

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

DERİN ÖĞRENME MODELLERİ İLE ELEKTRİK
KESİNTİ TAHMİNİ

YÜKSEK LİSANS TEZİ

Orçun KİTAPCI

İstanbul
Şubat-2022

T.C.
İSTANBUL SABAHATTİN ZAİM ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

DERİN ÖĞRENME MODELLERİ İLE ELEKTRİK KESİNTİ
TAHMİNİ

YÜKSEK LİSANS TEZİ

Orçun KİTAPCI

Tez Danışmanı
Dr. Öğr. Üyesi Ali HAMİTOĞLU

İstanbul
Şubat 2022

TEZ ONAYI

Lisansüstü Eğitim Enstitüsü Müdürlüğüne,

Bu çalışma, jürimiz tarafından Bilgisayar Bilim ve Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman Dr. Öğr. Üyesi Ali HAMİTOĞLU

Üye Dr. Öğr. Üyesi Abbas UĞURENVER

Üye Dr. Öğr. Üyesi Muhammed DAVUD

Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Prof. Dr. Metin TOPRAK

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİMİ

Yüksek lisans tezi olarak hazırladığım “**Derin Öğrenme Modelleri ile Elektrik Kesinti Tahmini**” adlı çalışmanın öneri aşamasından sonuçlandığı aşamaya kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığımı, bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

Orçun KİTAPCI

ÖN SÖZ

Araştırmamdaki her aşamada bana yardımcı olan değerli tez danışmanım Dr. Öğr. Üyesi Ali HAMİTOĞLU 'na, eğitim alanında dersleriyle bize vizyon katan çok değerli hocamız Prof. Dr. Akhtar JAMIL'e, yüksek lisans eğitimim boyunca benden desteklerini esirgemeyen sevgili eşim Şerife KİTAPCI 'ya ve aileme teşekkürlerimi sunarım.

Orçun KİTAPCI

İstanbul - 2022

ÖZET
DERİN ÖĞRENME MODELLERİ İLE ELEKTRİK KESİNTİ
TAHMİNİ

Orçun KİTAPCI

Yüksek Lisans, Bilgisayar Mühendisliği

Tez Danışmanı: Dr. Öğr. Üyesi Ali HAMİTOĞLU

Şubat, 2022 - 73 Sayfa

Gelişmekte olan ülkelerde artan nüfus, sanayi ve teknolojinin yaygınlaşması, ekonominin artan trendi ile birlikte enerji kullanımı da artmaktadır. Bu artışın ana enerji kaynağı ise elektriktir. Bu bakımdan elektrik kesintileri ağır sanayi, üretim gibi birçok alanın yanında hastane, eğitim kurumları, iletişim gibi önemli alanlarda etkisini büyük oranda hissettirmekte, kesinti süresi ile orantılı olarak ekonomik kayba sebebiyet vermektedir. Kesintilerin önceden tahmini ile kullanıcılarının önceden bilgilendirilmesi, ilgili dağıtım şebekesine yatırımlarının planlanması ve kesintinin yoğunluğuna göre müdahale ekibinin belirlenmesi ile kesinti süresinin en az seviyeye indirilmesi sağlanabilir. Bu alanda yapılan çalışmalar incelendiğinde yapay zeka modelleri kullanılarak daha çok elektrik arıza sayıları ve ekonomik maliyeti tahmini yürütülmüştür. Bu çalışmada bölgede günlük olarak alınan kesinti verilerinin analizi yapılarak önceki kesintilerin bölgesel olarak sayıları ve bölgenin meteorolojik koşulları dikkate alınarak derin öğrenme modelleri ile kesintinin oluşacağı bölgeyi ve kesinti yoğunluğunun (sayılarının) tahmin edilmesi önerilmiştir. Derin Öğrenme yöntemlerinden Konvolüsyonel Sinir Ağı (CNN), Tekrarlayan Sinir Ağı (RNN) ve Uzun Kısa Vadeli Hafıza (LSTM) modelleri aracılığı ile Uyarlanabilir Momentum Tahmini (adam) ve Karesel Ortalama Hata Olasılığı (RMSProp) optimizasyonları kullanılarak deneyler yapılmıştır. Deneylerde 3 farklı veri seti üzerinde özellik çıkarma, ekleme ve Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE) metrikleri ile modellerin başarıları değerlendirilmiştir. Yapılan değerlendirmede özellik sayısı bakımından RMSProp optimizasyonu kullanılan LSTM 'in çok özellikli verilerde 0.0202 MAE ve 0.008 MSE değerleri ile en başarılı model olduğu, genel olarak değerlendirildiğinde de yine aynı şekilde RMSProp optimizasyonu kullanılan LSTM' in 0.0377 MAE ve 0.0027 MSE değerleri ile az özellikli veride de en başarılı

sonucu verdiđi gözlemlenmiştir.

Anahtar Kelimeler: Elektrik Dağıtım, Kesinti Tahminleme, Derin Öğrenme, CNN, RNN, LSTM



ABSTRACT
POWER OUTAGE PREDICTION WITH DEEP LEARNING
MODELS

Orçun KİTAPCI

Master, Computer Science

Thesis Advisor: Assist. Prof. Dr. Ali HAMİTOĞLU

February, 2022 - 73 Pages

With the increasing population, the spread of industry and technology in developing countries, and the increasing trend of the economy, the usage of energy is also increasing. The main energy source of this increase is electricity. In this respect, power outages have a great impact in many areas such as heavy industry, production, as well as in important areas such as hospitals, educational institutions, communication, and cause economic loss in proportion to the duration of the outage. It can be ensured that the downtime is minimized by informing the users in advance, planning the relevant distribution network investments and determining the maintenance team according to the intensity of the outage. When the studies in this field are examined, mostly artificial intelligence models are used to estimate the number of electrical faults and its economic costs. In this study, it is suggested to estimate the region where the outages will occur and the density (numbers) of the outage with deep learning models by analyzing the daily outage data in the region, taking into account the regional numbers of the previous outages and the meteorological conditions of the region. Experiments were carried out using deep learning methods Convolutional Neural Network (CNN), Recurrent Neural Network (RNN) and Long Short Term Memory (LSTM) models using Adaptive Moment Estimation (adam) and Root Mean Square Error Probability (RMSProp) optimizer. In the experiments, the success of the models was evaluated with feature extraction, and Mean Absolute Error (MAE), Mean Squared Error (MSE) metrics on 3 different data sets. In the evaluation, it was seen that LSTM, which used RMSProp optimization in terms of number of features, was the most successful model with 0.0202 MAE and 0.008 MSE values in multi-feature data. When evaluated in general, it was observed that LSTM, which used RMSProp optimization in the same way, gave the most successful results with 0.0377 MAE and 0.0027 MSE values, as

well in low-featured data.

Keywords: Dicle Elektrik, Electricity Distribution, Power Outage Prediction, Deep Learning, CNN, RNN, LSTM



İÇİNDEKİLER

TEZ ONAYI	i
BİLİMSEL ETİK BİLDİRİMİ.....	ii
ÖN SÖZ.....	iii
ÖZET.....	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
TABLolar LİSTESİ.....	xi
ŞEKİLLER LİSTESİ.....	xii
KISALTMALAR	xiv
BİRİNCİ BÖLÜM.....	1
GİRİŞ	1
1.1. Amaç	3
1.1.1. Derin Öğrenme.....	3
1.2. Teze Genel Bakış	4
İKİNCİ BÖLÜM	6
LİTERATÜR TARAMASI	6
2.1. Konvolüsyonel Sinir Ağı (CNN)	6
2.2. Tekrarlayan Sinir Ağı (RNN)	7
2.3. Uzun Kısa Vadeli Hafıza (LSTM)	8
ÜÇÜNCÜ BÖLÜM	9
YÖNTEM.....	9
3.1. Konvolüsyonel Sinir Ağları (CNN)	9

3.1.1.	Giriş Katmanı (Input Layer).....	10
3.1.2.	Konvolüsyon (Evrışim) Katmanı (Convulation Layer)	10
3.1.3.	Havuz Katmanı (Pooling Layer)	11
3.1.4.	Unutma Katmanı (Dropout Layer).....	12
3.2.	Tekrarlayan Sinir Ağı (RNN)	12
3.3.	Uzun Kısa Vadeli Hafıza Ağları (LSTM).....	14
3.4.	Donanım ve Yazılım Gereksinimleri	17
DÖRDÜNCÜ BÖLÜM		18
VERİ KÜMESİ		18
4.1.	Özelliklerin Önemi.....	18
4.2.	Verinin Elde Edilişi.....	19
4.2.1.	Elektrik Kesinti Verileri	20
4.2.2.	Meteoroloji Verileri	21
4.3.	Veri Ön İşleme	23
4.4.	Öğrenme Veri Seti.....	27
4.5.	Test Veri Seti.....	27
BEŞİNCİ BÖLÜM		29
ÖNERİLEN MODEL		29
5.1.1.	CNN Tahmin Modelinin Geliştirilmesi	31
5.1.2.	RNN Tahmin Modelinin Geliştirilmesi	31
5.1.3.	LSTM Tahmin Modelinin Geliştirilmesi	32

ALTINCI BÖLÜM	34
DENEYSEL SONUÇLAR.....	34
6.1. Adam Optimizer Kullanılarak Derin Öğrenme Modelleri ile Tahminleme....	35
6.1.1. Toplam Kesinti Sayıları	36
6.1.2. Meteoroloji Verileri ile Toplam Kesinti Sayıları.....	37
6.1.3. Planı ve Plansız Kesinti Sayıları	39
6.2. RMSProp Optimizer Kullanılarak Derin Öğrenme Modelleri ile Tahminleme	42
6.2.1. Toplam Kesinti Sayıları	42
6.2.2. Meteoroloji Verileri ile Toplam Kesinti Sayıları.....	44
6.2.3. Planı ve Plansız Kesinti Sayıları	46
YEDİNCİ BÖLÜM	50
TARTIŞMA VE DEĞERLENDİRME	50
KAYNAKÇA	52
ÖZGEÇMİŞ.....	58

TABLULAR LİSTESİ

Tablo 4.1: Kesinti Sebeplerine Göre Sayı Dağılımı (2018 - 2021 Yılları)	20
Tablo 4.2: Kesinti Verileri Deseni (Tablo-1 Verileri)	20
Tablo 4.3: Yıllara Göre Kesinti Başına Ortalama Etkilenen Abone Sayıları	21
Tablo 4.4: Yıllara Göre İl Düzeyinde Kesinti Sayıları	21
Tablo 4.5: Meteoroloji Verileri - Alınan Özellikler Ve Örnek Verileri.....	22
Tablo 4.6: Tahminlemede Girdi Olarak Kullanılacak Kesinti Verisi Özellikleri Ana Veri Seti	23
Tablo 4.7: Ana Veri Seti Özellikleri	23
Tablo 4.8: Örnek Kesinti Ham Verisi (Diyarbakır)	25
Tablo 4.9: Null Değeri İçeren Özelliklerin İncelenmesi.....	25
Tablo 4.10: 2020 -2021 Diyarbakır Aykırı Kesinti Sayılarının Tespiti.....	26
Tablo 4.11: Diyarbakır Öğrenme Ve Test Veri Seti Özellikleri	28
Tablo 5.1: CNN Model Parametreleri	31
Tablo 5.2: RNN Model Parametreleri	32
Tablo 5.3: LSTM Model Parametreleri.....	33
Tablo 6.1: Önerilen Derin Öğrenme Modelleri İle Kesinti Tahmini Performans Analizi	49

ŞEKİLLER LİSTESİ

Şekil 3.1: CNN Genel Mimari	10
Şekil 3.2: RNN Genel Akış Mimarisi	14
Şekil 3.3: Temel LSTM Yapısı	16
Şekil 4.1: Ham Veriden ETL Süreci İle Veri Seti Oluşturma Akış Diyagramı	22
Şekil 4.2: 2020 – 2021 Diyarbakır Aykırı Kesinti Sayıları Dağılımı	27
Şekil 5.1: Elektrik Kesintileri Tahminleme Modeli Akış Şeması.....	30
Şekil 5.2: Diyarbakır Kesinti Sayıları Grafiği (2020 Yılı).....	30
Şekil 6.1: Bir Özellik Alınarak Adam Optimizer Kullanılan CNN Modeli.....	36
Şekil 6.2: Bir Özellik Alınarak Adam Optimizer Kullanılan RNN Modeli.....	36
Şekil 6.3: Bir Özellik Alınarak Adam Optimizer Kullanılan LSTM Modeli	37
Şekil 6.4: Adam Optimizer Kullanılan Modellerin Bir Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE	37
Şekil 6.5: Beş Özellik Alınarak Adam Optimizer Kullanılan CNN Modeli.....	38
Şekil 6.6: Beş Özellik Alınarak Adam Optimizer Kullanılan RNN Modeli.....	38
Şekil 6.7: Beş Özellik Alınarak Adam Optimizer Kullanılan LSTM Modeli	39
Şekil 6.8: Adam Optimize Kullanılan Modellerin Beş Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE	39
Şekil 6.9: Yedi Özellik Alınarak Adam Optimizer Kullanılan CNN Modeli	40
Şekil 6.10: Yedi Özellik Alınarak Adam Optimizer Kullanılan RNN Modeli	40
Şekil 6.11: Yedi Özellik Alınarak Adam Optimizer Kullanılan LSTM Modeli.....	41
Şekil 6.12 Adam Optimizer Kullanılan Modellerin Yedi Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE	41
Şekil 6.13: Bir Özellik Alınarak RMSProp Optimizer Kullanılan CNN Modeli	42
Şekil 6.14: Bir Özellik Alınarak RMSProp Optimizer Kullanılan RNN Modeli	43
Şekil 6.15: Bir Özellik Alınarak RMSProp Optimizer Kullanılan LSTM Modeli	43

Şekil 6.16: RMSProp Optimizer Kullanılan Modellerin Bir Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE	44
Şekil 6.17: Beş Özellik Alınarak RMSProp Optimizer Kullanılan CNN Modeli	44
Şekil 6.18: Beş Özellik Alınarak RMSProp Optimizer Kullanılan RNN Modeli	45
Şekil 6.19: Beş Özellik Alınarak RMSProp Optimizer Kullanılan LSTM Modeli ...	45
Şekil 6.20: RMSProp Optimizer Kullanılan Modellerin Beş Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE	46
Şekil 6.21: Yedi Özellik Alınarak RMSProp Optimizer Kullanılan CNN Modeli....	46
Şekil 6.22: Yedi Özellik Alınarak RMSProp Optimizer Kullanılan RNN Modeli....	47
Şekil 6.23: Yedi Özellik Alınarak RMSProp Optimizer Kullanılan LSTM Modeli .	47
Şekil 6.24: RMSProp Optimizer Kullanılan Modellerin Yedi Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE	48

KISALTMALAR

GSYH	:Gayri Safi Yurt İçi Hâsıla
EPDK	:Enerji Piyasası Denetleme Kurumu
DEDAŞ	:Dicle Elektrik Dağıtım A.Ş.
SYS	:Saha Yönetim Sistemi
ANN	:Yapay Sinir Ağı (Artificial Neural Network)
CNN	:Konvolüsyonel Sinir Ağı (Convolutional Neural Network)
RNN	:Tekrarlayan Sinir Ağı (Recurrent Neural Network)
LSTM	:Uzun Kısa Vadeli Hafıza (Long Short Term Memory)
ARIMA	:Oto regresif Entegre Hareketli Ortalama Model (Autoregressive Integrated Moving Average)
MLP	:Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
ADAM	:Uyarlanabilir Momentum Tahmini (Adaptive Moment Estimation)
RMSPROP	:Karesel Ortalama Hata Olasılığı (Root Mean Square Error Propability)
MSE	:Ortalama Karesel Hata (Mean Squared Error)
MAE	:Ortalama Mutlak Hata (Mean Absolute Error)
ETL	:Çek Dönüştür Yükle (Extract-Transform-Load)
ODS	:Operasyonel Veri Deposu (Operational Database Store)
DWH	:Veri ambarı (Datawarehouse)
PCA	:Temel Bileşenler Analizi (Principal Component Analysis)
1D	:Bir Boyutlu (One Dimensional)
2D	:İki Boyutlu (Two Dimensional)

BİRİNCİ BÖLÜM

GİRİŞ

Elektrik dağıtımını tıpkı bütün vücuda yayılan bir sinir sistemi gibi tüm ülkeyi saran birbiri ile bağımlı bir dağıtım ağından oluşur. Bu dağıtım ağı illerden bağımsız, ülkeyi saran bir biri ile ilişkili bir ağıdır. Dolayısıyla dağıtım ağında meydana gelen büyük çaplı bir yıkım tüm ülkeyi etkileyebilir. Bu nedenle elektrik kesintisi kapsadığı bölge bakımından büyüdükçe hem o bölgeyi hem de bütün ülkeyi etkileyebilir. Bundan dolayı elektrik kesintilerine ulusal bir anlam yüklemek yanlış olmayacaktır. Bu makaledeki inceleme Diele Elektrik Dağıtım (DEDAŞ) bölgesinde olacaktır.

Kesintilerini inceleyeceğimiz DEDAŞ dağıtım Bölgesi Diyarbakır, Şanlıurfa, Mardin, Siirt, Şırnak illerinden oluşmaktadır. Bölge ülkenin batısına göre gelişmekte olan Güneydoğu Anadolu illerinin çoğunu kapsamaktadır. Geçim illere bağlı olmakla birlikte büyük oranda tarım ve hayvancılık ile sağlanmaktadır. Sanayisi ise hızla büyümektedir. Bölge olarak Irak, İran, Suudi Arabistan gibi ülkelere kapı olma niteliği taşımaktadır. Bu nedenle bu bölgelere enerji, ürün, bilgi transferi bakımından önemli bir konumda yer almaktadır.

Ayrıca bölge enerji kullanımının diğer önemli parametreleri olan nüfus ve Gayri Safi Yurt İçi Hâsıla (GSYH) bakımından da sürekli artış göstermektedir. Nüfus artışı yıllık ortalama %2.5 ile 2010 yılında 5 milyondan bugün 6.5 milyona ulaşmıştır, GSYH artışı yıllık ortalama %19 artışla 2010 yılından 36 milyon TL'den bugün 120 milyona TL 'e yaklaşmıştır (İstatistik Veri Portalı, 2022).

Bu sorumluluk bölgesinde bulunan ve burada meydana gelen elektrik kesintileri sadece mesken, eğitim kurumları, küçük işletmeler değil sağlık, ulaşım, tarım, iletişim hatları, ağır sanayi ve üretim gibi birçok alanda etkisini büyük oranda hissettirmektedir. Bu alanlarda meydana gelen elektrik kesintileri bazen hayati önem de taşımaktadır (Dindar, 2020).

Literatürde elektrik arızaları ile ilgili birçok tahmin çalışması bulunmaktadır. Ancak bu yayınlar daha çok arıza üzerinden kesinti maliyetlerini tahminlemeye ve sınıflandırmaya yönelik olmuştur. (Panya vd.,2010), (Dindar, 2020) (Jha vd., 2012). Bazı kaynaklar ise kesinti sayılarını tahminlerken özellikle belli bir alanda incelemiş ve kesinti sayılarının tahminlemesine yönelik genel bir perspektif ortaya

konulmamıştır. (Tervo, Karjalainen ve Jung, 2018). Ayrıca bu makaleler derin öğrenme yöntemleri ile tahminleme yöntemlerini kullanmamışlardır.

Elektrik kesinti maliyetlerinin tahminlenmesi en öncelikle kesinti sayılarının doğru yerde ve doğru zamanda nerelerde oluştuğunu ortaya koymak ile başlamaktadır. Bu tahmin ile öncelikle maliyetleri düşürmeye yönelik aksiyon alınabilir böylece daha proaktif bir yaklaşım sergilenmiş olunur. Bununla birlikte elektrik kesintisinin yaşanacağı bölgelerde ekip yoğunluklarının planlanması ile kesintilerin daha kısa sürmesi sağlanabilir. Bu çalışmada veri daraltılarak öncelikle belli bir bölgede başarı sağlanacaktır. Bu başarı ile tüm bölgede sıralı bir şekilde uygulanması, uygulamanın geliştirilmesi ve tüm bölgeye ve hatta tüm Türkiye 'ye uygulanması yoluna gidilmesi amaçlanmaktadır.

Makalemizde elektrik kesintilerinin sayı ve sürelerini minimize etmeye yönelik tahminleme çalışması yapılacaktır. Tahminleme için derin öğrenme yöntemlerinden olan Konvolüsyonel Sinir Ağı (CNN), Tekrarlayan Sinir Ağı (RNN), Uzun Kısa Vadeli Hafıza (LSTM) modelleri uygulanarak, farklı özelliklerin gerek elle gerek yöntem aracılığı ile çıkartılarak optimizasyon çalışması yapılacaktır. Ortalama Mutlak Hata (MAE), Ortalama Karesel Hata (MSE) metrikleri ile doğrulukları ölçümlenecektir. Böylece minimum seviyede özellik ile en doğru modelin kurgulanması ve tahminlenmesi sağlanacaktır.

Tahmin sürecinde iki temel yaklaşım önerilmiştir. İlk yaklaşımda oluşturulan derin sinir ağı mimarileri farklı türden özniteliklerle beslenmiştir. İlk deneylerde kesinti verilerinden hesaplanan teknik göstergeler sinir ağı modellerine giriş verisi olarak verilmiştir, sonraki deneylerde giriş verisi olarak hava durumu, planlı ve plansız kesinti verileri de eklenerek öznitelikler genişletilmiştir. Böylece 1 özellikli, 5 özellikli ve 7 özellikli olmak üzere 3 ayrı veri seti üzerinden deneyler yürütülmüştür. Öznitelik seçme işlemi hem gözleme dayalı olarak hem de modelin seçme yeteneği ile çıkartılması sağlanmış, her iki durum için de sonuçlar elde edilmiştir.

Çalışmanın sonunda bu 3 model 2 optimizasyon kullanılarak, 3 farklı veri setinde, 2 farklı metrik ile doğruluk karşılaştırması yapılmıştır ve en doğru yöntem belirlenmiştir. Çalışmada öncelikle belli bir bölge incelenmiş daha sonra diğer bölgelerde yaygınlaştırılması amaçlanmıştır.

1.1. Amaç

Bu makalede derin öğrenme algoritmalarından olan CNN, RNN ve LSTM yöntemlerini kesinti sayılarının bölgesel düzeyde tahmin edilmesinde uygulayacağız. Modelin kurgulanması ve model çıktılarının karşılaştırılmasında kullanılacak olan MSE, MAE metriklerinin karşılaştırmalı sonuçlarını ele alacağız. Bölgede oluşabilecek kesinti sayılarını en keskin doğrulukla tahminlemedeki başarısı ele alınacak, en başarılı model belirlenecektir. Tezin ikinci amacı ise elektrik kesintilerinin tahminlenmesi ile bakım yatırımlarının doğru yere yapılmasını sağlayarak doğrudan fayda sağlamak ve kesintilere doğru yerlerde müdahale edilmesinin sağlanması ile süresini kısaltarak dolaylı yoldan fayda sağlamaktır.

1.1.1. Derin Öğrenme

Elektrik kesintileri ile ilgili yapılan birçok çalışma bulunmaktadır. Bunların bir kısmı tahminlerinde ekonomik etkilerine yoğunlaşmış ancak tahminde kullanılan araçlar derin öğrenme yöntemleri olmadığı gibi aynı zamanda kullanılan tahmin yöntemleri derinlemesine incelenmemiştir (Panya vd., 2010), (Dindar, 2020).

Bu makalede elektrik kesintilerinde makine öğrenmesinin bir alt sınıfı olan derin öğrenme regresyon yöntemleri kullanılarak kesintilerin hangi bölgede, hangi sayılarda meydana geleceğinin tahmini amaçlanmakta ve kullanılan bu yöntemlerin çıktıları karşılaştırılmaktadır. Ayrıca bu modeller için kullandığımız özellik çıkarma / ekleme yöntemleri tartışılacaktır. Kullanacağımız derin öğrenme algoritmaları aşağıdaki gibi olacaktır.

1. Convolutional Neural Network (CNN)
2. Recurrent Neural Network (RNN)
3. Long Short-Term Memory (LSTM)

1.1.1.1. Convolutional Neural Network (CNN)

Bir derin öğrenme algoritması olan CNN modeli çoğunlukla görüntü işleme ilgili çalışmalarda kullanılmaktadır. Zaman serileri ile ilgili yapılan çalışmalarda da oldukça başarılı sonuçlar elde edilmiştir. Bu makalede tek boyutlu CNN modeli kullanılarak zaman serileri yöntemi ile elektrik kesintilerinin tahmini yöntemini kullanacaktır

(Fukushima ve Miyake, 1982).

1.1.1.2. Recurrent Neural Network (RNN)

CNN mimarisi ileri beslemeli bir mimaridir. Yani zamana bağılı bir kavram yoktur, ilgilendiği tek girdi mevcut örnektir.

RNN (Hopfield, 1982), girdileri yalnızca anlık değil, önceki girdilere göre değerlendirir. RNN 'de giriş verilerinin yanı sıra bir önceki çıkışı gösteren içerik birimleri de ağı etkiler. Girdi için t-1 anındaki karar, t anında verilecek kararı da etkiler. Bu dokümanda zamana bağılı serilerde olduğu üzere kesinti tahminlemede özellik ekleme ve çıkarma yöntemleri kullanılarak RNN 'de model oluşturularak tahminlemedeki başarısına yer verilecek, diğer modeller ile karşılaştırılacaktır.

1.1.1.3. Long Short Term Memory (LSTM)

Derin öğrenme CNN ile başlayacak şekilde zaman içerisinde RNN ve RNN 'nin de yetersiz geldiği noktalarda LSTM (Hochreiter ve Schmidhuber, 1997) geliştirilmiştir. LSTM algoritmasında özellikle geriye dönük tüm özelliklerin verisi hafızada tutulmuş dahası özellik kaldırma ve ekleme ile kendi başarısını arttırmıştır. Makalemizde de LSTM in bu algoritmasından faydalanılarak kesinti tahminlemedeki başarısı diğer modeller ile karşılaştırılacaktır.

Modellerin oluşumunda tüm parametre detayları ve model kurgusuna yer verilecektir.

1.2. Teze Genel Bakış

Bu dokümanın bölümleri şu şekilde planlanmıştır. Bölüm 1 'de teze giriş ve makale özeti verilmiştir. Bölüm 2 'de ise literatür taraması yapılmış, özellikle elektrik kesintilerinin incelendiği makaleler taranmıştır. Bununla birlikte elektrik dağıtım arızaları ve bu konuda oluşan maliyetlerinin verildiği makaleler de incelenmiştir. Özellikle CNN, RNN ve LSTM 'de, zaman serileri üzerinde yapılan incelemelere de yer verilmiş, buradaki karşılaştırmalar ve başarı oranlarına değinilmiştir.

Bölüm 3 'de CNN, RNN ve LSTM 'in çalışma modelleri incelenmiş, formülleri ile birlikte modellere detaylı yer verilmiştir. İlk başta CNN algoritmasının detaylı

incelenmesi sağlanmıştır ardından RNN ve LSTM in CNN odaklı incelemeleri detaylı bir şekilde yapılmıştır. Bu bölümde bu algoritmaların çalışma modellerinin tasarımına da yer verilmiştir.

Bölüm 4 'de algoritma modellerinde kullanılacak verinin kaynak sistemlerden elde edilışinden detaylıca bahsedilmiştir. Burada verinin veri setine dönüşümüne de detaylıca yer verilmiştir. Verinin iki ayrı parça olarak temin edilmesi Operasyonel Veri Deposu (ODS) katmanından itibaren Çek Dönüştür Yükle (ETL) süreçlerinden geçirilerek veri seti oluşumu aktarılmıştır. Öğrenme ve Test veri seti oluşumu ve burada sağlanan veri miktarına da yer verilmiştir.

Bölüm 5 'de ise önerilen algoritmaların geliştirilmesinde ve uygulamalarında, kullanılan parametrelerine geniş bir şekilde yer verilmiştir. Bölüm 6 'da sonuçlar ortaya konulmuş ve açıklamalarına yer verilmiştir.

Sonuç olarak Bölüm 7 'de sonuçların analizi yapılmış, bir sonraki çalışma için bir yol haritası belirlenmiştir.

İKİNCİ BÖLÜM

LİTERATÜR TARAMASI

Bu bölümde kesinti tahminleme ile ilgili yapılan çalışmalarda karşılaşılan problemler, önerilen çözümler incelenmiştir. Ayrıca bir sonraki bölümde CNN ve alt modellerinin mimarisi incelenecek ve avantajları, dezavantajları ortaya konulacaktır.

Literatürde elektrik kesintileri ile ilgili birçok maliyet çalışması ve tahminler bulunmaktadır. Ancak bu yayınlar daha çok kesinti maliyetlerini tahminlemeye ve sınıflandırmaya yönelik olmuştur. (Panya vd., 2010), (Dindar, 2020) (Jha vd., 2012). Bazı kaynaklar ise kesinti sayılarını tahminlerken özellikle belli bir alanda incelemiş ve kesinti sayılarının tahminine yönelik genel bir perspektif ortaya konulmamıştır. (Tervo, Karjalainen ve Jung, 2018). Ayrıca bu makalelerde elektrik kesintileri ile ilgili derin öğrenme yöntemleri ile tahminleme ortaya konulmamıştır. Bu nedenle literatür araştırması daha çok derin öğrenme yöntemleriyle zaman serilerinde yapılmıştır.

2.1. Konvolüsyonel Sinir Ağı (CNN)

Bir zaman serisi örneği olan finansal verilerden hisse senetleri üzerinde yapılan bir çalışmada (Hameed vd., 2020) üç ayrı şirket veri seti üzerinde (Apple, Amerisource Bergen Corporation, Cardinal Health) derin öğrenme yöntemleri olan CNN /1D-CNN ve LSTM kullanılarak bir yöntem geliştirilmiştir. Ayrıca makalede ana bileşen analizi Temel Bileşenler Analizi (PCA) kullanılarak özellik azaltmanın kullanılan modeller üzerinde tahmin doğruluğundaki etkisi analiz edilmiştir. Böylece hem PCA hem de PCA olmadan tahmin başarısının karşılaştırmaları sağlanmıştır. Araştırma sonunda en başarılı yöntemin PCA uygulamalı LSTM 'in olduğu sonucuna varılmıştır.

CNN 'in ham sensör verilerinden anlamlı özellikleri belirlenmesi için kullanıldığı (Canizo vd., 2019) makalede, CNN 'den elde edilen çıktı ile RNN nin ise zaman serilerine uygun olarak tahminlemenin yapıldığı CNN-RNN bileşik mimarisi önerilmiştir. Modelde CNN 'e gönderilen veriler seri halde gönderilmesi ya da paralel olarak gönderilerek sonuçların birleştirilmesi ile iki farklı yöntem denenmiştir. RNN 'e giren bu özellikler ile sensör verilerinde anomali tespiti yapılmıştır. Makalede öğrenme veri setindeki anormalliklerin yüzdesi %3'e kadar azaltılsa bile

performansının yüksek olması sayesinde, çoklu zaman serileri üzerindeki anormallikleri etkili bir şekilde tespit ettiği gösterilmektedir. Paralel giriş yönteminde ise CNN mimarisinin, her bir sensör verisini bağımsız olarak işlemesi sayesinde, test edilen tüm senaryolarda geleneksel seri gönderime göre CNN mimarisinden daha iyi performans gösterdiği belirtilmektedir.

2.2. Tekrarlayan Sinir Ağı (RNN)

Zaman serisi analizinin temel amacı, mevcut tarihsel verilere göre gelecekteki değeri tahmin etmektir. RNN, zaman serisi analizinde en önemli sinir ağlarından biridir. Sıradan sinir ağları ile karşılaştırıldığında, RNN tartışmasız en iyisidir. RNN 'nin her gizli katmanının hesaplama sonuçları, mevcut girdi ve daha önce gizli katman sonuçlarıyla ilişkilidir. RNN, önceki sonuçları hafızaya alma özelliğine sahiptir (Yin vd., 2019).

Türkiye elektrik tüketimi tahmininin başarısının araştırıldığı (Tokgöz ve Ünal, 2018) makalede RNN, LSTM ve Kapı Özyinelemeli Geçitler (GRU) modellerinin zaman serisi yöntemleri sunulmakta ve buradaki sonuçlar Otoregresif Entegre Hareketli Ortalama Model (ARIMA) ve Yapay Sinir Ağı (ANN) ile karşılaştırılmaktadır. RNN ve LSTM modellerinden ARIMA ve ANN modellerine göre daha iyi başarı elde edildiği gözlemlenmiş, Yapılan bütün deneylerde katman sayısındaki artışın, farklı modellerde farklı başarı elde edilse de, tahmin başarısı arttırdığı gözlemlenmiştir. RNN ile yapılan incelemede ikinci katmanın eklenmesi başarıyı %0.13 oranında attırmış, katman sayısı üç olduğunda başarının düştüğü gözlemlenmiştir. LSTM deneylerinde ise eklenen her bir katmanda başarımın arttığı gözlemlenmiştir.

Sonuç itibariyle RNN için iki, LSTM için dört, GRU için ise üç katman sayısı üstüne çıkıldığında tahmin başarısının düştüğü görülmüştür.

Yeni Kapı Kontrol Birimi (NGCU) adı verilen yeni bir model öneren (Wang vd., 2022) çalışmalarını RNN üzerine yoğunlaştırmıştır. NGCU önerisinde genel olarak zaman serileri kullanarak tahminleme yapmıştır. Makalede deneysel veri seti olarak üç farklı veri karakteristiği seçilmiştir. Deneysel sonuçlar, hava kalitesi veri seti, Hang Seng endeksi veri seti ve altın vadeli işlem fiyat veri seti üzerinde yapılmıştır. Farklı veri setlerinde farklı modellerin başarıları karşılaştırıldığında her bir veri setinde farklı sıralamalar olmakla birlikte genel olarak RNN 'in LSTM 'e yakın bir başarı sağladığı

ve NGCU 'nın bu iki modele göre daha başarılı tahmin ürettiği sonucuna ulaşılmıştır. Önerilen NGCU modelinin diğer modellere göre daha başarılı olduğu gösterilmektedir.

2.3. Uzun Kısa Vadeli Hafıza (LSTM)

Verilerin RNN 'e uzun periyotlu olarak verilmesi durumunda veride geçmişe bağımlılık nedeniyle, model eğitiminde gradyan kaybolması ve patlama sorunları ortaya çıkmaktadır. LSTM, hafızaya sahip olması nedeniyle, RNN 'nin eğitim sürecinde gradyan kaybolması ve patlama problemlerini iyi bir şekilde hafifletebilir (Gers, Schmidhuber ve Cummins, 2000). LSTM, unutmaya kapısı, giriş kapısı ve çıkış kapısı yoluyla geçmiş verilerin ve giriş verilerinin silinmesini ve korunmasını belirlemek için kapı kontrol teknolojisini kullanır. LSTM 'nin önemli bir çeşidi (Cho vd., 2014) tarafından oluşturulan ve unutmaya kapısı ile giriş kapısını bir güncelleme kapısında birleştiren GRU 'dur. LSTM ile karşılaştırıldığında, GRU parametrelerinin sayısı azdır ve yapısı daha basittir.

LSTM ile ilgili zaman serileri konusunda birçok çalışma bulunmaktadır. Bu çalışmalar genellikle sadece LSTM modelini kullanmaya yönelik değildir. LSTM modeli ile diğer modellerin iç içe kullanımı şeklinde olmuştur. Örneğin (Mejia vd., 2022) makalede, önerilen mimari, CNN ve LSTM katmanlarını, iki kanallı bir analiz filterbank 'a benzer bir yapıda birleştirmektedir. Katmanların ilk elemanı, sinyalin zamansal bağımlılıklarını bulabilen LSTM ve takiben bir CNN katmanıdır. Son olarak, bir tahmin elde etmek için kanallar toplanır. Bu metotla belli bir miktar başarı elde edilmiştir. Gürültülü olmayan veride LSTM ve önerilen model aynı oranda başarıya ulaşmış, gürültülü veride ise önerilen model LSTM 'e göre daha başarılı olmuştur.

Bir başka makalede (Luo vd., 2021) ise yine hem LSTM hem de XGBoost algoritmaları uygulanarak zaman serisi verileri olarak günlük olarak doğrulanmış virüslü vaka tahmin modelleri oluşturulmuştur. MAE, MSE, MAPE ile doğruluk testleri yapılmış, LSTM ve XGBoost algoritmaları sırasıyla 0,0232 ve 0,0721 başarı elde edilmiştir. Ancak burada ele alınan örnek verinin küçüklüğü başarının büyük veride başarılı olacağı kuşkusu uyandırmaktadır.

ÜÇÜNCÜ BÖLÜM

YÖNTEM

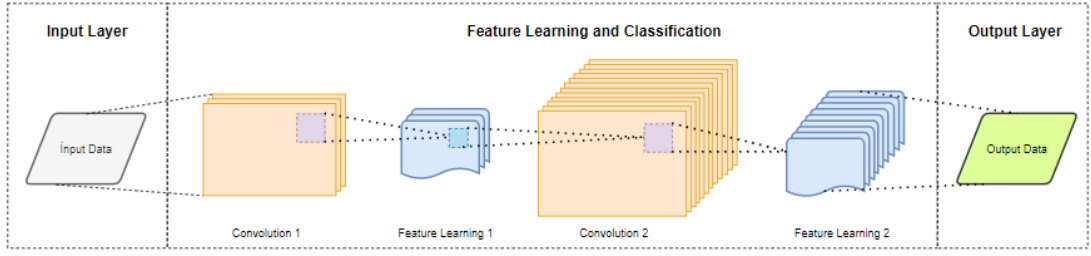
Bilimsel arařtırmalarda genel olarak iki tür tahmin vardır: nitel ve nicel. Niteliksel tahmin, çoğunlukla alanında deneyim sahibi uzmanların yorumlarına dayanır. Nicel tahmin, kabul edilmiş ve kanıtlanmış matematiksel fonksiyonlara dayanmaktadır.

Bu makalede ele alınan kesinti değerleri Şekil 5.2 de görüldüğü üzere dönemsel anlamda birer kesikli zaman serisi niteliğindedir. Zaman Serileri ilgi odağı olan değerlerin belirli zaman aralıkları içerisinde, dönemsel olarak, art arda (kronolojik olarak) gelen değerler bütünüdür. Belli periyotlarda meydana gelen sıralı dizilerden oluşan kayıtlardır (Hamilton, 2020).

Bu anlamda derin öğrenmenin en gelişmiş algoritmaları olan ve zaman serileri üzerinde başarılı tahminleme yapılabilen modelleri CNN, RNN ve RNN 'in bir alt modeli olan LSTM kullanılacaktır (Hameed vd., 2020).

3.1. Konvolüsyonel Sinir Ağları (CNN)

Çok Katmanlı Algılayıcıların (MLP) Konvolüsyonel bir türü sinir ağları (CNN) olarak ortaya çıkar. Görsel bir bütün olarak düşünüldüğünde, görselin kenarlarına basit hücreler, tüm görsele görme merkezi, basit hücreler, kenar benzeri özelliklere, karmaşık hücreler ise daha geniş alıcılarla alt bölgelere ayrılmış olduğu düşünülür. Canlıların görme yeteneği örnek alınarak ileri yönlü bir sinir ağı olarak CNN algoritması modellenmiştir. Buradaki bir nöronun kendi uyarı alanından uyarılara verdiği cevap olarak matematiksel konvolüsyon işlemi düşünülebilir (Fukushima ve Miyake, 1982) (Hubel ve Wiesel, 1968) (LeCun vd., 1998).



Şekil 3.1: CNN Genel Mimari

Şekil 3.1’de gösterildiği üzere CNN, sırasıyla alt katman ardından standart çok katmanlı bir sinir ağı gibi bir veya daha fazla tamamen birbirine bağlı katmandan oluşur.

3.1.1. Giriş Katmanı (Input Layer)

Tahminleme yapılacak verinin girişinin alındığı katmandır. Öğrenme verisi olarak girilen veri X giriş değerleri (bağımsız değişkenler) ve y ölçümlenen veri (bağımlı değişken) olarak bu katmanda girişi yapılır. Öğrenme verisinin artışı başarıyı arttırabileceği gibi modelin çalışma süresini de uzatacaktır.

3.1.2. Konvolüsyon (Evrışim) Katmanı (Convulation Layer)

Bu katmanda CNN başarısı için girilen özellikler arasında tahminlemenin başarısını arttıran özelliklerin belirlenmesi sağlanır. Her bölge için girdiler alınır ve bir ağırlık matrisi ile çarpılır sonrasında eşik değeri ilave edilir.

Zaman serisi olarak alacağımız bir veride konvolüsyon hesaplamaları (Goodfellow, Bengio ve Courville, 2016) ‘da detaylı bir şekilde incelenmiştir.

Bir uzay gemisinin lokasyon verilerini her bir t anı için (saniyelik olabilir) bir sensör ile aldığımızı varsayalım. Bu durumda t zaman, $x(t)$ ise t anındaki lokasyon verisi olsun. Sensörler gerçek hayatta her zaman temiz veri göndermeyebilir, kirli, gürültülü veri gönderiyor olabilir, bu verileri normalize etmek (yumuşatmak) için birbirine yakın birkaç ölçümün ortalaması alınacaktır. Bu nedenle ağırlıklı ortalaması alınacaktır. a bir ölçümün önceki değerleri olmak üzere $w(a)$ ağırlık fonksiyonumuz ve w kernel olarak tanımlanmak üzere

$$s(t) = \int x(a)w(t - a)da \quad (3.1)$$

3.1 denkleminde s düzeltilmiş tahmin (smoothed estimate) fonksiyonu elde edilir ve buna konvolüsyon işlemi denilir. Konvolüsyon işlemi bir yıldız işlemiyle ifade edelim ve 3.2 denklemindeki gibi gösterelim:

$$s(t) = (x * w)(t) \quad (3.2)$$

İşte tam burada çıktımız s (output) özellik eşleştirme (feature map) tir. Periyodik olarak sürekli ve düzenli ölçüm aldığımızı varsayarsak ayrık konvolüsyon, 3.3 denklemindeki gibi tanımlanır.

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t - a) \quad (3.3)$$

Burada x ve w değerleri her bir t zamanı için sayı (integer) olarak geldiği varsayılmıştır. Buraya kadar tüm varsayımlar tek boyutlu bir dizi olarak hesaplanmıştır. Girdi (input) değerlerimiz 2 boyutlu (2D) bir görüntü I olması durumunda, K 2 boyutlu bir çekirdek (kernel) olmak üzere denkleminiz 3.4 deki gibi olacaktır:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n) K(i - m, j - n) \quad (3.4)$$

Matematik kuralları gereği denkleminiz 3.5 denklemindeki gibi yazmamız eşitliği bozmayacaktır:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (3.5)$$

Bu makalede inceleyeceğimiz veri zaman serisi olduğundan CNN Conv1D, bir boyutlu olarak test edilecektir.

3.1.3. Havuz Katmanı (Pooling Layer)

Havuz katmanına hesaplama bölgesi de denilebilir. Bu katmanda özellik ekleme ve

çıkarma yapılarak modelin başarısı tekrar test edilir. Modelin başarısı arttırılana kadar devam ettirilebilir. Örneğin Max-Pool filtrenin uygulandığı bölgede maksimum değerleri seçme işlemi yapan bir havuzlama işlemidir (Salomon ve Bianca, 2018).

3.1.4. Unutma Katmanı (Dropout Layer)

Modele, sinir ağlarındaki ezberi bozmak için uygulanan bir katmandır. Öğrenme sırasında rastgele seçilen nöronların silinmesi ile yapılır. Böylece öğrenme başarısı artar. (Verma ve Pal, 2016)

CNN modellerinin, görüntü işlemenin haricinde, genellikle finansal veriler içeren zaman serileri verileri gibi bir olay sırasında alınan ölçümler ardışık zaman dilimi içinde uygun bir sırada düzenlenmiş verileri içeren istatistiksel veri analizlerinde ya da çeşitli Doğal Dil İşleme (NLP) ile ilgili problemlerin çözümü için kullanılmıştır. Anlama bakılarak yapılan ayrıştırmada (Grefenstette vd., 2014), arama sorgusu elde etmede (Shen vd., 2014), cümle oluşturmada (Kalchbrenner, Grefenstette ve Blunsom, 2014), sınıflandırma (Shin vd., 2018), tahmin problemlerinde (Collobert ve Weston, 2008) çok olumlu sonuçlar elde edilmiştir. İlaç incelemelerinde de CNN algoritmaları kullanılmıştır. İlaç formülasyonunda geliştirilen ilk derin sinir ağı AtomNet olmuştur (Wallach, Dzamba ve Heifets, 2015). Yeni biyomolekülleri keşfedebilmek için, sistem öğrenmesinde kimyasal tepkimelerin 3 boyutlu temsilleri kullanılmış, bu biyomoleküller Ebola ve skleroz gibi hastalıklarda kullanılmıştır (Yosinski vd., 2015). Bazı oyunların için de yine CNN kullanılmış, geleneksel yöntemlerle geliştirilen algoritmalar, önceden eğitilmiş çok katmanlı bir CNN modeli oyunların birçoğunu da yenmiştir (Maddison vd., 2014).

CNN normalde görüntü işleme için 2 boyutlu ızgara (2D grid) bir veri girdisi ile çalışmaktadır. Ancak zaman serileri gibi modeller için de 1D ızgara (1D grid) olarak modellenebilir (Hameed vd., 2020). Bu makalede incelenen veri kesinti verisi yani bir zaman serisi olması nedeniyle CNN modelimizi 1D olarak kurgulayacağız.

3.2. Tekrarlayan Sinir Ağı (RNN)

Tekrarlayan Sinir Ağı (RNN), 1982'de Saratha Sathasivam tarafından önerilen Hopfield ağından türetilmiştir (Hopfield, 1982). Zaman serileri gibi sıralı verileri

işlemek için bir sinir ağı (neural network) 'nin bir alt çözümüdür. Geleneksel makine öğrenimi algoritması, büyük ölçüde manuel özellik çıkarmaya dayanır, bu da görüntü tanıma, konuşma tanıma ve doğal dil işlemede darboğaz yapar (Wei vd., 2021).

Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN), adında da anlaşılacağı üzere tekrarlı bir şekilde nöronlar arasında bağlantıların olduğu bir yapay sinir ağı sınıfıdır. Zaman serisi şeklinde dinamik bir davranış sergilenmiş ve bir nöral ağ oluşumu sağlanmıştır (Şeker, Diri ve Balık, 2017). İleri beslemeli sinir ağların aksine, RNN 'ler kendi giriş belleğini girdilerin rastgele dizilerini işlemek için kullanabilmektedirler (Mikolov vd., 2010). Tekrarlayan sinir ağındaki (RNN) ana düşünce bilgileri sıralı bir şekilde kullanılmaktadır. Görüntü işleminin incelendiği verilerde girdi veya çıktı verilerinin bağımsız olduğunu öngörülmektedir. Ancak zaman serisi gibi değişkenlik içeren NLP gibi alanlar için bu durum mümkün değildir. Çünkü bir cümle içinde bir sonraki kelimeyi tahmin etmek için, o üzerinde bulunduğu kelimedenden önce hangi sözcüklerin geldiğini tutmak gerekmektedir. RNN algoritmasının yinelenen olarak anılmasının sebebi, bir dizinin her ögesi için (zaman sıralı verilerdeki gibi) aynı görevi önceki çıktılara bağlı olarak yerine getirmesi ve hatırlamasıdır, 3.8 denklemi. Örneğin dinamik bir sistem için 3.6 denklemini (Goodfellow, Bengio ve Courville, 2016) ele alalım:

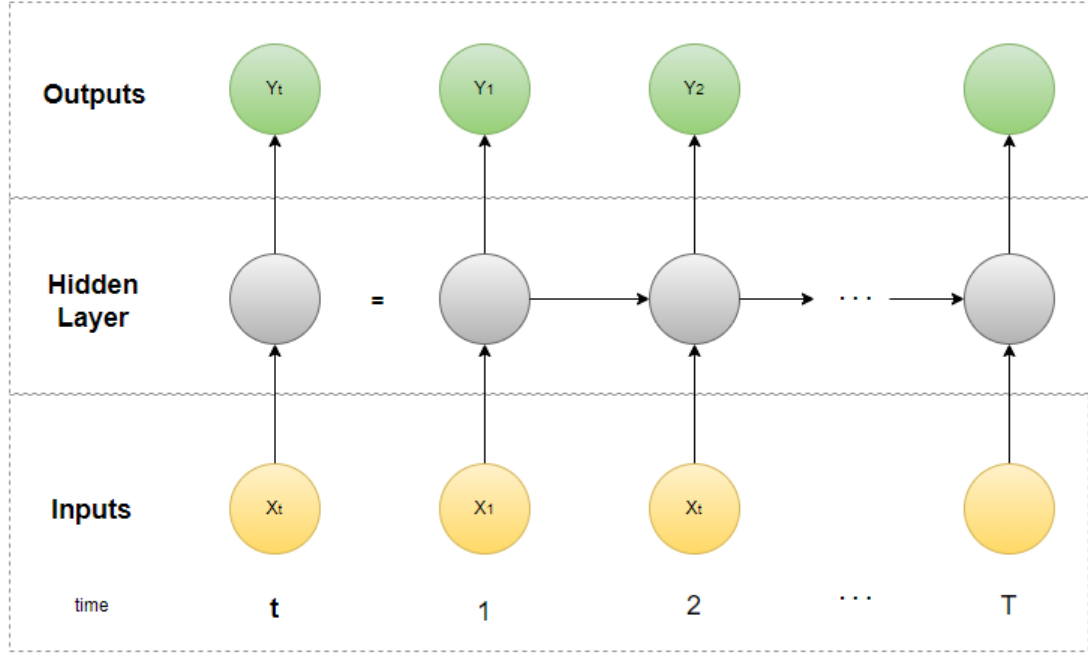
$$s^{(t)} = f(s^{(t-1)}; \theta) \quad (3.6)$$

$s^{(t)}$ sistem durumu, t zaman olduğuna göre $t - 1$ gibi bir zamanda denklemin tekrarlı (recurrent ya da recursive) olduğu görülüyor. Örneğin 3 adımlı bir zaman serisi için 3.7 denklemi meydana gelecektir.

$$\begin{aligned} s^{(3)} &= f(s^{(2)}; \theta) \text{ ve } s^{(2)} = f(s^{(1)}; \theta) \\ \text{ise } s^{(3)} &= f(f(s^{(1)}; \theta); \theta) \end{aligned} \quad (3.7)$$

Şekil 3.2'de görüldüğü üzere birçok tekrarlı (recurrent) sinir ağı, gizli (hidden) değerlerini tanımlamak için 3.6 denklemindeki gibi bir denklem kullanır. Bu durumda h hidden değeri olmak üzere denklemi yeniden yazalım, bir görüntü ya da zaman serisinin değerleri olarak $x^{(1)} \dots x^{(t)}$ dizisi olsun

$$h^{(t)} = f(h^{(t-1)}, x^{(t)}; \theta) \quad (3.8)$$



Şekil 3.2: RNN Genel Akış Mimarisi

RNN zaman serileri ve görüntü işleme dışında başka alanlarda da kullanılmıştır. (Graves ve Jaitly, 2014) çalışmasında, ses verilerinin fonetik incelemesi yapılmadan direk metin yazan bir RNN tabanlı konuşma yazım uygulaması geliştirmiştir. Diğer bir çalışmada RNN ve CNN birlikte kullanılarak etiketlenmemiş görüntüleri tanımlamak için kullanılmışlardır. Birleştirilmiş model, görüntüdeki nesnelere tanımlamanın yanında, tanımlayıcıların görüntülerdeki konumlarını bile bulmayı başarmıştır (Karpathy ve Fei-Fei, 2015).

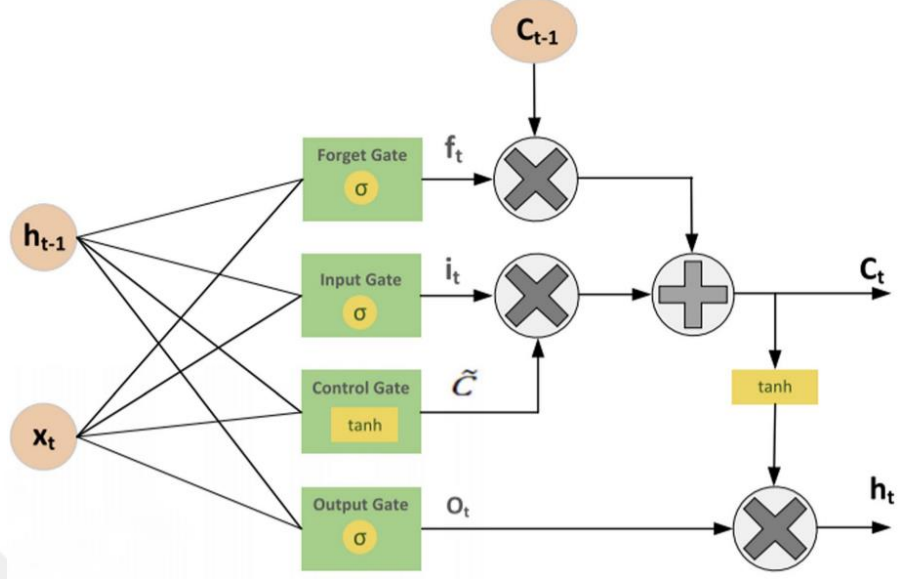
3.3. Uzun Kısa Vadeli Hafıza Ağları (LSTM)

RNN mimarisi geçmiş verilerin kullanımı üzerine tasarlanmıştır. Örneğin “Yemek kaşık ile yenir” cümlesinde “kaşık” kelimesini tahmin etmek kolaydır. Ancak veri setinin sıralı verileri arasında mesafe arttığında RNN modelinin önceki verilere ulaşması oldukça zordur. Örneğin, “Türkiye ‘de doğdum.... Türkçe ‘yi akıcı konuşurum.” cümlesinde “Türkçe” ifadesini tahmin ederken, mevcut cümleyi analiz ederek tahmin edilecek kelime bir dil adı olacağını tahmin edilebilir, fakat doğru kelimenin “Türkçe” olduğunu tahmin etmek için, cümle verisinin kelimelerini hafızada tutması ve geri yönlü gidilmesi gerekir. Teorik olarak “uzun-vadeli

bağımlılıklar”, gerçekte çözüm olmadığı görülmüştür (Bengio, Simard ve Frasconi, 1994). Bu soruna bir çözüm bulmak için, veride geri gidilmesini, dolayısıyla hafızda tutulmasını sağlayan ve bir RNN türü olan Uzun Kısa Vadeli Bellek (LSTM) ağları Hochreiter ve Schmidhuber tarafından 1997 yılında önerilmiştir (Hochreiter ve Schmidhuber, 1997). LSTM mimarisi giriş, unutma ve çıkış kapıları olacak şekilde 3 kapı, bununla beraber çıkış aktivasyon fonksiyonu, blok girişi, gözetleme (peephole) ve Sabit Hata Döngüsü bağlantılarına sahiptir (Greff vd., 2016). Blokların ürettiği çıktı tekrarlı bir şekilde bloğun girişine ve tüm kapılarına bağlanır. Mimari ilk geliştirildiğinde unutma kapıları ve gözetleme bağlantıları önerilmemişti. LSTM ‘de unutma kapısının amacı durumu sıfırlamak için (Gers vd., 2000), gözetleme bağlantıları ise öğrenmeyi kolaylaştırmak için eklenmiştir (Gers ve Schmidhuber, 2000). Bu yapısından dolayı konuşma ve metin işlemlerinde LSTM oldukça isabetli sonuçlar üretmiştir. Özellikle ses sınıflandırması çalışmalarında, oldukça zorlu koşullarda, farklı lehçelerde, kapsamlı kelime hazinesinin olduğu ortamlarda büyük başarılar sağlanmıştır (Graves ve Schmidhuber, 2005). Uygun parametreler ile uçtan uca eğitimden geçen başka bir LSTM yaklaşımı ile aynı veri seti üzerinde büyük başarı oranına ulaşılmıştır (Graves, Mohamed ve Hinton, 2013). (Fernández, Graves ve Schmidhuber, 2007) ise LSTM ile geliştirdiği önerisinde geniş kapsamlı konuşma verileri barındıran Verbmobil veri setinde inceleme yapılmış, anahtar kelime tahmininde 84,5 doğruluk ile başarı elde edilmiştir. İnsan eylemlerini öğrenme verisi kullanmadan sınıflandırabilen Baccouche’nin önerisinde CNN ve LSTM uygulaması otomatikleştirilmiş ve model başarılı olmuştur (Baccouche vd., 2011). Bir diğer başarılı LSTM önerisi ise müzik beste üretimidir. Nota tahmini RNN ile mümkün olabilir ancak dinlenebilir doğal bir beste yapılamamıştır. Ancak bu çalışmada LSTM ‘nin uzun vadeli öğrenme becerisi ile blues türü üzerinde yapılan çalışmada, öğrenmenin başarılı olduğu, yeni besteler oluşturabildiği gözlemlenmiştir (Eck ve Schmidhuber, 2002). Bağımsız protein homolojisinin tespit edilmesi (Hochreiter, Heusel ve Obermayer, 2007) kalp cerrahisinde kullanılmak üzere düğümleri bağlamayı öğrenen modelin tasarımı (Mayer vd., 2008), karmaşık dillerin öğrenimi (Schmidhuber, Gers ve Eck, 2002), (Graves ve Schmidhuber, 2008), el yazısı tanıma (Smolensky, 1986) gibi birçok alanda da LSTM algoritmalarından faydalanılmıştır.

Derin öğrenmenin bu mimarileri çok farklı alanlarda kullanılmaktadır. Bu makalede özellikle büyük veri üzerinde çalışarak başarısını gözlemlemiş olacağız. Burada daha

çok finansal işlemler için kullanılan zaman serilerine örnek bir çalışma ortaya koyacağız.



Şekil 3.3: Temel LSTM Yapısı

Sigmoid olarak ifade edilen fonksiyonda W ağırlık matrisi, σ aktivasyon fonksiyonudur. h_{t-1} bir önceki LSTM bloğunun çıktısını ifade eder, b ise ilgili kapılar için bias olarak alınır. Son olarak, x_t ise t zamanı için giriş (input) değeridir. Giriş kapısı i_t 3.9 denklemindeki gibi hesaplanır.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (3.9)$$

3.9 denklemi ile hücreye iletilebilecek bilgileri seçilir. Bir önceki belleğin girdi tarafından unutulacak olan verisi aşağıdaki unutma kapısı 3.10 denklemi ile karar belirlenir,

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (3.10)$$

3.12 denkleminde verilen kontrol kapısı C_t , tanh fonksiyonu kullanılarak değerleri -1 ile 1 aralığında olacak şekilde normalleştiren formül ile hücrelerdeki güncellemeleri kontrol eder. 3.11 denkleminde \tilde{C} ise t anında hücre durumunu verir.

$$\tilde{C} = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3.11)$$

$$C_t = f_t * C_{t-1} + i_t \quad (3.12)$$

3.13 denkleminde verilen o_t çıkış (output) katmanı hem gizli katman h_{t-1} hem de çıkış değerlerini verir

$$\begin{aligned} o_t &= \sigma(W_o * [h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \quad (3.13)$$

3.4. Donanım ve Yazılım Gereksinimleri

İşletim sistemi Windows 10 olarak kurulu olacaktır. 64-bit, 8th generation, 4 core i7 CPU ve 16GB RAM donanım ile çalışılacaktır. Kodlama Python 3.8 sürümünde standart kütüphaneler (pandas, numpy) kullanılacak ve spyder 5.1 editörü ile yapılacaktır. Model geliştirmeleri için Tensorflow 2.3 sürümü, Keras 2.4 sürümü, grafik çıktıları için Plotly 5.1 sürümü ve doğrulama, hata tespitleri için Scikit-learn 1.0 sürümü kütüphaneleri kullanılacaktır.

DÖRDÜNCÜ BÖLÜM

VERİ KÜMESİ

4.1. Özelliklerin Önemi

Veri analizini doğru yapabilmek için öncelikle iş süreçlerinin ve karakteristiğinin iyi anlaşılması gerekir. Veri bu sürecin ilerleyişi ile oluşacağından veriyi anlamak ve doğru yorumlamak için iş sürecini doğru anlamak en öncelikli kuraldır.

İncelediğimiz dağıtım bölgesinde elektrik kullanımı mesken ve sanayinin yanında tarım amaçlı olarak da kullanılmaktadır. Yazları çok sıcak geçen bir iklime sahiptir. Sıcaklık artışı ve düşüşü ile birlikte soğutma ve ısınma amaçlı elektrik kullanımı artmakta, bu şebeke üzerinde ek yük oluşturmakta ve arızalara ve dolayısıyla kesintilere sebebiyet vermektedir. Elektrik kullanım amacı her ilde değişmektedir. Şanlıurfa ilinde tarım amaçlı kullanım gerçekleştiğinden yazları, özellikle yağışın az olduğu dönemde kullanım yüksek miktarda gerçekleşmektedir. Batman ilinde ise kullanım daha çok ısınma amaçlı gerçekleştiğinden kışın kullanım artmakta dolayısıyla kesintiler yüksek miktarda gerçekleşmektedir. Kaçak kullanımın en düşük olduğu Siirt ilinde ise kullanım tüm mevsimlerde sabit olarak gerçekleşmektedir. Bundan dolayı incelemeyi il düzeyinde düşünmek daha doğru sonuç verecektir.

Tablo 4.3 ve Tablo 4.4 'de görüldüğü üzere bölge geneli olarak düşünüldüğünde oldukça önemli miktar kesintiler oluşmaktadır, birçok abone etkilenmektedir.

Meteoroloji koşullarının da yine incelemede etkisi olacaktır. Rüzgâr hızının yüksekliğine bağlı olarak elektrik şebekesi üzerinde fiziksel etkisi oluşmakta ve bu nedenle kesintileri oluşmaktadır. Bununla birlikte incelediğimiz dağıtım bölgesinin bazı illerinde elektrik tarım bölgelerinin sulanmasında da kullanılmaktadır. Yağış miktarının az olduğu zamanlarda elektrik kullanımı artmakta bu durumda dağıtım şebekesinde yine yük oluşturmaktadır. Bu nedenle kesintinin bulunduğu il ve yağış miktarı da kesinti oluşumunda önemli bilgilerdir.

Şebeke üzerinde belirli periyotlarda planlı bakımlar yapılmaktadır. Bakımların planlı olması nedeniyle elektrik kesintileri de planlı olmaktadır. Elektrik kesintilerinin planlı olması ve belirli aralıklarda yapılıyor olması tahmin modelimizde dikkate almamız gereken bir bilgidir.

Bu nedenle verimizde, kesintinin oluřtuđu tarih, il, toplam kesinti sayısı, planlı kesinti sayısı, plansız kesinti sayısı, hava sıcaklıđı, yađıř miktarı, rüzgâr hızı dikkate alınması gereken özelliklerdir.

4.2. Verinin Elde Ediliři

Kesinti verileri dađıtım řirketleri tarafından Enerji Piyasası Denetleme Kurumu (EPDK) 'a zorunlu olarak paylaşılan verilerdir. Bu veriler Dicle Elektrik Dađıtım A.ř. web sayfasında da yayınlanmaktadır (Hizmet Kalite Göstergeleri, 2022).

2015 – 2021 yılları arasındaki 2.426.775 satır veri içeren tüm kesintiler için günlük olarak elde edilmiřtir. Kesinti verileri 2015 – 2018 yılları arasında manuel olarak tutulan arıza çizelgelerinde kayıtlı idi. Elektronik ortama geçirilmesi için ek giriřler yapılmaktaydı. 2018 yılı ve sonrası veriler Saya Yönetim Sistemi (SYS) denilen ve Dicle Elektrik Dađıtım A.ř. (DEDAř) tarafından kullanılan uygulamada kaydedilmektedir. Elde edilen tüm veriler toplam 2,5 milyon kesintiyi içermektedir. 2022 yılı için tahminlemenin yapılması amaçlanmaktadır.

SYS uygulaması ile sahada arıza, elektrik kesme, elektrik açma, bađlama, bakım ve onarım, bađlantı ile ilgili iřler, abonenin kaçak ve diđer kontrolleri gibi iřlemler iř emri olarak takip edilmektedir. İř emri ile ilgili iřlem bařlatılırken kesinti bilgileri de girilmektedir. Bu kesinti bilgileri ile günlük olarak bölge, elektrik kesinti sebebi, elektrik kesinti seviyesi (orta gelirim, alçak gelirim), kesinti öncesi aboneye verilen bilgiye, kesintinin aboneye bildirilmiř olması, kesintinin aboneye bildirilmemiř yani bildirimsiz olmasına göre birçok veri saklanmaktadır. Bundan dolayı temin ettiđimiz veri her bir kesinti için detaylı özellikleri içeren bir satır řeklinde olacaktır Tablo 4.2.

Örnek kesinti incelemesi ve tahmini DEDAř bölgesinde yer alan Diyarbakır ili ele alınarak ve 2015 – 2021 yılları aralıđı için yapılacaktır. Daha sonra kabul edilebilir oranda elde edilecek bařarı sonrasında bu örnek çalıřma diđer illere uygulanabilecektir.

Ana konumuz olan ve tahmin edilen kesintilerin birçok sebebi bulunmaktadır. Bu sebepler kesinti esnasında giriři yapılan bilgiye göre belirlenir, kesinti sebeplerinin sayı dađılımı Tablo 4.1 'de görüldüđu üzere ayırt edilmektedir.

Tablo 4.1: Kesinti Sebeplerine Göre Sayı Dağılımı (2018 - 2021 Yılları)

Bildirime Göre (5D) (Kesinti Sebebi)	Kesinti Sayısı
Mücbir Sebep	1.110.103
Şebeke İşletmecisi	298.654
Dışsal	1.526
Güvenlik	254
Toplam	1.410.537

4.2.1. Elektrik Kesinti Verileri

Elektrik Dağıtım esnasında oluşan elektrik kesintileri, Elektrik Dağıtım ve Perakende Satışına İlişkin Hizmet Kalitesi Yönetmeliği 'ne uygun olarak dağıtım şirketleri tarafından kayıt edilmek zorundadır (Elektrik Dağıtım ve Perakende Satışına İlişkin Hizmet Kalitesi Yönetmeliği, 2022). Bu veriler aylık olarak her ay sonu ve yıllık olarak ise takip eden yıl içinde 31 Mart tarihine kadar Enerji Piyasası Denetleme Kurumu (EPDK) 'a sunulmakta, aynı zamanda dağıtım şirketlerinin web sitelerinde yayımlanmaktadır. Kesinti verileri EPDK 'nın yönetmelikte belirttiği çizelgeye, Tablo 4.2'e, uygun olarak verilmek zorundadır.

Tablo 4.2: Kesinti Verileri Deseni (Tablo-1 Verileri)

KOD NO (1)	KADEME(2)	YERİ (3)			KESİNTİNİN SINIFI (5)	KESİNTİ BAŞLAMA TARİHİ VE ZAMANI (6)	KESİNTİ SONA ERME TARİHİ VE ZAMANI (7)	KESİNTİ SÜRESİ (SAAT) (8)=(7)-(6)	ETKİLENEN KULLANICI SAYISI (9)		TOPLAM ETKİLENME SÜRESİ (10)	
		İL (3A)	İLÇE (3B)	ŞEBEKE UNSURU (3C)					İMAR ALANI İÇİ	İMAR ALANI DIŞI	İMAR ALANI İÇİ	İMAR ALANI DIŞI
					KAYNAĞA GÖRE (5A)			OG (9A)		OG(10A)=(9A)X(8)		
					SÜREYE GÖRE (5B)			AG (9B)		AG(10B)=(9B)X(8)		
					SEBEBE GÖRE (5C)			OG (9C)		OG(10C)=(9C)X(8)		
					BİLDİRİME GÖRE 5D			AG (9D)		AG(10A)=(9D)X(8)		

Tablo 4.3: Yıllara Göre Kesinti Başına Ortalama Etkilenen Abone Sayıları

İl	YIL			
	2018	2019	2020	2021
BATMAN	199	471	292	221
DİYARBAKIR	271	379	393	317
MARDİN	261	723	474	357
SİİRT	175	544	438	183
ŞANLIURFA	192	403	371	376
ŞIRNAK	133	244	219	179

Tablo 4.4: Yıllara Göre İl Düzeyinde Kesinti Sayıları

İl	YIL			
	2018	2019	2020	2021
ŞANLIURFA	139.336	111.649	138.218	108.116
DİYARBAKIR	82.753	70.577	96.457	71.658
MARDİN	63.383	64.179	58.309	41.008
ŞIRNAK	52.116	38.974	46.197	34.287
BATMAN	33.871	28.755	41.386	26.576
SİİRT	17.351	13.213	17.436	14.732
Genel Toplam	388.810	327.347	398.003	296.377

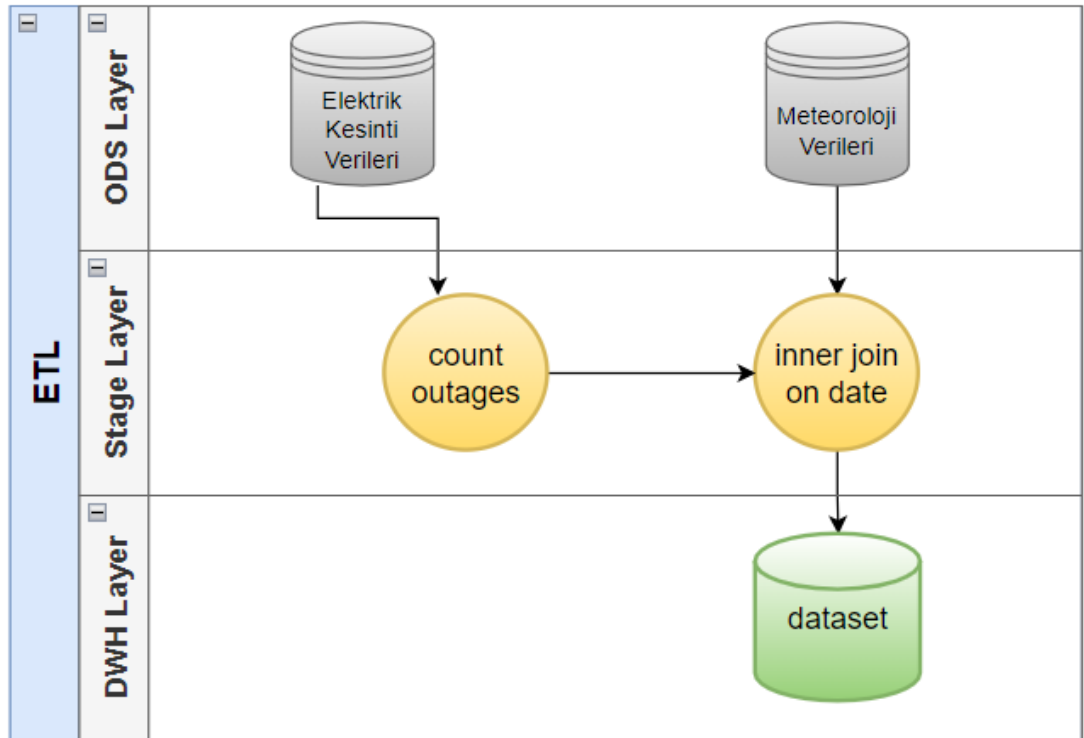
4.2.2. Meteoroloji Verileri

Tahmin çalışmasında özellik (feature) olarak hava durumu verileri de kullanılacaktır. Bu nedenle hava durumu verileri meteoroloji (Meteoroloji Veri Bilgi ve Sunum Sistemi, 2022) sayfasından elde edilmiştir. Buna göre veri deseni Tablo 4.5 deki gibidir. Meteoroloji verileri veri bütünlüğü bakımından 2015-2021 yılları arası verileri içermektedir.

Tablo 4.5: Meteoroloji Verileri - Alınan Özellikler Ve Örnek Verileri

Tarih (10)	Yüksek Sıcaklık (11)	Düşük Sıcaklık (12)	Rüzgâr Hızı (13)	Yağış Miktarı (14)
1.01.2020	10	0	15	0
2.01.2020	5	-1	13	12,9
3.01.2020	5	1	13	2
4.01.2020	7	4	11	1
5.01.2020	5	4	0	6,8

Elde ettiğimiz ham verileri iş zekâsı akış diyagramında Şekil 4.1 gösterildiği üzere klasik veriambarı (DWH) süreci olarak ODS katmanından itibaren ETL süreçlerinden geçirilerek tahmin için gerekli Tablo 4.6 ‘deki özellikler elde edilmiştir.



Şekil 4.1: Ham Veriden ETL Süreci İle Veri Seti Oluşturma Akış Diyagramı

Tablo 4.6: Tahminlemede Girdi Olarak Kullanılacak Kesinti Verisi Özellikleri Ana Veri Seti

Özellik Adı	Veri Kaynağı	Açıklama
İli	İL (3A)	Kesinti iş emrinin oluştuğu il bilgisi
Kesinti Başlangıç Tarihi	KESİNTİ BAŞLAMA TARİHİ (6)	Kesinti tarihi
Yüksek Sıcaklık	EN YÜKSEK SICAKLIK (11)	Meteorolojiden alınan en yüksek sıcaklık değeri
Düşük Sıcaklık	EN DÜŞÜK SICAKLIK (12)	Meteorolojiden alınan en düşük sıcaklık değeri
Rüzgar Hızı	RÜZGAR HIZI (13)	Meteorolojiden alınan rüzgâr hız değeri
Yağış Miktarı	YAĞIŞ MİKTARI (14)	Meteorolojiden alınan yağış miktarı değeri
Toplam Kesinti Sayısı	Aggregated Value	Toplam Kesinti sayısı Count of KOD(1)
Planlı Kesinti Sayısı	Aggregated Value	Planlı bakımdan dolayı oluşan kesinti sayısı Count of “Bildirimli”
Plansız Kesinti Sayısı	Aggregated Value	Arızadan dolayı oluşan kesinti sayısı Count of “Bildirimsiz”

ETL süreçleri ile elde edilen ve Tablo 4.6 de özellikleri belirtilen verimiz için elimizdeki ana veri seti adedi ve özellikleri Tablo 4.7 da gösterilmiştir.

Tablo 4.7: Ana Veri Seti Özellikleri

Tüm Datanın Sayısı	2.103	Veri Tarih Aralığı	01.01.2015 31.11.2021
En Büyük Kesinti Sayısı	369	En Küçük Kesinti Sayısı	1

4.3. Veri Ön İşleme

Kesinti sayılarını tahminleme temelde zaman serileri ile ilgili finansal düzeyde yapılan araştırmalara çok benzemektedir. Zamana bağlı olarak birbiri ardınca gerçekleşen ve genel itibariyle hava durumu (sıcak, yağış, rüzgâr hızı), elektrik kullanım amaçları, o bölgede bulunan nüfus sayısı gibi parametrelere bağlı olarak değişen bir kesinti sayısı

söz konusudur. Kesintinin yaşandığı gün ve bir önceki gün ve hatta ondan önceki günlerde şehrin bulunduğu şartlar birbirine benzerdir. Bundan dolayı kesinti sayıları da o günlerde birbirine benzerlik gösterecektir. Belirlediğimiz özelliklerde önemli bir değişikliğin olması durumunda kesinti sayısında da önemli bir değişiklik gerçekleşecektir.

Kesintinin oluşma nedeni kesinti tahminlemede önemli bir etken olabilir. Bu nedenle kesintinin planlı veya plansız olma durumuna göre iki ayrı inceleme yapılmıştır. Verimizde BİLDİRİME GÖRE (5D) kolonuna göre “Bildirimli” olarak işaretli olan satırlar planlı bakımlar, “Bildirimsiz” olarak işaretli satırlar ise plansız bakımlardır. Planlı bakımlar (ve bundan dolayı meydana gelen kesintiler) belli zamanlarda oluşmaktadır ve doğrusal bir artışı vardır. Bu nedenle planlı kesintiler, plansız kesintiler ve toplam kesintilerin olduğu bir veri seti ve tüm kesintilerin toplam olarak alındığı olduğu ayrı bir veri seti tahminlemeye sokulacaktır. Bununla birlikte bu iki ayrı veri seti CNN, RNN ve LSTM modellerinin kullanımı, başarı oranlarının karşılaştırılması ve en başarılı sonucunun belirlenmesi sağlanacaktır.

Kesinti verisini içeren veri setimizdeki örnek veri Tablo 4.8 da verildiği şekildedir.

Kaynak olarak (Hizmet Kalite Göstergeleri, 2022) sitesinden elde edilen tablolardan alınan veriler veri ambarı ETL süreçlerinden geçirilerek Tablo 4.8 ‘deki ham veri elde edilmiştir. Bu verinin modellemeye sokulabilmesi ve tahminlemeye uygun hale getirilebilmesi için veri ön işleme adımları olarak eksik verilerin doldurulması, gürültülü, tutarsız verilerin düzeltilmesi, kategorik veri dönüşümü gerekmektedir.

Şekil 4.1 ‘deki ETL süreçlerinden geçirilerek elde edilen ham verimiz her bir kesinti başına veri içermektedir. Bu nedenle veriyi modelde input değerlerini algılayabileceği şekilde dönüştürülmelidir. Özellik değerleri olarak iş emri no bazında değil il düzeyinde ve günlük olarak kesinti sayıları inceleneceğinden veriyi il düzeyinde, kesinti sayılarını, planı, plansız ve toplam verecek hale getirilecektir. Ayrıca meteoroloji verilerini gün düzeyinde bu veriler ile birleştirilecek ve Tablo 4.8 ‘deki örnek veri elde edilecektir.

Veriyi modelimizde işlemeyen önce veri ön işleme sürecinden geçirilecektir. Bu noktada verimizde hiçbir özelliğin eksik, tutarsız ya da gürültülü olmaması beklenir. Veriyi incelediğimizde Tablo 4.9 ‘da görüldüğü üzere hiçbir özelliğin eksik bir değere sahip olmadığı görülüyor.

Tablo 4.8: Örnek Kesinti Ham Verisi (Diyarbakır)

Kesinti Başlama Tarihi (6)	Sıcaklık (11)	Rüzgar Hızı (13)	Yağış Miktarı (14)	Kesinti Sayısı	Planlı Kesinti	Plansız Kesinti
2015-01-01	3,0	11	0,2	320	1	319
2015-02-01	10,0	34	3,8	293	5	287
2015-02-02	11,0	28	3,3	330	5	325
2015-02-03	12,0	21	0,0	247	5	242
2015-02-04	13,0	11	0,0	307	5	302
2015-02-05	12,0	11	0,0	284	5	278
2018-04-01	13,0	15	1,0	148	9	139
2018-04-02	15,0	22	1,7	189	2	187
2018-04-03	12,0	24	34,2	178	3	175
2018-04-04	14,0	22	3,3	230	4	226
2018-04-05	17,0	0	2,2	188	11	177
2020-06-01	31,0	22	0,0	250	30	220
2020-06-02	31,0	21	0,0	271	27	244
2020-06-03	29,0	24	0,0	255	28	227
2020-06-04	29,0	26	0,0	282	28	254
2020-06-05	30,0	13	0,0	288	21	267

Tablo 4.9: Null Değeri İçeren Özelliklerin İncelenmesi

Özellik Adı	Kayıp Veri Sayısı
Kesinti Başlama Tarihi (6)	0
Yüksek Sıcaklık (11)	0
Düşük Sıcaklık (12)	0
Rüzgar Hızı (13)	0
Yağış Miktarı (14)	0
Kesinti Sayısı	0
Planlı Kesinti	0
Plansız Kesinti	0

Elde ettiğimiz ana veri setinde tutarsız verilerin tespiti için 4.1 denkleminde tanımı verilen çeyrek (quartiles) uygulanacaktır. Quartiles toplam kesinti sayısı, planlı kesinti sayıları ve plansız kesinti sayıları üzerinde uygulanacaktır. Örnek olması açısından 2021 yılı Diyarbakır ‘da toplam kesinti sayıları üzerinde yaptığımız incelemede Tablo 4.10 ‘den de görüleceği üzere tutarsız olarak 644 adet kesintiye kadar sayıların olduğu verilere rastlanmaktadır. Bu durum Şekil 4.2 ‘de daha net görülmekte olup kesinti sayılarının daha çok 190 – 300 adetlerde yoğunlaştığı, 400 ve yukarı adetlerde sayıların oldukça düştüğü ve sığlaştığı anlaşılmaktadır. Bu veriler anlamsız, aykırı verilerdir ve bunların modelin doğru çalışması ve doğru tahminleme için normalize edilmesi gerekmektedir. Verilerin 0,90 quartile değerine bakıldığında, yani verinin %90 ‘ına kadar bakıldığında, 369 ‘a kadar kesintiye rastlanırken geri kalan kısmında aykırı (uç) olan değerler görülmektedir. Bu değerler de 0,90 quartile ‘e göre düzeltilmiştir. Bu şekilde verilerimiz modellemeye sokulacak hale getirilmiştir. Quartile hesaplamaları 4.1 denklemindeki hesaplamalar ile yapılmıştır.

$$i = cn \frac{qv}{100}$$

olmak üzere,

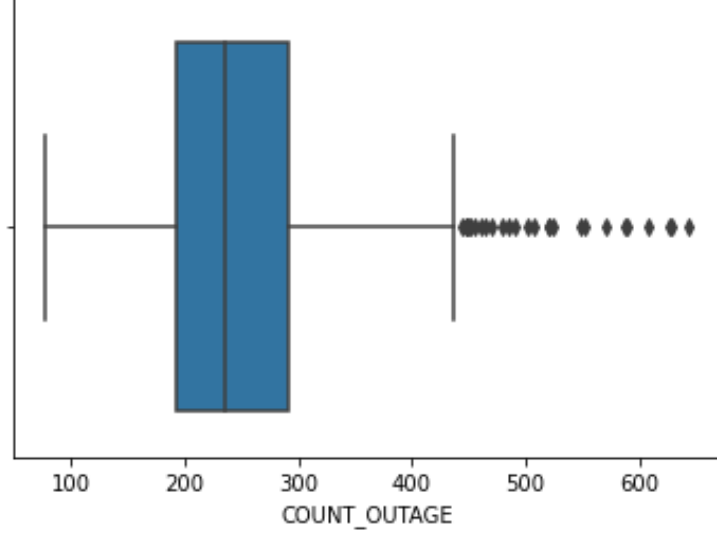
(4.1)

$$q_n = \frac{dt_i + dt_{i+1}}{2}$$

Burada verinin dt: kesinti verisinin bulunduğu tüm veri seti, i: indeks value veri setindeki satır numarası, qv: hesaplatılması istenen oran verisi, cn: veri setindeki veri sayısı, n: quartile sıra no sayıdır.

Tablo 4.10: 2020 -2021 Diyarbakır Aykırı Kesinti Sayılarının Tespiti

Çeyrek No (n) (Quartile No)	Çeyrek Değeri (qv) (Quartile Value)	Veri Değeri (q_n)(Data Value)
1	70	273.4
2	80	308.0
3	90	369.0
4	100	644.0



Şekil 4.2: 2020 – 2021 Diyarbakır Aykırı Kesinti Sayıları Dağılımı

4.4. Öğrenme Veri Seti

Derin öğrenmenin bir gereği olarak öncelikle öğrenim verileri elde edilmeye çalışılmıştır. Öğrenim verilerinin miktarı Diyarbakır ili için tüm veri içerisinde % 65 oranında alınacak ve 1.366 satır veri ile modelin eğitimi gerçekleştirilecektir. Tablo 4.11. Verinin değerlendirilmesi bakımından ele aldığımız verinin tümü Tablo 4.6’de görüldüğü üzere 9 alandan oluşmaktadır. Kesinti sayısını il, kesinti sebebi Tablo 4.1 ‘deki gibi Bildirime Göre (5D) incelenebilir. Bu dokümanda tahminlemede önemli girdi değerleri olarak kesintinin olduğu tarihteki hava sıcaklığı, rüzgâr hızı ve yağış miktarı ile bu ilde gerçekleşen kesinti sayıları öğrenim verisi olarak alınacaktır. Planlı kesinti sayıları ve plansız kesinti sayıları ise karşılaştırmamızda kullanacağımız diğer girdilerimiz olacaktır.

4.5. Test Veri Seti

Öğrenim verisi ile hazırlanacak olan modele sonuçlarını bildiğimiz test verisi gönderilerek elde edilecek sonuçlar incelenecektir. Modelin başarısı düşük olduğu müddetçe yeni özellikler eklenecek ya da modelde kullanılan katmanlarda ve parametrelerinde değişikliğe gidilecektir. Bu aşama, modelin başarısının artırılmasında büyük önem taşımaktadır. Test verisi olarak öğrenim verisinden geriye kalan %35 oranında 737 satır veri test olarak modelde kullanılacaktır Tablo 4.11.

Tablo 4.11: Diyarbakır Öğrenme Ve Test Veri Seti Özellikleri

Eğitim Veri Sayısı	1.366	Test Veri Sayısı	737
Eğitim Verisi En Büyük Değeri	369	Eğitim Verisi En Küçük Değeri	1
Test Verisi En Büyük Değeri	369	Test Verisi En Küçük Değeri	1

Eğitim ve test verimizi planlarken x girdi ve y çıktı değerlerini planlamamız gerekmektedir. Verimizi 5 gün (d) öncesinden (look_back) gelecek şekilde ve 6. Gün ise y değerini verecek şekilde bölümleyeceğiz. Bir sonraki gün aynı döngü devam edecek şekilde veri x girdi ve y çıktı verileri elde edilecek ve veri serisi oluşturulacaktır.

BEŞİNCİ BÖLÜM

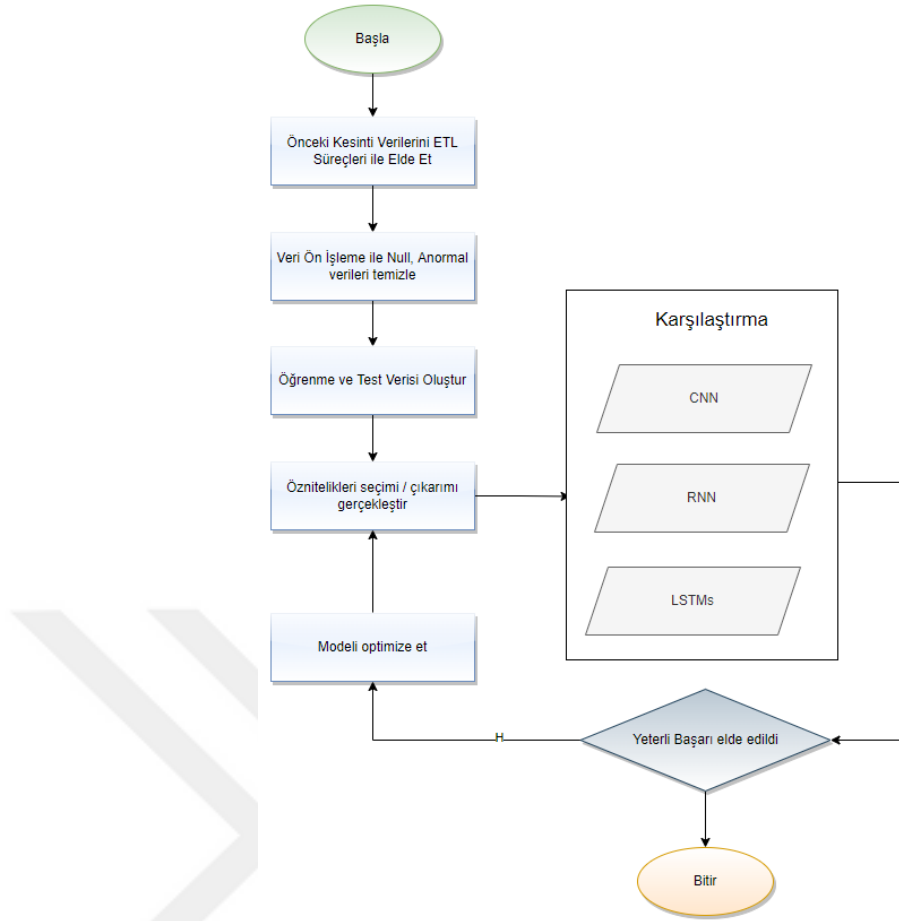
ÖNERİLEN MODEL

Elimizdeki veri zamana bağlı olarak belli periyotlarda (günlük) oluşan bir veridir Şekil 5.2. Bu tür veriler zaman serisi olarak ele alınır. Burada periyot olarak zamanın belli kısmı değişmeyecek şekilde alınır ve tüm kayıtlar için aynı aralıkta tutulur, bu saniyelik, dakikalık, aylık şeklinde olabilir. Bu makalede incelenen veri günlük veridir. Veriler içerisinde toplamı kesinti adedini veren planlı kesinti adedi ve plansız kesinti adedi de ayrı birer özellik olarak modellere sokulacaktır.

Buradaki amacımız en iyi sonucu elde etmek için manuel olarak özellik ekleme ve çıkarmanın özellikle CNN ve RNN 'deki sonucunu görmektir. Planlı kesintiler hâlihazırda zamanı belli olan birer kesinti tipi olduğundan toplam kesinti adedinden ayrıca verilmiş, modelin plansız kesinti adedine odaklanması sağlanmıştır. Bununla beraber sadece kesinti toplamının da modele sokulması ile elde edilen sonuçlar değerlendirilecektir. Böylece sadece kesinti adetlerinin olduğu bir veri seti, kesinti adetleri ve meteoroloji verilerinin olduğu bir veri seti ve kesinti adetleri, meteoroloji verileri ve kesintinin planlı ve planlı olmayan adetleri ayrıca verildiği bir diğer veri seti olmak üzere üç ayrı veri seti üzerinde çalışma yapılacaktır.


Modeli oluştururken başarısını ölçümünde ikinci parametre olarak optimizasyon fonksiyonları kullanılacaktır. Burada adam ile RMSProp optimizasyonları her bir model için ve her bir veri seti için ayrı ayrı uygulanacaktır. Böylece üç ayrı veri seti üzerinde, üç model ve her bir model için iki farklı optimizasyon çalışması önerilecek ve başarıları karşılaştırılacaktır.

Öğrenme verisinin dönemi de dikkate alarak eğitim verisinin miktarının doğru belirlenmesi, eğitim verisinin girdi sayısı (n_loop_back), özellik sayısı ($n_features$) tüm modellerimiz için önemli parametreler olacaktır. Epok sayıları, birim değerleri modelin başarısına göre değiştirilebilecektir.



Şekil 5.1: Elektrik Kesintileri Tahminleme Modeli Akış Şeması

Outage Graph of Diyarbakır



Şekil 5.2: Diyarbakır Kesinti Sayıları Grafiği (2020 Yılı)

5.1.1. CNN Tahmin Modelinin Geliştirilmesi

Elimizdeki veri bir zaman serisi biçimindedir bu nedenle one-dimensional ve 32 filtre uygulanarak modellenecektir. Aktivasyon fonksiyonu olarak relu alınacaktır. Girdi (features) sayımız ise tezimiz gereği değişecektir. Girdi sayısını değiştirerek başarıyı ölçümleyeceğimizden ilk başta girdi sayımız 1 ve look_back sayımız ise 5 olarak alacağız. Daha sonra girdi sayımızı 5 ve 7 olarak alacağız ve çıkan sonuçları değerlendireceğiz.

Tablo 5.1: CNN Model Parametreleri

Parametre (Parameter)	Değer (Value)
Geri Adım Sayısı (n_look_back)	5
Özellik Sayısı (n_features)	1, 5, 7 (Planlı ve Plansız Dahil)
Öğrenme Yüzdesi (training percentage)	0,65
Epok (Epochs)	2000
Birim (units)	32
Çerkidek Boyutu (kernel size)	2
Aktivasyon (activation)	relu
Optimizasyon (optimizer)	Adam, RMSProp
Kayıp (loss)	mse

5.1.2. RNN Tamin Modelinin Geliştirilmesi

CNN modelinden farklı olarak RNN, nöronlardan elde edilen değerleri modele tekrar sokar ve buradaki sonuç ile birlikte nöronda tekrar sonuç üretir. Bununla birlikte RNN daha çok sıralı verilerde daha başarılıdır. RNN modeli Tablo 5.2 de verildiği şekilde kurgulanmıştır. Modelde SimpleRNN algoritması kullanılmış, 25 birim, Dense 1 verilmiştir. Geri adım sayısı tüm tahmin modellerinde 5 olarak verilmiştir. Özellik sayısı yine 1,5,7 olmak üzere 3 farklı veri seti için yine tüm modellerde aynı şekilde girilmiştir. Epok, çekirdek boyutu, kernel sayısı, optimizasyonlar ve kayıp fonksiyonu değerleri tüm modellerde aynı değerler ile test edilmiştir.

Tablo 5.2: RNN Model Parametreleri

Parametre	Değer
Geri Adım Sayısı (n_look_back)	5
Özellik Sayısı (n_features)	1, 5, 7 (Planlı ve Plansız Dahil)
Öğrenme Yüzdesi (training percentage)	0,65
Epok (Epochs)	2000
Birim (units)	25
Çerkidek Boyutu (kernel size)	2
Aktivasyon (activation)	relu
Optimizasyon (optimizer)	Adam, RMSProp
Kayıp (loss)	mean_squared_error

5.1.3. LSTM Tahmin Modelinin Geliştirilmesi

LSTM uygulamasında başarıyı yakalamak için modelde dikkat edilmesi gereken önemli parametreler bulunmaktadır. Bunlar gizli katmandaki nöron sayıları (neuron number or hidden units) ve unutma katmanındır. Unutma katmanınının (dropout) modele eklenmesi ile ezberin bozulması, daha keskin ve doğru sonuçların üretilmesi sağlanır. Burada öğrenme verisinin eksik olması ya da veri biçimine uygun verilmemesi (mevsimsellik içeren veride eksik mevsim öğrenme verisinin verilmesi gibi), yüksek miktarda geri adım sayısının verilmesi (n_loop_back), gereksiz özelliklerin verilmesi (n_features), öğrenme süresini uzatacak şekilde yüksek miktarda döngü sayısının verilmesi gibi durumlar başarıyı olumsuz yönde etkileyebilecek unsurlardır. Bu nedenle parametrelerin dengeli verilmemesi modelin doğru çıktı üretmesini sağlayacaktır. Şekil 5.1 de görüldüğü üzere doğruluk oranı yakalana kadar bu parametrelerin iyileştirilmesi (optimizasyonu) gereklidir.

Tablo 5.3 'de görüldüğü üzere LSTM Modelinin gelişiminde de, diğer modellerle karşılaştırmanın yapılabilmesi için geri adım sayısı, özellik sayıları, epok sayıları, optimizasyonlar için aynı değerler kullanılmıştır. Farklı olarak modelin kendisine özel olarak kullanılan ve başarısında önemli katkıda bulunan unutma ve gizli katmanlar diğer modellerde görülmemektedir.

Tablo 5.3: LSTM Model Parametreleri

Parametre	Değer
Geri Adım Sayısı (n_look_back)	5
Özellik Sayısı (n_features)	1, 5, 7 (Planlı ve Plansız Dahil)
Öğrenme Yüzdesi (training percentage)	0,65
Epok (Epochs)	2000
Gizli Katman 1 (hidden layer 1)	100
Gizli Katman 2 (hidden layer 2)	50
Unutma (dropout)	0,2
Aktivasyon (activation)	relu
Optimizasyon (optimizer)	Adam, RMSProp
Kayıp (loss)	mse

ALTINCI BÖLÜM

DENEYSEL SONUÇLAR

Makalemizde bahsettiğimiz üzere DEDAŞ bölgesinde 2015 – 2021 yılları arasında meydana gelen kesinti verileri kullanılarak gelecekteki kesintilerin bölgesel olarak tahmin etmek için hem adam hem de Karesel Ortalama Hata Olasılığı (RMSPop) optimizasyonları kullanarak CNN, RNN ve RNN tabanlı LSTM modelleri önerilmiştir. Çalışma DEDAŞ bölgesinde gerçekleşen ve resmi olarak EPDK ‘a zorunlu olarak bildirilen veriler ile yürütülmüştür (Hizmet Kalite Göstergeleri, 2022). Ayrıca tahminde kullanılacak meteoroloji verilerini de yine resmi olarak duyurulan meteoroloji sisteminden (Meteoroloji Veri Bilgi ve Sunum Sistemi, 2022) alınmıştır. Şekil 5.2 de belirtildiği üzere verilerimiz zaman serisi halinde ve zamana göre sıralı biçimdedir. Hem kesinti verisi hem de metroloji verilerini modellerimize göndermeden önce ETL süreçlerinden geçirilerek birleştirdik Şekil 4.1. Elde edilen veri setini veri ön işleme işlemlerine tabi tutarak aykırı veri üzerinde düzeltme (normalize) işlemi gerçekleştirdik. Modelin başarısını kuşkusuz doğru özellik seçimi de etkileyecektir. Bundan dolayı özellikleri belirlerken kesintiye olan etkisi gözetilmiş bu kapsamda önce sadece kesinti sayılarının olduğu 1 özellikli veri seti alınmıştır. Ardından meteoroloji verilerinin olduğu 5 özellikli ve bunlara ek olarak planlı ve plansız kesintilerin olduğu 7 özellikli bir veri seti oluşturulmuş ve bu veri setleri üzerinden tahmin yapılmıştır Tablo 4.6. Toplam veri setimiz 2.103 satırdan oluşmuştur. Eğitim verisi %65 ve test verisi %35 ile belirlenmiş ve CNN-Conv1D, RNN-SimpleRNN ve LSTM modelleri ile kesinti tahmin edilmiştir. Her iki veri setinin başarıları adam ve RMSPop optimizasyonları ile değerlendirerek ve karşılaştırılarak en doğru öznelik seçimi sağlanmıştır. Burada adam ve RMSPop gradient iniş (gradient descent) yönetiminin esas alan algoritmalarıdır.

Önerilen modelleri değerlendirirken MAE (6.1 denklemi) ve MSE (6.2 denklemi) metrikleri kullanılmıştır. MAE, gerçek değerler ve tahmin değerleri arasındaki mutlak farkı alarak hatayı belirler:

$$MAE = \frac{1}{n} \sum_{t=1}^n |gerçek(t) - tahmin edilen(t)| \quad (6.1)$$

MSE ise aynı sonucun karesini alarak hatayı belirler:

$$MSE = \frac{1}{n} \sum_{t=1}^n (\text{gerçek}(t) - \text{tahmin edilen}(t))^2 \quad (6.2)$$

6.1. Adam Optimizer Kullanılarak Derin Öğrenme Modelleri ile Tahminleme

Adam, düşük mertebeden momentlerin uyarlanabilir tahminlerine dayalı, stokastik amaç fonksiyonlarının birinci dereceden gradyan tabanlı optimizasyonu için bir algoritmadır. Yöntemin uygulanması basittir, hesaplama açısından verimlidir, az bellek gereksinimine sahiptir, gradyanların çapraz olarak yeniden ölçeklenmesi sağlar. Büyük veri veya çok parametrelili veriler için çok uygundur. Yöntem aynı zamanda hareketli çıktılar ve çok gürültülü ve/veya boşluklu veriler için de uygundur (Kingma ve Ba, 2014).

while θ_t yakınsak olmayacak şekilde do

$$t \leftarrow t + 1$$

$$g_t \leftarrow \nabla_t f_t(\theta_{t-1})$$

$$m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$$

$$v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$$

$$\hat{m}_t \leftarrow m_t / (1 - \beta_1^t)$$

$$\hat{v}_t \leftarrow v_t / (1 - \beta_2^t)$$

$$\theta_t \leftarrow \theta_{t-1} - \alpha \cdot \hat{m}_t / (\sqrt{\hat{v}_t} + \epsilon)$$

(6.3)


end while

return θ_t

Adam fonksiyonu 6.3 denkleminde gösterildiği üzere hesaplanır. Burada α adım sayısı, $\beta_1, \beta_2 \in [0,1)$ anlık tahminler için üslü bozulma oranı, $f(\theta)$ θ parametrelili stokastik fonksiyonu, θ_0 başlangıç vektörü, m_0 ilk moment vektörünü, v_0 ikinci moment vektörünü, t zaman sayacıdır. Makine öğrenme için kullanılan verilerde en iyi sonucu veren değerler $\alpha = 0.001$, $\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$ ve $\epsilon = 10^{-8}$ 'dir.

6.1.1. Toplam Kesinti Sayıları


Sadece kesinti sayılarının girişi ile yaptığımız tahminde kesinti sayıları tahmin edilmiştir. Bu sıradan bir borsa tahmini ile aynıdır. Dokümanda daha önce bahsedildiği üzere veri inceleme Diyarbakır üzerinde yapılmış, model üzerinde yeterli başarı yakalandığında diğer illere uygulanmıştır. Diyarbakır ili üzerinde yapılan inceleme sonuçları şu şekilde gerçekleşmiştir. Tahmin doğruluğunun incelenmesinin kolaylaştırılması için tüm şekillerde sadece tahminin olduğu yere odaklanılmıştır bundan dolayı grafiklerde öğrenme verisinin küçük bir kısmına yer verilmiştir.



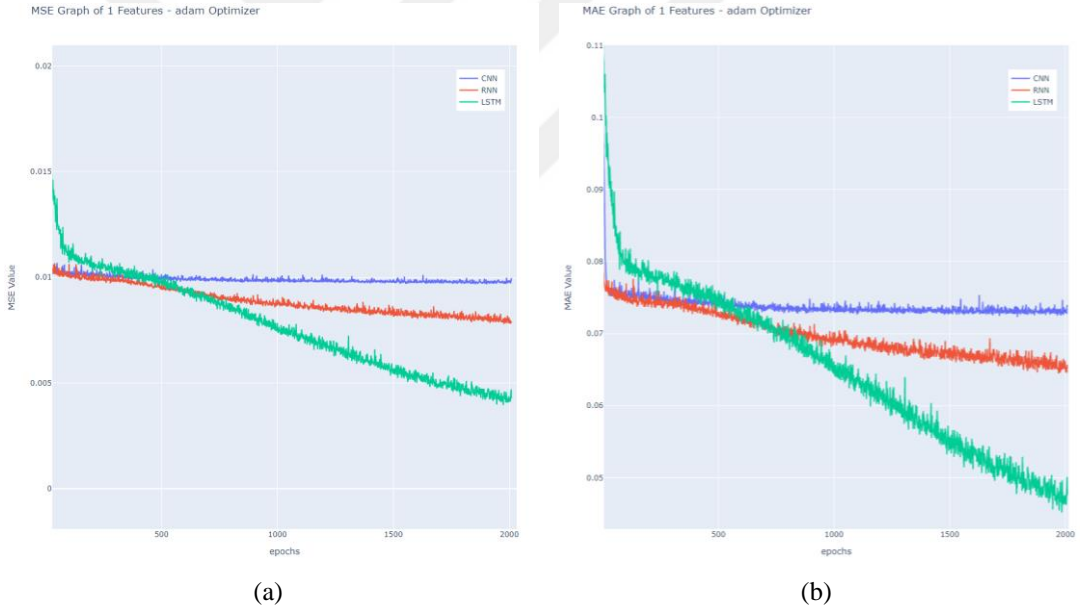
Şekil 6.1: Bir Özellik Alınarak Adam Optimizer Kullanılan CNN Modeli



Şekil 6.2: Bir Özellik Alınarak Adam Optimizer Kullanılan RNN Modeli



Şekil 6.3: Bir Özellik Alınarak Adam Optimizer Kullanılan LSTM Modeli




Şekil 6.4: Adam Optimizer Kullanılan Modellerin Bir Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE

6.1.2. Meteoroloji Verileri ile Toplam Kesinti Sayıları

5 Özellikli giriş verisi ile yaptığımız tahminde kesinti sayıları tahmin edilmiştir. 5 Özellik olarak 4 meteoroloji verisi ve bu tarihte gerçekleşen kesinti sayıları alınmıştır. Dokümanda daha önce bahsedildiği üzere veri inceleme Diyarbakır üzerinde yapılmış,


model üzerinde yeterli başarı yakalandığında diğer illere uygulanmıştır. Diyarbakır ili üzerinde yapılan inceleme sonuçları şu şekilde gerçekleşmiştir:



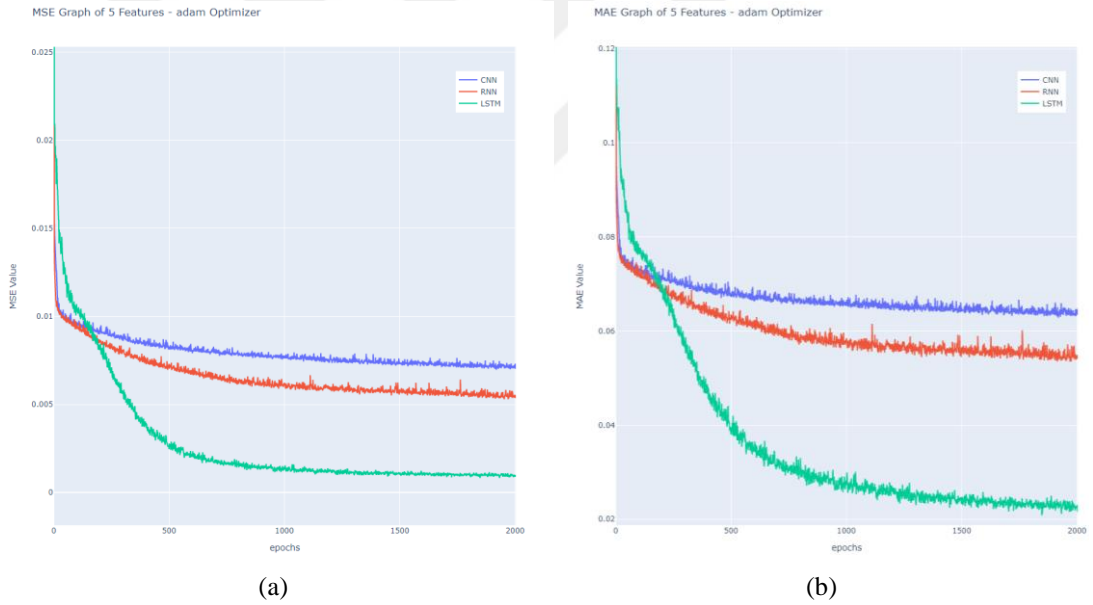
Şekil 6.5: Beş Özellik Alınarak Adam Optimizer Kullanılan CNN Modeli



Şekil 6.6: Beş Özellik Alınarak Adam Optimizer Kullanılan RNN Modeli



Şekil 6.7: Beş Özellik Alınarak Adam Optimizer Kullanılan LSTM Modeli




Şekil 6.8: Adam Optimize Kullanılan Modellerin Beş Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE

6.1.3. Planlı ve Plansız Kesinti Sayıları

7 Özellikli giriş verisi ile yaptığımız tahminde kesinti sayıları tahmin edilmiştir. 5 Özellikli veriye ek olarak planlı kesinti sayıları, plansız kesinti sayıları alınmıştır. Dokümanda daha önce bahsedildiği üzere veri inceleme Diyarbakır üzerinde yapılmış,

model üzerinde yeterli başarı yakalandığında diğer illere uygulanmıştır. Diyarbakır ili üzerinde yapılan inceleme sonuçları şu şekilde gerçekleşmiştir:



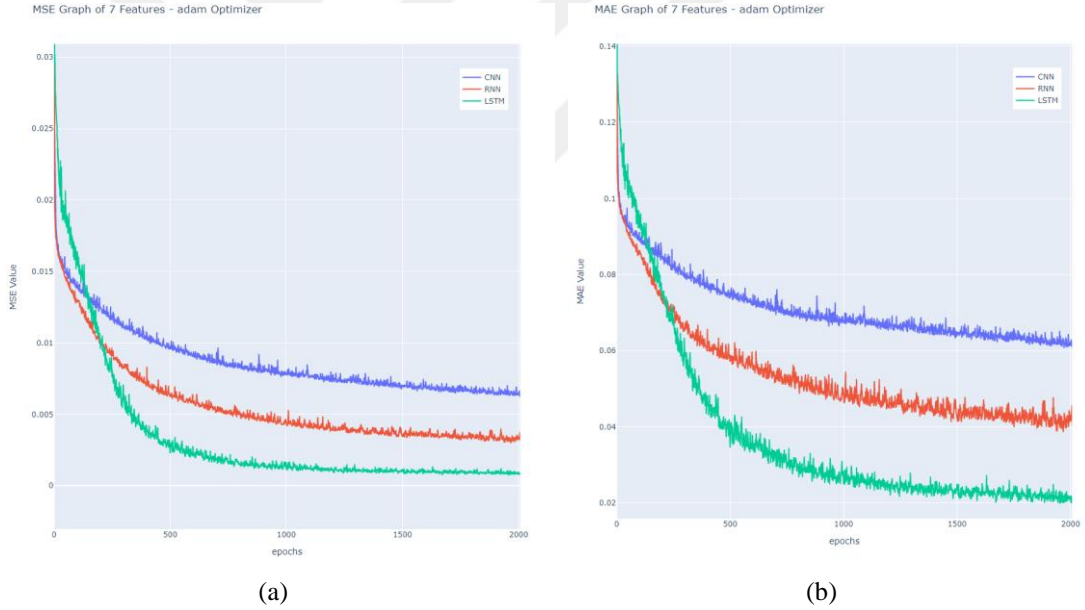
Şekil 6.9: Yedi Özellik Alınarak Adam Optimizer Kullanılan CNN Modeli



Şekil 6.10: Yedi Özellik Alınarak Adam Optimizer Kullanılan RNN Modeli



Şekil 6.11: Yedi Özellik Alınarak Adam Optimizer Kullanılan LSTM Modeli



Şekil 6.12 Adam Optimizer Kullanılan Modellerin Yedi Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE

Performans değerleri en iyi hale getirilmesi için Şekil 4.1 ‘deki akışta gösterildiği üzere Tablo 5.1, Tablo 5.2 ve Tablo 5.3 verilen model parametrelerinin optimizasyonu sağlandı. Her bir model için minmax kullanılarak veri [0,1] aralığında normalize edildi. Normalize edilen veri tahmin sonrası gerçek değerlerine döndürüldü. 3 farklı veri setinden elde edilen performans değerleri Tablo 6.1 de gösterildiği üzeredir.

6.2. RMSProp Optimizer Kullanılarak Derin Öğrenme Modelleri ile Tahminleme

RMSProp (Tieleman ve Hinton, 2012) Adam optimizasyonuna çok yakın bir optimizasyondur. Momentumlu ve momentumuz versiyonları bulunur. Adam ile arasındaki en büyük fark ise momentumlu versiyonunda RMSProp tahminlerini parametre güncellemelerini yeniden ölçeklenmiş gradyan üzerinde momentum kullanarak üretmiştir, adam ise birinci ve ikinci momentinin ortalamasını kullanarak üretir. Ayrıca RMSProp da bias-correction bulunmamaktadır (Kingma ve Ba, 2014).

6.2.1. Toplam Kesinti Sayıları

Bir özellikli veri olarak sadece kesinti sayıları alınarak ve RMSProp optimizasyonu kullanarak tahminleme yapılmıştır. Dokümanda daha önce bahsedildiği üzere veri inceleme Diyarbakır üzerinde yapılmıştır. Diyarbakır ili üzerinde yapılan inceleme sonuçları Şekil 6.13, Şekil 6.14, Şekil 6.15 'de gösterildiği şekliyle gerçekleşmiştir. Tahmin doğruluğunun incelenmesinin kolaylaştırılması için tüm şekillerde sadece tahminin olduğu yere odaklanılmıştır bundan dolayı grafiklerde öğrenme verisinin küçük bir kısmına yer verilmiştir.




Şekil 6.13: Bir Özellik Alınarak RMSProp Optimizer Kullanılan CNN Modeli

Outage Graph of DİYARBAKIR with RNN - 1 Features - RMSPROP Optimizer

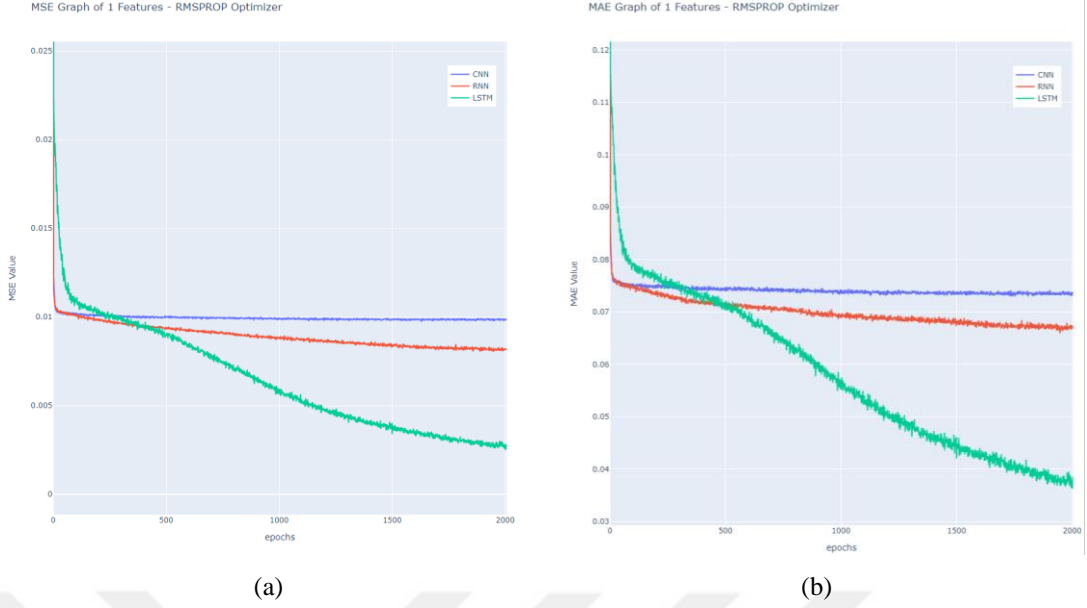


Şekil 6.14: Bir Özellik Alınarak RMSProp Optimizer Kullanılan RNN Modeli

Outage Graph of DİYARBAKIR with LSTM - 1 Features - RMSPROP Optimizer




Şekil 6.15: Bir Özellik Alınarak RMSProp Optimizer Kullanılan LSTM Modeli



Şekil 6.16: RMSProp Optimizer Kullanılan Modellerin Bir Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE

6.2.2. Meteoroloji Verileri ile Toplam Kesinti Sayıları


5 Özellikli giriş verisi ile yaptığımız tahminde kesinti sayıları tahmin edilmiştir. 5 Özellik olarak 3 meteoroloji verisi, tarih ve bu tarihte gerçekleşen kesinti sayıları alınmış ve optimizör olarak RMSProp kullanılmıştır. Dokümanda daha önce bahsedildiği üzere veri inceleme Diyarbakır üzerinde yapılmış, yapılan inceleme sonuçları Şekil 6.17, Şekil 6.18, Şekil 6.19 verilmiştir.



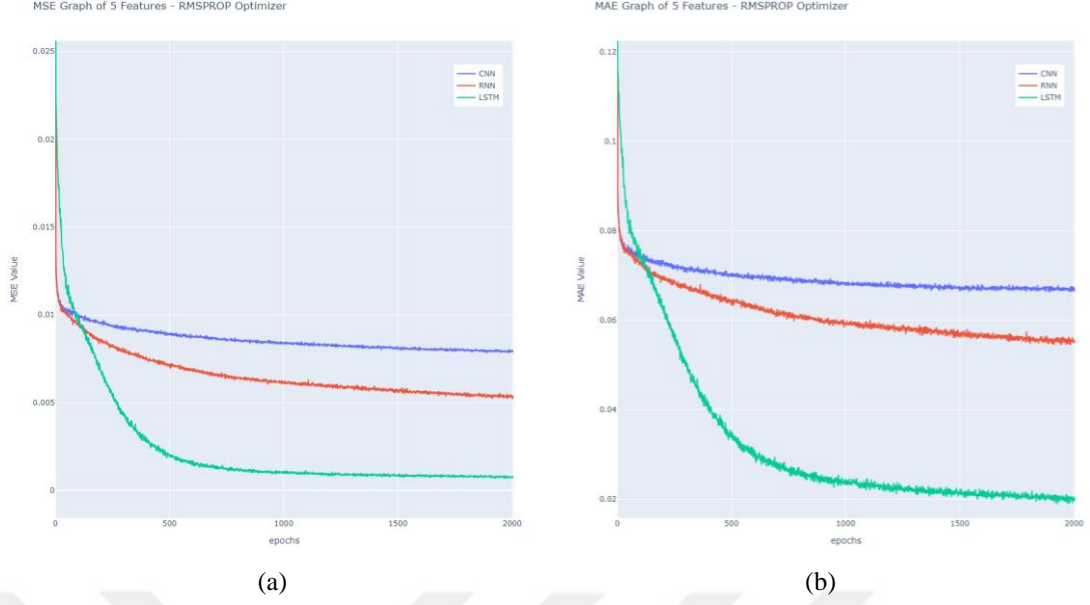
Şekil 6.17: Beş Özellik Alınarak RMSProp Optimizer Kullanılan CNN Modeli



Şekil 6.18: Beş Özellik Alınarak RMSProp Optimizer Kullanılan RNN Modeli



Şekil 6.19: Beş Özellik Alınarak RMSProp Optimizer Kullanılan LSTM Modeli



Şekil 6.20: RMSProp Optimizer Kullanılan Modellerin Beş Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE

6.2.3. Planlı ve Plansız Kesinti Sayıları

7 Özellikli giriş verisi ile yaptığımız tahminde kesinti sayıları tahmin edilmiştir. 5 Özellikli veriye ek olarak planlı kesinti sayıları, plansız kesinti sayıları alınmış ve optimizasyon olarak RMSProp kullanılmıştır. Diyarbakır ili üzerinde yapılan inceleme sonuçları Şekil 6.21, Şekil 6.22, Şekil 6.23 ile gösterildiği gibidir.



Şekil 6.21: Yedi Özellik Alınarak RMSProp Optimizer Kullanılan CNN Modeli

Outage Graph of DİYARBAKIR with RNN - 7 Features - RMSPROP Optimizer

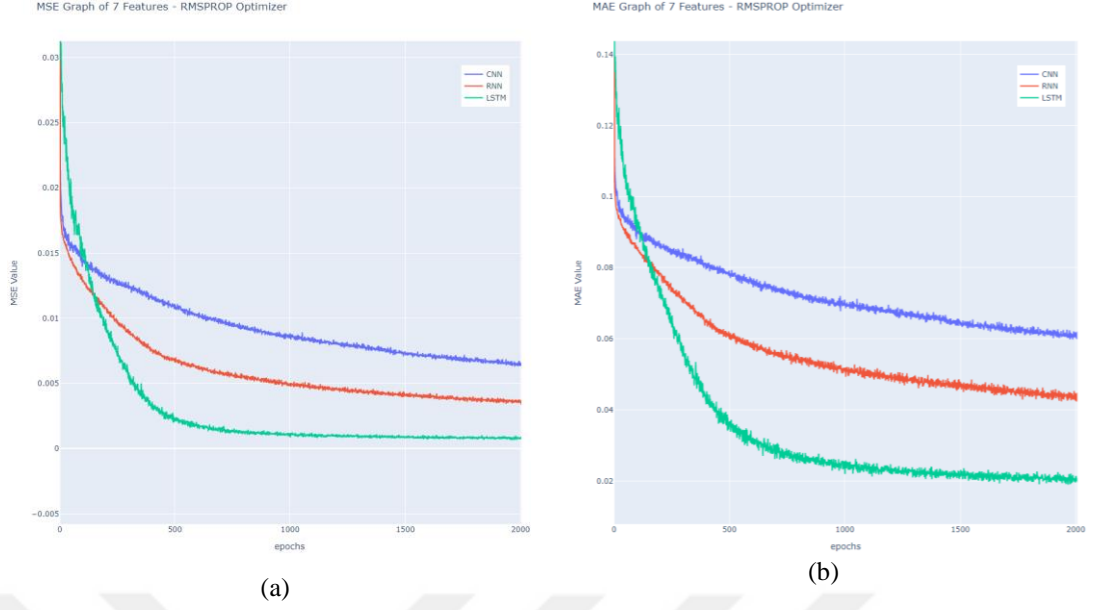


Şekil 6.22: Yedi Özellik Alınarak RMSProp Optimizer Kullanılan RNN Modeli

Outage Graph of DİYARBAKIR with LSTM - 7 Features - RMSPROP Optimizer



Şekil 6.23: Yedi Özellik Alınarak RMSProp Optimizer Kullanılan LSTM Modeli



Şekil 6.24: RMSProp Optimizer Kullanılan Modellerin Yedi Özellikli Veride Metriklerinin Karşılaştırılması, (a) MSE ve (b) MAE

Performans değerleri en iyi hale getirilmesi için Şekil 4.1 'deki akışta gösterildiği üzere Tablo 5.1, Tablo 5.2 ve Tablo 5.3 verilen model özelliklerinin optimizasyonu sağlandı. Her bir model için minmax kullanılarak veri [0,1] aralığında normalize edildi. Normalize edilen veri tahmin sonrası gerçek değerlerine döndürüldü. 3 farklı veri seti üzerinde adam ve RMSProp ile elde edilen performans değerleri Tablo 6.1 de gösterildiği üzeredir.

Tablo 6.1: Önerilen Derin Öğrenme Modelleri İle Kesinti Tahmini Performans Analizi

Veri Set Özellik Sayısı	Optimizasyon	Metrik	CNN	RNN	LSTM
Sadece Kesinti Sayıları (Bir Özellikli Veri Seti)	adam	MAE	0,0734	0,0662	0,0470
		MSE	0,0099	0,0081	0,0042
	RMSProp	MAE	0,0738	0,0673	0,0377
		MSE	0,0099	0,0082	0,0027
Meteoroloji Verileri ve Kesinti Sayıları (5 Özellikli Veri Seti)	adam	MAE	0,0636	0,0548	0,0223
		MSE	0,0071	0,0056	0,0009
	RMSProp	MAE	0,0670	0,0549	0,0204
		MSE	0,0080	0,0053	0,0008
Meteoroloji Verileri, Toplam Kesinti Sayısı, Planlı ve Plansız Kesinti Sayıları (7 Özellikli Veri Seti)	adam	MAE	0,0621	0,0432	0,0215
		MSE	0,0065	0,0034	0,0008
	RMSProp	MAE	0,0605	0,0434	0,0202
		MSE	0,0064	0,0036	0,0008

YEDİNCİ BÖLÜM

TARTIŞMA VE DEĞERLENDİRME

Bu çalışmada Dicle Elektrik Dağıtım A.Ş. bölgesinde yer alan Diyarbakır ilinin kesinti tahmini için 3 farklı yöntem önerilmiştir. Derin öğrenme yöntemlerinden olan bu modeller yaygın olarak kullanılmakta ve büyük miktarda ham veriden önemli miktarda özellik ekleme ve çıkarımında büyük olanaklar sağlar. Bu özellikler, modellerin tahmindeki doğruluğunu arttırmak için aralarındaki karmaşık ilişkiyi anlamamızı sağlar. Bu nedenle çalışmada kesinti verilerini 3 farklı Veri Seti kullanılarak kesintilerin tahmin edilmesi üç farklı model, CNN-Conv1D, RNN-SimpleRNN ve LSTM modelleri, adam ve RMSProp optimizasyonları ile ölçeklenerek önerilmiştir. Veri kümeleri yasal olarak paylaşılan Dicle Elektrik Dağıtım A.Ş. ve Meteoroloji Kurumundan alınmış, gerçekleşen verilerdir. Modeller bu veri kümeleri ile öğretilmiş ve test edilmiştir. Testler 2 farklı metriktен oluşan 18 ayrı sonuç ile değerlendirilmiştir.

Tablo 6.1 'de görüldüğü üzere veri seti bakımından değerlendirildiğinde veri setinin en çok özellik ile girdi sağlanması durumunda daha başarılı sonuca ulaşıldığı gözlemlenmekte, planlı ve plansız kesinti sayılarının ayrı dikkate alındığı Veri Setinin 3 modelde de en başarılı sonucun elde edildiği gözlemlenmiştir. 5 ve 1 özellikli diğer veri kümelerinde küçük oranda da olsa fark olmakla birlikte 5 özellikli veri setinin 1 özellikli veri setine göre daha başarılı sonuçlar verdiği gözlemlenmektedir. Bu durumda veri setinin özellikleri azaldıkça başarı oranının azaldığı sonucuna varılabilir.

Model bakımından değerlendirildiğinde ise LSTM 'in tüm veri kümelerinde en başarılı sonuç verdiği gözlemlenmektedir. LSTM 'den sonra RNN ise CNN 'e göre daha başarılı sonuç çıkarmaktadır. Özellik karmaşasında ise yine en başarılı sonucu LSTM sağlamaktadır.

MAE metriği ile değerlendirildiğinde, tüm veri setlerinde LSTM 'in en başarılı sonuç verdiği gözlemlenmiştir. 7 özellikli veri setinde diğerleri ile arasında az fark olsa da RMSProp optimizasyonu ile LSTM 0,0202 MAE değeri ile ardında 5 özellikli veride RMSProp optimizasyonu ile yine LSTM 0,0204 MAE değeri ile ve 7 özellikli veride adam optimizasyonu ile LSTM 0,0215 MAE değeri ile en iyi sonuçları vermektedir. LSTM 'in ardından RNN 'in başarılı sonuç ürettiği gözlemlenmektedir.

MSE metriği ile değerlendirildiğinde, tüm veri setlerinde yine LSTM 'in en başarılı sonuç verdiği gözlemlenmektedir. Burada 5 ve 7 özellikli veri setlerinde optimizasyon farkı gözetmeksizin LSTM her zaman 0,0008 MAE değeri ile aynı başarılı sonucu üretmiştir. Yine sırasıyla 7 ve 5 özellikli veri setlerinde RNN 'in optimizasyon fark etmeksizin 0,0035 MAE değeri ikinci sırada başarılı sonuç ürettiği gözlemlenmiştir. 1 özellikli veri setinde ise yine LSTM in RMSProp optimizasyonu ile yine en başarılı sonucu ürettiği görülmektedir.

Optimizasyon olarak değerlendirildiğinde ise her iki optimizasyonun bir birine çok yakın 0,0008 MSE değerleri ile sonuç ürettiği ancak çok az bir farkla da olsa RMSProp 'un genel olarak LSTM ve RNN 'de daha iyi sonuçlar verdiği gözlemlenmiştir.

Bu nedenle önerilen modeller ve veri kümelerindeki özellik sayıları olarak değerlendirildiğinde özellik sayısını olabildiğince yüksek tutulup RMSProp optimizasyonu kullanılarak LSTM ile tahminlerin en doğru sonuçları çıkartacağı sonucuna varılmıştır.

Gelecekte modellerin RNN-LSTM şeklinde birleşimi, mevsimsellik özelliklerinin alınması, aynı anda birden fazla ilin modellere verilmesi yada incelemenin ilçe seviyesinde yapılarak noktasal tahminlere gidilmesi, modellerde farklı aktivasyon (activation) fonksiyonlarının kullanılması, farklı model parametrelerinin denenmesi ve çok daha büyük veri seti ile derin öğrenme yaklaşımı kullanılarak tahminlerin değerlendirilmesi hedeflenmektedir.

KAYNAKÇA

- Baccouche, M., Mamalet, F., Wolf, C., Garcia, C., & Baskurt, A. (2011, November). Sequential deep learning for human action recognition. *International workshop on human behavior understanding*: 29-39.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient. *IEEE transactions on neural networks*, 5(2): 157-166.
- Canizo, M., Triguero, I., Conde, A., & Onieva, E. (2019). Multi-head CNN–RNN for multi-time series anomaly detection: An industrial case study. *Neurocomputing*, 363: 246-260.
- Cho, K., Merriënboer, B. v., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. arXiv:1406.1078.
- Collobert, R., & Weston, J. (2008). A unified architecture for natural language processing: Deep neural networks with multitask learning. *Proceedings of the 25th international conference on Machine learning*: 160-167.
- Dindar, B. (2020). *Türkiye'de elektrik kesintilerinin maliyeti: Tüketicilerin ve dağıtım şirketlerinin kesinti maliyetlerinin hesaplanması ve geleceğe yönelik tahminler*. İstanbul.
- Eck, D., & Schmidhuber, J. (2002). Learning the long-term structure of the blues. *International Conference on Artificial Neural Networks*: 284-289.
- Elektrik Dağıtımı ve Perakende Satışına İlişkin Hizmet Kalitesi Yönetmeliği*. (2022, 01 03). T.C. Enerji Piyasası Düzenleme Kurumu Resmi Web Sitesi: <https://www.epdk.gov.tr/Detay/Icerik/3-6740/elektrik-dagitimi-ve-perakende-satisina-iliskin-hizmet-kalitesi-yonetmeliği> adresinden alındı
- Fernández, S., Graves, A., & Schmidhuber, J. (2007, September). An application of recurrent neural networks to discriminative keyword spotting. *International Conference on Artificial Neural Networks*: 220-229.
- Fukushima, K., & Miyake, S. (1982). Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. *In Competition and*

cooperation in neural nets: 267-285.

- Gers, F. A., & Schmidhuber, J. (2000). Recurrent nets that time and count. *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks - IJCNN 2000*(3): 189-194.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10): 2451-2471.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM, *Neural Comput. Neural computation*, 12(10): 2451-2471.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Graves, A., & Jaitly, N. (2014). Towards end-to-end speech recognition with recurrent neural networks. *In International conference on machine learning*: 1764-1772.
- Graves, A., & Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6): 602-610.
- Graves, A., & Schmidhuber, J. (2008). Offline handwriting recognition with multidimensional recurrent neural networks. *Advances in neural information processing systems*, 21: 545-552.
- Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *IEEE international conference on acoustics, speech and signal processing*: 6645-6649.
- Grefenstette, E., Blunsom, P., De Freitas, N., & Hermann, K. M. (2014). A Deep Architecture for Semantic. *arXiv*: 1404,7296.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10): 2222-2232.
- Hameed, A. A., Jamil, A., Rasheed, J., Ilyas, M., Özyavaş, A., & Ajlouni, N. (2020). Improving Stock Prediction Accuracy Using CNN and LSTM. *2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy (ICDABI)*: 1-5. IEEE.

Hamilton, J. D. (2020). *Time Series Analysis*. Princeton, New Jersey: Princeton University Press.

Hizmet Kalite Göstergeleri. (2022, Ocak 03). Dicle Elektrik Dağıtım A.Ş. Resmi Web Sitesi:

https://www2.dedas.com.tr/bilgi/_H%C4%B0zmet_Kal%C4%B0te_G%C3%B6stergeler%C4%B0/67 adresinden alındı

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

Hochreiter, S., Heusel, M., & Obermayer, K. (2007). Fast model-based protein homology detection without alignment. *Bioinformatics*, 23(14): 1728-1736.

Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences*, 79(8): 2554-2558.

Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1): 215-243.

İstatistik Veri Portalı. (2022, Ocak 01). Türkiye İstatistik Kurumu: <https://data.tuik.gov.tr/> adresinden alındı

Jha, D. K., Sinha, S. K., Garg, A., & Vijay, A. (2012). Estimating electricity supply outage cost for residential and commercial customers. *In 2012 North American Power Symposium (NAPS)*: 1-6.

Kalchbrenner, N., Grefenstette, E., & Blunsom, P. (2014). A Convolutional Neural Network for Modelling Sentences. arXiv preprint arXiv:1404.2188.

Karpathy, A., & Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. *In Proceedings of the IEEE conference on computer vision and pattern recognition*: 3128-3137.

Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *ICLR 2015*, (s. arXiv preprint arXiv:1412.6980).

LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *IEEE*(86): 2278–2324.

Luo, J., Zhang, Z., Fu, Y., & Rao, F. (2021). Time series prediction of COVID-19

- transmission in America using LSTM and XGBoost algorithms. *Results in Physics*: 104462.
- Maddison, C. J., Huang, A., Sutskever, I., & Silver, D. (2014). Move Evaluation in Go Using Deep Convolutional Neural Networks. arXiv preprint arXiv:1412.6564.
- Mayer, H., Gomez, F., Wierstra, D., Nagy, I., Knoll, A., & Schmidhuber, J. (2008). A system for robotic heart surgery that learns to tie knots using recurrent neural networks. *Advanced Robotics*, 22(13-14): 1521-1537.
- Mejia, J., Avelar-Sosa, L., Mederos, B., Ramírez, E. S., & Roman, J. D. (2022). Prediction of time series using an analysis filter bank of LSTM units. *Computers & Industrial Engineering*, 157: 107371.
- Meteoroloji Veri Bilgi ve Sunum Sistemi*. (2022, Ocak 03). Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü: <https://mevbis.mgm.gov.tr/mevbis/ui/index.html#/Workspace> adresinden alındı
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J., & Khudanpur, S. (2010, September). Recurrent neural network based language model. *Interspeech*, 2(3): 1045-1048.
- Panya, S., Pattaraprakorn, W., Detmote, T., Teansri, P., & Bhasaputra, P. (2010). Economic impact of power outage in Thailand: Industry perspectives. *In Proceedings of the International Conference on Energy and Sustainable Development: Issues and Strategies (ESD 2010)*: 1-7.
- Q.Yin, R, Z., & X.L, S. (2019). CNN and RNN mixed model for image classification, MATEC. *In MATEC Web of Conferences*. 277, s. 02001. MATEC Web Conference.
- Salomon, J., & Bianca, S. (2018). *Lung cancer detection using deep learning*. Dublin Institute of Technology.
- Schmidhuber, J., Gers, F., & Eck, D. (2002). Learning nonregular languages: A comparison of simple recurrent networks and LSTM. *Neural computation*, 14(9): 2039-2041.
- Shen, Y., He, X., Gao, J., Deng, L., & Mesnil, G. (2014). Learning semantic representations using convolutional neural networks for web search. *In*

- Proceedings of the 23rd international conference on world wide web: 373-374.*
- Shin, J., Kim, Y., Yoon, S., & Jung, K. (2018). A novel architecture capturing unified meaning for sentence classification. *IEEE International Conference on Big Data and Smart Computing (BigComp)*: 491-494. IEEE.
- Siame-Namini, S., Tavakoli, N., & Namin, A. S. (2018). A Comparison of ARIMA and LSTM in Forecasting Time Series. *17th IEEE International Conference on Machine Learning and Applications (ICMLA)*: 1394-1401.
- Smolensky, P. (1986). Information processing in dynamical systems: Foundations of harmony theory. *Colorado Univ at Boulder Dept of Computer Science*.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3): 47-64.
- Tervo, R., Karjalainen, J., & Jung, A. (2018). Predicting Electricity Outages Caused By Convective Storms. *In 2018 IEEE Data Science Workshop (DSW)*: 145-149.
- Tieleman, T., & Hinton, G. (2012). *Lecture 6.5 - RMSProp, COURSERA: Neural Networks for Machine Learning*. Technical report.
- Tokgöz, A., & Ünal, G. (2018, May). A RNN Based Time Series Approach for Forecasting Turkish Electricity Load. *26th Signal Processing and Communications Applications Conference (SIU)*: 1-4.
- Verma, H. K., & Pal, S. (2016). Modified sigmoid function based gray scale image contrast enhancement using particle swarm optimization. *Journal of The Institution of Engineers (India): Series B(97(2))*: 243-251.
- Wallach, I., Dzamba, M., & Heifets, A. (2015). AtomNet: A Deep Convolutional Neural Network for Bioactivity Prediction in Structure-based Drug Discovery. *arXiv preprint arXiv:1510.02855*.
- Wang, J., Li, X., Li, J., Sun, Q., & Wang, H. (2022). NGCU: A New RNN Model for Time-Series Data Prediction. *Big Data Research*, 27, 100296.
- Wei, X., Zhang, L., Yang, H. Q., Zhang, L., & Yao, Y. P. (2021). Machine learning for pore-water pressure time-series prediction: Application of recurrent neural

networks. *Geoscience Frontiers*, 12(1): 453-467.

Yosinski, J., Clune, J., Nguyen, A., Fuchs, T., & Lipson, H. (2015). Understanding neural networks through deep visualization. arXiv preprint arXiv:1506.06579.



ÖZGEÇMİŞ

Orçun KİTAPCI

A. EĞİTİM

Yüksek Lisans	İstanbul Sabahattin Zaim Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bilim Dalı, Bilgisayar Mühendisliği Tezli Yüksek Lisans Öğrencisi 2022, İstanbul
Yüksek Lisans	İstanbul Şehir Üniversitesi, Tezsiz İşletme Yüksek Lisansı, 2015, İstanbul
Lisans	Kocaeli Üniversitesi Matematik Bölümü, 2006, Kocaeli
Ön Lisans	Sakarya Üniversitesi, Bilgisayar Programcılığı, 1999, Sakarya

B. MESLEKİ DENEYİM

2001-2008	Bosphorus Stone LTD. şirketinde Bilgisayar Şefi
2009-2011	Ströer Out-of-Home Media şirketinde Yazılım Uzmanı
2011-2014	Ströer Out-of-Home Media şirketinde Yazılım Yönetmeni
2014-2020	Dicle Elektrik Dağıtım A.Ş. şirketinde Veri Ambarı Yöneticisi
2020-Devam Ediyor	Dicle Elektrik Dağıtım A.Ş. şirketinde İş Zekası ve Raporlama Müdürü