Şekil 4.7. – CNN-LSTM model son 100 veri grafiği	51
Şekil 4.8. – CNN-LSTM model güç-sıcaklık veri grafiği	52
Şekil 4.9. – CNN-LSTM model güç-nem veri grafiği	53
Şekil 4.10. – CNN-LSTM ilk 4 yıl eğitim 5. test verisi	55
Şekil 4.11. – İlk 4 Yıl Eğitim, 5.yıl test ve 6. 7. yıllar tahmin grafiği	55
Şekil 4.12. – 4.yıl eğitim ve test grafiği	56
Şekil 4.13. – 4.yıl ilk 100 eğitim ve test grafiği	56

TABLO LİSTESİ

<u>Tablo No</u>	<u>Sayfa</u>
Tablo .1; CNN model için, ilk 3 yıl eğitim verileri hata metrikleri	46
Tablo . 2; CNN model için, son 2 yıl test verileri hata metrikleri	47
Tablo . 3; LSTM model için, ilk 3 yıl eğitim verileri hata metrikleri.....	48
Tablo . 4; LSTM model için, son 2 yıl test verileri hata metrikleri	48
Tablo . 5; CNN-LSTM model için, ilk 3 yıl eğitim verileri hata metrikleri.....	50
Tablo . 6; CNN-LSTM model için, son 2 yıl test verileri hata metrikleri	50
Tablo . 7; Tüm modeller için, son 2 yıl test verileri hata metrikleri	52
Tablo . 8; CNN-LSTM model, Güç-Sıcaklık ilk 3 yıl eğitim verileri hata metrikleri.....	53
Tablo . 9; CNN-LSTM model, Güç-Sıcaklık son 2 yıl eğitim verileri hata metrikleri.....	53
Tablo . 10; CNN-LSTM model, Güç-Nem ilk 3 yıl eğitim verileri hata metrikleri .	54
Tablo . 11; CNN-LSTM model, Güç-Nem son 2 yıl eğitim verileri hata metrikleri	54
Tablo . 12; Meteorolojik faktörlerin değiştirilerek alınan son 2 yıl test verilerinin hata metrikleri.....	54
Tablo . 13; CNN-LSTM model 6.7. yıl tahminlemesi için 4. Yılın test verileri hata metrikleri.....	57

KISALTMALAR VE SİMGELER LİSTESİ

YZ	:Yapay Zeka
SA	:Sinir Ağı
YSA	:Yapay Sinir Ağları
RMSE	:Kök Ortalama Kare Hatası
EPDK	:Enerji Piyasası Düzenleme Kurumu
MÖ	:Makine Öğrenimi
DÖ	:Derin Öğrenme
RNN	:Tekrarlanan Sinir Ağları
MA	:Hareketli Ortalamalar
MAPE	:Ortalama Hata Oranı
MGM	:Meteoroloji Genel Müdürlüğü
MSE	:Hata Oranlarının Kareleri
YSH	:Yapay Sinir Hücresi
CNN	:Evrişimsel Sinir Ağları
LSTM	:UzunKısa Süreli Bellek Ağı
MW	:Mega Watt
MLP	:Çok Katmanlı Yapay Sinir Ağı
FFNN	:İleri Beslemeli Sinir Ağı
BPNN	:Geri Beslemeli Sinir Ağı
DNN	:Derin Sinir Ağı
ReLU	:Doğrultulmuş Doğrusal Aktivasyon Fonksiyon
LReLU	:Sızıntılı Doğrultulmuş Doğrusal Aktivasyon Fonksiyonu

1. GİRİŞ

Her geçen gün sanayileşme ve büyüme ile birlikte elektrik üretim ve tüketimindeki değişiklikler de artmaktadır. Geleceğe yönelik tüm yatırımlar ve planlamalar, geleceği doğru tahmin etme becerisine bağlıdır. Elektrik tüketiminizin gelecekteki doğruluğu, doğru planlamayı destekleyecektir. Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre, 2022 yılı Kasım ayı itibarıyla ülkemizin kurulu gücü 103.541 MW'a ulaşmıştır. Bu kurulu güç, kaynaklara göre şu şekilde dağılım göstermektedir: %30,5'i hidrolik enerji, %24,4'ü doğal gaz, %21,1'i kömür, %11,0'ı rüzgâr, %9,0'ı güneş, %1,6'sı jeotermal ve %2,4'ü diğer kaynaklardan oluşmaktadır. Ülkemizde 2022 yılı Kasım ayı itibarıyla 301.707,819 GWh elektrik tüketimi gerçekleştirilmiştir. Enerji Piyasası Düzenleme Kurumu tarafından yayımlanan Elektrik Piyasası Talep Tahminleri Yönetmeliği, talep tahmin modelini bilimsel yöntemlerle oluşturulacak model olarak tanımlamaktadır. Talep tahmini ise dağıtım şirketleri tarafından belirli zaman aralıklarında çeşitli senaryolar oluşturularak, elektrik enerjisinin miktarı, puant güç talebi ve abone sayısının tahmin edilmesini ifade eder.

Gelecekteki değerlerin tahmini, geçmiş dönem gözlem verileri kullanılarak oluşturulan modellerle yapılır. Bir tahmin sistemini iki aşamada incelemek mümkündür: model kurma ve tahmin aşaması. Model kurma aşaması, tahminlerin doğruluğunu etkileyen kritik bir aşamadır; doğru bir model, daha gerçekçi tahminler sağlar (Hamzaçebi 2011a). Elektrik enerjisi planlaması, elektriğin üretiminden son kullanıcıya ulaşana kadar olan tüm maliyetleri minimize etmek, güç sistemlerinin verimliliğini artırmak, sistemin güvenilirliğini yükseltmek ve elektrik enerjisinin en yüksek kalite ile tüketiciye ulaştırılmasını amaçlar. Bu planlama ve düzenlemelerin en önemli adımlarından biri, gelecekteki elektrik yükünün yüksek doğruluk oranı ile tahmin edilmesidir. Tahmin süresinin uzaması, doğruluk oranını azaltarak belirsizliklere yol açabilir, bu nedenle tahmin sürelerinin kısa olması gerekmektedir. Bugüne kadar birçok tahmin yöntemi çeşitli alanlarda kullanılarak tahminler yapılmıştır.

1.1 TEZİN AMACI

Bu çalışmada, elektrik tüketim talebinin tahmin yöntemlerini incelemek, tahmini etkileyen parametreleri değerlendirmek, Google Colab kütüphanesi platformunda yapay sinir ağları (YSA) kullanarak kısa dönemli yük talep tahmini modeli oluşturmak, oluşturulan modelin test edilmesi ve sonuçların analiz edilmesi hedeflenmektedir.

1.2 KAPSAM

Tokat Gaziosmanpaşa Üniveristesi Hastanesi saatlik elektrik tüketimi ve metoroloji bilgileri alınarak Evrişimsel Sinir Ağları (CNN), Uzun Kısa Süreli Bellek Ağı (LSTM) ve CNN-LSTM Hibrit model kullanılarak elektrik tüketim tahmini yapılmıştır. Doğru tahminleme ile gelecekteki elektrik sisteminde planlama yapılabilir. Gelecekteki elektrik tüketimine göre maliyetler en düşük seviyeye çekilebilir. Tez çalışmasında temel olarak bugüne kadar kullanılan analitik, yapay zeka ve hibrit yöntemleri araştırmak ve elektrik tüketim talebi tahmininde başarıyı incelemektir. Tez çalışmasında ilk hedef, elektrik talep tahmini sorunlarında CNN ve LSTM'lerin kullanılmasını araştırmak ve literatüre katkıda bulunmak amaçlanmaktadır. Asıl hedef, kısa dönemli tahminlemeyi doğru yaparak, elektrik tesisinde doğru planlama ve maliyetlerin en düşük seviyeye indirilmesine yardımcı olmaktır.

1.3 LİTERATÜR ÇALIŞMALARI

Bu tez çalışmasında, bugüne kadar enerji tahminlemede yapılan literatür çalışmaları incelendiğinde çeşitli yöntemlerin etkinliğini değerlendirilmiştir. Araştırmalarda farklı birçok yöntem kullanılarak tahminleme sonucuna ulaşılmıştır. Yapılan tahmin çalışmalarının analitik, yapay zeka ve hibrit yöntemler olmak üzere üçe ayrıldığı görülmektedir. Analitik yöntemle yapılan tahminleme çalışmalarında en küçük kareler, regülasyon analizi v.b. yöntemler yaygın olarak kullanılmıştır.

Nalbant ve arkadaşları (2005), en küçük kareler yöntemiyle üç model geliştirmişlerdir. Yaptıkları modelde doğrusal ve üstel modellerde %5, kuadratik modelde %17 hata oranı bulmuşlardır.

Balcı ve arkadaşları (2010) enerji tahminlemesi yapmışlardır. Çalışmalarında regresyon analizinin en küçük kareler yöntemine göre daha güvenilir olduğunu belirlemiştir.

Uğurel (2013) yılındaki çalışmasında, regresyon modelini kullanarak enerji kaynakları ve Türkiye'nin elektrik tüketimini incelemiş, oluşturduğu modelle gelecekteki tüketimi tahminlemiştir. Çalışmasında, elektrik tüketiminin modellenmesi ile kazanımların neler olacağı üzerine durulmuştur. Elektrik tüketimi doğru bir strateji ile belirlendiğinde işlemlerin maliyeti, zamanı, verimliliği, hataları ve memnuniyet gibi birçok avantajın sağlanacağı belirtilmiştir.

Torkzadeh ve arkadaşları (2014), çoklu lineer regresyon ve korelasyon yöntemleriyle hibrit bir model oluşturmuş ve haftalık tahminlerde %3,68, aylık tahminlerde %1,46 hata oranı yakalamıştır.

Aydın (2016) yaptığı çalışmasında, İstanbulun 2016 ile 2019 arası elektrik tüketimini etkileyen faktörleri incelemiştir. Elektrik tüketiminde meteorolojik faktörlerin etkili olduğu bu nedenle çalışmalarında meteoroloji istasyonundan alınan verilerde kullanılmıştır. TEİAŞ'tan alınan veriler ile meteorolojik veriler kullanılarak regresyon analiz yöntemi modeli oluşturmuştur. Çalışmasında nem, sıcaklık, güneşlenme ve rüzgâr hızı süreleri elektrik tüketimini etkilediği belirtmiştir. Elektrik tüketimi tahminlemesinde doğru sonuca daha yakın tahminleme için meteorolojik faktörlerin kullanılması gerektiğini belirtmiştir.

Sezgin (2018) çalışmasında, tahminleme alanında değil elektrik tüketiminde etkili faktörleri incelemiştir. Elektrik tüketimin artıran veya azaltan faktörleri sıraladığında illerin kişi başı geliri, sanayi kapasitesi, finansal durumu, eğitim oranı, ticaret olanağı, karbon emisyon durumu ve şehirleşme parametreleri kullanılmıştır. Yapılan çalışmada ekonomi, gelir ve karbon emisyon parametrelerinin elektrik tüketiminde arttırıcı olduğu fakat şehirleşme ve fiyatları artıran bir etki yarattığı belirtilmiştir. Yapılan araştırmada kişi başı gelir ve karbon emisyonu yükseldiğinde elektrik tüketiminin yükseldiği, ancak şehirleşmeye ve fiyatlandırmaya olumsuz etki ettiği gözlemlenmiştir.

Öksüz (2018) yaptığı çalışmasında YSA kullanarak elektrik tüketiminde etkili faktörleri incelemiştir. Çalışmasında, meteorolojik faktörlerin sıcaklığı, nem, rüzgâr hızı, güneş ışınımı, günün saatleri, haftanın günleri ve tatil günlerinin elektrik tüketimini etkilediğini belirtmiştir. Yapılan tahminlerde meteorolojik faktörlerin nasıl etkilediği incelemiştir. Gerçek veriler ile yapılan tahminlemelerde, tahmin ve gerçek veriler karşılaştırılmıştır. %10,28 Mape değeri ile tahminleme sonucuna varmıştır.

Hou ve arkadaşları (2014) yaptığı enerji tahminleme çalışmasında, dalgacık dönüşümü ve ARIMA'yı kullanmışlardır. Bu hibrit yöntem sayesinde hata oranını %30 azaltmıştır.

Kaytez (2012) yaptığı çalışmasında en küçük kareler yöntemi kullanmıştır. Çalışmasında günlük sıcaklık değişimi ve üçbin saatlik geçmiş yük verisini kullanarak araştırmalarını tamamlamıştır. Ülkedeki elektrik tüketiminin En Küçük Kareler yöntemi ile yapılan tahminlememin yapılan diğer çalışmalara göre daha doğru sonuç verdiğini göstermiştir. Yaptığı çalışmanın test verilerini, çoklu korelasyon katsayısı, performans ve ortalama

yüzde mutlak hata ile değerlendirildi. Yaptığı çalışmanın ilk başlangıcında doğru sonuçlar vermediği, giriş verilerinin değiştirilmesi ile doğru sonuçlar almıştır. Geçmişte analitik ve yapay zeka yöntemleri tahminlemede yoğunlukla kullanılırken, son zamanlarda derin öğrenme (DÖ) temelli tahminleme çalışmaları mevcuttur.

Kaysal ve arkadaşları (2014) elektrik yük tahmini alanında YSA, regresyon analizi ve hibrit modeller kullanmışlardır. Sonuç olarak hata oranlarını %6,67, %7,49 ve %5,26 olarak belirlemiştir.

Var ve Türkay (2014) kısa dönemli yük talep tahmini yapmışlardır. Sonuç olarak YSA kullanarak %7-%8 hata oranı ile yüksek doğruluklu bir model oluşturmuştur.

Yavuz Demir (2014) yılında bulanık mantık, zaman serisi ve regresyon yöntemleriyle modeller oluşturmuş ve hata oranlarını %4,81, %2,75 ve %7,64 olarak hesaplamıştır.

Karabulut (2017) yapmış olduğu çalışmada, elektrik tüketimini tahmini için farklı yöntemler ve modeller yapmıştır. YSA, karar ağaçları, çoklu doğrusal regresyon ve destek vektör makineleri gibi modeller kullanmıştır. Çalışmasında bu modeller karşılaştırıldığında destek vektör makineleri yöntemi ile gerçeğe daha yakın sonuçlar almıştır. Enerji tahminlemesinde YSA gelişmesi ile DÖ kullanımı artmış ve çalışmalar bu yönde ilerleme kaydettiği görülmektedir.

Sahay ve Tripathi (2013), kısa dönemli elektrik yük talep tahmini modeli için YSA yöntemi kullanmıştır. Oluşturduğu modelde 2007 ile 2012 yılının verilerini kullanmıştır. Bu verilerden 2007 ile 2011 arasını modelini eğitmek 2012 yılı verileri ile modelini test etmek için kullanmıştır. Bu çalışmasında %3,4 hata ortalaması sonucuna ulaşmıştır.

Topallı ve Erkmen (2006), kısa dönemli yük tahmini modellemesi yapmıştır. Yaptığı çalışmada YSA ve otoregresif entegre hareketli ortalama yöntemlerini kullanarak modeller oluşturulmuştur. Bu modeller içerisinde YSA daha başarılı sonuç verdiği ve hata oranının %1,60 olduğu sonucuna varmıştır.

Yalçınöz vd. (2002). Yaptığı çalışmada iki farklı modelle tahminleme yapmıştır. Bu modeller içinde hareketli ortalamalar ve YSA kullanmıştır. Orta dönemli yük tahmininde bulunmuştur. Bu farklı modellerin ikisinde de başarıya ulaşmıştır. Fakat YSA daha başarılı olduğu sonucuna varmışlardır.

Erkmen ve Özdoğan (1997), yapmış oldukları çalışmada yapay sinir ağları, genetik algoritmalar ve kohonen algoritması yöntemlerini kullanmıştır. Bu yöntemler ile ayrı ayrı ve hibrit modeller oluşturulmuştur. YSA modelinde 2,76'lık, Genetik Algoritmalar ve

YSA hibrit modelinde %2,64'lük, Kohonen ve YSA modelinde %1,89'luk, Kohonen, Genetik Algoritmalar ve YSA üçlü hibrit modeliyle %0,96'luk hata oranlarına ulaşmışlardır.

Topallı ve Erkmen (2003), yapmış oldukları çalışmada kısa dönemli yük tahmini yapmaya çalışmışlardır. Çalışmalarında YSA yöntemiyle modelleme yapmışlardır. Türkiye'nin genel elektrik yük tahminini yapmaya çalışan Topallı ve Erkmen bu yöntemle 2000 yılı için %2,31'lik, 2001 yılı için %2,45'lik hata oranlarına ulaşmışlardır.

Fan ve Hyndman (2012), çalışmalarında kısa dönemli yük tahminlerinde bulunmuşlardır. YSA, genelleştirilmiş toplamsal model ve bunlarla oluşturduğu hibrit modeller oluşturmuşlardır. Bu modellerin içinden genelleştirilmiş toplamsal modelin %1,68'lik hata oranı ile daha başarılı tahminleme yaptığı sonucuna ulaşmışlardır.

Masaebi (2016) yapmış olduğu çalışmasında, YSA kullanmıştır. İran'ın elektrik tüketimini kullanarak modelini oluşturmuştur. Modeli eğitim ve test seti olarak ikiye ayırmıştır. Eğitim setinde mutlak hata oranı %5.76, test seti için %3.35' olarak sonuç almıştır. Bu veriler ile, oluşturulan modelin doğru sonuçlar verdiğini göstermiştir. Ayrıca çok katmanlı algılayıcı (MLP) yapısında çalışmasında kullanılmıştır. Oluşturduğu modelin performansını ölçmek için tahmin sonuçları ile gerçek değerleri karşılaştırmıştır.

Reddy ve arkadaşları (2023) çalışmalarında, elektrik tüketimi tahminlemede MÖ modelini kullanarak doğru tahminleme yapmayı amaçlamıştır. Farklı MÖ teknikleri ile modeller oluşturulmuş, K En Yakın Komşu (KNN) modeli ile diğer modellere göre daha doğru sonuçlara ulaşmışlardır.

Elgohary ve Amasyali (2017) çalışmalarında, Binalarda elektrik tüketiminde DÖ nasıl kullanılacağı ve oluşturulan veri tabanlı modellerin enerji verimliliğinde önemini belirtmişlerdir. Yapılan çalışmada Support Vector Machine, Random Forest, Deep Neural Network ve Doğrusal Regresyon gibi modeller üzerinde testler yapılmıştır.

Özkan, Güler ve Aladağ'ın (2020) yaptığı çalışmada, analitik yöntemler den en küçük kareler, fourier ve Winters yöntemi kullanılarak tahminlemelerin doğruluk oranları karşılaştırılmıştır. Elektrik tüketim verileri kullanılarak yapılan tahminleme modellerinin her üç analitik yöntemde de uygun olduğu belirlemiştir.

Aydınlı (2018) yaptığı çalışmasında YSA kullanarak, soğutma sisteminin yapmış olduğu elektrik tüketimin tahmini için kullanılabilirliğini araştırmıştır. Yapılan tahminlemeler ile soğuk hava depolarının, enerjiyi verimli olarak kullanmayı ve girdi maliyetleri düşürmesi

hedeflenmiştir. Soğuk hava depolarında tüketilen elektrik miktarını vurgulayarak, elektrik girdisinin sektördeki önemi gösterilmiştir. Oluşturulan tahmin modelinde %92,126'lık bir sonuca ulaşılmış, bu sonucun soğutma depolarında başarılı olması hakkında bir sonuç elde edilmemiştir.

Yoo ve Alvarez (2018) yazıdıkları bu çalışmalarında, Seoul kentindeki konutların elektrik tüketimlerinin tahmini için YSA kullanmıştır. Seoul kentinin yerleşim durumunun konutlarda kullanılan elektriğin ve son yıllardaki elektrik tüketim değişiminin incelemeye çalışmıştır. Yapılan araştırmada, gerçek veriler kullanılarak SA modeli oluşturmakta ve oluşturulan modelde farklı gerçek veriler ile karşılaştırma yapılmaktadır. Yapılan tahminlerin doğrulunda etki eden faktörler incelenmiş, tahminlemede hangi faktörlerin daha fazla etkili olduğu belirlenmiştir.

Bayar (2019) yaptığı çalışmada, yapay zeka yöntemi kullanarak elektrik tüketimin tahmini yapmaya çalışmıştır. Birçok yapay zeka yöntemi kullanılmıştır. Bunlardan bulanık mantık, karınca kolonisi, diferansiyel polinom SA ve bunların hibrit modelleri bulunmaktadır. Yapılan araştırmalar sonucunda yöntemler karşılaştırıldı ve yapay zeka yöntemlerinin klasik tahmin yöntemlerine göre daha başarılı sonuç verdiğini belirtti.

Meng ve arkadaşları (2022) çalışmalarında, Destek vektör regresyon ve markov zinciri analiz modellerini kullanarak Çin'deki enerji tüketimini tahmin etmiştir. Sonuçları incelendiğinde kömür tüketiminin azalacağı, temiz enerji tüketiminin artacağı, Çin'nin toplam elektrik tüketiminin artacağı belirtilmiştir.

Özcan (2022) yaptığı çalışmada, farklı DÖ modellerini kullanmıştır. Veri olarak Türkiye'nin toplam elektrik tüketimi kullanmıştır. Sonuçlar incelendiğinde verilerin ve faktörlerin kullanılmasıyla kısa dönemli tahminleme başarı elde edildiğini göstermiştir. Elektrik tüketim tahmini konusunda DÖ modellerinin etkili olduğu sonucuna varmıştır. DÖ modellerinden bulanık mantık ve ANFIS'ın kısa dönemli tahminlemede alternatif olacağı belirtilmiştir.

Ateş (2019) araştırmasında yapay zeka yöntemleri kullanmıştır. YSA, genetik algoritmalar ve bulanık mantık gibi çeşitli modeller ile tahminleme yapılmıştır. Bu modeller karşılaştırıldığında en doğru ve başarılı yöntemin YSA olduğunu belirtmiştir. Kullanılan veri seti, 2016 yılına ait Türkiye Elektrik İletim Anonim Şirketi'ne ait 2016 yılı saatlik elektrik tüketim veri setini kullanmıştır.

Wei ve arkadaşları (2019) çalışmalarında, analitik yöntemler ile yapay zeka yöntemlerini arasındaki farklılıkları araştırmışlardır. Sonuç olarak analitik yöntemlerin istatistik modellere dayandığı, yapay zeka modellerin daha karmaşık analiz tekniklerinin kullanıldığını belirtmiştir. Yapay zeka modellerinin tahmin süresinin kısaldığını ve doğruluğunun sağlandığını belirtilmiştir.

Liu ve Li (2022) çalışmasında, yapay zeka yöntemlerinden geri beslemesi SA, çoklu doğrusal regresyon, en küçük kare destek vektör makinesi modellerini Birleşik Krallığın senelik elektrik tüketimi tahminlemek için kullanmıştır. Bu modellerden en küçük kare destek vektör makinesi en iyi tahmin sonucu alındığı belirtilmiştir.

Halaç (2019) çalışmasında, kısa dönem tahminleme yapmak için Türkiye'nin elektrik tüketim verilerini kullanmıştır. YSA modelleriden Facebook'un Prophet Kütüphanesi, Twitter Anormallik Kütüphanesi ve Long/Short Term Memory tahminleme modelleri kullanmıştır. Araştırmanın sonucunda YSA tahminlemede kullanılabileceği belirtmiştir. Yapay zeka teknolojisinin, elektrik tüketim tahminlemesini doğruluğu sayesinde, üreticilerin talebi karşılaması, üretimi planlanması ve üretim maliyetlerini düzenlemeyi sağlanacağını belirtmiştir.

Alanbar ve arkadaşları (2020) yılındaki çalışmasında, elektrik tüketim tahmini için DÖ modellerini kullanılmıştır. Elektrik tüketimi tahmini için DÖ tekniklerinden Deep Neural Network, Deep Belief Network, Recurrent Neural Network, Long Short-Term Memory modelleri oluşturmuştur. Bu modellerden en doğru sonucu ong Short-Term Memory modelleri alındığını belirtmiştir.

Altunkaya (2021) yılında yapmış olduğu çalışmasında, kısa dönem yük tahminlemesinde bulunmuştur. Yaptığı araştırmada Türkiye'nin ve diğer ülkelerin elektrik tüketim tahminlemelerini araştırmıştır. Elektrik tüketim tahmin modellerinde takvim etkisi, benzer günlerin etkisini incelemiştir. Belirli günlerin verisini saatlik olarak 2 boyutlu görüntüye dönüştürerek oluşturulan modelin başarı oranını %0,72 oranında artırmıştır.

Nebati, Taş ve Ertaş (2021) makalelerinde elektrik tüketimi talebi için türkiyedeki geçmiş elektrik tüketim verileri kullanmış tahminleme yapılmıştır. Yapılan çalışmada zaman serisi ve regresyon analizi yöntemleri kullanılmıştır. Bu moeller için sonuçlar incelendiğinde zaman serisi %11,63 Mape değeri alınırken, regresyon analizi modelinde %1.30 olarak tespit edilmiştir. Daha doğru tahminlemenin regresyon analizi modeli ile yapılan tahmin-

leme olabileceği belirtilmiştir. Shapi ve arkadaşları (2021) çalışmalarında, elektrik tüketimi tahminlemesi için MÖ tekniklerini kullanmışlardır. Farklı modeller kurularak yapılan çalışmada K-En Yakın Komşu tekniği ile oluşturulan modelin daha doğru bir şekilde elektrik tüketimi tahminini yaptığı belirtilmiştir.

Dincer (2022) yaptığı çalışmasında, aylık tüketim tahmin modeli için yapay zeka yöntemini kullanmıştır. Çok katmanlı algılayıcı yapısı ile kısa dönemli yük tahminlemesi yapılmıştır. Elektrik talep tahminleme için bazı parametrelerin kullanılması gerektiğini belirledi. Tahminleme için yapılan modeller ve kullanılan parametrelerin performansı ölçülmüştür. Sonuç olarak regresyon analizi, zaman serisi analizi, yapay zeka ve YSA teknikleri ile elektrik tüketimlerinin tahminlemesi yapılabileceği göstermiştir. elektrik tüketimin doğru tahminlemesi ile daha doğru ve verimli planlama yapılacağı belirtilmiştir.

Marmara (2022) yaptığı çalışmasında, elektrik tüketim tahminlemesi ve maliyetlerin iyileştirilmesinde uzman sistemler, YSA ve zaman serileri analizi yöntemlerini kullanmıştır. Sonuç olarak modellerinin elektrik tüketim tahminlemesini doğru yaptığı ve maliyetleri azaltabileceği belirtmiştir.

Tokgöz (2018) çalışmasında, DÖ yöntemini kullanmıştır. Geliştirdiği modelinde tekrarlayan sinir ağı (RNN) ve 81 ilimizin saatlik elektrik tüketim bilgisini kullanmıştır. Elektrik tüketim tahminle modelinde kısa vadeli dönemi tahminlemiştir. Modelleme içindeki parametrelerde illerin nüfus yoğunluğunu elektrik tüketimine doğru orantılı olduğu varsayılmıştır. Araştırmaların sonucunda tekrarlayan sinir ağlarının diğer modellere göre daha başarılı sonuç verdiğini göstermiştir.

Berriel ve arkadaşları (2017) çalışmalarında, DÖ yönetmi ile aylık elektrik tüketimi tahmini yapmıştır. Modeller için toplamda 934.945 farklı tüketiciden 21.978.437 ölçüm alınmıştır. Çalışma, Tamamen Bağlantılı Sinir Ağı (FC), CNN ve LSTM inceledi ve modeller yapıldı. Bu modeller arasında LSTM modelinin mutlak ve göreceli hatalarda en iyi sonucu verdiğini göstermiştir.

Literatürde DÖ çalışmalarında hibrit yöntemlerde kullanılmıştır. Gözüoğlu 2024 yılında yapmış olduğu çalışmasında, gelecekte kurulacak olan akıllı şebekelerin tüketici tarafını tahminlenmesi için CNN-LSTM hibrit modeli kullanılmıştır. Tasarlanan ve uygulanan yönetilebilir enerji sistemi ile yönetilebilir cihazları olmayan meskenlerin dahil az maliyetler ile yönetilebilir meskenlere döndürüleceği sonucuna varmıştır Gozuoglu (2024).

Sonuç olarak, enerji talebi tahmini için çeşitli yöntemler ve hibrit modeller geliştirilmiş ve YSA, hibrit modeller ve regresyon analizlerinin başarılı sonuçlar verdiği gösterilmiştir.



2. KURAMSAL TEMELLER

Bu tezde, öncelikle elektrik tüketimi talep tahmini konusu ele alınmış ve ardından tahmin yöntemleri detaylı olarak incelenmiştir. Uygulama kısmında ise, YSA yöntemi ayrıntılı bir şekilde ele alınmıştır. Elektrik tüketimi talep tahmini, enerji piyasasının planlanması ve düzenlenmesinde kritik bir rol oynar. Elektriğin üretiminden son kullanıcıya ulaşana kadar yapılması gereken altyapı ve üstyapı yatırımları ile diğer maliyetlerin en düşük seviyeye çekilmesi, güç sistemlerinin verimliliğinin artırılması, sistem güvenilirliğinin sağlanması ve elektrik enerjisinin en yüksek kaliteyle kullanıcıya ulaştırılması hedeflenir. Bu sayede planlamalar ve düzenlemeler en önemli adımlarından biri yapılmış olur. Gelecekte tüketilecek elektrik yükünün yüksek doğruluk oranı ile tahmin edilmesidir. Tahmin süresinin uzun olmaması istenilir, çünkü kısa süreli tahminler belirsizlikleri ortadan kaldırır. Uzun süreli tahminler belirsizliklere neden olabilir (EPDK 2006). Bu nedenle, talep tahminleri zaman dilimlerine göre sınıflandırılır.

2.1. Yük Talep Tahmininin Sınıflandırılması

Tahminleme sürelerini kısa, orta ve uzun dönem olarak sınıflandırılmıştır. (Pala 1998). Kısa dönemli tahminler, saatlik ya da günlük olarak yapılan tahminlerdir. Bir saatten bir haftaya kadar olan periyotlarda yapılan bu tahminler, kısa dönemli yük talep tahmini olarak adlandırılır. Bu tür tahminler, tesisin düzenli çalışmasını sağlama açısından en uygun tahmin dönemi olarak kabul edilir. Elektrik yük talebinin her saat ya da yarım saatte yüksek doğrulukla tahmin edilmesi, elektrik güç sisteminin etkin bir şekilde planlanabilmesi için büyük önem taşır. Elektrik tüketimi gün içerisinde sürekli değişir ve talep edilen enerji de sürekli olarak değişkendir. Bu nedenle, devreye girip çıkan elektrik santrallerinin planlaması kısa dönemli yük talep tahminine göre yapılır. Kısa dönemli yük talep tahminleri, elektrik güç sisteminin tüketim ve üretim dengesini sağlamada önemli bir rol oynar (Pala 1998). Bu sayede, tesis dengeli bir enerji alır ve elektrik enerjisi üretildiği gibi tüketilir. Ayrıca, tesisin verimi, frekans dengesinin sağlanması, sistem güvenilirliğinin artırılması ve maliyetlerin düşürülmesi açısından da önemli bir planlama aracıdır. Enerji Piyasası Deneleme Kurumu tarafından 2018 tarihinden sonra, belirli bir tüketim değerinden sonra son kaynak tedarik tarifi uygulanmaya başlamış ve bu tarife kapsamında tüm aboneler elektriği saatlik olarak satın alıp aylık olarak fatura ödemektedir (20.01.2018 tarih ve 30307 sayılı EPDK' tebliği). Bu değişiklik, kısa

dönemli tahminlemenin önemini artırmıştır. Orta Dönemli Tahminler, Aylık Tahminler, Bir haftadan bir yıla kadar olan yük talep tahminleri orta dönemli tahminler olarak adlandırılır. Bu tahminler, güç sistemlerinin periyodik bakımlarının planlanması ve kısa süre içinde devreye alınabilecek üretim santrallerinin planlanması için kullanılır (Biçer 2018). Uzun Dönemli Tahminler, Yıllık Tahminler, Bir yıldan daha uzun süreli tahminler uzun dönemli yük talep tahmini olarak adlandırılır. Bu tahminler, mevcut üretim tesislerinin ve iletim dağıtım ağlarının gelecekteki talebi karşılayabilecek kapasitede olup olmadığını değerlendirmeye olanak tanır. Yeni santral veya iletim hattı ihtiyacı olup olmadığına karar verilir ve bu karar doğrultusunda yeni üretim santralleri ve ilgili kaynakların tesis planlamaları yapılır. Ayrıca, iletim dağıtım hatlarında yapılacak eklemeler ve yeni hatların kurulacağı yerler de planlanır (Biçer 2018).

2.2. Yük Tahmin Parametreleri

Elektrik tesislerinden çekilen yük, günün saatine ve tüketicinin bulunduğu bölgeye bağlı olarak farklılık gösterir. Pala (1998), elektrik tesislerinde bölgesel tüketim tahminini incelerken yükleri dört ana kategoriye ayırmıştır: ticarethaneler, konutlar, sanayi ve diğerleri (Pala 1998). Bilge'de sistemi yükünü dört ayrı bileşene ayırmıştır (Bilge):

$$Y = Y_n + Y_w + Y_s + Y_r \quad (2.1)$$

Bu denklemde; Y sistemdeki toplam elektriksel tüketimi, Y_n normal elektrik tüketimi bölümü, tüm yıl süresince günlük genelleşmiş elektrik tüketim veri setini, Y_w yıl içinde mevsimlerin hava durumuna bağlı olarak elektrik tüketimi değişimi değerini, Y_s genelleşmiş elektrik tüketiminden, değişik sapmaya sebep olan yük değişimini, Y_r öngörülemeyen olarak rastlantısal ortaya çıkan, elektrik tüketim değerini ifade etmektedir.


Elektrik enerjisi büyük güçlerde depolanamaz, bu yüzden üretildiği gibi tüketilmesi gerekir, iletim ve dağıtım hatlarının kapasiteleri sınırlı olduğundan elektrik maliyetleri mekana, tüketime ve zamana göre değişmektedir. Bundan dolayı tesisten çekilen yükü etkileyen faktörler ile fiyat arasında ilişki vardır (Chen et al. 2001). Bu nedenle talep edilecek elektriksel yükün tahminini yapmak oldukça karışık bir sorun haline getirmektedir (Chen et al. 2001). Yukarıdaki formülde her bileşen değişken olduğundan, tahmin fonksiyonu da değişken bir fonksiyon haline gelir. Bu nedenle, elektriksel yükün tahmin edilmesi oldukça karmaşık bir sorun haline gelir (Chen et al. 2001). Tüketimde yükü etkileyen faktörler şunlardır:

Meteorolojik Faktörler

Metorolojik faktörlerin elektrik tüketimini değiştirdiği gözlemlenmiştir. Mevsim değişikliğinde iç mekanların iklimlendirme ihtiyacı değişecektir. Bu değişim Kimi zaman ısıtma kimi zaman soğutma ihtiyacı doğuracaktır Pala (1998). Bu tez çalışmasında kullanılan uygulama alanımız hastane olduğundan temiz hava veya basınçlandırılmış alanlar olduğundan elektrik tüketimi ihtiyaca göre şekillenecektir. Meteorolojik değişimlerin tüketimi etkilediği Tokat Gaziosmanpaşa Üniveritesi Hastanesi'nin yapılarında iklimlendirme ihtiyaçlarının devreye alınması sonucu elektrik tüketimlerinin değiştiği gözlemlenmiştir.

Zamana Göre Değişim

Zamana göre elektrik tüketimleri değişmektedir. Gündüz sanayinin, kurumların ve ticarethanelerin tüketimi en fazla seviyeye çıkarken, gece insanların genelde dinlenme ihtiyaçlarını giderdiğinden elektrik tüketimi en az seviyeye düşmektedir (EPDK). Şekil 2.1. de Tüketim verisinin bir haftalık yük grafiği görülmektedir.




Şekil 2.1. Uygulama alanı tüketim verisinin bir haftalık grafiği.

Çalışmamızın uygulama alanı olan Tokat Gaziosmanpaşa Üniveritesi Hastanesinin Şekil 2.1'de görülen elektrik enerjisi tüketim verilerinin bir haftalık elektrik yükü incelendiğinde hafta sonu tüketimlerin düştüğü, hafta içi gündüz tüketimlerin arttığı görülmektedir. Özellikle 09:00 – 11:00 ile 14:00 – 16:00 arası tüketimlerin en fazla olan dönemler olduğu görülmektedir.

Rasgele Değişkenler

Rasgele değişkenler önceden belirlemeyen, öngörülemeyen durumlar olup enerji tüketimini etkilemektedir. Önceden toplu görev bırakma, doğal afet, dağıtım ve iletim tesisinde oluşabilecek kesintiler gibi rasgele değişkenlerin oluşması durumunda elektrik tüketimi değişime uğrar (Saçlı 2020). Şekil 2.2'de Tokat Gaziosmanpaşa Üniveritesi Hastanesine

ait 22 Aralık – 20 Mart 2023 Aralığı Yük Grafiği görülmektedir.



Şekil 2.2. 22 Aralık – 20 Mart 2023 aralığı yük grafiği.

Bu grafik incelendiğinde rasgele değişkenlerden dolayı tüketimlerin bazı günler sıfıra düştüğü görülmektedir. Yapılan araştırmalarda tüketimin sıfıra düştüğü saatlerde elektriğin dağıtım şirketi tarafından kesildiği tespit edilmiştir. Elektriğin çok arttığı saatlerde kesintilerden sonra Kesintisiz güç kaynaklarının yeniden şarj olması gibi durumlarda saatlik tüketimlerin arttığı görülmüştür.

Nüfus ve Ekolojik Faktörler

Nüfus ve Ekolojik Faktörler enerji tüketimini etkileyen bir diğer unsurdur. Nüfus bakımından şehirlerimizde mevsimsel nüfus yoğunluğu değişmektedir. Bu değişim elektrik tüketiminin de değişimine sebep olmaktadır (Saçlı 2020).

2.3. YÜK TAHMİN YÖNTEMLERİ

Literatür incelendiğinde yük tahminlerinde çeşitli yöntemler kullanılmaktadır: Analitik yöntemler, yapay zeka yöntemleri ve hibrit yöntemler olarak üçe ayrılmaktadır (Chen et al. 2001). Şekil 2.3’de talep tahmin yöntemleri görülmektedir.



Şekil 2.3. Talep tahmin yöntemleri.

Yapılan bu tez çalışmada, YSA temelli yük tahmini gerçekleştirilmiştir. Arka arkaya gelen gizli katmanların sayısının artırılmasıyla YSA yeni ve farklı bir perspektif kazandıran MÖ'nün bir alt dalı "DÖ" olarak adlandırılmıştır. DÖ yönteminde derin kelimesi, ağın başarısındaki artış değil, modelin kat kat olduğunu ifade etmektedir. YSA genellikle bir veya iki katman üzerinden öğrenme gerçekleştirir; bu sebeple bu yaklaşım çoğunlukla "sığ öğrenme" olarak adlandırılır. Buna karşılık, DÖ, çok sayıda ardışık gizli katmana sahip olabilir, bazen yüzlerce veya binlerce katmanı içerir (Patterson et al. 2017). Aşağıdaki bölümde, geleneksel SA yapılarının temelleri derin sinir ağları (DNN) ve önde gelen algoritmalar açıklanmıştır.

2.3.1 Yapay Zeka Temelleri

Sinir ağları (SA), birden fazla birimin merkezi kontrol ünitesi tarafından paralel olarak çalıştığı ve insan beyninin işleyişine benzer özellikler taşıyan hesaplamalı bir modeldir (Patterson et al. 2017). Bu modeller YSA olarak da adlandırılmaktadır.

Yapay Sinir Ağları (YSA)


YSA'lar, insan beyninin geleneksel bilgisayarlardan farklı bir şekilde işlediği kabulü ile geliştirilmiştir (Haykin et al, 2009). İnsan beyni, karmaşık değişkenlerle paralel işlemler gerçekleştirebilen bir bilgi işleme sistemidir.

Nöron adı verilen yapısal bileşenleri düzenleme kabiliyetine sahip olup, bu sayede belirli hesaplamaları günümüzün en hızlı bilgisayarlarından çok daha hızlı bir şekilde gerçekleştirebilir. Beyin, doğumda belirgin bir yapıya sahip olup tecrübe kavramı sayesinde kendi davranış kurallarını geliştirme yeteneğine sahiptir. İnsan beyninin belirli bir işlevi yerine getirme şeklini YSA ile modellemek için tasarlamıştır (Haykin et al. 2009). SA genellikle elektronik komponentler kullanılarak uygulanmış ve bilgisayar arayüz yazılımı ile analiz edilir. SA, deneyimsel verileri saklama eğilimine sahip olup bu bilgiyi kullanılabilir hale getiren büyük ölçüde paralel dağıtılmış işlemciler olarak tanımlanır (Haykin et al, 2009).

Biyolojik Nöron


İnsan vücudunun sinir sisteminde değişen tip ve uzunluklarda milyonlarca nörondan oluşmaktadır. Şekil 2.4'de gösterilen nöron yapısı üçe ayrılmaktadır. Bu üç ana yapı akson, dendrit ve hücre gövdesidir (Basheer et al. 2000). Kalıtım özellikleri hücre gövdesinden alınır. Hücre gövdesinde bulunan plazma bilgi veren bir çekirdeğe ve nöronun ihtiyaç

duyduğu malzemeleri üretmek için kullanılan moleküler ekipmanı içeren bir yapıya sahiptir. Sinyali dendritler öbür nöronlardan alır ve bu sinyalleri hücre gövdesine iletir.



Şekil 2.4. Biyolojik nöronun şekli (Basheer et al. 2000).

Normal bir nöronun dendritlerinin sinyal alma alanı, toplam yaklaşık olarak 0.25 mm^2 'dir (Zupan et al. 1991). Aksonlar, hücre gövdesinden gelen sinyalleri alıp komşu nöronların dendritlerine sinaps yoluyla iletmektedir. Bu şekilde metin, aksonların işlevini ve sinyal iletim sürecini daha açık bir şekilde ifade eder. Şekil 2.5, iki biyolojik nöron arasındaki elektriksel sinyal transferini göstermektedir (Basheer et al. 2000).




Şekil 2.5. İki biyolojik nöron arasındaki elektriksel sinyal transferi (Basheer et al. 2000). Bir alıcı nöronun gelen sinyalin miktarı, her bir beslenme nöronundan gelen sinyallerin sayısına, sinaptik kuvvetlere ve alıcı nöronun eşik değerine bağlıdır. Bir nöron çok sayıda dendrit ve sinaps barındırır, bu nedenle nöron, aynı anda birçok sinyali alabilir ve verebilir. Bu sinyaller, nöronun aktif hale gelmesini veya engellenmesini sağlayabilir. Bu basitleştirilmiş sinyal transfer mekanizması, YSA temel birimlerinin yapı taşlarını ve işleyişinin temel adımlarını oluşturmuştur (Basheer et al, 2000).

Yapay Nöron

1958 yılında Rosenblatt, karakter tanıma sorunlarını çözmek amacıyla tek bir nöronun

oluşan ve "Perceptron" adını verdiği yapıyı tanıtmıştır (Basheer et al. 2000). Şekil 2.6'da tek katmanlı perceptron içeren bir yapay nöronda sinyal toplama ve n sayıda nöron ile sinyal transferinin benzeşimi gösterilmektedir.




Şekil 2.6. Yapay nöronda sinyal toplama ve n sayıda nöron ile sinyal transferi (Basheer et al. 2000).

Biyolojik nöronların mekanizmalarından elde edilen bulgular, basit yapay nöronların işleyişini modellemek için yapılan ilk araştırmalara temel oluşturmuştur. Yapay bir nöron işlemcisi dışarıdan gelen uyarıcıları giriş olarak alır ve bu girişleri özel bir yöntemle birleştirir. Şekil 2.6' da gösterildiği gibi yapay nöron bu sinyali belirli bir sınır değerinin üzerinde olduğunda bir başka nörona ya da çevreye iletir. Nöron, birleştirilen değerin belirli bir sınır değerini aşması durumunda aktifleşir. Giriş değeri, nöronların x ve ağırlıkların w çarpılması ile hesaplanır. N adet nöron için bu hesaplama, Eşitlik 2.2'de gösterilmektedir.

$$y = \begin{cases} 1, & \text{eğer } \sum_{i=1}^n w_i x_i \geq b \\ 0, & \text{eğer } \sum_{i=1}^n w_i x_i < b \end{cases} \quad (2.2)$$

Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı yapay sinir ağları (MLP) mimarisinde, nöronlar, Şekil 2.7'de gösterildiği gibi, eş girdi verilerini paylaşan ve paralel bir düzenlemeye sahip olan birden fazla katmana ayrılmıştır (Souza et al. 1991).



Şekil 2.7. Çok katmanlı yapay sinir ağı mimarisi (Souza et al. 1991).

Bu mimariye verilebilecek en iyi örnekler, radyal tabanlı fonksiyonlar ve çok katmanlı algılayıcılar olarak bilinmektedir (Souza et al. 1991). Bu tür mimariye sahip ağlar gerçek verileri özel bir fonksiyonla temsil etmek için kullanışlıdır.


Öğrenme Süreci

Yapay bir mimaride öğrenme, belirli bir görevi yerine getirmek için iç süreçlerin güncellenmesi ve dıştan gelen uyarılara yanıt verilmesi olarak tanımlanır (Basheer et al. 2000). Bu sürece ayrıca, “eğitim” adı verilmektedir, çünkü eğitim, YSA mimarilerinde bulunan bağlantı ağırlıklarının iteratif olarak ayarlanma işlemidir (Yao, X et al. 1999). Bu işlem, bağlantı ağırlıklarının ayarlanması, bazı bağlantıların ayrılması ya da birleştirilmesi, nöronların sınır değerlerinin değiştirilmesi gibi ağ mimarisinde yapılan değişiklikleri içerir. Ağ, insan beyninin deneyimlerle öğrenme sürecine benzer bir şekilde, yani yinelemeli olarak, YSA öğrenimini gerçekleştirir. Bu süreç göz önüne alındığında, öğrenmenin olasılıksal olduğu ve öğrenilen yöntemden yola çıkarak genelleme yapılabildiği söylenebilir (Basheer et al. 2000).

YSA’de öğrenme; Denetimli öğrenme, Denetimsiz öğrenme ve Takviyeli öğrenme olarak üçe ayrılmaktadır (Yao, X et al. 1999). Denetimli öğrenme, bir SA mevcut çıktısı ile beklenen çıkış değeri arasındaki karşılaştırmaya dayanır. Genellikle bu süreç, tüm veriler üzerinde oluşan çıkış verisi ile beklenen çıkış verisi arasındaki Ortalama Karesel Hata (MSE) fonksiyonunun toplamını en aza indirmeyi hedefler. Denetimsiz öğrenme, sadece giriş verilerini kullanır ve bu veriler arasındaki ilişkilere dayanır. Öğrenme sonuçlarında sonuçların doğruluğu hakkında kesin bilgi bulunmaz. Takviyeli öğrenme, istenilen çıktının tam olarak bilinmediği denetimli öğrenmenin özel bir türüdür. Bu süreç, sadece gerçek çıktının doğru olup olmadığı bilgisini kullanır (Yao, X et al. 1999).

İleri Beslemeli Sinir Ağları

İleri Beslemeli Sinir Ağları (FFNN), bir veya daha fazla gizli sigmoid nöron katmanına ve son olarak bir doğrusal nöron çıkış katmanına sahip ağ mimarisi olarak tanımlanır (Demuth et al. 2009). NN çıkışlarının belirli sınırlar içinde (örneğin, 0 ya da 1) tutulması istendiğinde, çıkış katmanında sigmoid aktivasyon fonksiyonları kullanılabilir. Doğrusal olmayan aktivasyon fonksiyonlarına sahip çoklu nöron katmanları, ağın giriş ve çıkış vektörleri arasındaki olasılıksal ilişkileri öğrenmesini sağlar (Haykin et al. 2009).



Şekil 2.8. İleri Beslemeli Sinir Ağı Yapısı

Şekil 2.8'de, bir gizli katman ve bir çıkış katmanına sahip tam bağlı FFNN yapısı gösterilmektedir (Haykin et al. 2009). Ağın giriş katmanındaki bağlantılar (kaynak düğümleri), ikinci katmandaki (yani, ilk gizli katman) nöronlara (hesaplama düğümleri) giriş sinyalini (giriş vektörü) sağlar. İkinci katmanın çıkış verileri, ağın üçüncü katmanına giriş olarak kullanılır. Benzer şekilde, ağın her katmanındaki nöronlar, yalnızca bir önceki katmanın çıkış verilerini giriş olarak alır. Ağın çıkış (son) katmanındaki nöronlarda oluşan çıkış veri seti, ağın giriş (birinci) katmanındaki kaynak bağlantılar tarafından sağlanan aktivasyon düzeninin genel tepkisini temsil eder. m kaynak bağların sayısı, h_1 birinci gizli katmandaki nöron sayısı, h_2 ikinci gizli katmandaki nöron sayısı ve q çıkış katmanındaki nöron sayısı olan bir FFNN, $m-h_1-h_2-q$ ağı olarak adlandırılmaktadır (Haykin et al. 2009). Şekil 2.8'de gösterilen ağlarda, her katmandaki her düğümün bitişik ön katmandaki tüm nöronlarla bağlı olduğu duruma "tam bağlı" ağ adı verilir. Bitişik ön katmandaki her düğüm ile bağlı olmayan durum ise "kısmi bağlı" ağ olarak adlandırılır.

Geri Beslemeli Sinir Ağları

Geri beslemeli sinir ağları (BPNN) mimarisi, en az bir geri besleme döngüsüne sahip

olmasıyla FFNN'den ayrılır (Haykin et al. 2009). Geriye doğru yayılma algoritması, ortalama hatalar karesi öğrenme algoritmasına benzer ve gradyan azalmaya dayanır; yani, ağırlıklar hata ölçüsünün negatif gradyanı yönünde güncellenir (Kishan et al. 1996). Geri yayılım algoritması, SA alanında önemli bir etkiye sahiptir ve birçok disiplinde yaygın olarak kullanılmaktadır (Hecht-Nielsen et al. 1989). Geri yayılım, fonksiyon yaklaşımı, sınıflandırma ve kestirim gibi çeşitli uygulamalar için kullanılır (Kishan et al. 1996).

Aktivasyon Fonksiyonları


Bir nöron tarafından hesaplanan ağırlıklı toplam, artı sonsuz ile eksi sonsuz arasında değerler alabilir (Specht et al. 1988). Nöronun ürettiği bu toplam değerinin sınırlarının bilinmemesi, hangi durumlarda aktif olup olmayacağı problemini ortaya çıkarır (Rapunal et al. 2006). Nöronun çıkışını "hayır" ya da "evet" gibi kararlaştırmak için transfer fonksiyonu olarak da bilinen aktivasyon fonksiyonları kullanılır. Kullanılan fonksiyona bağlı olarak, elde edilen toplam değer 0 ile 1 veya -1 ile 1 arasında değişir. Aktivasyon fonksiyonları, doğrusal ve doğrusal olmayan olmak üzere iki ana kategoriye ayrılır (Souza et al. 1991). Doğrusal olmayan aktivasyon fonksiyonları, birden fazla katman istiflenmesini mümkün kılar ve türevlenebilir yapıları sayesinde ağırlık eğitimi sırasında gradyan temelli optimizasyon yöntemlerinin kullanılmasına olanak tanır (Tavanaei et al. 2018).

Günümüzde birçok aktivasyon fonksiyonu kullanılmaktadır; bunlardan bazıları kullanım sıklığına göre aşağıda açıklanmaktadır:

Adım Aktivasyon Fonksiyonu

Adım aktivasyon fonksiyonu, nöronun belirlenen bir eşik değeri aştığında aktif olmasını, aksi halde pasif olmasını sağlar (Bishop et al. 2006). İkili sınıflandırma problemlerinde "hayır" veya "evet" gibi ikili sonuçlar üretir. Ancak, birden fazla çıktı nöronunun olduğu sınıflandırma problemlerinde olasılıksal sonuçlar (%20, %30 gibi) üretemediği için kullanımı zordur. Adım fonksiyonu matematiksel olarak Eşitlik 2.3'de, grafik olarak şekil 2.9'da gösterilmektedir.


$$f(x) = \begin{cases} 1, & \text{eğer } x \geq 1 \\ 0, & \text{eğer } x < 0 \end{cases} \quad (2.3)$$



Şekil 2.9. Adım aktivasyon fonksiyonu

Doğrusal Aktivasyon Fonksiyonu


Doğrusal aktivasyon fonksiyonu, çıkışların girişlerle doğru orantılı olduğu düz bir hat fonksiyonudur. Bu fonksiyon, matematiksel olarak $y = xw$ şeklinde ifade edilir. Ağ ne kadar fazla katman içerirse içersin, doğrusal fonksiyonlar kullanıldığında, son katmandaki aktivasyon fonksiyonu giriş katmanının doğrusal bir fonksiyonu olacaktır. Bu durum, tüm ağın doğrusal bir tek katmana eşdeğer olmasına yol açar. Dolayısıyla, doğrusal fonksiyonlar yalnızca çıktı katmanında kullanılır (Souza et al. 1991). Şekil 2.10'da, doğrusal fonksiyonuna ait grafik gösterilmektedir.



Şekil 2.10. Doğrusal aktivasyon fonksiyonu grafiği (Souza et al. 1991).

Sigmoid Aktivasyon Fonksiyonu


Sigmoid türevlenebilen ve düz bir fonksiyondur (Haykin et al. 2009). Sigmoid aktivasyon fonksiyonu, adım ve doğrusal fonksiyonlara göre en büyük avantajı doğrusal olmamasıdır. Sigmoid fonksiyonunu kullanan bir sinir hücresinin çıkış değerleri doğrusal değildir (Specht et al. 1988). Sigmoid fonksiyonu 0 ile 1 arasında değerler üretir. Şekil 2.11'de 0 ve 1 aralığında değer üreten sigmoid fonksiyonunun grafiği gösterilmektedir. Sigmoid fonksiyonunun sorunu, -3 ve +3 bölgelerinin ötesinde doğrusal olmamasıdır. Bu düzleşme bu bölgelerde eğimin küçük olduğu anlamına gelir.



Şekil 2.11. Sigmoid aktivasyon fonksiyonunun grafiği (Souza et al. 1991).

Tanh Aktivasyon Fonksiyonu

Tanh aktivasyon fonksiyonu, ölçeklendirilmiş bir sigmoid fonksiyonu olarak bilinir (Haykin et al. 2009). Doğrusal olmaması, ağıın katmanlar halinde çalışmasını sağlar. Tanh aktivasyon fonksiyonu, -1 ile 1 arasında değerler üretir (Ozkan ve Erbek et al. 2003). Bu fonksiyon, giriş değerlerinin negatif bölgesinde -1'e, pozitif bölgesinde ise 1'e yakın değerler üretir, bu da sinir ağlarının daha geniş bir değer aralığına sahip olmasına olanak tanır. Tanh fonksiyonun eğimi ile sigmoid fonksiyonun eğimi arasındaki fark tanh fonksiyonun daha dik olmasıdır. Tanh fonksiyonun avantajı, negatif girişlerin negatif karşılığı olmasıdır. (Souza et al. 1991).



Şekil 2.12. Tanh aktivasyon fonksiyonunun grafiği.

Rectified Linear Aktivasyon Fonksiyonu (ReLU)


Rectified Linear Aktivasyon Fonksiyonu (ReLU), $f(y)=\max(0, y)$ olarak tanımlanır. ReLU fonksiyonu 0 ile artı sonsuz arasında değerler üretir (Jin et al. 2015). Ancak, ReLU fonksiyonunun temel problemi, negatif değerli girişler için çıkışların sıfır olarak kalmasıdır. Bu durum, ağıın eğitim gücünü sınırlayabilir.

DNN çok sayıda katman içerir (Krizhevsky et al. 2012). Bu yapılar ReLU fonksiyonunun daha fazla kullanımına neden olur çünkü ReLU'nun matematiksel işlemleri tanh ve sigmoid fonksiyonlarına göre daha basittir ve daha verimli hesaplama sağlar (Krizhevsky et al. 2012).

Leaky Rectified Linear Aktivasyon Fonksiyonu (LReLU)

Leaky Rectified Linear Aktivasyon Fonksiyonu (LReLU), ReLU fonksiyonunun genişletilmiş bir versiyonudur (Maas, Hannun et al. 2013). ReLU fonksiyonunda, giriş değerleri sıfır olduğunda eğimin sıfır olur ve bu durum nöronların "ölü" olarak kabul edilmesine yol açar. Bu sorunun çözümü için LReLU fonksiyonu geliştirilmiştir.

LReLU, x değerinin sıfırdan küçük olduğu durumlarda, değerleri sıfır olarak tanımlamak yerine, x 'in küçük bir doğrusal bileşeni olarak tanımlar. Bu, negatif değerli girişler için küçük bir eğim sağlar ve böylece nöronların aktif kalmasını sağlar (Maas, Hannun et al. 2013).



Şekil 2.13. Relu ve LReLU (Krizhevsky et al 2012).

Yatay Hattın Kaldırılmasının Avantajları

Yatay hattın kaldırılmasının temel avantajı eğimin sıfır olmasını engellemektir. Bu, grafiğin sol tarafındaki eğimin sıfır olmasını engeller ve böylece ölü nöronları ortadan kaldırır. Şekil 2.13'te ReLU ve LReLU fonksiyonlarına ait grafikler gösterilmektedir. LReLU için negatif kısmın katsayısı sabit değildir bu katsayı ayarlanabilir ve öğrenme sürecinde optimize edilebilir.

Softmax Aktivasyon Fonksiyonu

Softmax fonksiyonu genellikle sınıflandırma sorunlarında kullanılan bir aktivasyon fonksiyonudur ve sigmoid fonksiyonunun bir genellemesidir (Demuth et al. 2009). Sigmoid fonksiyonu yalnızca iki sınıfı ayırt edebilir, bu nedenle iki sınıftan fazla olan sınıflandırma problemleri için yetersizdir (Bishop et al. 2006). Softmax fonksiyonu her çıktı değerini 0 ile 1 arasında sıkıştırır ve çıktılar toplamına böler. Bu her girdinin belirli bir sınıfa ait olma olasılığını sağlar (Demuth et al. 2009).

Hata Fonksiyonları

SA kullanımını sınırlayan temel faktörlerden biri, eğitilmiş bir ağın gerçek dünya kullanımında güvenilir sonuçlar üreteceğini göstermenin zorluğudur (Bishop et al. 1994). Eğitim sırasında kullanılan verilerle benzer veriler sunulduğunda ağın güvenilir sonuçlar verdiği gözlemlenmiştir, ancak yeni veriler sunulduğunda, beklenen değer ve çıkış değeri arasında ciddi farklar ortaya çıkabilir (Bishop et al. 1994). Hata fonksiyonları, ağın tutarsızlıklarını belirlemek için kritik bir rol oynar. Ağ modelinin doğruluğu hata fonksiyonunun sonucu ile ters orantılıdır ve negatif olmayan değerler alır. Ağın çözüm aradığı sorunlara göre kullanılan hata fonksiyonları aşağıda açıklanmıştır.

MSE (Ortalama Karakök Hatası)

Bir SA eğitilmesi, bağlantı ağırlık değerlerinin ayarlanmasını içermektedir (Demuth et al. 2009). Ortalama karakök hatası olarak bilinir. Ağın beklenen tahmin değeri ile elde edilen tahmin değeri arasındaki farkların karelerinin toplanarak ağın performansı değerlendirilir. Bu yöntem, Ortalama Kareli Hata (MSE) olarak adlandırılır. (Demuth et al. 2009) ve Eşitlik 2.4'teki formül ile tanımlanır.

$$f = mse = \frac{1}{N} \sum_{i=1}^N e_i^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (2.4.)$$

Burada, t :1 beklenen değeri ve a elde edilen çıkış değerini temsil eder. MSE, her bir veri noktası için beklenen değer ile elde edilen değer arasındaki farkların karesini alır. Bu yöntem, negatif sonuçların ortaya çıkmasını engelleyerek tüm hata değerlerini pozitif hale getirir. MSE'nin temel amacı, beklenen değer ile elde edilen çıkış değerlerinin arasındaki farkların karelerinin ortalamasını alarak, toplam hata miktarını minimize etmektir. Başka bir deyişle, MSE, tahminlerin doğruluğunu ölçmek için kullanılan bir kriter olup, modelin performansını iyileştirmek için hata değerlerinin mümkün olduğunca küçük olmasını hedefler (Demuth et al. 2009).

RMSE (Kök Ortalama Karakök Hatası)

Kök Ortalama Karekök Hatası (RMSE), MSE'nin kareköküdür. RMSE, MSE'den daha yaygın olarak kullanılır çünkü MSE değeri bazen karşılaştırılamayacak kadar büyük olabilir. Eşitlik 2.5'teki formül ile tanımlanır. RMSE, hata karesinin karekökünü aldığı için yorumlamayı kolaylaştırır. Ancak, MSE gibi, RMSE de aykırı değerlere karşı yüksek derecede duyarlıdır. RMSE, MSE'nin kareköküdür ve hata büyüklüğünü aynı birimde ifade eder. RMSE, hatanın büyüklüğünü anlamak için kullanışlıdır ve daha düşük bir RMSE değeri, modelin daha iyi performans gösterdiğini belirtir (Demuth et al. 2009)

$$f = \sqrt{mse} = \sqrt{\left(\frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2\right)} \quad (2.5.)$$

MAE (Ortalama Mutlak Hata)

Eğitilmiş bir SA doğruluğunu ölçmek için öngörülen sonucun gerçek sonuç ile karşılaştırılması gerekmektedir (Wang et al. 2016). Eşitlik 2.6'te, t_i beklenen değeri ve a_i ise gerçek ölçüm değerini temsil eder. Ortalama Mutlak Hata (MAE) hesaplanırken, test veri setinde bulunan her ölçüm değeri için, gerçek değer ile tahmin edilen değer arasındaki mutlak farkların toplamı alınır. Bu toplam, veri setindeki ölçüm sayısına bölünerek MAE değeri elde edilir (Demuth et al. 2009)

MAE, her bir tahmin hatasının mutlak değerini alarak bu değerlerin ortalamasını hesaplar. Bu yöntem, tahmin hatalarının büyüklüğünü ölçerken, hata işaretlerini dikkate almaz, yani pozitif ve negatif hataları eşit olarak değerlendirir. MAE'nin temel amacı, tahminlerin ne kadar doğru olduğunu ölçmek ve modelin performansını değerlendirmektir. Düşük bir MAE değeri, tahminlerin gerçek değerlerle yakın olduğunu ve modelin yüksek doğrulukta tahmin yaptığını gösterir (Demuth et al. 2009)

Ortalama Mutlak Hata, modelin tahminleri ile gerçek değerler arasındaki ortalama mutlak farkı gösterir. MAE, modelin doğruluğunu ölçmek için kullanılan bir metriktir ve daha düşük bir MAE değeri, tahminlerin gerçek değerlere daha yakın olduğunu gösterir (Demuth et al. 2009)

$$f = mae = \frac{1}{N} \sum_{i=1}^N |t_i - a_i| \quad (2.6.)$$

R Kare / Düzeltilmiş R Kare

R Kare, modeldeki bağımsız verilere göre bağımlı verilerin varyasyon oranını, yani bağımlı değişkendeki değişkenliğin ne kadarının model tarafından açıklanabileceğini ölçer. Eşitlik 2.7’teki formül ile tanımlanır. Bu korelasyon katsayısının karesidir. Ancak, R Kare aşırı uyum (overfitting) sorununu dikkate almaz. Eğer regresyon modelinde çok fazla bağımsız değişken varsa model eğitim verilerine çok iyi uyabilir ama test aşamasında beklenen başarıyı göstermeyebilir. Bu nedenle, Düzeltilmiş R Kare kullanılır. Düzeltilmiş R Kare, modele eklenen bağımsız değişkenlerin etkisini çıkararak aşırı uyum sorununu çözer. R Kare metriği, modelin açıklayıcılık oranını gösterir ve 1'e ne kadar yakınsa modelin o kadar iyi olduğunu belirtir (Demuth et al. 2009).

$$R^2 = \frac{\sum_{t=1}^T (\hat{Y}_t - \bar{Y})^2}{\sum_{t=1}^T (Y_t - \bar{Y})^2} \quad (2.7.)$$

Başlatma Yöntemleri

SA ağırlıkların başlangıç değerlerinin belirlenmesi, ağırlık eğitim sürecini en fazla etkileyen faktörlerden biridir. Optimal ağırlıkların belirlenmesi, ağırlık eğitim aşamasında gerçekleştirdiği iterasyon sayısını önemli ölçüde azaltabilir (Yam, Chow et al. 2000).

Gauss ve Tekdüze Başlatma

SA oluşturan nöron ağırlıkları, simetrik olarak küçük bir değerle başlatılır. Temel fikir, nöronların başlangıç değerlerinin benzersiz ve rastgele olması, farklı güncelleme aşamalarından sonra yeniden hesaplanmaları ve böylece ağırlık değerleri bütünüyle uyumlu hale gelmeleridir. Gaussian Dağılımı ile Başlatma: Bu yöntemde, ağırlıklar genellikle ortalaması 0 ve standart sapması 0.1 olan Gaussian dağılımına göre rastgele seçilir. Bu şekilde, her nöronun ağırlık vektörü çok boyutlu bir Gaussian dağılımından elde edilen rastgele bir vektör olarak başlatılır ve nöronlar giriş alanında rastgele yönler belirler. Ancak, bu yöntemin bir dezavantajı, çıktının rastgele başlatılmış nöronlardan kaynaklanan varyansının, girdi sayısı ile birlikte artmasıdır. Bu sorunu çözmek için Glorot başlatma yöntemi kullanılabilir (Glorot & Bengio, 2010).

Glorot Başlatma Yöntemi

Glorot Başlatma Yöntemi, ağırlık ve bias değerlerini başlatmanın basit ve etkili yöntemlerinden biridir. Bu yöntemde, nöronlara rastgele ve eşit aralıklı değerler, genellikle 0.01 ile -0.01 arasında, atanır. Özellikle ReLU aktivasyon fonksiyonunu kullanan SA başarılı

sonuçlar verir. Glorot yöntemi, DNN her bir ağırlığın ortalama 0.0 olan küçük bir Gaussian değeri ile başlamasını ve varyansın çıkış ve giriş aralığına göre ayarlanmasını öngörür. Bu yöntem, ağırlıkları sınırlı bir değer aralığında rastgele eşit olarak dağıtarak başlatır. Böylece ağırlıkların uygun şekilde başlatılması sağlanır ve ağırlık eğitimi sürecinde daha stabil ve hızlı öğrenme elde edilir (Glorot & Bengio, 2010).

$$\pm \frac{\sqrt{6}}{\sqrt{n_i + n_{i+1}}} \quad (2.8.)$$

Eşitlik 2.8'de, n_i katmana giriş veya ağa gelen bağlantıları, n_{i+1} ise bu katmandan çıkış yelpazesini yani giden ağ bağlantılarını temsil eder.

Ortogonal Başlatma Yöntemi

Saxe ve ekibi, DNN ağırlıkların başlatılması üzerine yaptıkları araştırmalarda, ağırlık matrisinin rastgele ortogonal bir matris olarak seçilmesini önermiştir. Bu yaklaşım, ağırlık matrisinin kare bir matris olarak seçilmesi ve belirli koşulları sağlaması gerektiğini ifade eder (Saxe, McClelland, Ganguli et al. 2013).

Ortogonal matrislerin DNN eğitimi için iki önemli özelliği bulunur:


1. Normların Korunması: $\|w_x\|_2 = \|x\|_2$, formülüyle ifade edilen bu özellik, ağırlık genelinde normun sabit kalmasını sağlar. Bu, eğitimin başlangıcında kaybolan veya patlayan gradyan sorunlarının aşılmasına yardımcı olabilir.
2. Ortonormal Sütunlar ve Satırlar: Ortogonal matrisler, sütunlar (ve satırlar) arasındaki ortonormaliteyi sağlar. Bu özellik, farklı girdi özelliklerinin öğrenilmesini teşvik eder ve ağırlık vektörlerinin daha sezgisel olmasını sağlar (İnternet, Github et al. 2019).

Optimizasyon Yöntemleri

DÖ süreçleri, çok büyük sayıda iterasyon içerir ve ağırlık hangi ağırlık kombinasyonunda başarılı sonuçlar elde ettiğini bulabilmek için çeşitli permütasyonlar denemeyi gerektirir. Bu durum, modelin eğitim sürecinin zaman maliyetinin düşürülmesini önemli kılar. Optimizasyon yöntemleri, bu süreci hızlandırmak ve daha verimli hale getirmek için kritik bir rol oynar. Birçok optimizasyon yöntemi vardır. Bunlardan bazıları; Stokastik Gradyan İniş Optimizasyon Yöntemi, Nesterov Hızlandırılmış Gradyan Yöntemi, ADAM Optimizasyon Yöntemi' dir (Le, Ngiam, Coates, Lahiri, Prochnow et al., 2011).


2.3.2 DERİN ÖĞRENME

Son yıllarda yapay zeka yoğun ilgi gören çalışma alanlarından biri haline gelmiştir (Chollet et al 2017). Yapay zeka (AI), MÖ ve DÖ arasında sıkı bir ilişki bulunmaktadır. AI, MÖ ve DÖ'lerin öğrenmeyi kapsayan genel bir alandır ve bu alanın dışında kalan diğer birçok yaklaşımı da içerir. Şekil 2.14'te bu ilişkilerin kapsamı gösterilmektedir. Yapay zeka, insanların gerçekleştirdiği işleri otomatikleştirme çabası olarak tanımlanır (Chollet et al. 2017). 1950'li yıllarda bu alanda çalışmalar başlamış olup, o dönemde, insan gibi düşünebilen bir yapay zekanın geniş bir kurallar alanına sahip olması gerektiği düşünülüyordu. Bu görüş, sembolik yapay zeka olarak bilinir ve 1950-1980 yılları arasında baskın bir paradigma olmuştur (Chollet et al. 2017). Ancak, sembolik yapay zeka konuşma tanıma, görüntü tanıma ve dil işleme gibi alanlarda yetersiz kalmıştır. Bu eksiklikler, MÖ ortaya çıkmasına neden olmuştur (Chollet et al., 2017). MÖ, verilerden öğrenme yeteneği sunarak bu sorunları çözmeye kapasitesine sahip yeni bir yaklaşım olarak kabul edilmiştir.




Şekil 2.14. Yapay Zeka, MÖ ve DÖ ilişkisi (Chollet et al 2017).

MÖ son on yılda büyük bir popülerlik kazanmıştır. Temel olarak, bu alan ham verilerden bilgi çıkarmak ve çeşitli algoritmalar kullanarak bir model oluşturmakla ilgilenir (Patterson et al. 2017). Bu model, daha önce analiz edilmemiş verilerle tahminlerde bulunmak için kullanılır. Yeni paradigmalar, Şekil 2.15'te örneklerle gösterilmiştir. MÖ teknolojisi, web aramalarından sosyal medyaya, içerik filtreleme ve e-ticaret sitelerindeki kullanıcı yorumlarına kadar birçok alanda hayatımızın bir parçası olmuştur. Ayrıca, akıllı telefonlar ve kameralar gibi tüketici ürünlerinde de uygulanmaktadır (LeCun, Bengio, Hinton et al., 2015). Bu teknolojiler, görüntülerdeki nesneleri tanıma, haber öğelerini işleme, konuşmaları metne çevirme, yayınları veya ürünleri kullanıcı ilgi alanlarına göre eşleştirme ve arama sonuçlarını iyileştirme gibi birçok uygulamada kullanılmaktadır. Artan bir şekilde, bu uygulamalar DÖ olarak bilinen tekniklerden yararlanmaktadır.



Şekil 2.15. MÖ Yaklaşımı (Chollet et al 2017).

DÖ, metin, görüntü ve ses gibi çeşitli alanlarda son derece başarılı olduğu kanıtlanmış geniş bir MÖ alt dalıdır. DÖ, insan beynindeki nöronlar ve algılayıcılar arasındaki ilişkileri taklit eden algoritmalar içerir. Bu yaklaşımlar, konuşma tanıma, doğal dil işleme, bilgisayarla görme ve görüntü oluşturma gibi birçok uygulamada kullanılır (Goyal, Pandey, Jain et al. 2018).



Şekil 2.16. Öğrenme teknikleri performansları

DÖ, geniş bir MÖ alt alanıdır ve sayıca fazla ardışık katmanın, belirli iterasyonlar içinde verilerden daha iyi öğrenmeyi amaçlayan yeni bir yaklaşımı temsil eder (Chollet et al. 2018). Şekil 2.16 veri miktarının veri bilimi tekniklerinin başarısını nasıl etkilediğini göstermektedir (Goyal, Pandey, Jain et al. 2018).

DÖ algoritmaları, YSA kavramına dayanır ve günümüz dünyasında bu tür algoritmaların eğitimi, büyük veri setleri ve yeterli hesaplama kaynaklarının sağlanmasıyla daha erişilebilir hale gelmiştir. (Goyal, Pandey, Jain et al. 2018). Eğitim kümesinde kullanılan verinin büyümesiyle DÖ modellerinin performansı da artmaktadır. Şekil 2.16 veri artışının veri bilimi performansına etkisini örnek olarak göstermektedir.


DNN'ler, birden fazla gizli katmana sahip olup, bu mimari sayesinde ağ, girişler ve çıkışlar arasındaki karmaşık ilişkileri öğrenme kapasitesine sahip olabilir (Srivastava et al.

2014). Bu katmanlar, birbirinin üzerine yığılmış YSA ile yapılandırılmıştır (Chollet et al, 2017). SA terimi nörobiyolojiye atıfta bulunur ancak, DÖ modelleri bire bir beyin modelini yansıtmaz bunun yerine insan beyninden esinlenmiş bazı kavramları içerir (Chollet et al. 2017).

Otomatik özellik çıkarımı, DÖ geleneksel MÖ yöntemlerine kıyasla en belirgin avantajlarından biridir (Patterson et al., 2017). Bu süreç, ağı veri kümesindeki özelliklerden hangilerinin verileri doğru bir şekilde etiketlemek için kullanılacağını belirlemesini içerir (Patterson et al., 2017).

Tam Bağlantılı Derin Ağlar

Tam bağlantılı sinir ağları, yoğun bağlantılı ağlar olarak da bilinir. Bu ağ yapısı, her bir düğümün kendisinden sonraki katmandaki tüm düğümlerle bağlantılı olduğu bir mimari- dir (Kishan et al., 1996). Bu bağlantıların ağırlıkları pozitif (uyarıcı), negatif (engelleyici) veya sıfır değerlerinde olabilir. Şekil 2.17, farklı ağırlık değerlerine sahip tam bağlantılı bir ağ örneğini göstermektedir.




Şekil 2.17. Tam Bağlantılı Asimetrik Sinir Ağı (Kishan et al. 1996).

Diğer ağ algoritmaları genellikle ağırlık değerleri sıfıra ayarlanarak tam bağlantılı ağlardan türetilmiş özel durumlar olarak kabul edilir. Bu ağ mimarisi, kavramsal basitliği ve geniş uygulama yelpazesi nedeniyle dikkat çekici olsa da, çok sayıda parametre içerdiği için sıkça kullanılmaz (Kishan et al., 1996). Ayrıca, tam bağlantılı ağlar biyolojik olarak gerçekçi görünmemektedir, çünkü sinir hücreleri arasındaki bağlantılar genellikle sadece yakındaki nöronlarla sınırlıdır.

Yineleyen Sinir Ağları (RNN)

Yapacağımız çalışmada yinelenen sinir ağları kullanılmayacaktır. Bu nedenle basit olarak tanımlanacaktır. Yineleyen sinir ağları (RNN), ilk kez 1980’li yıllarda tanıtılmıştır ve son yıllarda gelişen donanım yenilikleri sayesinde yeniden popülerlik kazanmıştır (Buduma,

Locascio et al. 2014). RNN'ler, enaz bir geri besleme döngüsüne sahip olma şartıyla kendini FFNN ayırır (Haykin et al. 2009). Şekil 2.18'de gösterilen tekrarlayan bir sinir ağı modelinde, bir nöronun birden çok bağlantıya sahip olduğu ve aynı katmandaki diğer nöronlarla bağlantılı olabileceği görülmektedir. Tamamen yineleyen bir sinir ağı, r adet nörondan oluştuğunda, r^2 kadar bağlantıya sahip olduğu kabul edilir (Buduma, Locascio et al. 2014).




Şekil 2.18. Yineleyen ağlarda nöronların bağlantıları (Buduma, locascio et al 2014).

RNN sıralı bilgileri işlemek ve bu bilgilerdeki desenleri öğrenmek için geliştirilmiş bir sinir ağı modelidir (Pattanaik et al. 2017). Bu ağ mimarisinin bir diziye ait tüm elemanlar için aynı görevi gerçekleştirmesi beklenir. Konuşma dilinde kelimelerin sıra bağımlılıkları nedeniyle RNN'ler dil işleme problemlerinde oldukça kullanışlıdır (Pattanaik et al. 2017).


Uzun Kısa Süreli Bellek (LSTM)

Sepp Hochreiter ve Jürgen Schmidhuber, kaybolan gradyanlar problemini çözmek amacıyla LSTM mimarisini geliştirmiştir. (Hochreiter, Schmidhuber et al. 1997). LSTM'nin temel ilkesi ağıın önemli bilgileri uzun iterasyonlar boyunca güvenilir bir şekilde iletebilmesidir (Buduma, Locascio et al. 2014). Şekil 2.19'de görüldüğü gibi, LSTM ünitesi birkaç ana bileşenden oluşur. Bu bileşenlerden biri şekil ortasında kalın çerçeve ile gösterilen bellek hücresi olarak bilinen tensördür. Şekil 2.19'de bu tensöre ait algoritma gösterilmektedir. Bu bellek hücresi, birçok iterasyon süresince faydalı bilgileri kaydetmek ve kritik bilgileri zaman içinde saklamak üzere tasarlanmıştır (Buduma, Locascio et al. 2014).




Şekil 2.19. Tensör ve İşlem Düzeyinde gösterilen LSTM birimine ait mimari (Buduma Locascio et al 2014.)

Her adımda LSTM ünitesi yeni bilgilerle üç farklı aşama gerçekleştirir ve bu aşamalar sırasında tensör hücrelerini günceller. İlk olarak keep gate olarak tanımlanan ünite önceki hafızanın ne kadarını tutacağına karar verir.




Şekil 2.20. Bir LSTM biriminin "Keep Gate" mimarisi (Buduma, Locascio et al. 2014). Keep Gate'in temel prensibi oldukça basittir. Önceki zaman adımındaki hafıza durumu tensörü önemli bilgiler içerse de, bazı bilgilerin eski olabileceği ve dolayısıyla silinmesi gerekebilir.



Şekil 2.21. Bir LSTM biriminin Write Gate mimarisi (Buduma, Locascio et al. 2014).

Bu silme işlemi, bit sensörünün değerine bağlı olarak gerçekleştirilir. Eğer bit sensörünün değeri 1 ise, bu, hafızadaki ilgili bilginin geçerli olduğu ve korunması gerektiği anlamına gelir. Eğer değer 0 ise, bilgi geçerliliğini yitirmiştir ve güncellenmesi gerekir. Bit tensörü, mevcut zaman adımındaki girdiyle LSTM biriminin bir önceki zaman adımının çıktısını birleştirir ve elde edilen tensörü bir sigmoid katmandan geçirir.

Sigmoidal bir fonksiyon, çıktıyı sıfıra yakın veya bire yakın değerlere dönüştürür. Bu özellik, sigmoidal katmanın çıktısının bit tensörün işleyiş prensibine benzer olmasını sağlar. Bu nedenle, Write Gate işlevinin gerçekleştirilmesinde sigmoidal fonksiyon kullanılır (Buduma, Locascio et al. 2014). LSTM ünitesinin bilgi yazma işlemi Write Gate olarak adlandırılır. Şekil 2.21'te gösterilen bu bileşen iki ana kısımdan oluşur. İlk kısım, hangi bilgilerin tensöre yazılacağını belirler ve bu işlem tanh katmanı tarafından yapılır. İkinci kısım ise hangi bilgilerin yazılmadan silineceğini belirler ve bu seçim, Keep Gate'de kullanılan stratejiye göre yapılır. Bit vektörü, ara tensörle çarpılır ve LSTM için yeni bir durum vektörü oluşturulur.




Şekil 2.22. Bir LSTM Birimine Ait Output Gate Mimarisi (Buduma,locascio et al 2014). Output Gate mimarisi, Şekil 2.22'te gösterilmiştir ve benzer bir yapıyı kullanır. Tanh katmanı, durum vektöründen bir ara tensör oluşturur. Sigmoid katmanı, mevcut giriş ve önceki çıkışı kullanarak bir bit tensörü oluşturur. Bu ara tensör, bit tensörü ile çarpılarak son çıktı elde edilir.

Kapı Yenileyen Birim (GRU)

Günümüzde kullanılan birçok LSTM varyasyonu bulunmaktadır. Bunlar arasında en fazla tercih edilenlerden biri, Kapı Yenileyen Birim (GRU) olarak bilinir (Goyal, Pandey, Jain et al 2018). GRU giriş ve unutmaya kapılarını birleştirerek tek bir güncelleme kapısı oluşturur ve çıktının üretim sürecinde değişiklikler yapar. Bu yapı standart LSTM algoritmalarına göre daha az karmaşıklığa sahiptir (Chung, Gülçehre, Cho, Bengio et al 2014).

Genel olarak LSTM'nin büyük veri setleri için daha iyi performans gösterdiği GRU'nun

ise daha küçük veri setleri için daha etkili olduğu gözlemlenmiştir (Goyal,Pandey,Jain et al 2018).




Şekil 2.23. LSTM ve GRU mimarileri (Goyal, Pandey, Jain et al 2018).

Evrişimsel Sinir Ağları (CNN)

Bir CNN verilerdeki yüksek dereceli özellikleri konvolüsyon işlemleri ile öğrenmeyi amaçlar. Bu ağlar, özellikle resimlerle sınıflandırma ve nesne tanıma gibi görevlerde etkili olup yüzleri sokak işaretlerini, bireyleri ve diğer görsel verileri tanımlamada yeteneklidir (Patterson et al. 2017).

CNN'ler, mimari olarak çok katmanlı algılayıcılardan esinlenir ve ardışık ağ katmanlarındaki nöronlar arasında yerel bağlantı kısıtlamaları uygulayarak yerel mekansal korelasyonlardan yararlanır. (Pattanaak et al. 2017). CNN'lerin temel odak noktası, konvolüsyon operasyonu yoluyla verileri işlemektir. Bu işlem, sinyalleri başka sinyallere çevirerek, orijinal sinyalin sunduğundan daha fazla bilgi açığa çıkaran üçüncü bir sinyal üretir (Krizhevsky, Sutskever, Hinton et al. 2014). CNN mimarisi girdi katmanından alınan veriyi işleyerek tüm bağlı katmanlardan geçirir ve çıktı katmanında sınıf puanlarına dönüştürür (Patterson et al. 2017). Çeşitli CNN algoritmaları mevcut olmakla birlikte genellikle Şekil 2.24'de gösterilen temel mimariye dayanır.



Şekil 2.24. Genel Bir CNN mimarisi (Patterson et al. 2017).

Şekil 2.24.'de CNN mimarisinin üç ana bileşenini göstermektedir:

Giriş Katmanı (Input Layer):

Giriş katmanı, görüntünün boyutlarından oluşan üç boyutlu bir veri kümesini kabul eder (genişlik x yükseklik). Ayrıca, renk kanallarını temsil eden bir derinlik içerir (genellikle RGB renk kanalları için üç derinlik seviyesine sahiptir) (Krizhevsky, Sutskever, Hinton et al. 2014).

Öznitelik Bulma Katmanları (Feature-Extraction (Learning) Layers):

Evrişim Katmanı (Convolutional Layer): ReLU aktivasyon fonksiyonu kullanılarak çalışır ve konvolüsyonel işlemler gerçekleştirir.


Havuz Katmanı (Pooling Layer): Görüntülerde çeşitli öznitelikler çıkarır ve bu öznitelikleri aşamalı olarak daha yüksek seviyeli özniteliklere dönüştürür. Bu işlem, özniteliklerin otomatik olarak öğrenilmesini sağlar ve DÖ tanımına uygundur (LeCun, Bengio, Hinton et al. 2015).

Sınıflandırma Katmanı (Classification Layer):

Bu katman, kendisinden önceki tüm nöronlarla tam bağlantılıdır ve $[b \times N]$ boyutlarında iki boyutlu bir sonuç üretir. Burada b örnek sayısını ve N beklenen sınıf sayısını ifade eder (Patterson et al. 2017).

Giriş Katmanı:

Giriş katmanları, ağız işlem yapabilmesi için ham giriş verilerini yükler ve depolar. Bu veriler, görüntünün yüksekliğini, genişliğini ve kanal sayısını belirler. Örneğin, bir RGB görüntüde her piksel için üç kanal bulunur. Bu yapı Şekil 2.25'de gösterilmektedir.




Şekil 2.25. 3d Boyutlu Giriş Katmanı (Patterson et al. 2017).

Özellik Çıkartma Katmanları

Özellik çıkarımı, ham verinin daha anlamlı ve daha küçük boyutlu verilere dönüştürülmesi sürecidir. Bu aşamada kullanılan katmanlar şunlardır:

Evrişim Katmanı (Convolutional Layer)

Evrişim katmanları, CNN mimarisinin temel bileşenleridir (Patterson et al. 2017). Şekil 2.26'de görüldüğü gibi, evrişim katmanları, önceki katmandan gelen nöronları yerel olarak bağlayarak giriş verisini dönüştürür. Bu katman, giriş katmanındaki nöronların belirli bir bölgesi ile çıkış katmanındaki yerel olarak bağlı ağırlıklar arasında yeni bir piksel ürünü oluşturur. Bu işlem, giriş verisindeki önemli özellikleri çıkarmak ve temsil etmek amacıyla gerçekleştirilir.



Şekil 2.26. Giriş ve çıkış değerlerine sahip konvolüsyonel katman (Patterson et al. 2017).

Evrişim Katmanı:

Evrişim katmanları, CNN mimarisinin temel bileşenleridir (Patterson et al. 2017). Şekil 2.26'de gösterildiği gibi, bu katmanlar giriş verisini dönüştürür ve genellikle çıkışta aynı uzamsal boyutları (veya daha küçük boyutları) korur. Ancak, çıkışın derinlik boyutundaki parçaların sayısı artabilir. Bu katmanlar, giriş verisindeki öznitelikleri tanımak için yerel bağlantılar kullanarak verinin önemli özelliklerini çıkarır.

Havuzlama Katmanı:

Havuzlama katmanları, evrişim katmanlarının aralarına yerleştirilir ve verinin uzamsal boyutlarını (genişlik ve yükseklik) aşamalı olarak küçültür. Bu işlemin amacı, aşırı uyumu (overfitting) azaltmaktır (Patterson et al. 2017). Havuzlama katmanı, her derinlik diliminde bağımsız olarak çalışır ve genellikle max() işlemi kullanılarak veri boyutunu yeniden düzenler. Bu işlem maksimum havuzlama olarak adlandırılır.

Örneğin, 2×2 boyutunda bir filtre kullanarak yapılan max() işlemi, filtre alanındaki dört değerden en büyüğünü seçer. Bu işlem, derinlik boyutunu değiştirmeden giriş görüntüsünün uzamsal boyutlarını küçültür. Örneğin, 32×32 piksellik bir görüntü, havuzlama işlemi sonrasında 16×16 piksel boyutuna indirgenebilir ve bu, aktivasyon işlemlerinde %75'lik bir azalma anlamına gelir.

Sınıflandırma Katmanı:

Sınıflandırma katmanı, ağıın çıktısı olarak sınıf puanlarını hesaplamak için kullanılır. Bu katman, sınıf sayısı kadar boyuta sahip bir çıktı vektörü üretir ve genellikle softmax aktivasyon fonksiyonunu kullanır (Chollet et al. 2017). Sınıflandırma katmanındaki her nöron, önceki katmandaki tüm nöronlarla bağlantılıdır, bu sayede her nöronun çıktısı sınıf puanlarına dönüştürülür.

2.4 KULLANILAN PROGRAMLAR

Python programı ile tez çalışmamız yapılmıştır. Python, web uygulamaları, yazılım geliştirme, veri bilimi ve MÖ yaygın olarak kullanılan bir programlama dilidir. Etkili ve öğrenmesi kolay olduğu için tercih edilir ve birçok farklı platformda çalıştırılabilir (www.techcareer.net). Python'ın en çok kullanılan kütüphaneleri şunlardır:

Matplotlib: Geliştiricilerin verileri yüksek kaliteli iki boyutlu (2B) veya üç boyutlu (3B) grafiklerde görselleştirmelerine olanak tanır. Bilimsel uygulamalarda sıkça kullanılır. Matplotlib ile çubuk grafikler, çizgi grafikler ve diğer grafik türlerini oluşturabilir ve birden fazla grafiği aynı anda çizebilir. Grafikler, tüm platformlarda taşınabilir (www.techcareer.net).

Pandas: Zaman serileri ve yapılandırılmış verilerle çalışmak için optimize edilmiş ve esnek veri yapıları sunar. Verileri okumak, yazmak, birleştirmek, filtrelemek ve gruplandırmak için kullanılır. Veri bilimi, veri analizi ve MÖ görevlerinde yaygın olarak tercih edilir (www.techcareer.net).

NumPy: Diziler oluşturmak, yönetmek ve doğrusal cebir işlemleri gerçekleştirmek için kullanılan popüler bir kütüphanedir. NumPy, C ve C++ gibi dillerle entegrasyon desteği sunar ve mantıksal işlemler için kullanılır (www.techcareer.net).

Keras: Python'da DNN geliştirmek için kullanılan bir kütüphanedir. Veri işleme ve görselleştirme gibi konularda destek sağlar. Keras, çeşitli SA destekler ve modüler yapısı sayesinde inovasyon uygulamaları yazma konusunda esneklik sunar.

TensorFlow; TensorFlow, değişik seviyelerde yapay zeka sistemi oluşturma imkanı sunan yazılım kütüphanesidir. Açık kaynaklı sistem, DÖ teknolojisiyle kolaylık sağlar. Masaüstü ve mobil platformlarda kullanılabilir. Komut işleme, veri toplama, bilgi değerlendirme donanımıyla öne çıkar. Sistemin DNN gelişmiştir. Bu YSA, vücuttaki sinir siste-

mine benzer. Ağ birimleri, deęişik fonksiyonlarla eř zamanlı alıřır. Yapay zekanın tahmin kabiliyeti, SA kaynaklanır. TensorFlow ile hata payı düşük algoritmalar oluřturabilir (www.techcareer.net).

Scikit-learn (Sklearn); Denetimli ve denetimsiz öğrenme algoritmalarını bulunduran bir python kütüphanesidir. Numpy, Pandas, Scipy, Matplotlib gibi kütüphaneler üzerine kuruludur.


Bu tezde Python yazılımı Colaboratory (Google python kütüphanesi) Üzerinden analizler yapılmıřtır. Colaboratory (ya da kısaca "Colab"); Google Research tarafından sunulan bir python kodlama kütüphane ürünüdür. Özellikle MÖ, veri analizi ve eğitim için uygun olan kütüphane sayesinde isteyen herkes tarayıcı üzerinden rastgele Python kodu yazıp yürütebilir (www.github.com).

3. METARYEL ve YÖNTEM

Tezin bu aşamasında DÖ yöntemleri kullanılarak, toplanan elektrik tüketim verileri, meteorolojik veriler ile elektrik tüketimini tahminleyen modeller oluşturulmuş ve başarı performanslarının analizleri yapılmıştır.


3.1 VERİ TOPLAMA

Tokat GOP Üniversitesine ait Araştırma ve Uygulama Merkez Müdürlüğü hastanesi bünyesinde 3 adet 1600 kVA trafo olduğu, tek ölçüm noktası ve tek sayaç olduğu tüm hastanenin tüketimlerinin bu sayaç üzerinden kayıt altına alınmaktadır. Şekil 3.1’ de veri toplama sistemi görülmektedir.



Şekil 3.1. Elektrik tüketim verisi toplama şeması


Enerji tüketim verisi, sayacı okuyan optik okuyucu modem ve WEB üzerinden bilgisayarlara kayıt edilmektedir. Bu çalışmada 01.01.2019- 31.12.2023 tarihleri arasında kaydedilen tüm veriler kullanılmıştır. Veri toplama işlemi 2 dk ile 20 dk aralığında yapılarak toplam 253.454 veri alınmıştır. Bu ham verilerin zaman aralığının eşit değildir. Yapılan literatür araştırmalarında zaman aralığının saatlik, günlük aylık gibi eşit olarak tahminlemelerin yapıldığı tespit edilmiştir. Ham veriler veri toplama programı üzerinden saatlik ve aylık raporlanabilmektedir. Toplanan ham enerji tüketimi verisi sayaç izleme sistemi programı üzerinden saatlik olarak 43.796 adete dönüştürülmüş ve Şekil 3.2’de görülen veri seti oluşturulmuştur.



Şekil 3.2. Toplanan 5 yıllık elektrik tüketim verisi

Toplanan tüketim verileri incelendiğinde mevsimsel olarak dinamik değişen bir enerji tüketimi yapıldığı görülmektedir.


Bu tez çalışmasında, Tokat Gaziosmanpaşa Üniveristesi Hastanesi enerji tüketim tahminlemesi için kullanılacak 2019 ile 2023 yılları arası Tokat merkez bölgesine ait saatlik meteoroloji verileri Tokat Meteoroloji Müdürlüğünden alınmıştır. Bu veriler ham veriler olarak kaydedilmiştir. Şekil 3.3 ‘de ham nem verileri ve Şekil 3.4 ‘de ham sıcaklık verileri görülmektedir.



Şekil 3.3. 01 Ocak 2019 – 31 Aralık 2023 aralığı nem grafiği.

Mevsimsel değişiklikler, binaların iklimlendirilmesinde önemli rol oynar ve bu nedenle

elektrik tüketimi mevsimlere göre farklılık gösterir. Bu değişikliklerin nedeni, hava sıcaklıklarındaki dalgalanmalardır.



Şekil 3.4. 01.Ocak 2019 – 31.Aralık 2023 aralığı sıcaklık grafiği.

Shi ve arkadaşları (2014), "Yük Profili ve Hava Durumu İlişkisi Analizi" başlıklı çalışmalarında, yük değişiminde hava koşullarının önemli bir rol oynadığını belirlemişlerdir (Shi et al. 2014). Yük-sıcaklık ve yük-nem grafikleri incelendiğinde, sıcaklığın yüke doğrudan etkisi açıkça görülürken, nemin yüke etkisinin sıcaklık kadar belirgin olmadığı sonucuna varılmıştır.

Bu bölümde verilen veriler incelendiğinde, sıcaklığın arttığı dönemlerde elektrik tüketimlerinin arttığı görülmektedir. Bu değişim nem grafiğinde benzer şekilde görülmemektedir. Mevsimlerin direk elektrik tüketimine etki ettiği, hafta sonu, hafta içi veya gece gündüz olma durumunda elektrik tüketiminin değiştiği görülmektedir.

3.2 VERİ HAZIRLAMA;

Veri hazırlama süreçlerinde elektrik ham verisini eşit zaman aralığına ayırma, verilerin yazılım programa uyumlu hale getirme, anlamsız verilerin yeniden düzenlenmesi ve normalize işlemleri kullanılmıştır.


Enerji tüketimi verilerinin işlenmesinde öncelikle, dakikalık olan 253454 adet olan ham veri eşit zaman aralığına dönüştürülmüştür. Bu dönüştürme işlemi otomatik sayaç okuma sistemi içeriğinde bulunan program üzerinden raporlandırılarak eşit zaman aralığında saatlik 43796 adet veriye dönüştürülmüştür.

Elektrik tüketim verisi saatlik olarak düzenlendikten sonra, veri hazırlama işlemi başlanmıştır. Başlangıcında ilk olarak, beş yıllık veriyi içeren bir CSV dosyasını yükletilmiş ve okutulmuştur. Veri dosyası, `files.upload()` fonksiyonu kullanılarak yüklenmiş, bu fonksiyon CSV dosyasının seçilmesini ve yüklenmesini sağlamıştır. Yükleme tamamlandığında, dosya pandas DataFrame'e aktarılmıştır. Daha sonra, modelleme için aşağıdaki veri işleme işlemleri yapılmıştır.


Sıcaklık verisi üzerinde öncelikle anlamsız veriler düzenlenmiştir. Ardından saatlik sıcaklık verisi üzerinde brim dönüşümü gerçekleştirilmiştir. Sıcaklık sütunu, $((\text{Celsius} \times 9/5) + 32)$ sıcaklık dönüşümü kullanılarak Celsius'tan Fahrenheit'a dönüştürülmüştür. Son olarak MinMaxScaler kullanılarak bu veri normalize edilmiştir.

Nem verisinin işlenmesinde ilk olarak anlamsız veri eliminasyonu yapılmış ardından normalize edilmiştir. Elektrik tüketim verileri daha sonra üzerinde anlamsız veriler atılarak 43700 adet veri elde edilmiştir. Son olarak normalize edilerek işlenmiş enerji tüketim verisi oluşturulmuştur.


Aşağıda verilen şekillerde 01.Ocak 2019 ile 31.Aralık 2023 tarihleri arası 5 yıllık işlenmiş meteoroloji ve enerji tüketim verileri sunulmuştur. Şekil 3.5'de işlenmiş elektrik tüketim verisi, Şekil 3.6'da işlenmiş nem verisi ve Şekil 3.7'da işlenmiş sıcaklık verisi görülmektedir.



Şekil 3.5. 01.Ocak 2019 ile 31.Aralık 2023 aralığı işlenmiş elektrik tüketim verisi.



Şekil 3.6. 01.Ocak 2019 ile 31 aralık 2023 Aralığı işlenmiş nem verisi.



Şekil 3.7. 01 ocak 2019 ile 31 aralık 2023 Aralığı işlenmiş sıcaklık verisi.

3.3 MODELLEME SÜRECİ;

Bu çalışmada, enerji kullanım verilerini tahmin etmek için CNN ve LSTM modellerinin kullanılması süreci detaylı bir şekilde ele alınmıştır. Çalışma, beş yıllık enerji kullanım verilerini kullanarak modelin eğitilmesi ve ardından modelin performansının değerlendirilmesi adımlarını içermektedir. Veriler, eğitim ve test setlerine ayrıldıktan sonra, çeşitli modeller kullanılarak tahminler yapılmıştır.

Zamana bağılı enerji verilerinin öğrenilmesi ve tahmini konusunda çeşitli DÖ yöntemleri faydalı olabilir. Bu yöntemler arasında RNN, LSTM, GRU ve CNN gibi modeller yer almaktadır. RNN'ler, zaman serisi verilerinde ardışık bağımlılıkları öğrenme yetenekleri nedeniyle yaygın olarak kullanılmaktadır. Ancak, RNN'ler uzun süreli bağımlılıkları öğrenmede zorluk çekebilir ve eğitimi sırasında gradyan kaybolması (vanishing gradient) problemi yaşayabilir. Bu sorunları aşmak için geliştirilen LSTM ve GRU modelleri, uzun süreli bağımlılıkları daha iyi öğrenme kapasitesine sahiptir ve bu nedenle zaman serisi tahminlerinde sıklıkla tercih edilmektedir (Gozuoglu 2024).

Bununla birlikte, CNN'ler genellikle görüntü işleme alanında kullanılsa da, zaman serisi verilerinde de başarılı sonuçlar verebilmektedir. CNN'ler, verilerdeki yerel özellikleri ve paternleri etkili bir şekilde öğrenebilir. Zaman serisi verilerinde, özellikle enerji kullanımı gibi verilerde, belirli dönemlerde tekrar eden paternler ve lokal ilişkiler önemlidir. CNN'ler bu tür paternleri ve ilişkileri öğrenmede etkili olabilir.

Hibrit modeller, birden fazla MÖ veya DÖ yöntemini birleştirerek daha güçlü ve etkili tahmin modelleri oluşturmayı hedefler. Bu tür modeller, farklı algoritmaların güçlü yönlerini bir araya getirerek belirli bir problemin çözümünde daha yüksek performans ve doğruluk sağlayabilirler. Enerji kullanım verilerinin tahmini gibi karmaşık problemler için hibrit modeller oldukça faydalı olabilir. Hibrit modellerin avantajları arasında gelişmiş performans, daha iyi genelleme, esneklik ve kapsamlı öğrenme bulunmaktadır. Örneğin, CNN-RNN/LSTM modelleri zaman serisi verilerinde, görüntü ve metin analizinde yaygın olarak kullanılır. CNN katmanları, giriş verilerindeki lokal paternleri ve özellikleri çıkarır. Bu çıkarılan özellikler daha sonra RNN veya LSTM katmanlarına aktarılır ve bu katmanlar uzun süreli bağımlılıkları öğrenir. Enerji kullanım verilerinde, CNN katmanları belirli dönemlerde tekrarlayan paternleri öğrenirken, LSTM katmanları uzun süreli trendleri ve bağımlılıkları öğrenir. Benzer şekilde, CNN-GRU modelleri de zaman serisi analizinde ve sinyal işleme gibi alanlarda kullanılır. Hibrit modeller, enerji kullanım tahmini gibi karmaşık problemlerde daha yüksek doğruluk ve genelleme yeteneği sağlayabilir (Gozuoglu 2024).

Burada yapılan modellemelerde CNN, LSTM ve CNN-LSTM hibrit modeli üzerinden analiz yapılmış ve Bulgular bölümünde sunulmuştur. Alınan sonuçlar CNN-LSTM hibrit modelline göre diğer modellerin hata oranlarının daha yüksek çıktığından hibrit modeli tercih edilmiştir. Hibrit modelin tercihinden sonra meteorolojik faktörlerin etkileri analiz

edilmiştir. Öncelikle herbir parameter tekil olarak kullanılmış, ardından tüm parametreler birlite değerlendirilmiştir. Karşılaştırmalar sonucunda meteorolojik faktörlerin hepsi bir arada kullanıldığında daha doğru sonuç alındığı görülmüştür. Daha doğru sonuçlar alındığından geleceğe yönelik tahimleme modelimiz CNN-LSTM hibrit model ve tüm meteorolojik faktörler bir arada kullanılarak yapılması tercih edilmiştir.

Bu çalışmada, enerji kullanım verilerini tahmin etmek amacıyla çeşitli senaryolar uygulanmış ve analiz edilmiştir. Çalışma kapsamında, beş yıllık enerji kullanım verileri kullanılarak bir CNN ve LSTM modeli oluşturulmuş ve modelin performansı değerlendirilmiştir. Veriler eğitim ve test setlerine ayrıldıktan sonra, model eğitilmiş ve tahminler yapılmıştır. Bu süreçte, modelin hem eğitim hem de test seti üzerindeki performansı çeşitli hata metrikleri kullanılarak değerlendirilmiştir. Ayrıca, modelin performansı görselleştirilmiş ve farklı zaman dilimleri için detaylı analizler yapılmıştır.

4. BULGULAR


Bu tez çalışmamızda Tokat Gaziosmanpaşa Üniversitesi elektrik tüketimleri üzerinden elde edilen verileri kullanarak, elde edilen verilerin tahmini yapılmış ve gelecekteki veriyi tahmin çalışması yapılmıştır. Bunun için iki farklı senaryoda çalışmalar yapılmıştır;

Seneryo-1; Bu çalışmada tüm meteorolojik parametrelerin birlikte olduğu elde edilen veri kullanılarak en iyi performanslı model seçimi ve seçilen model üzerinde meteorolojik parametrelerin etkisinin analizi hedeflenmiştir. Öncelikle 5 yıllık elektrik tüketim verileri 3 yılı eğitim ve son 2 yılı test olarak alınmıştır. Bu veriler üzerinde üç farklı model oluşturulmuştur. CNN model, LSTM model ve CNN-LSTM hibrit model oluşturulmuş hata oranları çıkarılmıştır. En doğru alınan sonuç üzerinden meteorolojik faktörler tek tek ve bir arada kullanılması durumu analiz edilmiş hata oranları çıkarılmıştır.

Seneryo-2; Bu çalışmada en iyi performanslı model ile meteorolojik verilerin tümü kullanılarak elde edilen veriler ile gelecekteki elektrik tüketimi hedeflenmiştir. Elektrik tüketim verilerinin 4 yıllığı eğitim, 5. yılı test ve 6. 7. yılların tahminlemesi yapılmıştır.

4.1. SENERYO-1

Bu senaryoda öncelikle, CNN, LSTM ve CNN-LSTM hibrit modelleri kullanarak enerji kullanımı tahmini yapılmıştır. Veri, eğitim ve test setlerine ayrıştırılmıştır. Şekil 4.1. de görüldüğü gibi, ilk üç yılın verileri, toplam verinin %60'ını oluşturan, modeli eğitmek için kullanılmıştır. Kalan iki yıl ise, modelin performansını test etmek için kullanılmış ve bu verinin %40'ını oluşturur.



Şekil 4.1. 5 yıllık eğitim ve test verisi

4.1.1. CNN modeli sonuçları

Özellikler, CNN'in Conv1D katmanının gereksinimlerine uygun hale getirilmek için her zaman adımında tek bir özellik olacak şekilde yeniden şekillendirilmiştir. Keras Sequential API kullanılarak bir CNN modeli oluşturulmuştur. Model, her biri ReLU aktivasyon fonksiyonuna sahip ve artan filtre boyutlarına (32, 64 ve 128) sahip üç Conv1D katmanından oluşur. İlk Conv1D katmanı, eğitim verisinin şekline uygun giriş şeklini belirtir. Katmanlar, 3 çekirdek boyutu kullanır ve sonraki Conv1D katmanları girdi boyutunu korumak için padding kullanır. Conv1D katmanlarından sonra, veriler bir Flatten katmanı kullanılarak düzleştirilir, ardından 64 birime sahip ve ReLU aktivasyonlu bir Dense katmanı ve son olarak bir birime sahip bir çıktı katmanı gelir.

Model, 'adam' optimizasyon algoritması ve 'mean_squared_error' kayıp fonksiyonu kullanılarak derlemiştir. Daha sonra model, 40 epoch boyunca 32 batch boyutu ile eğitim verisi üzerinde eğitilmiştir. Eğitimden sonra, model test seti (dördüncü ve beşinci yıllar) için enerji kullanımı tahmini yapılmıştır.

Son olarak, senaryo, test dönemindeki tahmin edilen enerji kullanımı ile gerçek değerleri karşılaştırılmış. Gerçek ve tahmin edilen enerji kullanımı değerlerini içeren bir karşılaştırma DataFrame'i oluşturulur, bu da modelin performansının değerlendirilmesini sağlar. Bu karşılaştırma, modelin yeni ve görülmemiş veriler üzerinde ne kadar iyi genelleme yaptığını anlamaya yardımcı olmuştur.

Bu seneryo'nun hata metriklerini hesapladığımızda; seneryo içinde eğitim seti için yapılan tahminlerin değerlendirilmesinin yanı sıra, test seti (son iki yıl) için yapılan tahminlerin doğruluğunu da değerlendirir ve hata metriklerini hesaplanır. İlk olarak, model test verisi üzerindeki tahminleri yapar ve bu tahminler predictions değişkenine atanır. Ardından, bu tahminlerin doğruluğunu değerlendirmek için çeşitli hata metrikleri hesaplanmıştır.

Aşağıda, hesaplanan hata metriklerinin sonuçları tablo halinde sunulmuştur:


Tablo.1; CNN model için; İlk Üç yıl eğitim verileri hata metrikleri

Hata Metrikleri	Değerler
MAE (İlk üç yıl)	0.00651
MSE (İlk üç yıl)	0.00396
RMSE (İlk üç yıl)	0.05337
R2 (İlk üç yıl)	0.98236


Tablo.2; CNN model için; Son İki yıl test verileri hata metrikleri

Hata Metrikleri	Değerler
MAE (Son iki yıl)	0.00560
MSE (Son iki yıl)	0.00318
RMSE (Son iki yıl)	0.05116
R2 (Son iki yıl)	0.98801

Tablo.1, modelin eğitim seti üzerindeki performansını göstermektedir. Tablo.2 de test setinin performansı görülmektedir. Bu CNN modelini görselleştirdiğimizde; Şekil 4.2’de gerçek ve tahmin edilen enerji kullanımı verilerini görselleştirerek modelin eğitim verisini performansını analiz etmek amacıyla bir grafik oluşturulmuştur.



Şekil 4.2. CNN model grafiği



Şekil 4.3. CNN model son 100 veri grafiği

4.1.2. LSTM modeli sonuçları

Keras Sequential API kullanılarak bir LSTM modeli oluşturulmuştur. Model, 50 düğüm ve ReLU aktivasyon fonksiyonuna sahip giriş katmanından oluşur. İlk giriş katmanı,

eğitim verisinin şekline uygun giriş şeklini belirtir. Giriş katmanından sonra 64 birim ve ReLU aktivasyonlu dense katmanı ile birbirlerine bağlanır. Son olarak bir birime sahip dense katmanı bir çıktı katmanı gelir.

Bundan sonraki işlemler CNN modelinde olduğu gibi, 'adam' optimizasyon algoritması ve 'mean_squared_error' kayıp fonksiyonu kullanılarak derlemiştir. Daha sonra model, 40 epoch boyunca 32 batch boyutu ile eğitim verisi üzerinde eğitilmiştir. Eğitimden sonra, model test seti (dördüncü ve beşinci yıllar) için enerji kullanımı tahmini yapılmıştır.

Son olarak, senaryo, test dönemindeki tahmin edilen enerji kullanımı ile gerçek değerleri karşılaştırılmış. Gerçek ve tahmin edilen enerji kullanımı değerlerini içeren bir karşılaştırma DataFrame'i oluşturulur, bu da modelin performansının değerlendirilmesini sağlar. Bu karşılaştırma, modelin yeni ve görülmemiş veriler üzerinde ne kadar iyi genelleme yaptığını anlamaya yardımcı olmuştur. Bu senaryo'nun hata metriklerini hesapladığımızda; senaryo içinde eğitim seti için yapılan tahminlerin değerlendirilmesinin yanı sıra, test seti (son iki yıl) için yapılan tahminlerin doğruluğunu da değerlendirir ve hata metriklerini hesaplanır. İlk olarak, model test verisi üzerindeki tahminleri yapar ve bu tahminler predictions değişkenine atanır. Ardından, bu tahminlerin doğruluğunu değerlendirmek için çeşitli hata metrikleri hesaplamıştır.

Aşağıda, hesaplanan hata metriklerinin sonuçları tablo halinde sunulmuştur:

Tablo.3; LSTM model için; İlk Üç yıl eğitim verileri hata metrikleri


Hata Metrikleri	Değerler
MAE (İlk üç yıl)	0.09175
MSE (İlk üç yıl)	0.04019
RMSE (İlk üç yıl)	0.31333
R2 (İlk üç yıl)	0.97999

Tablo.4; LSTM model için; Son İki yıl test verileri hata metrikleri


Hata Metrikleri	Değerler
MAE (Son iki yıl)	0.04096
MSE (Son iki yıl)	0.05961
RMSE (Son iki yıl)	0.76711
R2 (Son iki yıl)	0.97999

Tablo.3, modelin eğitim seti üzerindeki performansını göstermektedir. Tablo.4 de test setinin performansı görülmektedir. Bu LSTM modelini görselleştirdiğimizde; Şekil 4.4'de

gerçek ve tahmin edilen enerji kullanımı verilerini görselleştirerek modelin eğitim verisini performansını analiz etmek amacıyla bir grafik oluşturulmuştur.



Şekil 4.4. LSTM model grafiği



Şekil 4.5. LSTM model son 100 veri grafiği

4.1.3. CNN-LSTM Hibrit Model Sonuçları

Özellikler, CNN-LSTM'in Conv1D katmanının gereksinimlerine uygun hale getirilmek için her zaman adımında tek bir özellik olacak şekilde yeniden şekillendirilmiştir.

Keras Sequential API kullanılarak bir hibrit model oluşturulmuştur. Model, her biri ReLU aktivasyon fonksiyonuna sahip ve artan filtre boyutlarına (32 ve 64) sahip iki Conv1D katmanı ve LSTM katmanından oluşur. İlk Conv1D katmanı, eğitim verisinin şekline uygun giriş şeklini belirtir. Katmanlar Conv1D katmanları girdi boyutunu korumak için

padding kullanır. LSTM katmanı 50 düğüm ve ReLU aktivasyon fonksiyonuna sahiptir. Daha sonra katmanları birbirine bağlamak için 64 birim ve ReLU aktivasyonlu dense katmanı kullanılmıştır.

Model, diğer modellerde olduğu gibi, 'adam' optimizasyon algoritması ve 'mean_squared_error' kayıp fonksiyonu kullanılarak derlemiştir. Daha sonra model, 40 epoch boyunca 32 batch boyutu ile eğitim verisi üzerinde eğitilmiştir. Eğitimden sonra, model test seti (dördüncü ve beşinci yıllar) için enerji kullanımı tahmini yapılmıştır.

Son olarak, senaryo, test dönemindeki tahmin edilen enerji kullanımı ile gerçek değerleri karşılaştırılmış. Gerçek ve tahmin edilen enerji kullanımı değerlerini içeren bir karşılaştırma DataFrame'i oluşturulur, bu da modelin performansının değerlendirilmesini sağlar. Bu karşılaştırma, modelin yeni ve görülmemiş veriler üzerinde ne kadar iyi genelleme yaptığını anlamaya yardımcı olmuştur. Bu senaryo'nun hata metriklerini hesapladığımızda; senaryo içinde eğitim seti için yapılan tahminlerin değerlendirilmesinin yanı sıra, test seti (son iki yıl) için yapılan tahminlerin doğruluğunu da değerlendirir ve hata metriklerini hesaplanır. İlk olarak, model test verisi üzerindeki tahminleri yapar ve bu tahminler predictions değişkenine atanır. Ardından, bu tahminlerin doğruluğunu değerlendirmek için çeşitli hata metrikleri hesaplamıştır.

Aşağıda, hesaplanan hata metriklerinin sonuçları tablo halinde sunulmuştur:

Tablo.5; CNN-LSTM model için; İlk Üç yıl eğitim verileri hata metrikleri


Hata Metrikleri	Değerler
MAE (İlk üç yıl)	0.00332
MSE (İlk üç yıl)	0.00114
RMSE (İlk üç yıl)	0.02391
R2 (İlk üç yıl)	0.99999

Tablo.6; CNN-LSTM model için; Son İki yıl test verileri hata metrikleri


Hata Metrikleri	Değerler
MAE (Son iki yıl)	0.00275
MSE (Son iki yıl)	0.00104
RMSE (Son iki yıl)	0.02224
R2 (Son iki yıl)	0.99999

Tablo.5, modelin eğitim seti üzerindeki performansını göstermektedir. Tablo.6 de test setinin performansı görülmektedir. Bu LSTM modelini görselleştirdiğimizde; Şekil 4.6'de

gerçek ve tahmin edilen enerji kullanımı verilerini görselleştirerek modelin eğitim verisini performansını analiz etmek amacıyla bir grafik oluşturulmuştur. Gerçek ve tahmin edilen enerji kullanımının son 100 verisi Şekil 4.7’de görülmektedir.



Şekil 4.6. CNN-LSTM model grafiği



Şekil 4.7. CNN-LSTM model son 100 veri grafiği

Seneryo-1’in Güç-Sıcaklık-Nem verileri giriş olarak kullanıldığında, elektrik tüketim tahminlemesi için oluşturulan modeller; CNN, LSTM ve CNN-LSTM modellerin hata metrikleri Tablo.7’de karşılaştırılmış, görüleceği üzere hata metriklerinin değerleri tüm modellerde hata fonksiyonları kabul edilebilir minimum değerler içinde olduğu fakat hibrit modelin daha doğru sonuç verdiği görülmektedir.


Tablo.7; Tüm Modellerin Son İki yıl test verileri hata metrikleri

Hata Metrikleri	CNN	LSTM	CNN-LSTM
MAE (Son iki yıl)	0.00560	0.04096	0.00275
MSE (Son iki yıl)	0.00318	0.05961	0.00104
RMSE (Son iki yıl)	0.05116	0.76711	0.02224
R2 (Son iki yıl)	0.98801	0.97999	0.99999

Elde edilen CNN, LSTM ve CNN-LSTM Hibrit modellerinhata metrik parametre sonuçları değerlendirildiğinde en iyi performansı veren modelin CNN-LSTM Hibrit model olduğu görülmektedir. Bu sonuç dikkate alınarak bundan sonraki analizlerde bu model kullanılmıştır.

4.1.4. Meteorolojik Parametrelerin Tahminleme Etkisi

Seçilen en iyi model olan modelin CNN-LSTM Hibrit model kullanılarak meteorolojik parametrelerin etkisi kombinasyonlu (Güç-Sıcaklık, Güç-Nem, Güç-Sıcaklık-Nem) olarak analiz edilmiştir. Güç-Sıcaklık verileri giriş olarak ve elektrik tüketimi tahminlemesi olacak şekilde hibrit modelimiz üzerinde yapılan analizde Şekil 4.8. grafiği sonucu alınmıştır. Tablo.8’de eğitim verilerinin, Tablo.9’da test verilerin hata metrikleri görülmektedir.



Şekil 4.8. CNN-LSTM model, Güç-Sıcaklık veri grafiği


Tablo.8; CNN-LSTM model, Güç Sıcaklık ilk 3 yıl eğitim verileri hata metrikleri

Hata Metrikleri	Değerler
MAE (İlk üç yıl)	0.19876
MSE (İlk üç yıl)	0.04878
RMSE (İlk üç yıl)	0.22072
R2 (İlk üç yıl)	0.98999

Tablo.9; CNN-LSTM model, Güç Sıcaklık son 2 yıl test verileri hata metrikleri

Hata Metrikleri	Değerler
MAE (Son iki yıl)	0.19992
MSE (Son iki yıl)	0.04847
RMSE (Son iki yıl)	0.22016
R2 (Son iki yıl)	0.98999

Güç-Nem verileri giriş olarak ve elektrik tüketimi tahminlemesi olacak şekilde hibrit modelimiz üzerinde yapılan analizde Şekil 4.9 grafiği sonucu alınmıştır. Tablo.10’da eğitim verilerinin, Tablo.11’de test verilerin hata metrikleri görülmektedir.



Şekil 4.9. CNN-LSTM model, Güç-Nem veri girişi

Tablo.10; CNN-LSTM model, Güç Nem ilk 3 yıl eğitim verileri hata metrikleri

Hata Metrikleri	Değerler
MAE (İlk üç yıl)	0.05579
MSE (İlk üç yıl)	0.00535
RMSE (İlk üç yıl)	0.07318
R2 (İlk üç yıl)	0.98999

Tablo.11; CNN-LSTM model, Güç Nem son 2 yıl test verileri hata metrikleri

Hata Metrikleri	Değerler
MAE (Son iki yıl)	0.05750
MSE (Son iki yıl)	0.03575
RMSE (Son iki yıl)	0.18910
R2 (Son iki yıl)	0.98999

Güç-Sıcaklık, Güç-Nem ve model seçiminde Güç-Sıcaklık-Nem verileri kullanılarak sonuçlar alınmıştır. Meteorolojik faktörler ayrı ayrı kullanılarak CNN-LSTM modeli kullanıldığında elektrik tüketim tahminlemesi Tablo.12’de oluşturulmuştur.

Tablo.12; Meteorolojik faktörler değiştirilerek alınan son 2 yıl test verileri hata metrikleri.

Hata Metrikleri	Güç-Sıcaklık-Nem	Güç-Sıcaklık	Güç-Nem
MAE (Son iki yıl)	0.00275	0.19992	0.05750
MSE (Son iki yıl)	0.00104	0.04847	0.03575
RMSE (Son iki yıl)	0.02224	0.22016	0.18910
R2 (Son iki yıl)	0.99999	0.98999	0.98999


Tablo.12’de görüldüğü gibi meteorolojik verilerin birlikte veri girişi olarak kullanımı, tek kullanımına göre daha doğru sonuç verdiği görülmektedir. Bu analiz sonuçları incelendiğinde meteorolojik parametrelerin birlikte giriş verisi olarak kullanılması daha doğru sonuç vermektedir.

4.2 SENERYO-2;

Bu senaryoda eldeki verilerle eğitilen ağ modelinin ileriye dönük(elde olmayan) tüketimin tahminlemesi amaçlanmıştır. 5 yıllık tüketim verisi ve meteorolojik verilerin


tümü birlikte kullanılarak 4 yıllık veri eğitim, 5. yıllık veri test, 6. ve 7. yılların tahminlemesi yapılmıştır.

Güç-Sıcaklık-Nem verisi giriş ve CNN-LSTM modeli kullanılarak 4 yıllık veri eğitim 5. yıl test için bu seneryoda kullanılan Şekil 4.9. veri grafiği görülmektedir.




Şekil 4.10. İlk 4 yıl eğitim ve 5.yıl test verisi

Şekil 4.11'deki veri kullanılarak eğitilmiş modelin 6. Ve 7. yılların elektrik tüketim tahminlemesi için yapılan analiz Şekil 4.12. görülmektedir. 6. ve 7. Yıllar'ın elektrik tüketim verisi olmadığından testleri yapılamaz. Test için kullanılan 5. yılın verisi için hata metrikleri alınmıştır.




Şekil 4.11. İlk 4 yıl eğitim, 5.yıl test ve 6.7. yıllar tahmin grafiği.

5.yılın gerçek ve test verileri analiz edildiğinde, Şekil 4.12. grafiğinde tüm yıl, Şekil 4.13 grafiğinde 4.yılın ilk 100 veri ve tahminlemesi görülmektedir.



Şekil 4.12. 4.yıl eğitim ve test veri grafiği.



Şekil 4.13. 4.yıl ilk 100 eğitim ve test veri grafiği.

Tablo.13’de Güç-Sıcaklık-Nem verileri birlikte giriş ve CNN-LSTM model kullanılarak ilk 4 yıl eğitim 5. yıl test için kullanılmıştır. 6.ve7.yılların tahminlemesi yapılmıştır. Hata metrik oranları sadece 4.yıl test için çıkarılmıştır. Hata fonksiyonları kabul edilebilir minimum değerler içinde olduğu Tablo.13 de görülmektedir.

Tablo.13; CNN-LSTM model, 6.7. yıl tahminlemesi için, 4.yılın test verileri hata metrikleri

Hata Metrikleri	Değerler
MAE	0.00622
MSE	0.00595
RMSE	0.00748
R2	0.99991

Şekil 4.11'deki grafik incelendiğinde, mevcut donanımsal haliyle hastanenin henüz yaşanmamış 6. ve 7. yıllarda, önceki yıllara bezer bir enerji tüketimi yapacağı tahminlenmektedir.

5. SONUÇLAR

Bu çalışmada, enerji kullanım verilerini tahmin etmek için kullanılan CNN, LSTM ve CNN-LSTM modelinin performansı detaylı bir şekilde analiz edilmiştir. Modelin hem eğitim hem de test seti üzerindeki performansı çeşitli hata metrikleri kullanılarak değerlendirilmiştir. Ayrıca meteorolojik faktörlerin ayrı ayrı kullanımında hibrit model üzerinde hata metrikleri kullanılarak analiz edilmiştir. Güç-Sıcaklık-Nem verileri ile CNN-LSTM hibrit modelin diğer modellere göre daha iyi tahmin sonuçları verdiği tespit edilmiştir. Bu nedenle hibrit model üzerinden İlk dört yıl (eğitim seti), son bir yıl (test seti) ve 6. ve 7. yılların tahminlemesi yapılmış, yapılan tahminler test verileri üzerinden doğruluğu ayrı ayrı analiz edilmiş ve sonuçlar tablo halinde sunulmuştur.

Sonuçlar, modelin enerji kullanımı tahminlerinde yüksek bir doğruluk sağladığını ve veriler üzerinde iyi bir genelleme yeteneğine sahip olduğunu göstermektedir. Modelin eğitim seti üzerindeki performansı MAE, MSE, RMSE ve R2 metrikleri kullanılarak değerlendirilmiş ve benzer şekilde test seti üzerindeki performans da analiz edilmiştir. 4 yıl eğitim, 5. yıl test veri seti ve 6. ve 7. yıllar tahminlemesi için yapılan analizler de modelin genel performansını doğrulamaktadır.

Tablo.13, modelin tüm 5 yıllık veri seti üzerindeki yüksek doğruluğunu ve iyi genelleme yeteneğini göstermektedir. Modelin performansını daha da artırmak ve daha karmaşık veri yapılarını işleyebilmek için gelecekte daha farklı DÖ modelleri ve yöntemleri de araştırılabilir. Ancak, CNN, LSTM modellerinin CNN-LSTM hibrit modele göre hata oranlarının yüksek çıktığı görülmüştür. Bu durum, CNN ve LSTM katmanlarının birlikte kullanılması ile modelin karmaşıklığının azalması ve bunun da modelin daha iyi öğrenmesine veya yeterince genelleme yapmasına neden olabileceğini göstermektedir. Bu nedenle, modelin daha stabil ve güvenilir tahminler yapabilmesi için CNN-LSTM modeli kullanılmasının doğru tahminlemeyi getirdiği gözlemlenmiştir.

Bu tez çalışmamızda kullanılan CNN-LSTM yöntem yerine Transfer Learning vs. yöntemler kullanılarak bu veri seti üzerinde gelecekte çalışmalar yapılabilir. Bundan başka bu tez çalışmasında önerilen tahmin yöntemi ile diğer alanlarda, meteorolojik tahminlemeler, rüzgar hızı tahmini ve benzeri alanlarda kullanılabilir.

KAYNAKLAR

- Türkiye Elektrik Enerjisi Talep Projeksiyonu Raporu (2020-2040 Dönemi)
Enerji Piyasası Düzenleme Kurumu, Elektrik Piyasası Talep Tahminleri Yönetmeliği (EPDK 2006) Ankara.
- Hamzaçebi C. (2011a). Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolution Uygulamaları. Ekin Basım Dağıtım, Bursa.
- Var, H. ve Türkay, E.B. (2014). Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yükü Tahmini. İstanbul Teknik Üniversitesi, İstanbul.
- Kaysal, K., Hocaoglu, F.O. ve Kaysal, A. (2014). Yük Tahmini için Hibrit (YSA ve Regresyon) Model. Afyon Kocatepe Üniversitesi, Afyonkarahisar.
- Yavuz Demir, M. (2014). Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini. Ankara Üniversitesi, Ankara.
- Sahay, K.B. and Tripathi, M.M. (2013). Day Ahead Hourly Load Forecast of PJM Electricity Market and ISO New England Market by Using Artificial Neural Network. Department of Electrical Engineering, Delhi Technological University, New Delhi, India.
- Torkzadeh, R., Mirzaei, A., Mirjalili, M.M., Anaraki, A.S., Sehhati, M.R. and Behdad, F. (2014).
- Mert SAÇLI- Dağıtım Şebekesinde Kısa Dönem Yük Tahmini (İtü - 2020)
- Bonanno, F., Capizzi, G. and Sciuto, G.L. (2014). A Neuro Wavelet-Based Approach for Short-Term Load Forecasting in Integrated Generation Systems. Department of Electrical, Electronics and Informatics Engineering, University of Catania, Catania, Italy.
- Yang, H., Liao, J. and Lin, C. (2013). A Load Forecasting Method for HEMS Applications. Department of Electrical Engineering, Research Center for Energy Technology and Strategy, National Cheng Kung University, Tainan, Taiwan. 68
- Fan, S. and Hyndman, R.J. (2012). Short-Term Load Forecasting Based on a Semi Parametric Additive Model. IEEE Transactions on Power Systems, 27: 134-141.
- Dordonnat, V., Koopman, S.J., Ooms, M., Dessertaine, A. and Collet, J. (2008). An Hourly Periodic State Space Model for Modelling French National Electricity Load. Intelligent Journal of Forecasting, 24: 566-587.
- Topallı ve Erkmen, yapay sinir ağları ve ARIMA yöntemlerini kullanarak oluşturduğu iki farklı ile kısa dönemli yük tahmini modellerini karşılaştırmıştır. Bu çalışmada yapay sinir ağlarının daha başarılı olduğu sonucuna varan Topallı ve Erkmen %1,60'lık hata oranına ulaşmıştır (Topallı ve Erkmen 2006).
- Toker, A.C. ve Korkmaz, O. (2011). Türkiye'nin Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi. 17.Uluslararası Enerji ve Çevre Konferansı, İstanbul, 32-35.
- Erkmen, I. and Ozdogan, A. (1997). Short Term Load Forecasting Using Genetically Optimized Neural Network Cascaded with a Modified Kohonen Clustering Process. 12th IEEE International Symposium on Intelligent Control, Istanbul, 107-112.
- Topallı, A.K. and Erkmen, I. (2003b). Four Methods for Short-Term Load Forecasting Using Benefits of Artificial Intelligence. Electrical Engineering, 85: 229-233.
- Topallı, A.K., Erkmen, I. and Topallı, I. (2006). Intelligent Short-Term Load Forecasting in Turkey. Electrical Power & Energy Systems, 28: 437-447.
- Topallı, A.K., Erkmen, I. and Topallı, I. (2006). Intelligent Short-Term Load Forecasting in Turkey.
- Pala, İ. (1998). Elektrik Sistemlerinde Bölgesel Yük Tahmini. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul.

- Bilge, B. Kısa Dönem Yük Tahmini. TEİAŞ Milli Yük Tevzi İşletme Müdürlüğü, Gölbaşı, Ankara.
- Chen, H., Canizares, C. and Singh, A. (2001). ANN-based Short-Term Load Forecasting in Electricity Markets. Department of Electrical & Computer Engineering, University of Waterloo, Waterloo, ON, Canada.
- Liu, Q., Xu, H., Shi, C. and Wei, S. (2014). The Application of Intelligent Control Technology in Power Systems. International Conference on Mechatronics and Automation, 2034-2038.
- Chollet, F., and Joseph, J. A., “Deep Learning with R”, Manning Publications, Shelter Island, 1-112 (2018).
- Patterson, J. and Gibson, A., “Deep Learning: A practitioner’s Approach”, O’Reilly Press, ISBN:978-1-491-91425-0, 41-114, 125-165 (2017).
- Haykin, S., “Neural Networks and Learning Machines (3d Edition)”, Prentice Hall, ISBN-13:978-0-13-147139-9, 1-68 (2009).
- Basheer, I.A. and Hajmeer, M., “Artificial neural networks: fundamentals, computing, design, and application”, Journal of Microbiological Methods, 43 3–31 (2000).
- Zupan, J. and Gasteiger, J., “Neural networks: a new method for solving chemical problems or just a passing phase?”, Anal Chim. Acta, 248 1–30 (1991).
- Souza, A.M. and Soares, F.M., “Neural Network Programming with Java”, Packt Publishing Ltd, Birmingham, 1-79 (2016).
- Yao, X., “Evolving artificial neural networks”, Proceedings of the IEEE, 87(9):1423–1447 (1999).
- Demuth, H., Beale, M. and Hagan, M., “User Guide, Neural Networks Tool-box™ 6”, The MathWorks, Inc., ISBN:0-9717321-0-8, 2-25, 3-5, 8-6 (2009).
- Kishan, M., Chilukuri, K.M. and Sanjay, R., “Elements of Artificial Neural Networks”, ISBN13:0-262-13328-8, 16-22, 70-80 (1996).
- Hecht-Nielsen, R., “Theory of the back propagation neural network”, In Proceedings of the International Joint Conference on Neural Networks, San Diego, 593-606 (1989).
- Specht, D.F., “Probabilistic neural networks for classification, mapping, or associative memory”, IEEE Int. Conf. Neural Networks, 1, 525-532 (1988).
- Rabunal, J.R. and Dorrado, J., “Artificial Neural Networks in Real-Life Applications”, Hershey, Idea Group Pub, 1-47 (2006).
- Tavanaei, A., Ghodrati, M., Kheradpisheh, S. R., Masquelier, T. and Maida, A. S., “Deep learning in spiking neural networks”, Neural Networks (2018).
- Bishop, C.M., “Pattern Recognition and Machine Learning”, Springer, New York, ISBN13: 978-0387-31073-2, 225-284 (2006).
- Ozkan, C. and Erbek F. S., “The comparison of activation functions for multispectral Landsat TM image classification,” Photogrammetric Engineering and Remote Sensing, 69(11), 1225–1234 (2003).
- Jin, X., Xu, C., Feng, J., Wei, Y., Xiong, J., and Yan, S., “Deep learning with s-shaped rectified linear activation units”, Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence (AAAI-16) (2015).
- Krizhevsky, A., Sutskever, I. and Hinton, G.E., “Imagenet classification with deep convolutional neural networks”, Advances in neural information processing systems (2012).
- Maas, A. L., Hannun, A. Y. and Ng, A. Y., “Rectifier nonlinearities improve neural network acoustic models”, ICML (2013).
- Bishop, C., “Novelty detection and neural network validation”, Proceedings of the IEEE Conference on Vision, Image and Signal Processing, 141, IET, 217– 222 (1994).

Yam, J.Y.F., Chow, T.W.S., “A weight initialization method for improving training speed in feedforward neural network”, *Neurocomput*, 30:219–232 (2000).

Glorot, X. and Bengio, Y., “Understanding the difficulty of training deep feed forward neural networks”, *AISTATS* (2010).

Saxe, A. M., McClelland, J. L., and Ganguli, S., “Exact solutions to the nonlinear dynamics of learning in deep linear neural networks”, *CoRR* (2013).

Internet : Github, “Orthogonal Initialization in Convolutional Layers”, <https://hjweide.github.io/orthogonal-initialization-in-convolutional-layers> (2019).

Le, Q. V., Ngiam, J., Coates, A., Lahiri, A., Prochnow, B. and Ng, A. Y., “On optimization methods for deep learning”, *Proc. 28th Int. Conf. Machine Learning*, 265–272 (2011).

Sutskever, I., Martens, J., Dahl, G. E. and Hinton, G. E., “On the importance of initialization and momentum in deep learning”, In *ICML (3)*, 28 of *JMLR Proceedings*, 1139–1147 (2013).

Internet : <https://github.com/AhmetFurkanDEMIR/Google-Colab>

Kingma, D. P. and Ba J. L., “Adam: A method for stochastic optimization”, *arXiv preprint*, arXiv:1412.6980 (2014).

Chollet, F., “Deep Learning with Python”, Manning 1-56, 196-207 (2017).

LeCun, Y., Bengio, Y. and Hinton, G., “Deep learning”, *Nature*, 521 436–444 (2015).

Goyal, P., Pandey, S., and Jain, K., “Deep Learning for Natural Language Processing”, *Apress*, 35 -75, 119-168 (2018).

Srivastava, N., Hinton G., Krizhevsky, A., Sutskever, I. and Salakhutdinov R., “Dropout: A simple way to prevent neural networks from overfitting”, *The Journal of Machine Learning Research*, 1929–1958 (2014).

Buduma, N. and Locascio, N., “Fundamentals of Deep Learning. Designing Next-Generation Machine Intelligence Algorithms”, *O'Reilly Media*, 172-217 (2017).

Pattanayak, S., “Pro Deep Learning with TensorFlow”, *Apress*, New York, ISBN 978-1-4842-3095-4, 153-278 (2017).

Le, Q.V., “A tutorial on deep learning part 2: Autoencoders, convolutional neural networks and recurrent neural networks”, *Google Brain*, 1–20 (2015).

Hochreiter, S. and Schmidhuber J., “Long short-term memory”, *Neural computation*, 9(8):1735–1780 (1997).

Chung, J., Gülçehre, Ç., Cho, K., and Bengio, Y., “Empirical evaluation of gated recurrent neural networks on sequence modeling”, *CoRR*, abs/1412.3555 (2014).

Krizhevsky, A., Sutskever, I. and Hinton, G., “Imagenet classification with deep convolutional neural networks”, *NIPS* (2012).

Wang, J., Gu, Q., Wu, J., Liu, G., and Xiong, Z., “Traffic speed prediction and congestion source exploration: A deep learning method”, *Data Mining (ICDM)*, *IEEE 16th International Conference*, 499–508 (2016).

Internet; https://www.techcareer.net/blog/python-nedir-ve-kimler-icin-dir?gad_source=1&gclid=Cj0KCQjwsc24BhDPAIaFXqAB1EaVid1AJ7SOz4A23zb6P9wrJ8ovz6Y8RcFxlMLvfl1SsXrXcqdwAAl0kEALw_wcB

Gozuoglu, Geleceğin akıllı şebekelerinde talep tarafı için enerji yönetim sistemi (2024).