

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**YÜKSEK LİSANS
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ PROGRAMI**

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK HİSSE
SENEDİ FİYATLARININ TAHMİN EDİLMESİ: BİST’TE BİR
UYGULAMA**

Özgür SARACIK

**Danışman
Dr. Öğr. Üyesi Aynur İNCEKIRIK**

MANİSA–2023

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**YÜKSEK LİSANS
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ PROGRAMI**

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK HİSSE
SENEDİ FİYATLARININ TAHMİN EDİLMESİ: BİST’TE BİR
UYGULAMA**

Özgür SARACIK

**Danışman
Dr. Öğr. Üyesi Aynur İNCEKIRIK**

MANİSA–2023

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Derin Öğrenme Teknikleri Kullanılarak Hisse Senedi Fiyatlarının Tahmin Edilmesi: BIST’te Bir Uygulama” adlı çalışmanın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin bibliyografyada gösterilen eserlerden oluştuğunu, bunlara atıf yapılarak yararlanmış olduğumu belirtir ve bunu onurumla doğrularım.

../../2023

Özgür SARACIK

İmza

ÖZET

DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK HİSSE SENEDİ FİYATLARININ TAHMİN EDİLMESİ: BİST’TE BİR UYGULAMA

Borsa yatırımcıları, kâr edebilmek amacıyla geleceği tutarlı bir şekilde öngörerek yerinde hamleler yapabilmelidir. Bu amaçla yatırımcılar sahip oldukları bilgileri doğru analiz edip başarılı tahminlerde bulunmalıdırlar. Gün geçtikçe daha da globalleşen finansal piyasalara yönelik gelecek fiyat tahminlerinde bulunmak gittikçe zorlaşmaktadır. Örneğin bazı zamanlarda Türkiye’deki bir hisse senedinin fiyat tahmini için sadece Türkiye’deki faktörler değil aynı zamanda dünyadaki diğer faktörlerin de göz önünde bulundurulması gerekmektedir. Dolayısıyla bu durumda basit istatistiksel hesaplamalar yetersiz kalmaktadır. Bu yetersiz kalmaya çözüm olarak bilgisayar programları ve bu programlar içerisindeki algoritmalar ile tekniklerden faydalanılmaktadır. Derin öğrenme, yaklaşık 80 yıl önce ilk kez temelleri atılan yapay zekânın en gelişmiş araçlarından ve son 10 senedir popülerliği artarak finans alanındaki çalışmalarda kendine çokça yer bulmaktadır. Çalışmanın birinci bölümünde Türkiye’de borsa ve enerji kaynakları hakkında bilgi verilmiştir. İkinci bölümde derin öğrenmenin tanımı, tarihçesi, teknikleri ve kullanım alanları tanıtılmıştır. Son bölüm olan üçüncü bölümde ise veri seti ve değişkenlerin tanıtılması, daha önce yapılmış benzer çalışmalar, yapılan uygulamanın adımları ve görselleri bulunmaktadır. Bu çalışmada bir hisse senedi tahmini için son gelişmiş teknolojilerden olan derin öğrenmenin LSTM (Long-Short Term Memory) ve GRU (Gated Recurrent Unit) teknikleri Google Colab programı ortamında uygulanmıştır. Çalışmada kullanılan veri seti Yahoo Finance’den alınmış ve 02.01.2013 ile 30.12.2022 tarihleri arasında kapsamaktadır. BİST (Borsa İstanbul)’in bünyesinde yer alan XELKT (Borsa İstanbul Elektrik Endeksi) endeksine ait 5 şirket ele alınarak tahmin modelleri oluşturulmuştur. Ardından oluşturulan bu tahmin modellerinin başarıları hesaplanan model performans kriterleri ile test edilmiş ve kullanılan tekniklerin hisse senedi fiyat tahmini konusunda başarılı olup olmadığının belirlenmesi hedeflenmiştir. Buna ek olarak hesaplanan model performans kriterleri arasından MSE (Mean Squared Error) ve MAPE (Mean Absolute Percentage Error)’nin sonuçları baz alınarak kullanılan teknikler birbiriyle kıyaslanmış ve bu tekniklerden hangisinin daha az hata ile tahmin yaptığının tespit edilmesi amaçlanmıştır. Son olarak, 4 farklı gün sayısı alınarak yapılan analizlerden

hangi gün ile daha başarılı tahminlerin yapıldığı kestirilmeye çalışılmıştır. Bu analizlerin sonucunda elde edilen model performans kriteri çıktıları, MSE için 1' in altında ve MAPE için de %5' in altında olduğundan dolayı iki tekniğin de başarılı fiyatı tahminleri gösterdiği söylenebilir. Sonuç olarak bu iki tekniğin birbiriyle karşılaştırılması neticesinde çok az bir farkla LSTM tekniğinin, GRU tekniğinden daha başarılı olduğu görülmektedir.

Anahtar Kelimeler: LSTM, GRU, Derin Öğrenme, Hisse Senedi Fiyat Tahmini, BİST, XELKT



ABSTRACT

FORECASTING STOCK PRICES USING DEEP LEARNING TECHNIQUES: AN APPLICATION IN BIST

Stock market investors should be able to make appropriate moves by predicting the future consistently in order to make a profit. For this purpose, investors should analyze the information they have correctly and make successful predictions. It is getting harder and harder to make future price predictions for financial markets, which are becoming more and more global day by day. For example, sometimes, for the price prediction of stock in Turkey, not only the factors in Turkey but also other factors in the world should be taken into consideration. Therefore, simple statistical calculations are insufficient in this case. As a solution to this inadequacy, computer programs and algorithms and techniques in these programs are used. Deep learning is one of the most advanced tools of artificial intelligence the foundations of which were laid for the first time about 80 years ago, and deep learning's popularity has increased in the last 10 years and has found a lot of place in studies in finance. In the first part of the study, information is given about the stock market and energy resources in Turkey. In the second part, the definition, history, techniques, and usage areas of deep learning are introduced. In the third section, which is the last section, there are the introduction of the data set and the variables, previous similar studies, the steps and visuals of the application. In this study, LSTM (Long-Short Term Memory) and GRU (Gated Recurrent Unit) techniques of deep learning, which are among the latest advanced technologies, were applied in the Google Colab program for stock price predictions. The data set used in the study was taken from Yahoo Finance and covers the dates between 02.01.2013 and 30.12.2022. Forecast models were created by considering 5 companies belonging to the XELKT (Borsa Istanbul Electricity Index) index, which is part of BIST (Borsa Istanbul). Afterward, the success of these prediction models were tested with the calculated model performance criteria and it was aimed to determine whether the techniques used were successful in stock price prediction. In addition, based on the results of MSE (Mean Squared Error) and MAPE (Mean Absolute Percentage Error) among the calculated model performance criteria, the techniques used were compared with each other and it was aimed to determine which of these techniques made predictions with less error. Then, from the analyzes made by taking 4 different days,

it was tried to predict which day made the most successful predictions. As a last step, it is aimed to find a model with the least error by technique, epoch number, and number of day forecast for both MSE and MAPE on the basis of stocks. Since the model performance criteria outputs obtained as a result of these analyzes are below 1 for MSE and below 5% for MAPE, it can be said that both techniques show successful price predictions. As a result, as a result of the comparison of these two techniques with each other, it is seen that the LSTM technique is more successful than the GRU technique with a slight difference.

Key Words: LSTM, GRU, Deep Learning, Stock Price Prediction, BIST, XELKT



TEŞEKKÜR

Çalışmamın her aşamasında bana destek olan, bilgi ve deneyimleri ile yol gösteren danışman hocam Sayın Dr. Öğr. Üyesi Aynur İNCEKIRIK' a, çalışmalarım sırasında ve öğrenim hayatım boyunca bana karşı maddi ve manevi desteklerini her zaman hissettiğim değerli aile üyelerim annem Fatma Gül SARACIK, babam Harun Reşit SARACIK ve abim Arif SARACIK' a, yürekten teşekkür ederim.

Özgür SARACIK
Manisa, 2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
KISALTMALAR	xi
TABLOLAR LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ	xiv
GİRİŞ	1

BİRİNCİ BÖLÜM

BORSA' DAKİ HİSSE SENETLERİ PİYASASI VE ENERJİ SEKTÖRÜ

1.1. TÜRKİYE' DE BORSA VE HİSSE SENETLERİ	3
1.1.1. Hisse Senetleri.....	4
1.1.2. Hisse Senedi Analiz Yöntemleri	5
1.1.2.1. Temel Analiz	5
1.1.2.2. Teknik Analiz.....	5
1.1.3. XELKT Endeksi.....	5
1.1.3.1. Akenerji Elektrik Üretim A.Ş.	6
1.1.3.2. Aksa Enerji Üretim A.Ş.	7
1.1.3.3. Aksu Enerji ve Ticaret A.Ş.	7
1.1.3.4. Ayen Enerji A.Ş.	7
1.1.3.5. Zorlu Enerji Elektrik Üretim A.Ş.....	7
1.2. TÜRKİYE' DE ENERJİ SEKTÖRÜ.....	8
1.2.1. Yenilenebilir Enerji Kaynakları	8
1.2.1.1. Güneş Enerjisi	9
1.2.1.2. Rüzgar Enerjisi.....	12

1.2.1.3. Hidroelektrik Enerjisi.....	13
1.2.1.4. Jeotermal Enerji	15
1.2.1.5. Biyokütle Enerjisi	17
1.2.2. Yenilenemeyen Enerji Kaynakları	19
1.2.2.1. Kömür	19
1.2.2.2. Petrol	21
1.2.2.3. Doğal Gaz.....	23
1.2.2.4. Nükleer Enerji	24

İKİNCİ BÖLÜM

DERİN ÖĞRENME YÖNTEMİ

2.1. DERİN ÖĞRENME YÖNTEMİNİN TANIMI.....	25
2.1.1. Derin Öğrenmenin Tarihçesi.....	28
2.1.2. Derin Öğrenmede Öğrenme Türleri	29
2.1.2.1. Denetimli Öğrenme	29
2.1.2.2. Denetimsiz Öğrenme.....	31
2.1.3. Yapay Sinir Ağlarının Türleri	32
2.1.3.1. İleri Beslemeli Ağlar	32
2.1.3.2. Geri Beslemeli Ağlar.....	33
2.1.4. Aktivasyon Fonksiyonu	35
2.1.4.1. Doğrusal Aktivasyon Fonksiyonu.....	36
2.1.4.2. Düzeltilmiş Doğrusal Birim (Rectified Linear Unit – ReLU):	37
2.1.4.3. Sigmoid Aktivasyon Fonksiyonu.....	38
2.1.4.4. Hiperbolik Tanjant Fonksiyonu (Tanh)	38
2.1.5. Optimizasyon Algoritmaları	39
2.1.5.1. Adam Algoritması.....	40
2.1.5.2. AdaGrad Optimizasyon Algoritması.....	41
2.1.5.3. RMSProp.....	41

2.1.6. Performans Değerlendirme Kriterleri	42
2.1.6.1. Hata Kareler Ortalaması (Mean Squared Error -MSE).....	42
2.1.6.2. Ortalama Mutlak Hata (Mean Absolute Error – MAE)	42
2.1.6.3. Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error – MAPE)	43
2.1.7. Yinelemeli Sinir Ağı (Recurrent Neural Network – RNN)	43
2.1.7.1. Epoch ve Batch Size.....	46
2.1.7.2. RNN’ de Hesaplama Aktivasyonları.....	46
2.1.7.3. Kaybolan Gradyan Problemi.....	49
2.1.7.4. Stokastik Gradyan İnişi	51
2.1.7.5. Stokastik Gradyan Güncellemesi	53
2.1.8. Uzun Kısa Dönemli Bellek (Long Short-Term Memory – LSTM)	55
2.1.9. Kapılı Yinelemeli Hücre (Gated Recurrent Unit – GRU).....	60

ÜÇÜNCÜ BÖLÜM

HİSSE SENEDİ FİYAT TAHMİNİ UYGULAMASI

3.1. LİTERATÜR TARAMASI.....	62
3.2. ÇALIŞMANIN AMACI	68
3.3. KULLANILAN DEĞİŞKENLER VE YÖNTEMLER	70
3.3.1. GRU Uygulaması	71
3.3.2. LSTM Uygulaması.....	79
3.3.3. İki Tekniğin Karşılaştırılması.....	83
SONUÇ	87
KAYNAKÇA.....	91

KISALTMALAR

AAPG	American Association of Petroleum Geologists
ADALINE	Adaptive Linear Neuron
AKBNK	Akbank Hisse Kodu
AKENR	Akenerji Elektrik Üretim A.Ş.
AKGRT	Aksigorta Hisse Kodu
AKSEN	Aksa Enerji Üretim A.Ş.
AKSUE	Aksu Enerji ve Ticaret A.Ş.
ARCLK	Arçelik Hisse Kodu
ARIMA	Autoregressive Integrated Moving Average
ASELS	Aselsan Hisse Kodu
AYEN	Ayen Enerji A.Ş.
BEPA	Biyokütle Enerjisi Potansiyel Atlası
BİST	Borsa İstanbul
BJKAS	Beşiktaş Hisse Kodu
CNN	Convolutional Neural Network
CPN	Counter Propagation Networks
FENER	Fenerbahçe Hisse Kodu
GARAN	Garanti Bankası Hisse Kodu
GEPA	Güneş Enerjisi Potansiyeli Atlası
GOLTS	Göлтаş Göller Bölgesi Çimento Sanayi A.Ş. Hisse Kodu
GRU	Gated Recurrent Unit
GSRAY	Galatasaray Hisse Kodu
HALKB	Halk Bankası Hisse Kodu
ISCTR	İş Bankası Hisse Kodu
ISGYO	İş Gayrimenkul Yatırım Ortaklığı Hisse Kodu
İMKB	İstanbul Menkul Kıymetler Borsası
KAP	Kamuyu Aydınlatma Platformu
kWh	Kilowatt Saat
LSTM	Long Short-Term Memory
LVQ	Learning Vector Quantization
m	Metre
m²	Metre Kare

MADALINE	Multiple Adaptive Linear Neuron
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MSE	Mean Squared Error
MTA	Maden Tetkik ve Arama
MW	Mega Watt
OPENAI	Open Artificial Intelligence
PETFORM	Petrol ve Doğal Gaz Platformu Derneği
QNBFB	QNBFinansbank Hisse Kodu
RELU	Rectified Linear Unit
RMSE	Root Mean Squared Error
RMSPprop	Root Mean Squared Propagation
RNN	Recurrent Neural Network
s	Saniye
Sm³	Saniye Metre Küp
SVM	Destek Vektör Makineleri
T.C.	Türkiye Cumhuriyeti
TBPTT	Truncated Backpropagation Through Time
THYAO	Türk Hava Yolları Hisse Kodu
TKİ	Türkiye Kömür İşletmeleri
TMOOB	Türkiye Maden Mühendisleri Odası
TPAO	Türkiye Petrolleri Anonim Ortaklığı
U.S.	United States
USD/TL	Dolar kuru
VAKBN	Vakıfbank Hisse Kodu
W	Watt
XELKT	Borsa İstanbul Elektrik Endeksi
XGBOOSTER	eXtreme Gradient Boosting
YKBNK	Yapı Kredi Bankası Hisse Kodu
ZOREN	Zorlu Enerji Elektrik Üretim A.Ş.
GOOGL	Google Hisse Kodu
NKE	Nike Hisse Kodu

TABLÖLER LİSTESİ

Tablo 1: BİST XELKT Endeksindeki Şirketler ve İlk İşlem Tarihleri.....	5
Tablo 2: Epoch' un 20, Batch' ın 5 Olduğu GRU Sonuç Tablosu.....	77
Tablo 3: Epoch' un 50, Batch' ın 32 Olduğu GRU Sonuç Tablosu.....	78
Tablo 4: Epoch' un 100, Batch' ın 64 Olduğu GRU Sonuç Tablosu.....	78
Tablo 5: Epoch' un 200, Batch' ın 128 Olduğu GRU Sonuç Tablosu.....	79
Tablo 6: Epoch' un 20, Batch' ın 5 Olduğu LSTM Sonuç Tablosu	81
Tablo 7: Epoch' un 50, Batch' ın 32 Olduğu LSTM Sonuç Tablosu	81
Tablo 8: Epoch' un 100, Batch' ın 64 Olduğu LSTM Sonuç Tablosu	82
Tablo 9: Epoch' un 200, Batch' ın 128 Olduğu LSTM Sonuç Tablosu	83
Tablo 10: Sonuçların Karşılaştırılması.....	84
Tablo 11: Şirketler İçin En az Hatalı Model Performans Kriterini Veren Modeller .	89

ŞEKİLLER

Şekil 1: Türkiye Yıllık Güneş Radyasyonu Haritası.....	10
Şekil 2: Aylık Ortalama Radyasyon Değeri (kWh/m ²).....	11
Şekil 3: Kurulu Güç (MW – Mega Watt).....	11
Şekil 4: Toplam Kurulu Güç İçerisindeki Oran	12
Şekil 5: Türkiye’ de Rüzgar Hızı (m/s).....	13
Şekil 6: Hidroelektrik Enerjisine Dayalı Kurulu Güç	14
Şekil 7: Hidroelektrik Enerjisinin Toplam Kurulu Güç İçerisindeki Oranı	14
Şekil 8: Türkiye Jeotermal Kaynak Alanları ve Sıcaklık Dağılımı.....	16
Şekil 9: Türkiye Jeotermal Enerji Kaynaklı Kurulu Güç.....	16
Şekil 10: Jeotermal Enerjisinin Toplam Kurulu Güç İçerisindeki Oranı	17
Şekil 11: Türkiye’ de Biyokütle Enerjisi Kurulu Güç Miktarı (MW)	18
Şekil 12: Biyokütlenin Türkiye’ deki Toplam Kurulu Güç İçerisindeki Oranı	19
Şekil 13: Kömürün Oluşma Süreci	20
Şekil 14: Türkiye’ de Enerjiye ve Kömüre Ait Üretim – Tüketim ve Enerji Tüketimini Karşılama Oranı Grafiği.....	21
Şekil 15: Milyon Ton Bazında Türkiye’ de Petrol Üretimi	22
Şekil 16: Türkiye’ de 2012-2021 Yılları Arasında Günlük Ortalama Üretilen Ham Petrol Varili Sayısı	22
Şekil 17: 2011-2021 Yılları Doğal Gaz Üretim Miktarları (Milyon Sm ³).....	23
Şekil 18: Türkiye Doğal Gaz İthalat/İhracat (milyon m ³).....	24
Şekil 19: Klasik Programlama ve Derin Öğrenme Şeması	26
Şekil 20:Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme İlişkisi.....	27
Şekil 21: Makine Öğrenmesi ile Derin Öğrenmenin Karşılaştırılması	28
Şekil 22: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Tarihsel Süreci ...	29
Şekil 23: İleri Beslemeli Sinir Ağı Gösterimi	32
Şekil 24: Geri Beslemeli Sinir Ağı Gösterimi.....	34
Şekil 25: Aktivasyon Fonksiyonları.....	36
Şekil 26: ReLU Fonksiyonunun Türev Grafiği.....	37
Şekil 27: Sigmoid Fonksiyonunun Türev Grafiği.....	38
Şekil 28: Tanh Fonksiyonunun Türev Grafiği	39
Şekil 29: Standart İleri Beslemeli Sinir Ağı Ve RNN Şeması	44
Şekil 30: Tek Gizli Katmanlı Ağ ve Çoklu Gizli Katmanlı Ağın Açık Gösterimi	45

Şekil 31. Bir RNN Şemasındaki Ağırlık Matrisleri Gösterimi	46
Şekil 32: Aktivasyonların Hesaplanma Süreci.....	48
Şekil 33: RNN Girdi – Çıktı Kombinasyonları.....	48
Şekil 34: Tek Gizli Katmanlı RNN İçin Hata Yüzeyi	50
Şekil 35: Bir Boyutlu Kayıp Eğrisinde Stokastik Gradyan İnişi (Bir Adet Öğrenilebilir Parametreli)	52
Şekil 36: İki Boyutlu Kayıp Yüzeyinde Stokastik Gradyan İnişi (İki Adet Öğrenilebilir Parametreli)	53
Şekil 37: Stokastik Gradyan İnişinde Değişkenlerin Yörüngesi.....	54
Şekil 38: LSTM Bellek Hücresi Diyagramı.....	55
Şekil 39:LSTM ile Görsel Altyazısı Oluşturma.....	59
Şekil 40: LSTM ile Otomatik Metin Çevirisi	59
Şekil 41: LSTM ile Otomatik El Yazısı.....	60
Şekil 42: GRU Model Yapısı	61
Şekil 43: Analiz İçin Kullanılacak Python Kütüphaneleri.....	71
Şekil 44: Satır ve Sütun Sayısı.....	71
Şekil 45: AKSEN Hissesinin Tarihsel Kapanış Grafiği.....	72
Şekil 46: Veri Seti İçerisinden Eğitim Setini Ayarlamak	72
Şekil 47: GRU Modelinin Kodu	73
Şekil 48: GRU Modeline Kayıp Fonksiyonu ve Optimize Edici Atanması.....	73
Şekil 49: Girilmiş Olan Epoch ve Batch Sayılarına Göre Modelin Eğitilmesi.....	74
Şekil 50: MSE, MAE ve MAPE’ nin Sonuçlarının Çıktıları	74
Şekil 51: Tahmin Sonucunun Grafiği	75
Şekil 52: Gerçek Kapanış Değerleri ve Modelin Tahmin Değerleri.....	76
Şekil 53: LSTM Uygulaması İçin Kütüphanelerin İçeri Aktarılması	80
Şekil 54: LSTM Modeli	80

GİRİŞ

İlk para milattan önce 7. yüzyılda Lidyalılar tarafından icat edilmiştir. Ancak insanoğlu paranın icat edilmesinden yıllar öncesinde bile ellerindeki deniz kabuğu ve odun gibi malları birbirleriyle takas etme yoluyla ticaret yapmaktaydı (TÜBİTAK, 2021). 15. yüzyılda denizcilikte yaşanan teknolojik gelişmeler ve pusulanın icadı sayesinde dünya üzerinde yeni ticaret yolları bulunmuş ve bilhassa devletler arası ticaret gelişim göstermiştir. Dönemin en büyük denizci devletlerinden olan İtalyan şehir devletleri, İngiltere ve Hollanda gibi ülkelerin şehirlerinde kurulan kalabalık pazarlarda kıymetli madenler, mallar ve ticari senetlerin alınıp satılması borsacılığın ilk adımları olmuştur. Avrupa’ da ilk borsa günümüz Belçika’ sında bulunan Anvers şehrinde 1487 yılında faaliyete geçmiştir. Hollanda’ nın 16. yüzyılda ticarete gelişim göstermesi ve zenginleşmesi sonucunda Amsterdam’ da da borsacılık popülerleşmiş ve bazı kurallar getirilerek modern borsacılık anlamında atılımlar gerçekleştirilmiştir. Bu şehirleri 16. yüzyılda Paris ve Londra, 17. yüzyılda Berlin ve Basel, 18. yüzyılda Viyana ve New York ve 19. yüzyılda İstanbul, Roma, Milano, Madrid, Brüksel ve Tokyo borsalarının kurulması izlemiştir (Sayılğan, 1994: 28).

Finansal piyasaların giderek küreselleşmesi nedeniyle bu tahminler karmaşılaşp zorlaşmaktadır. Örneğin Amerika’ da Merkez Bankası’ nın aldığı bir karar Türkiye’ de dolar kurunu hemen etkilerken, aynı şekilde Türkiye’ nin coğrafyasında bulunan Rusya’ nın Ukrayna ile savaşması da Türkiye’ deki enerji piyasalarını ve fiyatlarını derinden etkilemektedir. Dolayısıyla örneklerdeki gibi birçok etkenin kolayca etkileşime girdiği durumlarda kullanılan teknikler ve basit istatistiksel hesaplamalar yetersiz kalmaktadır. Basit tekniklerin yetersiz kaldığı bu durumlara çözüm olarak ilk kez yaklaşık 80 sene önce temelleri atılan yapay zekâ algoritmaları ve teknikleri çözüm olarak ortaya çıkmıştır. Yapay zekânın en gelişmiş araçlarından bir tanesi de derin öğrenmedir. Derin öğrenmenin temelleri de ilk kez 1990’ ların sonunda atılmıştır. Derin öğrenme teknikleri, büyük veri kümelerindeki karmaşık yapıları anlamak ve modellemek için oldukça kullanışlıdır. Bu artışına ek olarak en yeni araçlardan bir tanesi olması ve diğer eski araçlara göre daha başarılı sonuçlar vermesinden dolayı da finans olmak üzere hayatın birçok alanında popülerliğini geliştirmektedir.

Bu çalışmada BİST (Borsa İstanbul)' te XELKT (Borsa İstanbul Elektrik Endeksi) endeksi baz alınarak, hisse senedi fiyatlarının derin öğrenme teknikleriyle tahmin edilmesi ve kullanılan tekniklerin hisse senedi fiyat tahmininde uygulanabilirliği amaçlanmaktadır. Buna ek olarak kullanılan yöntemler arasında yapılan kıyaslama ile hangisinin daha başarılı çıktılar verdiği saptanmaya çalışılmıştır. Çalışmada kullanılan yöntemler, LSTM ve GRU teknikleridir.

Üç bölümden oluşan bu çalışmanın ilk bölümünde, borsadaki hisse senetleri piyasası ve enerji sektörü hakkında bilgiler verilmiştir. XELKT endeksi tanıtılmış ve içerişimdeki şirketler tanıtılmıştır. Yenilenebilir ve yenilenemeyen enerji kaynaklarının tanımları, Türkiye' deki enerji kaynaklarına dair bilgiler, Türkiye' deki enerji kaynaklarıyla alakalı geçmişteki üretim ve tüketimlerin istatistiksel verileri ve gelecekteki üretim ve tüketim beklentileri anlatılmıştır. İkinci bölümde derin öğrenmenin tanımı, tarihçesi ve yöntemleri hakkında bilgi verilmiştir. Uygulamada kullanılan LSTM ve GRU teknikleri ile bu tekniklerin temeli olarak ileri sürülen RNN tekniği anlatılmıştır. Ayrıca RNN' in maruz kaldığı en büyük sorun olan kaybolan gradyan problemi de tanıtılmış ve çözüm olasılıklarından bahsedilmiştir. Ek olarak modellerin başarısını ölçmeye yarayacak model performans kriterlerinden de söz edilmiştir. Çalışmanın üçüncü bölümünde, literatür taraması yapılarak, veri seti tanıtılmış ve ikinci bölümde teorik olarak anlatılan teknikler uygulanarak yapılan analizlerin adımları açıklanmıştır. Analizde Google tarafından geliştirilmiş ve Python yazılım programı ortamını sunan Google Colab yazılım programı kullanılmıştır. Çalışma için BİST' te ve dolayısıyla enerji endeksi olan XELKT' de işlem gören şirketler arasından AKENR, AKSEN, AKSUE, AYEN ve ZOREN şirketleri seçilmişlerdir. Bu şirketlere ait veri seti 02.01.2013 ile 30.12.2022 tarihleri arasında 10 yılı kapsayacak şekilde belirlenmiştir. Şirketlere ait veriler Yahoo Finance' tan alınmıştır. Her bir şirket için oluşturulan veri seti 2511 gözleme ve 17 değişkene sahiptir. Bu veri setlerinde hisse senedi fiyatına etki edeceği düşünülen BİST 100, USD/TL ve XELKT değişkenlerine ait günlük açılış, kapanış en yüksek ve en düşük değerleri bulunmaktadır. Aynı şekilde her hisse senedi de kendisine ait açılış kapanış, en yüksek ve en düşük değerleri ile veri setinde yer almaktadır.

BİRİNCİ BÖLÜM

BORSA' DAKİ HİSSE SENETLERİ PİYASASI VE ENERJİ SEKTÖRÜ

1.1. TÜRKİYE' DE BORSA VE HİSSE SENETLERİ

6362 sayılı Sermaye Piyasası Kanunu' na göre borsanın tanımı aşağıdaki gibidir:

“Anonim şirket şeklinde kurulan, sermaye piyasası araçları, kambiyo ve kıymetli madenler ile kıymetli taşların ve kurulca uygun görülen diğer sözleşmelerin, belgelerin ve kıymetlerin serbest rekabet şartları altında kolay ve güvenli bir şekilde alınıp satılabilmesini sağlamak ve oluşan fiyatları tespit ve ilan etmek üzere kendisi veya piyasa işleticisi tarafından işletilen ve/veya yönetilen, alım satım emirlerini sonuçlandıracak şekilde bir araya getiren veya bu emirlerin bir araya gelmesini kolaylaştıran, bu kanuna uygun olarak yetkilendirilen ve düzenli faaliyet gösteren sistemleri ve pazar yerlerini” ifade eder (T.C. Resmi Gazete, 2012).

Tarih olarak ilk borsa faaliyetleri Osmanlı İmparatorluğu döneminde başlamıştır. 1854 yılındaki Kırım Savaşı için borçlanan Osmanlı İmparatorluğu' nun tahvillerinin İstanbul' da alım satım işlemi gerçekleşmiştir. Osmanlı İmparatorluğu' ndan alacaklı olan devletlerin destekleriyle 1866 yılında borsa kurulmuştur. Cumhuriyet döneminde ise 1929 yılında düzenlemeler yapılarak menkul kıymetler ve kambiyo borsaları kanunu yürürlüğe girmiştir. Türkiye' deki ilk modern anlamdaki borsa faaliyeti ise 26 Aralık 1985 yılında kurulan İstanbul Menkul Kıymetler Borsası (İMKB) ile başlamıştır. 2013 yılında ise İMKB, Vadeli İşlemler Opsiyon Borsası ve İstanbul Altın Borsası' nın birleşmesi sonucunda “Borsa İstanbul (BİST)” oluşumu ortaya çıkmıştır. Dolayısıyla İMKB yerini BİST' te bırakmıştır (Borsa İstanbul, 2023).

BİST faaliyetleri, Resmi Gazete' de “Borsa İstanbul A.Ş. Borsacılık Faaliyetlerine İlişkin Esaslar Yönetmeliği” başlıklı ve 29150 sayılı olarak 19 Ekim 2014 tarihinde aşağıdaki gibi belirlenerek yayınlanmıştır (T.C. Resmi Gazete, 2014).

“Bu Yönetmeliğin amacı, sermaye piyasası araçlarının ve Sermaye Piyasası Kurulu tarafından uygun görülen diğer sözleşmelerin, belgelerin ve kıymetlerin Borsa İstanbul Anonim Şirketi bünyesinde güvenilir, şeffaf, etkin, istikrarlı, adil ve rekabetçi bir ortamda işlem görmesine ilişkin usul ve esasları düzenlemektir.

Bu Yönetmelik;

- a) Kota alınma, kottan çıkarılma ile borsada işlem görme ve işlem görmenin durdurulması,
 - b) Emirlerin iletilmesi ve eşleştirilmesi,
 - c) Gerçekleştirilen işlemlere ilişkin yükümlülüklerin zamanında yerine getirilmesi,
 - ç) Borsada işlem yapma yetkisi verilmesi,
 - d) Disiplin düzenlemelerinin yürütülmesi,
 - e) Borsa gelirleri ile bunların tahsili,
 - f) Uyuşmazlıkların çözülmesi,
 - g) Borsa, Borsanın pay sahipleri ve/veya piyasa işleticisi arasındaki muhtemel çıkar çatışmalarının önüne geçilmesi,
 - ğ) Borsanın işletim, denetim ve gözetim sistemleri,
 - h) Piyasa oluşturma, işletme ve yönetilmesi
- konularına ilişkin usul ve esasları düzenler.”*

1.1.1. Hisse Senetleri

Hisse senedi, bir ticari işletmeye ait olan gayrimenkul, makine, demirbaş, para, borç ve alacaklar, başka işletmelerde bulunan iştirak payları ve patentlerinin oluşturduğu tüm maddi varlıkların ve manevi varlıkların belirli bir parçasını temsil eden mülkiyet senedidir. Bir şirkete ait hisse senedi sahip olan kimse ayrıca söz konusu şirketin aktif ve pasiflerindeki her şeye ortak olmuş olur (Bakkal, Bakkal, & Öztürk, 2012: 15).

Hisse senedinin fiyatı belirlenirken mevcut yıldaki üretim düzeyi, ekonomik seyir veya şirketlerin ilgili dönemde gösterdiği performans yani kısaca genel ekonomik durum etkili olmaktadır. Etkin bir piyasa durumunda bu bilgiler yatırımcı tarafından kolayca öğrenilebileceği için hisse senedi fiyatları sürekli ve aşırı tepkilerle değişmez. Dolayısıyla işlemeye ait tüm bilgiler ışığında hisse senedi fiyatı belirlendiği için bu fiyat doğru bir fiyattır (Aytekin, 2018: 167).

Hisse senetleri fiyatları medyadaki haberlerden oldukça fazla etkilenmektedirler. Örneğin ekonomiye ve siyasete dair kötü haberler borsada fiyatları

düşürürken, iyi haberler ise borsadaki fiyatları arttırmaktadır (Özçalık & Özçalık, 2020: 375).

1.1.2. Hisse Senedi Analiz Yöntemleri

1.1.2.1. Temel Analiz

Hisse senedinin asıl değerini kavrayabilmek ve ona göre strateji belirlemek amacıyla şirketin faaliyet gösterdiği sektör incelenip analiz edilir ve şirketin kazancı ile gelecekteki büyüme potansiyeli göz önünde bulundurularak bir karara varılır. En yaygın kullanılan analiz çeşididir (Öndeş vd., Sermaye ve Para Piyasaları, 2014: 181)

1.1.2.2. Teknik Analiz

Teknik analiz, geçmişteki finansal verileri matematiksel ve görsel metotlar ile inceleyerek geleceği tahmin etme ve geleceğe yön verme amacıyla kullanılır. Teknik analiz araçlarının özellikleri bakımından iki farklı gruba ayrılmaktadır. Hareketli ortalamalar, indikatörler gibi araçların matematiksel ve istatistiksel metotların kullanıldığı birinci grup varken, ayrıca Fibonacci çizgileri, Eliot dalgaları, trend çizgilerinin oluşturduğu daha çok görsel olan ikinci grup vardır (Akça, 2005: 5).

1.1.3. XELKT Endeksi

BİST’ te toplam 55 adet endeks yer alır ve XELKT kodlu enerji endeksi bunlardan bir tanesidir. XELKT endeksinde sadece enerji sektöründe faaliyet gösteren şirketler bulunmaktadır. Endeks 27 Aralık 1996’ dan beri işlem görmektedir (Kamuyu Aydınlatma Platformu, 2023).

XELKT endeksinde toplamda 23 adet şirket yer almaktadır. Tablo 1’ de bu şirketlerin borsadaki hisse senedi adları ve borsada işlem gördükleri ilk tarihe dair bilgiler verilmektedir.

Tablo 1: BİST XELKT Endeksindeki Şirketler ve İlk İşlem Tarihleri

Hisse Senedi Adı	Şirketin Adı	Borsadaki İlk İşlem Tarihi
AHGAZ	Ahlatçı Doğal Gaz Dağıtım Enerji ve Yatırım A.Ş.	23/12/2022
AKENR	Akenerji Elektrik Üretim A.Ş.	10/07/2000
AKSEN	Aksa Enerji Üretim A.Ş.	24/05/2010
AKSUE	Aksu Enerji ve Ticaret A.Ş.	05/01/2000
ALFAS	Alfa Solar Enerji Sanayi ve Ticaret A.Ş.	17/11/2021

ARASE	Doğu Aras Enerji Yatırımları A.Ş.	12/11/2021
AYDEM	Aydem Yenilenebilir Enerji A.Ş.	30/04/2021
AYEN	Ayen Enerji A.Ş.	06/07/2000
BIOEN	Biotrend Çevre ve Enerji Yatırımları A.Ş.	29/04/2021
CANTE	ÇAN2 Termik A.Ş.	03/05/2021
CONSE	Consus Enerji İşletmeciliği ve Hizmetleri A.Ş.	21/04/2022
ENJSA	Enerjisa Enerji A.Ş.	09/02/2018
ESEN	Esenboğa Elektrik Üretim A.Ş.	12/10/2020
GWIND	Galata Wind Enerji A.Ş.	26/04/2021
HUNER	Hun Yenilenebilir Enerji Üretim A.Ş.	22/02/2022
KARYE	Kartal Yenilenebilir Enerji Üretim A.Ş.	19/07/2021
MAGEN	Margün Enerji Üretim Sanayi ve Ticaret A.Ş.	01/10/2021
NATEN	Naturel Yenilenebilir Enerji Ticaret A.Ş.	09/08/2019
NTGAZ	Naturelgaz Sanayi ve Ticaret A.Ş.	02/04/2021
ODAS	Odaş Elektrik Üretim Sanayi Ticaret A.Ş.	22/05/2013
PAMEL	Pamel Yenilenebilir Elektrik Üretim A.Ş.	16/06/2014
SMRTG	Smart Gün. En. Tek. Araş. Gel. Üretim Sanayi ve Ticaret A.Ş.	25/03/2022
ZOREN	Zorlu Enerji Elektrik Üretim A.Ş.	26/05/2000

Yukarıdaki tabloda yer alan 23 şirket arasından şirketlerin borsadaki ilk işlem tarihleri dikkate alınarak 5 şirket çalışma için seçilmiştir. Seçilen bu şirketlere ait ayrıntılı bilgiler aşağıda yer almaktadır.

1.1.3.1. Akenerji Elektrik Üretim A.Ş.

Akenerji 1989 yılında kurulmuştur. Türkiye' nin ilk otoprodüktör enerjisi üreten şirketi olarak faaliyetlerine başlamıştır. 2021 yılı sonu itibariyle 266 çalışanıyla ve 1 adet doğal gaz, 1 adet rüzgar ve 7 adet de hidroelektrik santrali olmak üzere toplam 9 adet santral ile hizmet vermektedir. Bu 9 adet santralde toplam 1224 MW elektrik üretilmektedir. Şirketin hizmet gösterdiği alanlar ise elektrik üretimi ve satışı, elektrik ihracatı ve toptan ticareti, elektrik perakende satışı, doğal gaz ithalatı, ihracatı

ve toptan ticareti ve enerji servislerinden oluşmaktadır (Akenerji Elektrik Üretim A.Ş., 2023).

1.1.3.2. Aksa Enerji Üretim A.Ş.

Aksa Enerji Üretim A.Ş., Kazancı Holding iştiraki olarak 1997 yılında kurulmuştur. Şirket, Türkiye'nin en büyük halka açık serbest elektrik üreticisi olma özelliğini taşımaktadır. 2021 yılı itibariyle Avrupa, Afrika ve Asya olmak üzere 3 kıtadaki 7 ülkede 8 santral ile hizmet vermektedir. Bu 8 adet santralin 2 adeti doğal gaz, 1 adeti termik ve 5 adeti de akaryakıt santrallerinden oluşmaktadır. 2021 sonu itibariyle kurulu güç miktarı 1.966MW' tır. 2021 yılında 1,680,000,000 Türk Lirası kâr açıklanmıştır. 30 Eylül 2022 yılı itibariyle 1231 çalışanı bulunmaktadır. (Aksa Enerji Üretim A.Ş., 2023).

1.1.3.3. Aksu Enerji ve Ticaret A.Ş.

30 kurucu ortak tarafından Türkiye' nin ilk yap-işlet-devret modeli şirketi olma özelliğini taşıyarak 21 Kasım 1985 tarihinde kurulmuştur. Şirket güneş enerjisi santralleri ve hidroelektrik santrallerinde hizmet göstermektedir. Şirketin tamamı halka açıktır ve hiçbir ortağın sermaye payı %10' dan fazla değildir. 31 Aralık 2021 itibariyle şirketin 16 çalışanı bulunmaktadır (Aksu Enerji ve Ticaret A.Ş., 2023).

1.1.3.4. Ayen Enerji A.Ş.

1990 yılında kurularak faaliyetlerine başlamıştır. Şirketin üretimlerinin %68' ini hidroelektrik oluştururken %32' lik kısmını ise rüzgar enerjisi oluşturmaktadır. 2021 yılı içerisinde 637.758.867 kWh hidroelektrik enerjisi ve 393.934.660 kWh güneş enerjisi olmak üzere toplam 1.031.693.527 kWh elektrik enerjisi üretilmiştir. Türkiye' ye ek olarak Arnavutluk, Sırbistan ve Slovenya' da faaliyetlerde bulunmaktadır. 2021 raporlarına göre şirkette 255 kişi çalışmaktadır (Ayen Enerjisi A.Ş, 2023).

1.1.3.5. Zorlu Enerji Elektrik Üretim A.Ş.

1993 yılında Zorlu Grubu' na ait sanayi kuruluşlarının elektrik ve buhar ihtiyaçları gidermek amacıyla kurulmuştur. Şirketin faaliyet gösterdiği alanlar elektrik üretimi, elektrik dağıtımı, elektrik satışı ve ticareti, doğal gaz dağıtımı ve ticareti, iletme ve bakım, güneş panelleri ticareti, akıllı sistemler ve son olarak elektrikli araç şarj istasyonları olarak söylenebilir. Şirket toplam 990 MW kurulu güce sahiptir. Bu

kurulu güç içerisinde 643 MW Türkiye’ de bulunmaktadır. Sahip olunan 19 santralin 14’ ü Türkiye’ de geri kalan 5’ i de Pakistan, İsrail ve Filistin’ de bulunmaktadır. Türkiye’ de bulunan santrallerin 7’ si hidroelektrik, 4’ ü jeotermal, 2’ si doğal gaz ve 1’ i rüzgar santralleridir. Yurtdışında Pakistan’ da 1 adet rüzgar santrali, Filistin’ de 1 adet güneş santrali ve İsrail’ de 3 adet doğal gaz santrali bulunmaktadır. 2021 yılı raporlarına göre şirkette 2048 kişi istihdam edilmektedir (Zorlu Enerji Elektrik Üretim A.Ş., 2023).

1.2. TÜRKİYE’ DE ENERJİ SEKTÖRÜ

2022 yılında Türkiye’ nin elektrik enerjisi tüketimi önceki yıl olan 2021’ e göre %1.2 azalmıştır ve 328.9 TWh düzeyine gerilemiştir. Elektrik üretimi de 2021 yılına göre %2.5 azalmış ve 326.2 TWh düzeyine gelmiştir. Türkiye Ulusal Enerji Planı’ nın gelecek için yaptığı çalışmada gelecekte Türkiye’ nin elektrik tüketimi 2025 yılı için 380.2 TWh, 2030 yılı için 455.3 TWh 2035 yılında da 510,5 TWh olacaktır. Nisan 2023 sonu itibariyle Türkiye’ nin kurulu gücünün kaynakları şöyledir: %30.2 hidrolik enerji, %24.3 doğal gaz, %20.9 kömür %11 rüzgar, % 9.5 güneş, %1.6 jeotermal ve %2.5 de diğer enerji kaynakları olarak dağılmaktadır. Türkiye’ nin sahip olduğu santraller ise şöyle dağılmaktadır: 751 hidroelektrik, 67 kömür, 361 rüzgar, 63 jeotermal, 345 doğal gaz, 9864 güneş ve 491 adet de diğer kaynaklar (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

1.2.1. Yenilenebilir Enerji Kaynakları

Yenilenebilir enerjiler, doğal bir çevrim sürecinde değişmeyip aynen kalabilen, kullanıldığında azalmayan ve tükenmeyen enerji türleridir (Koç & Kaya, 2015: 37).

Yenilenebilir enerji, sürekli yenilenen doğal süreçlerden üretilir. Bazen güneş, rüzgar, yağmur, okyanus gelgitleri, biyokütle ve jeotermal gibi kaynaklardan direkt olarak elde edilmektedir (Montasham, 2015: 1290).

Yenilenebilir enerji kaynakları:

- Güneş
- Rüzgar
- Hidroelektrik
- Jeotermal

- Biyokütle

Türkiye’ de yenilenebilir enerji, son yıllarda hidroelektrik, rüzgar ve güneş enerjilerindeki büyümenin sonucunda artış göstermiştir. 2018 yılında toplam nihai enerji tüketimi içerisinde toplam yenilenebilir enerjinin %60’ ı yenilenebilir elektrik tarafından gerçekleştiriyordu. Jeotermal ve biyoenerjiden elde edilen ısı enerjisi de büyük rol oynamaktadır. Güneş ve biyokütle enerjilerinin rolü ise oldukça azdır (International Energy Agency, 2021:73).

1.2.1.1. Güneş Enerjisi


Kurulmasının ve kullanılmasının kolay olması ayrıca çevreyi kirletmemesi ve zararlı atık oluşturmaması güneş enerjisini yenilenebilir enerji kategorisine koymaktadır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Güneş enerjisi, gezegenimizdeki en bol yenilenebilir kaynaktır. Bu bolluğa rağmen, fotovoltaik panel kullanmak fosil yakıtlı enerjileri kullanmaktan daha maliyetli olduğu için insanlar tarafından kullanılan enerjinin küçük miktarı güneşten gelmektedir (Moulé, 2010: 123).

Güneş, çapının yaklaşık 1,4 milyon kilometre, çekirdek sıcaklığının ise 15 milyon °C olduğu bir yapıya sahiptir. Bu olağanüstü sıcaklık eğer dünyadaki atmosferik basınçtan 70 milyar kat daha büyük bir basınçla birleşirse füzyon reaksiyonları için ideal koşullar oluşur (Ghosh & Prelas, 2011: 79).

Güneşin çekirdeğinde yer alan füzyon süreci diğer bir deyişle hidrojen gazının helyuma dönüşmesi işlemi sonucunda açığa çıkan ısıma enerjisidir. Güneşin yaydığı yaklaşık $3.9 \times 10^{26} W(Watt)$ güçteki enerjiden çok az bir miktar dünyaya ulaşmaktadır. Bu güç içerisinde atmosferin dış yüzeyindeki her m^2 ’ ye ortalama 1367 W güç düşmektedir. Ancak atmosfere düşen ışımaların çoğunlukla X ışınları ve ultraviyole ışınlarından oluşan bir bölümü emilirken diğer bölümü de yansıtılmaktadır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Şekil 1: Türkiye Yıllık Güneş Radyasyonu Haritası




Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Türkiye coğrafi konumundan dolayı güneş enerjisinde önemli potansiyele sahiptir. T.C. Enerji ve Tabii Kaynaklar Bakanlığı' nca hazırlanan Güneş Enerjisi Potansiyeli Atlasından (GEPA) alınan bilgilerle Türkiye' de ortalama yıllık toplam güneşlenme süresi 2741 saat, ortalama yıllık toplam ışıınım değeri de 1.527.46 kWh/m²' dir (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Şekil 1' e göre Türkiye' de güneş ışıını en çok güney bölgelerine düşmektedir. Miktar bakımından bu bölgeler içerisinde Akdeniz Bölgesi' nde Antalya ve Karaman illerinin çevreleri ve Güneydoğu Anadolu Bölgesi' nde ise Van ve Hakkari illerinin çevreleri ön plana çıkmaktadır.


Şekil 2: Aylık Ortalama Radyasyon Değeri (kWh/m²)



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Şekil 2' den de anlaşılacağı üzere Türkiye' ye en çok güneş ışınları hava sıcaklığının yüksek olduğu Haziran ve Temmuz aylarında düşmektedir. En düşük değerler ise kışın sert geçip sıcaklıkların düşük olduğu Aralık ve Ocak aylarında görülmektedir.


Şekil 3: Kurulu Güç (MW – Mega Watt)



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Şekil 3 ve Şekil 4’ teki bilgilere göre 2022 yılının Haziran ayı sonu itibariyle Türkiye’ de güneş enerjisine dayalı elektrik kurulu gücü 8479 MW iken güneş enerjisinin toplam kurulu güç içerisindeki oranı ise %8,35’ tir.

Şekil 4: Toplam Kurulu Güç İçerisindeki Oran



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023


1.2.1.2. Rüzgar Enerjisi

Güneş enerjisinin dolaylı bir şekli olan rüzgar enerjisi, yeryüzünde her bölgenin farklı şekilde ısınmasından kaynaklı oluşan alçak basınç ve yüksek basınç merkezlerinin birbirlerini karşılıklı etkilemelerinden meydana gelmektedir (Doğanay & Coşkun, 2020: 252).

2006 yılında hazırlanan Türkiye Rüzgar Enerjisi Potansiyeli Atlası (REPA - V1) verilerine göre yüksekliğin yer seviyesinden 50 metre yüksek olduğu ve yıllık ortalama rüzgar hızının da 7.5 m/s olan alanlarda kilometrekare başına 5 MW gücünde rüzgar santrali kurulabilmektedir. Türkiye’ de bu kriterlere göre kurulması mümkün rüzgar elektrik santrallerinin toplam kapasitesi 47.849.44 MW güçtedir. Bu potansiyel güce karşılık gelen toplam alan Türkiye’ nin yüzölçümünün %1.30’ una tekabül etmektedir. Türkiye’ de rüzgar enerjisine dayalı elektrik kurulu gücü 2022 yılı Haziran ayı sonu itibariyle 10.976 MW ve böylelikle rüzgar enerjisinin Türkiye’ deki toplam kurulu güç içerisindeki oranı %10,81’ dir (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Şekil 5’ te Türkiye haritası üzerinde metre bölü saniye bazında Türkiye sınırları içindeki rüzgarların hızları verilmiştir. Haritaya göre Türkiye’ nin rüzgar bakımından en zengin bölgesi Kuzey Batı Ege ve Batı Marmara bölgeleridir.

Şekil 5: Türkiye’ de Rüzgar Hızı (m/s)



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

1.2.1.3. Hidroelektrik Enerjisi

Hidroelektrik santralleri, elektrik üretmek için nehir ve şelale gibi akışa sahip suların kinetik enerjisinden faydalanır. Bir türbin ve bir jeneratör sudan gelen kinetik enerjiyi bir jeneratör kullanarak önce mekanik enerjiye sonra da elektrik enerjisine dönüştürür (Ghosh & Prelas, 2011: 157).

Hidroelektrik su döngüsü sayesinde yenilenebilir enerji olmaktadır. Dolayısıyla hidroelektrik enerjisini anlayabilmek için üç aşamalı su döngüsünü de anlamak oldukça önemlidir (U.S. Energy Information Administration, 2022):


1. Adım: Güneş, yeryüzündeki nehir, göl, deniz ve okyanusları ısıtması sonucu bu su kaynaklarında buharlaşma meydana gelir.

2. Adım: Buharlaşan sular yoğunlaşarak bulut formunu alır ve yeryüzüne yağmur veya kar olarak yağarlar.

3. Adım: Yağış sonucunda okyanuslara, denizlere ve göllere dökülen akarsularda ve nehirlerde toplanıp burada buharlaşır. Böylelikle döngü tekrar başlamış olur.

Ancak hidroelektriğin dezavantajları da mevcuttur. Bunlar: yüksek basınç maliyetleri, yağışlara bağımlı olması, arazi ve yaban hayatın sular altında kalma riski ve bölge insanının yerinden edilmeleri dezavantajlar arasındadır (Montasham, 2015: 1291).


Şekil 6: Hidroelektrik Enerjisine Dayalı Kurulu Güç



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Şekil 6' e göre 2022 yılı Haziran ayı sonu itibariyle Türkiye' de hidroelektrik enerjisine dayalı kurulu güç 31.558 MW' tır.

Şekil 7: Hidroelektrik Enerjisinin Toplam Kurulu Güç İçerisindeki Oranı



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Yukarıdaki şekle göre Türkiye’ de hidroelektrik enerjisinin gücünün oranı toplam kurulu güçler içerisinde %31’ dir.

1.2.1.4. Jeotermal Enerji

Yer kabuğunun içinde ve birçok derinlikte muhafaza biçiminde duran sıcak su, buhar, gaz ya da sıcak kuru kayaların barındırdığı enerjiye jeotermal enerji denilmektedir (Türkiye Maden Mühendisleri Odası (TMOOB), 2023).


Yerkabuğunda yer alan ısı coğrafi olarak oldukça değişken bir biçimde dağılmıştır. Bu nedenle en yüksek ısı aktif tektonik levha sınırları ve volkan faaliyetlerinin fazla olduğu bölgelerde görülmektedir (Barbosa, Sigfusson, Carlsson, & Tzimas, 2017: 6671).

Isı, enerji çeşitlerinden bir tanesidir ve jeotermal enerji de dünyada büyük ölçeklerde jeolojik olaylar üreten ısıdır. Gelişmiş teknolojiyle birlikte günümüzde insanlık jeotermal enerjiyi ihtiyaçları gidermede kullanılabilmektedir (Dickson & Fanelli, 2003: 2).

Türkiye’ de ilk kez jeotermalden elektrik üretimi 1975 yılında Maden Tetkik ve Arama (MTA) Genel Müdürlüğü tarafından 0,5MW güce sahip Kızıldere Santralinde yapılmıştır. Türkiye’ nin dört bir yanına yayılmış yaklaşık 1000 adet doğal çıkış durumunda ve değişik sıcaklıklarda birçok jeotermal kaynak vardır. Türkiye’ de jeotermal açısından oldukça zengin bir ülkedir. Bu potansiyel açısından %78’ lik oran ile Batı Anadolu birinci sıradadır. Batı Anadolu’ yu %9 ile İç Anadolu, %7 ile Marmara, %5 ile Doğu Anadolu ve %1 ile de diğer bölgeler takip etmektedir. Türkiye’ de jeotermal enerjiden en çok elektrik üretimi, ısıtma, termal ve sağlık turizmi, endüstriyel mineral, balıkçılık, kurutmacılık gibi alanlarda faydalanılmaktadır (MTA, 2023).

Şekil 8’ de Türkiye’ de bulunan jeotermal suların alanları ve bu suların sıcaklığı hakkında bilgiler mevcuttur. Buna göre sıcaklığın en fazla olduğu bölgeler öncelikle Batı Anadolu Bölgesi, daha sonra ise Doğu Anadolu Bölgesi’ nde Ağrı şehri ve çevresidir.


Şekil 8: Türkiye Jeotermal Kaynak Alanları ve Sıcaklık Dağılımı



Kaynak: MTA, 2023

2022 yılı Haziran ayının sonu itibariyle Türkiye’ de jeotermal enerji kurulu gücü 1686 MW’ tır.


Şekil 9: Türkiye Jeotermal Enerji Kaynaklı Kurulu Güç



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Şekil 9 ve Şekil 10 grafiklerindeki verilere göre jeotermal enerjisi, 2022 yılı Haziran ayı sonu itibariyle Türkiye’ deki toplam kurulu güç içerisinde %1,66’ lık bir orana sahiptir.

Şekil 10: Jeotermal Enerjisinin Toplam Kurulu Güç İçerisindeki Oranı



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

1.2.1.5. Biyokütle Enerjisi

Atıkları ve kalıntıları da dahil olmak üzere bitki ve hayvanların materyallerine biyokütle denir. Organik, karbon bazlı bir yapıda olup, ısıyı elde etmek için yanma ve doğal metabolik süreçler içerisinde oksijen ile reaksiyona girer. Eğer ısıнын sıcaklığı 400°C' tan büyük ise elektrik ve iş üretimi için idealdir (Twidell & Weir, 2006: 351).

Odunculuk, tarım ve ormancılık kalıntıları, mevcut başlıca yenilenebilir enerji kaynaklarından bazılarıdır. Belediye katı atıklarına ek olarak ticari ve endüstriyel atıkların biyolojik olarak parçalanabilen bileşenleri de önemli biyoenerji kaynakları arasındadır. Günümüzün modern dünyasında biyokütle enerjisi hem gelişmiş hem de gelişmekte olan ülkelerin ihtiyaçlarını giderme konusunda en yüksek potansiyelli enerji kaynağı olarak düşünülmektedir. Ayrıca kısa dönemli ormancılık ve diğer kaynaklardan elde edilen biyokütle enerjisi sera gazı emisyonlarının azaltılması ve iklim değişikliğinin önlenmesi konularında Kyoto Protokolü' nün amaçlarına büyük ölçüde yardımcı olmaktadır (Bridgewater, 2006: 1755).


Türkiye Cumhuriyeti 5346 sayılı kanunundaki biyokütle tanımına göre:

“İthal edilmemek kaydıyla; belediye atıklarının (çöp gazı dâhil) yanı sıra bitkisel yağ atıkları, gıda ve yem değeri olmayan tarımsal atıkları, endüstriyel odun dışındaki orman ürünleri ile atık lastiklerin işlenmesi sonucu ortaya çıkan yan ürünlerden elde

edilen kaynakları ve sanayi atık çamurları ile arıtma çamurlarını ifade eder” (T.C. Resmi Gazete, 2005)

T.C. Enerji ve Tabii Kaynaklar Bakanlığı’ nca biyokütle enerji potansiyelinin belirlenmesi amacıyla hazırlanan Biyokütle Enerjisi Potansiyel Atlası (BEPA) verilerine göre toplanıp değerlendirilme imkanı olan atıkların toplam ekonomik enerji değeri yaklaşık 3.9 MTEP (Milyon Ton Eşdeğer Petrol) / yıl olarak hesaplanmıştır. Böylelikle Türkiye’ de 2022 yılı Haziran ayı sonu itibariyle biyokütle ve atık ısı enerjisine dayalı kurulu güç 2172 MW’ tır (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).


Şekil 11: Türkiye’ de Biyokütle Enerjisi Kurulu Güç Miktarı (MW)



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Şekil 12’ e göre Türkiye’ deki toplam kurulu güçler arasında biyokütle enerjisinin oranı %2.14’ tür.

Şekil 12: Biyokütlenin Türkiye’ deki Toplam Kurulu Güç İçerisindeki Oranı



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

1.2.2. Yenilenemeyen Enerji Kaynakları

Yenilenemeyen enerji kaynakları, devamlı şekil değiştiremeyen, şekil değiştirmesinin de çok yavaş olan ve tamamen doğal süreçlere bağımlı olan kaynaklardır. Yenilenemeyen enerjiler kategorisinde olan fosil yakıtlar, bitki ve hayvanların çürümesinden elde edilebilir ancak bu elde etme işlemi çok yavaş olduğu için kullanılan fosilin yerine konması yüzlerce milyon yılı bulabilmektedir. Bu nedenle de tüketilmiş kaynaklar olarak kabul edilip yenilenemeyen enerji kaynakları olarak adlandırılırlar. Yenilenemeyen enerji kaynakları (Gosh & Prelas, 2009: 2):


- Kömür
- Petrol
- Nükleer Enerji
- Doğal Gaz

1.2.2.1. Kömür

Kömür, içeriğinde yüksek miktarda karbon ve hidrokarbon bulunduran ayrıca yanıcı özelliğe de sahip siyah bir kayadır. Kömürün içerisinde yüz milyonlarca yıl önce bataklık ormanlarında yaşayan bitkilerin depoladığı enerji mevcuttur. Bitkilerin, toprak ve kaya katmanları tarafından milyonlarca yıl korunması sonucunda da bitkiler

kömür formuna dönüşmüşlerdir. Bu olayın gerçekleşmesi milyonlarca yıl sürdüğünden dolayı kömür yenilenemez enerji olarak kabul edilmektedir (U.S. Energy Information Administration, 2022).


Şekil 13: Kömürün Oluşma Süreci



Kaynak: Türkiye Kömür İşletmeleri, 2023

Şekil 13’ teki tanımla kömür; yüksek basınç ve sıcaklığa maruz kalarak sıkışıp katılaşan bitki kalıntıları ile inorganik minerallerin oluşturduğu tortul bir kayalardır. Şekil 14’ ten de anlaşılacağı üzere 2018 yılındaki kömür üretimi 1972 yılına göre artmıştır. Ancak Türkiye’ de üretilen kömür miktarının Türkiye’ de tüketilen toplam enerji miktarını karşılama oranı da 2018 yılında 1972 yılına göre azalma göstererek %20’ lik orandan %11,52’ lik bir orana düşmüştür (Türkiye Taş Kömür İşletmeleri Kurumu, 2023).

Şekil 14: Türkiye’ de Enerjiye ve Kömüre Ait Üretim – Tüketim ve Enerji Tüketimini Karşılama Oranı Grafiği



Kaynak: Türkiye Kömür İşletmeleri, 2023

1.2.2.2. Petrol

Petrol kelimesi İngilizcede “petroleum” demektir ve bu kelime, “kaya” anlamına gelen Latince petra ve “yağ” anlamına gelen oleum’dan türetilmiştir (American Association of Petroleum Geologists (AAPG), 2023).

Petrol kelimesinin ilk kullanımı Georgius Agricola ismiyle tanınan Almanya doğumlu George Bauer tarafından 1556 tarihli “De Re Metallica” adlı eserinde gerçekleşmiştir (McDonald, 2011:351).

Hidrojen ve karbondan oluşan petrolün yapısında az miktar da olsa nitrojen, oksijen ve kükürt de yer almaktadır. Dolayısıyla petrolün yalın bir formülü mevcut değildir. Rafine edilmemiş petrol eğer sıvıysa ham petrol, gaz halindeyse doğal gaz, yarı katı hal ve tamamen katı halde olup ayrıca ağır hidrokarbon ve katran barındıran petroler ise özelliklerine ve yöresel kullanımlarına göre asfalt, zift, katran vb. adlandırılır. Ayrıca ham petrol ile doğal gaz ana elementleri hidrojen ve karbon olmasından dolayı hidrokarbon ismi de kullanılmaktadır (Petrol ve Doğal Gaz Platformu Derneği (PETFORM), 2020).

Petrolün oluşumuyla ilgili kesin bir bilgi yoktur. Ancak 1900’lerin başında başlayan araştırmaların sonucunda durgun deniz ve göl tabanlarında yaşamlarını kaybetmiş canlıların birikmesi sonucu petrol oluştuğu düşünülmektedir. Yaşam

özelliğini kaybetmiş ölü organizmalar, akarsuların taşıdığı kum, kil ve mineral parçacıklarıyla tabana çökerler. Bu çökme olayının milyonlarca sürerek çöken malzemenin kalınlığını artırır. Malzemeler çökerken oluşan gözenekler su ile dolarsa petrol oluşumu yaşanırken su yerine hava ile dolarsa doğal gaz oluşur. Bu oluşumlar, yer altındaki ısı, radyoaktif element ışıması, bakteri etkisi ve üst ağırlık baskısı etkenler sonucu oluşan kimyasal bozulma ve moleküler değişimin sonucunda gerçekleşmektedir (İstanbul Teknik Üniversitesi, Petrol ve Doğal Gaz Mühendisliği Bölümü: 2023).

Türkiye’ de 2019 yılında 340.863 sondaj çalışma yapılmış ve 153 kuyu açılmıştır. Ayrıca 2.984.800 ton ham petrol üretimi yapılmış olup geriye kalan üretilbilir petrol rezervi 51.076.078 tondur (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Şekil 15: Milyon Ton Bazında Türkiye’ de Petrol Üretimi



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Şekil 16: Türkiye’ de 2012-2021 Yılları Arasında Günlük Ortalama Üretilen Ham Petrol Varili Sayısı



Kaynak: Türkiye Petrolleri Anonim Ortaklığı (TPAO), 2021:41


Şekil 16' ya göre 2013 ve 2017 yılları haricinde ham petrol üretimi 2012 yılından 2021 yılına kadar artarak devam etmiştir ve sonuç olarak 2012 yılında günlük üretilen varil sayısı 50.127 iken bu sayı dokuz sene sonrasında 2021 yılında %38 artışla 69.332 varile çıkmıştır.

1.2.2.3. Doğal Gaz

Doğal gaz antik çağlardan bu yana insanlık tarafından bilinmektedir. MÖ 1000 yıllarında antik Yunanistan' da bulunan Delphi şehri Parnassus dağında doğal gazın bulunduğu bölgeye inşa edilmiştir. Ayrıca MÖ 500 yıllarında Çinliler yer altından sızan gazı taşımak ve bu gazı ocaklarında ateş olarak kullanmak için boru hatları inşa etmişlerdir. Doğal gazın ilk ticari kullanımı 1785 yılı civarlarında İngiltere' de kömürde üretilen doğal gazın fenerlerde ve sokak lambasında kullanımıdır (American Public Gas Association, 2023).

Doğal gazın içerisinde birbirinden farklı moleküler özellik yapısında olan ve doğal olarak oluşan dört gaz bulunmaktadır. Bu karışımın %70-90' ı metandan oluşurken diğer kalan kısımlar etan, bütan ve propan tarafından oluşmaktadır. Dünya yüzeyinin altında milyonlarca yıldır gömülü olan ölü organizmaların yarattığı sıkıştırılmış ısı ve basının sonucu bu dört gaz oluşmuştur. Doğal gaz sondajları ve petrol sondajları sayesinde elde edilmektedir. Elde edilme işleminden sonra sıvı haldeki ham petrol ile birleştirilerek günlük kullanıma hazır hale getirilir (American Petroleum Institute, 2023).


Şekil 17: 2011-2021 Yılları Doğal Gaz Üretim Miktarları (Milyon Sm³)



Kaynak: T.C. Enerji Piyasası Düzenleme Kurumu, 2022

Şekil 17’ den de anlaşılacağı üzere 2011 yılında son 10 yılın zirvesini gören doğal gaz üretim miktarı, 2021 yılına gelindiğinde %48’ lik bir düşüşle 394 Milyon Sm³ olmuştur.

Şekil 18: Türkiye Doğal Gaz İthalat/İhracat (milyon m³)



Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023

Doğal gaz bakımından kısıtlı kaynaklara sahip olan Türkiye’ nin doğal olarak doğal gaz ithalatı doğal gaz ihracatına oranla çok daha fazladır. Şekil 18’ de Türkiye’ nin doğal gaz ithalatına ve ihracatına dair bilgiler yer almaktadır.

1.2.2.4. Nükleer Enerji

Nükleer enerji, proton ve nötronların meydana getirdiği atomik çekirdek olarak adlandırılan çekirdekten yayılan bir enerji çeşididir. Nükleer enerjiyi üretmenin iki yolu vardır:

Fisyon: Atomların çekirdekleri birkaç parçaya bölünerek

Füzyon: Çekirdekler bir araya gelerek

Günümüzde nerdeyse tüm dünyada elektrik üretmek için kullanılan nükleer enerji fisyon yöntemiyle olurken, füzyon yönteminden elektrik üretmek şu an araştırılma aşamasındadır (International Atomic Energy Agency, 2022).

Türkiye’ de şu anda bir adet nükleer enerji santrali inşaatı mevcut iken bir adet de yapılması planlanmaktadır. Bunlardan inşaat halinde olan Mersin şehrinde 2015 yılında inşaatına başlanmış Akkuyu Nükleer Güç Santrali’ dir. Planlanma aşamasındaki santral ise Sinop şehri civarına düşünülen Sinop Nükleer Güç Santrali’ dir (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2023).

Birinci bölümde Türkiye’ de borsa ve hisse senetleri, çalışmada kullanılan şirketlere ait bilgiler, yenilenebilir ve yenilenemeyen enerji kaynakları ve Türkiye’ de enerji sektörü hakkında bilgiler verilmiştir. İkinci bölümde derin öğrenmenin tanımı, tarihçesi, derin öğrenme türleri ve derin öğrenme teknikleri hakkında bilgiler verilecek.

İKİNCİ BÖLÜM


DERİN ÖĞRENME YÖNTEMİ

2.1. DERİN ÖĞRENME YÖNTEMİNİN TANIMI

Derin öğrenme, insanların gördüğü görüntüyü ve duyduğu sesi tanımlayabilme ve tahmin yapabilme gibi yeteneklerini bilgisayarlara öğretmeye yarayan bir makine öğrenimi türüdür (Aktürk & Talan, 2022: 108). Başka bir kaynakta derin öğrenme; çok katmanlı yapay sinir ağlarını nesne tanıma, konuşma tanıma ve doğal dil işleme gibi alanlarda kullanan bir yapay zekâ yöntemi ve makine öğrenmesinin çeşitlerinden bir tanesidir. Klasik programlama yöntemlerinde öğrenme önceden kodlanmış kurallar ile yapılırken, derin öğrenmede öğrenme işlemi, otomatik bir şekilde görsel, ses ve metinsel verilerin simgelerinden gerçekleştirilmektedir. Yapılarının esnek olması sayesinde ham görsel ve ham metinsel verilerden öğrenim yapabilmekte ve veri setinin büyüklüğüne bağlı olarak tahmin doğrulukları artabilmektedir (Yılmaz & Kaya, 2019: 1).

Şekil 19’ da klasik programlama ile derin öğrenme arasındaki fark görselleştirilmiştir:

Şekil 19: Klasik Programlama ve Derin Öğrenme Şeması




Kaynak: Chollet, 2018: 5

Derin öğrenme, denetimli veya denetimsiz özellik çıkarma ve dönüştürme ile örüntü analizi ve sınıflandırma için birçok doğrusal olmayan bilgi işleme katmanından yararlanır. Ayrıca veriler arasındaki karmaşık ilişkileri modellemek için birden çok temsil düzeyini öğrenmeye yönelik algoritmalara dayalı, makine öğrenimi içinde bir alt alandır (Deng & Yu, 2014).

Şekil 20’ de görüldüğü üzere ayrıca bir dizi algoritmadan oluşan ve birden çok düzeyde öğrenme gerçekleştirmeyi gerçekleştiren derin öğrenme aslında makine öğrenmesi ve yapay zekânın alt sınıfıdır.

Şekil 20:Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme İlişkisi




Kaynak: Madan & Madhavan, 2020

Dolayısıyla derin öğrenme ve makine öğrenmesi arasında farklılıklar mevcuttur. Şekil 21’ de de görüldüğü gibi derin öğrenmede özellik çıkarım işini model kendisi yaparken makine öğreniminde bu adım için insanın müdahalesi gereklidir. Dolayısıyla makine öğrenimi insan müdahalesine derin öğrenmeye kıyasla daha fazla gerek duyar.

Ayrıca makine öğrenimi, derin öğrenmeye kıyasla daha küçük veri setleriyle çalıştığında iyi performans gösterirken, derin öğrenmeden verim alabilmek için sayısı milyonlara varan gözlemler ile çalışmak gereklidir (He vd., 2021: 5).

Şekil 21: Makine Öğrenmesi ile Derin Öğrenmenin Karşılaştırılması




Kaynak: Asher vd., 2021: 8

2.1.1. Derin Öğrenmenin Tarihçesi

Warren McCulloch ve Walter Pitts' in 1943 yılında insan beyninin düşünce sürecini taklit etmek amacıyla sinir mantığı ve matematik algoritmalarına dayanan sinir ağları için bir hesaplama modeli oluşturmaları yapay zekâ alanında ilk çalışma olduğu kabul edilmektedir. 1940' larda yapay zekâ ilk adım atılmış, 1980' lerde yapay zekânın bir alt dalı olan makine öğrenmesine geçilmiştir. 21. Yüzyılın ilk 10 yılında yani 2010' larda makine öğrenmesinde yaşanan zorluklar ve eksiklikler makine öğrenmesinin bir alt dalı olan derin öğrenme ile çözüme kavuşturulmuştur (Kayaalp & Süzen, 2020: 9).

Yukarıda açıklaması yapılan gelişim sürecinin görsel açıklaması Şekil 22' de gösterilmiştir.

Şekil 22: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Tarihsel Süreci



Kaynak: Seetharam vd., 2019

2.1.2. Derin Öğrenmede Öğrenme Türleri

Derin öğrenme içerisinde denetimli öğrenme, yarı denetimli öğrenme ve denetimsiz öğrenme olmak üzere üç adet öğrenme çeşidi bulunmaktadır. Ancak genellikle bunların içerisinde denetimli öğrenme ve denetimsiz öğrenme daha yaygın olarak kullanılmaktadır.

2.1.2.1. Denetimli Öğrenme

Denetimli öğrenme, özelliklerini öğrenmek amacıyla önceden etiketlenmiş verileri kullanan, böylece benzer ancak etiketlenmemiş verileri sınıflandırabilen bir makine öğrenimi sınıfıdır (Vasilev vd., 2019: 8).

Denetimli öğrenmede, her şeyden önce tahmin problemlerine odaklanılır. İlk olarak kesikli veya sürekli değer alabilen Y_i 'nin sonucuyla ilgili verileri içeren ve X_i gibi bazı tahmin edicilerin yer aldığı bir veri seti oluşturulur. Ardından veri seti içerisinde daha önce eğitim seti olarak ayrılmış sette tahmin işlemi yapılır. Eğitim setindeki tahmin işleminin sonuçları veri setinin eğitim setine bölünmesinden artı kalan kısım olan test setinin verilerindeki sonuçları tahmin etmek için kullanılır. Denetimli öğrenme tekniklerinin çoğunlukla çapraz doğrulama yoluyla veriye dayalı model seçimine dayanması ve genellikle ana odak noktası olan sonuçlar için olası çıktıları dikkate almaksızın gerçekleştirdiği tahmin performansı pek çok ekonometrik

yaklaşım ile denetimli öğrenme arasındaki önemli farklardır (Athey & Imbens, 2017: 22).

Bir veri seti verildiğinde, girdi verilerini önceden bilinen hedeflerle eşleştirme işlemi yapılarak öğrenme gerçekleştirilir. Genel olarak, optik karakter tanıma, konuşma tanıma, görüntü sınıflandırma ve dil çevirisi gibi popüler olan neredeyse tüm derin öğrenme uygulamaları denetimli öğrenme ile yapılmaktadır. Denetimli öğrenme çoğunlukla sınıflandırma ve regresyondan oluşsa da aşağıdakiler de dahil olmak üzere daha başka varyantlar da vardır (Chollet, 2018: 94):

- Sekans oluşturma: Bir resim verildiğinde, onu açıklayan bir açıklamayı tahmin etmek.
- Söz dizimi ağacı tahmini: Bir cümle verildiğinde, onun bir söz dizimi ağacına ayrışmasını tahmin etme işlemidir.
- Nesne algılama: Bir fotoğrafın veya resmin içindeki belirli nesnelerin çevrelerine nesneleri çevreleyecek şekilde bir sınırlayıcı kutu çizilir. Bu alan içine alma işlemi aynı zamanda bir sınıflandırma problemi olarak veya sınırlayıcının koordinatlarının vektör regresyon yoluyla tahmin edildiği ortak bir sınıflandırma ve regresyon problemi olarak da ifade edilebilir.
- Görüntü segmentasyonu: Bir fotoğraftaki, belirli bir nesne üzerine piksel düzeyinde desenler çizilerek nesneler arası ayrıştırma yani sınıflandırma işlemi yapılmasıdır.

Örüntü tanımlama konusunda denetimli öğrenme modellerinden olan Destek Vektör Makinesi (Support Vector Machine – SVM) tekniği kullanılmaktadır. SVM, tanımlama işlemini yaparken sınırları tanımlayan hiperdüzlem kavramından yararlanır. İlk olarak karar düzlemi nesneler sınıf üyeliğine göre ayırır ardından kategorik ve sürekli değişkenleri analiz işlemi başlar (Dunis, Middleton, Theofilatos , & Karathanasopoulos , 2016 : 6-7).

Denetimli Öğrenmede her giriş modeli için “hedef” çıktının doğru değerlerinin bilindiği varsayılır. Bazı denetimli öğrenme ağları şunlardır (Agrawal & Agrawal, 2015: 770):

- Algılayıcı Ağları (Perceptron Networks)
- Uygulanabilir Doğrusal Nöron (Adaptive Linear Neuron – ADALINE)
- Çoklu Uygulanabilir Doğrusal Nöron (Multiple Adaptive Linear Neurons – MADALINE)
- Geri Beslemeli Ağlar (Back-Propagation Networks)
- Radyan Tabanlı Fonksiyon Ağı (Radial Basis Function Network)
- Zaman Gecikmeli Sinir Ağı (Time Delay Neural Network)
- Fonksiyonel Bağlantı Ağı (Functional Link Network)
- Ağaç Sinir Ağları (Tree Neural Networks)
- Dalgacık Sinir Ağları (Wavelet Neural Networks)

2.1.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme modelinde hem girdi verileri önceden etiketlenmemiştir hem de eğitim aşamasında bilinen sonuçlar verilmemiştir. Amaç, veri bileşenleri arasında mevcut olan öğrenme ilişkilerini tahmin etmeyi sağlamaktır (Mason, Traore, & Woungang, 2016: 15).

Her $i = 1, \dots, n$ gözlemi için bir ölçüm vektörü X_i 'nin gözlemlenmesine rağmen ilişkili yanıt değişkeni Y_i 'nin olmaması denetimsiz öğrenmeyi denetimli öğrenmeden biraz daha zorlu öğrenme seçeneği yapar. Ayrıca tahmin edilecek bir yanıt değişkeni olmadığından dolayı regresyon modeli denetimsiz öğrenmede değil denetimli öğrenmede gerçekleştirilebilir (James, Witten, Hastie, & Tibshirani, 2021: 26).

Kümeleme, boyutluluk azaltma ve aykırı değer tespiti yöntemleri en önemli denetimsiz öğrenme yöntemlerindendir. Boyut azaltma, kalıpları yüksek boyutlu alanlardan daha düşük boyutlu alanlara eşleyen, tipik olarak denetimsiz bir problem yöntemidir (Kramer, 2016: 3-4). Kümeleme yönteminde girdinin hangi kümeye girileceği baştan belirtilmeyip yöntemin kendisi tarafından belirlenmesi beklenildiğinden dolayı kümeleme yöntemi genellikle denetimsiz öğrenme yöntemi olarak görülür (Zielesny, 2016: 159).

Denetimsiz öğrenme, bir eğitmenin yardımı olmadan gerçekleştirilir. Böylelikle, ağı kendisi giriş verilerinden özellikler, kategoriler, modeller veya

düzenlilikler ve çıkış üzerinden giriş verileri için ilişkiler bulur. Bazı denetimsiz öğrenme ağları (Agrawal & Agrawal, 2015: 770):

- Kohonen Kendi Kendini Düzenleyen Özellik Haritaları (Kohonen Self-Organizing Feature Maps)
- Öğrenme Vektörü Nicelleme (Learning Vector Quantization – (LVQ))
- Karşı Yayılma Ağları (Counter Propagation Networks – (CPN))
- Uyarlanabilir Rezonans Teorisi Ağı (Adaptive Resonance Theory Network)


2.1.3. Yapay Sinir Ağlarının Türleri

Yapay sinir ağları ağı çalışma yapısına göre ileri beslemeli ve geri beslemeli olarak ikiye ayrılmaktadır.

2.1.3.1. İleri Beslemeli Ağlar

İleri beslemeli ağlar çoğunlukla geri yayılım öğrenme algoritması ile kullanılmaktadır (Tekinay, 2021 : 44). Ayrıca ileri beslemeli sinir ağları, sigmoid eşik fonksiyonlarıyla çalışan mantıksal nöronlardan oluşmaktadırlar (Zielesny, 2016 : 238).

Şekil 23: İleri Beslemeli Sinir Ağı Gösterimi



Kaynak: Krenker vd., 2011: 6

Şekil 23’ teki okların yönünden anlaşılacağı üzere ileri beslemeli sinir ağları yalnızca tek yönlü sinyal akışına olanak sağlamaktadır. İleri beslemeli bir ağda hücreler katmanlar şeklinde düzenlenmişlerdir. Girdi katmanına sunulmuş olan girdi verileri aktivasyon fonksiyonundan geçerek gizli katmana gelirler. Ardından gizli katmandan ayrılan veriler çıktı katmanına gelerek eğer problem sınıflandırma problemi ise sınıfı, regresyon problemi ise tahmin sonucunu veren çıktılar üretirler.

Basit bir sinir ağında ileri besleme denklemi şu şekildedir:

$$\hat{y}(x; w) = f_n(FC_n(f_{n-1}(FC_{n-1}(\dots f_1(x)))) \quad 2.1$$

Denklemde i ’ inci tam bağlantılı katman FC_i , girdi olarak $\{h_j\}_{j=1}^{d_{i-1}}$ nöronlarını alan ve çıktı olarak da $\{h_j\}_{j=1}^{d_i}$ nöronlarını veren bir fonksiyondur. Girdiler üzerinde bütün çıktılar doğrusal bir modeldir. Ek olarak i ’ inci aktivasyon fonksiyonu, $f_i: \mathbb{R} \rightarrow \mathbb{R}$ tanımlı olduğu unutulmayarak, bir sonraki adımda tam bağlı katmana tam bağlı katmanın hangi nöronlarının aktarılacağı sonucunu veren bir dönüşüm fonksiyonunu ifade etmektedir (Karadağ, 2022: 46).

Lowe, (1994) İleri beslemeli sinir ağları, doğrusal olmayan çok kanallı zaman serisi tahmininde kısa vadeli hisse senetlerinin tahmininde kullanmıştır. Diğer bir çalışmada Thawornwong & Enke, (2004) stok tahmini için ileri beslemeli ve olasılıksal ağılı sinir ağı modelinin düşük riskle yüksek karlar ürettiği sonucu elde etmiştir.

2.1.3.2. Geri Beslemeli Ağlar


Geri beslemeli ağlar ilk olarak 1970’ lerde tanıtılmıştır. Ancak popülerliğini ve önemini 1986 yılında David Rumelhart, Geoffrey Hinton ve Ronald Williams tarafından yayınlanan “Learning Representations by Back-Propagating Errors” adlı eserle kazanmıştır. Makalede geri beslemeli ağların önceki öğrenme yaklaşımlarından daha hızlı ve çözilemeyen sorunları çözmekte daha efektif olduğu açıklanmaktadır. Günümüzde ise geri beslemeli ağlar sinir ağlarında öğrenmenin öncü tekniklerindendir (Nielsen, 2015 : 39).

Akışın ileriye doğru olabildiği gibi geriye doğru da olabildiği ağ yapısıdır. Kısmi türev ve zincir kuralı kullanılarak hesaplanan ağırlık güncellenme işlemi geriye veya ileriye doğru yapılabilir. Ağırlık güncelleme işlemi, her bir ağırlığın hesaplanan

toplam hataya etkisi hesaplanarak yapılır. Geri besleme yöntemi sayesinde hesaplanmış olan hata değerinin ağıın geride kalan bölümlerine dağıtılması sağlanır (Kuş, 2019 : 11).

Şekil 24’ te geri beslemeli bir sinir ağının işleyişi ile alakalı olarak görsel bilgi verilmiştir.

Şekil 24: Geri Beslemeli Sinir Ağı Gösterimi



Kaynak: Krenker vd., 2011: 6

Geri besmeli sinir ağlarında ilk katmandaki çıktı değerleri hesaplanıp ileriye aktarılır. Daha sonra her parametreye göre hatanın kısmi türevleri hesaplanarak ağda geriye gönderilme işlemi yapılır. Geri yayılımında çıktıdan girdi katmanına doğru gradyanları ters sırada hesaplayarak zincir kuralının kullanılmasına imkan varken çıktının da $\hat{y}(x; w)$ parametrelerle türevlenebilir olması lazımdır.

İlk adımda son katmandan başlayıp kayıp fonksiyona ait türevler aşağıdaki eşitlik eşitlik 2.2. ile hesaplanır:

$$\hat{y}(x; w) = (h_n(h_{n-1}, w_n, b_n)) \quad 2.2$$

Ardından sondan bir önceki katman için fonksiyona ait türevler hesaplanır ve bu hesaplama işlemi sırasıyla modelde bulunan tüm katmanlara uygulanır.

$$\hat{y}(x; w) = h_n(h_{n-1}(h_{n-2}, w_{n-1}, b_{n-2})) \quad 2.3$$

Geri yayılım, bir katmandaki gradyan hesaplamasının önceki katmanın da gradyan hesabında tekrardan kullanabilmesinden dolayı yeni hesaplamalar için ara kısmi türevleri saklar. Ayrıca bu yöntem her katmanda ayrı ayrı gradyan hesaplama yönteminden de çok daha verimlidir. Sadece bir katmandaki hücreler arasında değil aynı zamanda katmanlar arasındaki hücrelerde de geri besleme olabilmektedir. Bu nedenle geri beslemeli yapay sinir ağı doğrusal olmayan dinamik bir yapıdır (Karadağ, 2022 : 47).







2.1.4. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu içerisindeki girdi verilerine yapay sinir hücresi işlem yaparak karşılık gelen net çıktı sonuçlarını verir. Ancak söz konusu fonksiyon çoğunlukla doğrusallık göstermemektedir. Seçilecek olan aktivasyon fonksiyonu sonuç performansında oldukça etkili olduğu için aktivasyon fonksiyonunun doğru seçilmesi oldukça kritiktir (Öztürk & Şahin, 2018: 33).

Eğer bir sinir ağına aktivasyon fonksiyonu uygulanmamışsa model doğrusal regresyon gibi performans sergiler dolayısıyla tahmin edilen çıktı değeri ile girilmiş olan girdi değeri aynıdır. Bu sorun sadece aktivasyon fonksiyonsuz modelde değil aynı zamanda doğrusal aktivasyon fonksiyonu uygulandığında da gerçekleşir. Doğrusal aktivasyonlar, sınırlarının doğrusal olması ve bundan dolayı sadece doğrusal değişiklikleri öğrenebildiğinden gerçek hayattaki doğrusal olmayan durumlarda kötü performans göstermektedir. Bu sebeple de çoğunlukla doğrusal olmayan aktivasyon fonksiyonları tercih edilmektedir (Athaiya, Sharma, & Sharma, 2020: 310).

Şekil 25' te aktivasyon fonksiyonlarına ait denklem ve grafik bilgileri bulunmaktadır.

Şekil 25: Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonu	Denklem	Örnek	1D Grafiği
Doğrusal	$f(x) = ax$	Adaline, Doğrusal Regresyon	
Birim adım (Heaviside Fonksiyonu)	$f(x) = \begin{cases} 0 & x < 0 \\ 0.5 & x = 0 \\ 1 & x > 0 \end{cases}$	Algılayıcı Varyantı	
Signum	$f(x) = \begin{cases} -1 & x < 0 \\ 0 & x = 0 \\ 1 & x > 0 \end{cases}$	Algılayıcı Varyantı	
Parçalı Doğrusal	$f(x) = \begin{cases} 0 & x \leq -1/2 \\ x + 1/2 & -1/2 \leq x \leq 1/2 \\ 1 & x \geq 1/2 \end{cases}$	Destek Vektör Makineleri	
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	Lojistik Regresyon, Çok Katmanlı Sinir Ağları	
Hiperbolik Tanjant	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Çok Katmanlı Sinir Ağları, RNN' ler	
ReLU	$f(x) = \begin{cases} 0 & x < 0 \\ x & x > 0 \end{cases}$	Çok Katmanlı Sinir Ağları, Evrişimli Sinir Ağları	

Kaynak: Raschka & Mirjalili, 2017: 450

2.1.4.1. Doğrusal Aktivasyon Fonksiyonu

Eğer çözülecek problem doğrusal ise doğrusal aktivasyon fonksiyonu kullanılabilir. Bu aktivasyon fonksiyonunun çalışma mantığı, toplama fonksiyonundan elde edilen değeri belli bir katsayı ile çarparak hücrenin çıktısını oluşturmaktır (Çelik, 2022: 803).


2.1.4.2. Düzeltilmiş Doğrusal Birim (Rectified Linear Unit – ReLU):

ReLU aktivasyon fonksiyonu, sigmoid ve tanjant fonksiyonlarına göre daha çabuk sonuca varmaktadır. İşlem kapasitesi güçlü olmayan bilgisayarlar açısından bu özellik oldukça hız artışı sağlamaktadır. Ancak ReLU' nun olumsuz bir tarafı ise model eğitilirken ünitelerin kırılğan olup veriye göre olumsuz sonuçlar üretme ihtimalidir. ReLU' da öğrenme oranı oldukça doğru seçilmelidir. Yoksa örneğin öğrenme oranının yüksek olduğu zamanlarda ağın eğitim için ayrılmış veri setinin tamamında etkinleştirilmemiş nöronlar yer alabilir (Tümen, Söylemez, & Ergen, 2017: 2).

$$ReLU(x) = \max(x, 0) \quad 2.4$$

ReLU işlevi yalnızca pozitif elemanları muhafaza eder ve karşılık gelen aktivasyonları 0' a ayarlayarak tüm negatif elemanları dışlar. Şekil 25' te görüldüğü gibi, aktivasyon fonksiyonu parçalı doğrusaldır. Girdi değeri eğer negatif ise ReLU fonksiyonunun türevi 0 iken girdi değerinin pozitif olduğu durumda da türev 1' dir. Üçüncü ihtimal olan girdinin 0 olması durumunda ise ReLU fonksiyonu türevlenememektedir. Eğer bu ihtimal gerçekleşirse sol taraftaki türev baz alınarak girdi 0 değeri ise türev de 0 değerini alır denir. ReLU türevlerinin ya kaybolmaları ya da sadece argümanların geçmesine izin vermeleri hem optimizasyonun daha iyi sonuçlar vermesini sağlarken hem de kaybolan gradyan sorununu önlemektedir. (Zhang, Lipton, Li, & Smola, 2022: 171).

Şekil 26: ReLU Fonksiyonunun Türev Grafiği



Kaynak: Zhang, Lipton, Li, & Smola, 2022: 172

2.1.4.3. Sigmoid Aktivasyon Fonksiyonu


Aynı zamanda lojistik fonksiyon olarak da adlandırılan Sigmoid aktivasyon fonksiyonu, derin öğrenmenin ilk yıllarında yaygın olarak kullanılmaktaydı. Fakat sigmoid fonksiyonu girdileri sadece 0 ile 1 sınırları arasına sıkıştırdığı için bu sınırların dışına çıkılmak istendiğinde kullanılabiliirliğini yitirmektedir (Stevens, Antiga, & Viehmann, 2020: 148).

Şekil 27’ de sigmoid fonksiyon grafiğinden de anlaşılacağı üzere girdi değerinin 0’ a yakın bir değerde olması durumunda sigmoid fonksiyonu doğrusal bir dönüşüme yakınsamaktadır. Girdi değerinin 0 olması halinde türev maksimum 0.25’ e yakınsarken, girdi değerinin 0’ dan uzaklaşması durumunda ise türev 0’ a yaklaşmaktadır.

Sigmoid fonksiyonun türevi eşitlik:

$$\frac{d}{dx} \text{sigmoid}(x) = \frac{\exp(-x)}{(1 + \exp(-x))^2} \text{sigmoid}(x)(1 - \text{sigmoid}(x)) \quad 2.5$$

Şekil 27: Sigmoid Fonksiyonunun Türev Grafiği



Kaynak: Zhang, Lipton, Li, & Smola, 2022: 173

2.1.4.4. Hiperbolik Tanjant Fonksiyonu (Tanh)

Tanh fonksiyonunda da Sigmoid gibi girdiler (-1, 1) aralığındaki elemanlara dönüştürülürler.


$$\tanh(x) = \frac{1 - \exp(-2x)}{1 + \exp(-2x)} \quad 2.6$$

Şekil 25’ teki Tanh grafiğinden de anlaşılacağı üzere yine Sigmoid’ teki gibi girdi 0’ a yakınsadıkça fonksiyon doğrusal dönüşüme yaklaşır. Şekil olarak da Sigmoid ile benzerlik gösterebilir. Tanh fonksiyonunun şekli, koordinat sisteminin orjinine göre simetriktir. Girdi değeri 0’ a yaklaştıkça Tanh’ ın türev değeri de maksimum 1 olur. Yine Sigmoid’ deki gibi girdi değeri 0’ dan uzaklaştıkça türev değeri de 0’ a yaklaşır (Zhang, Lipton, Li, & Smola, 2022: 171-174).

Tanh fonksiyonunun türevi:

$$\frac{d}{dx} \tanh(x) = 1 - \tanh^2(x) \quad 2.7$$

Şekil 28: Tanh Fonksiyonunun Türev Grafiği



Kaynak: Zhang, Lipton, Li, & Smola, 2022: 175

2.1.5. Optimizasyon Algoritmaları

Derin öğrenme ve makine öğrenmesi girdi verilerine ait parametreleri öğrenebilmek için optimizasyon algoritmalarına ihtiyaç duyarlar. Çünkü optimizasyon algoritmaları, gerçek dünyadaki problemleri çözümlemede oldukça başarılıdır. Ancak problemleri çözmek için uygun olan tek bir genel optimizasyon algoritması yoktur. Bu nedenle probleme uygun çözüm sunan optimizasyon algoritması seçilmelidir (Zaheer & Shaziya, 2019: 536).

Makine öğrenmesinde ve derin öğrenmede hata oranını minimum yapmak amacıyla yararlanılan 6 adet optimizasyon algoritması bulunmaktadır. Bunlar ilk

kullanılma tarihleri baz alınarak kronolojik sıralandığında: 1951 yılında Stokastik Gradyan İnişi, 1964 yılında Momentum, 2011 yılında AdaGrad, 2012 yılında RMSProp (Root Mean Squared Propagation) ve Adadelta algoritmaları ve son olarak 2014 yılından itibaren de Adam algoritmasıdır (Seyyarer, Ayata, Uçkan, & Karcı, 2020: 92).

2.1.5.1. Adam Algoritması

Adam optimizasyonu algoritması, 2015 yılındaki Uluslararası Öğrenme Temsilleri Konferansı (International Conference on Learning Representations) adlı konferansta OpenAI (OPEN Artificial Intelligence)' den Diederik Kingma ve Toronto Üniversitesi' nden Jimmy Ba tarafından "Adam: A Method for Stochastic Optimization" adlı makale ile tanıtıldı (Kholik & Harjoko, 2020: 74).

Adam algoritması, geleneksel Stokastik Gradyan İniş sürecinin yerine kullanılabilecek birinci dereceden bir optimizasyon algoritmasıdır. Sinir ağı parametrelerini, eğitim verilerine dayalı olarak yinelemeli olarak güncelleyebilme kabiliyeti vardır. Adam algoritması ile Stokastik Gradyan İniş arasındaki fark; Stokastik Gradyan İniş' inde tüm parametreleri güncellemek amacıyla tek bir öğrenme oranı korunup eğitim süreci boyunca bu oran değişmez iken Adam algoritmasında birinci an tahmini ve ikinci an tahmini hesaplanıp farklı parametreler için bağımsız uyarlamalı öğrenme oranları hesaplanır (Yuan & Tian, 2019: 6).

Adam algoritması, seyrek gradyanlarla başarılı sonuçlar veren AdaGrad algoritması ile çevrimiçi ve çevrimdışı ortamlarda uyumlu çalışan RMSProp algoritmasının avantajlarını birleştirerek ortaya çıkmıştır. Dolayısıyla da az bellek gereksinimi ve sadece birinci dereceden gradyanlar gerektiren verimli stokastik optimizasyonu için oldukça verimli bir yöntemdir. Yöntem, gradyanların birinci ve ikinci anların tahminlerinden farklı parametreler için bireysel uyarlamalı öğrenme oranlarını hesaplar. Adam adı uyarlanabilir zaman tahmininden türetilmiştir (Kingma & Ba, 2017: 1).

Adam algoritmasının bazı avantajları:

- Gradyanın yeniden ölçeklendirilmesinde parametre güncellemelerinin büyüklüklerinin değişmez olması,

- Adım boyutlarının yaklaşık olarak adım boyutu hiperparametresi tarafından sınırlandırılması,
- Durağan bir hedef gerektirmemesi
- Seyrek gradyanlarla çalışması

2.1.5.2. AdaGrad Optimizasyon Algoritması

AdaGrad adı “Adaptive Gradient” ten gelmektedir ve Türkçede “uyarlanabilir gradya” anlamını taşımaktadır. Bu algorithmada, her parametrenin, ilgili özelliğin önemine göre ölçeklenen ayrı ve benzeri olmayan bir öğrenme oranı vardır. Bazı özelliklerin nadiren oluştuğu seyrek veriler için bu durum, oldukça kullanışlıdır. Bu özellikler ortaya çıktığında, parametrelerinde daha büyük güncellemeler yapmak istenir ve güncelleştirme işlemi her parametre için geçmiş gradyanların karelerinin toplamının bir matrisini koruyarak ve öğrenme oranını kareköküne bölerek yapılır. AdaGrad’ın önemli bir dezavantajı, geçmiş gradyanların matrisi boyut olarak arttıkça, öğrenme oranının giderek daha büyük ve daha büyük bir değere bölünmesi, bunun da sonunda öğrenme oranını uygulanamayacak kadar küçük hale getirmesi ve böylece öğrenmenin esasen durmasıdır (Krohn, Beyleveld, & Bassens, 2019: 182).

AdaGrad algoritmasında, algoritma boyunca her bir parametreye göre kısmi türevin toplu kare büyüklüğü hesaplanır. Hesaplanan bu değerin karekökü, ilgili parametre için ortalama karekök eğimiyle orantısaldır. Ayrıca ardışık toplama sebebiyle mutlak değer de epoch (dönem) sayısı ile birlikte artış gösterecek (Aggarwal, 2018: 138).

2.1.5.3. RMSProp

Toronto Üniversitesi’ nin Bilgisayar Bilimleri Fakültesi’ nde öğretim görevlisi olan Geoffrey Hinton tarafından bulunmuştur. RMSProp AdaGrad’ ın radikal bir şekilde azalan öğrenme oranlarını çözme amacıyla bağımsız olarak geliştirilmiştir. RMSProp ayrıca öğrenme oranını, katlanmış gradyanların üstel olarak azalan ortalamasına böler. Buna ek olarak geçmiş kareli gradyanların üssel olarak azalan ortalamasına katkıda bulunur (Ruder, 2017: 7-8).

RMSProp, katsayıları ölçeklendirmek için gradyan karesini kullandığından dolayı AdaGrad ile benzerlik taşımaktadır. Öğrenme oranının pratikte deney yapan tarafından planlanması gerekir (Zhang, Lipton, Li, & Smola, 2022: 531).

2.1.6. Performans Değerlendirme Kriterleri

Model performansını değerlendiren kriterlerdir. Oluşturulan model tahminlerinin gerçek değere ne kadar benzediğini açıklamak için kullanılırlar.

2.1.6.1. Hata Kareler Ortalaması (Mean Squared Error -MSE)

Tahminin doğruluk performansını ölçmeye yarayan MSE' nin asıl amacı tahmin edilmiş değerleri kıyaslamak ve aralarındaki fark seviyelerini belirlemektir (Altubaş, 2021: 46).

x_i = Gerçekleşen değer,

y_i = Tahmin edilen değer,

N = Gözlem sayısı

Olduğunda hata (e_i) aşağıdaki gibi hesaplanır:

$$e_i = (x_i - y_i) \quad 2.8$$

Bu durumda MSE aşağıdaki denklemle hesaplanmaktadır:

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad 2.9$$

Bu denkleme göre elde edilecek sonuç her zaman sıfırdan büyüktür. Ayrıca elde edilen sonuç eğer sıfıra yakınsa başarılı tahmin olarak kabul görür (Wang & Bovik, 2009: 99).

2.1.6.2. Ortalama Mutlak Hata (Mean Absolute Error – MAE)

MAE, tahmini yapılmış değerler ile gerçekleşmiş değerler arasında farktan oluşan hata teriminin mutlak değeri hesaplanarak elde edilir (Yapa, 2022: 80).

x_i = Gerçekleşen değer,

y_i = Tahmin edilen değer,

N = Gözlem sayısı

olarak verildiğinde MAE aşağıdaki denklemle hesaplanmaktadır:

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - y_i| \quad 2.10$$

MAE, hata değerlerinin ortalama büyüklüğünü hesaplamaktadır. Bu nedenle de çoğunlukla sınıflandırma, regresyon ve zaman serileri analizlerinde tercih edilir. MAE değerlerinin, 0 ile ∞ arasında değişmesinden dolayı her zaman en düşük MAE değerinin elde edildiği model en iyi performanslı model olarak kabul görmektedir (Durmuş, 2023: 62).

2.1.6.3. Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error – MAPE)

MAPE, hata tahmininde başarılı performans gösterdiği için sıklıkla tercih edilmektedir. Finans alanında kâr ve zararlar çoğunlukla tahminsel değerlerle ölçüldüğü için MAPE finans alanında daha çok kendine yer bulmaktadır. MAPE için tercih edilecek bir diğer durum ise gerçek veriler üzerine yapılan uygulamalarda tahmin edilmek istenen miktarın sıfırdan çok büyük olduğu durumdur (Myttenaere, Golden, Grand, & Rossi, 2016: 38).

x_i = Gerçekleşen değer,

y_i = Tahmin edilen değer,

N = Gözlem sayısı

Olduğunda MAPE aşağıdaki denklemle hesaplanmaktadır:


$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|x_i - y_i|}{x_i} \quad 2.11$$

2.1.7. Yinelemeli Sinir Ağı (Recurrent Neural Network – RNN)

İnsanların geçmiş tecrübeleri her zaman hafızalarında yer tutar ve hayatlarındaki sonraki adımlar için geçmiş tecrübelerini hatırlayıp bir karara varırlar. Örneğin bir yemek çok tuzlu pişirilmiş ise bir daha ki yemek pişirilmesinde bu tecrübe hatırlanır ve yemeğin tuzlu olmaması için tuz miktarında değişiklik yapılır. Yinelemeli sinir ağı da insan beyninin bu hatırlama özelliğine sahiptir ve bir adımı işlerken bir önceki adımdan gelen bilgileri de kullanır.

RNN, sıralı verileri değişebilen uzunluklarda işleyebilme yeteneğine sahip bir sinir ağı türüdür. Bir cümlenin sözcükleri veya bir döviz kurunun çeşitli anlardaki fiyatı bu tür verilere örnek olarak verilebilir. Bu tür verilerde dizinin öğeleri birbirleriyle ilişkiye sahiptir ve öğeler arasındaki sıra çok önemlidir. Örnek vermek gerekirse, bir kitap alınıp içindeki tüm kelimeleri rastgele okunursa, tek tek kelimeler bilinmesine rağmen metnin bütünlüğü anlamını yitirecek ve okuyucu için bir anlam ifade etmeyecektir (Vasilev vd., 2019: 198).

Şekil 29: Standart İleri Beslemeli Sinir Ağı ve RNN Şeması



Kaynak: Raschka & Mirjalili, 2017: 541

Şekil 29’ta da görüleceği üzere yinelemeli sinir ağı, ardışık bilgilerden faydalanan ve gizli katman çıktısını yeniden aynı katmana giriş olarak gönderebilen bir derin öğrenme algoritmasıdır (Kayaalp & Süzen, 2020: 16). Ayrıca üç adet katmanın bir arada olmasından meydana gelir.

x : giriş katmanı,

h : gizli katman,

y : çıkış katmanı


olarak temsil edilmiştir. Şekil 29’ teki ağların şekline göre ağların ikisi de sadece birer adet gizli katmana sahiptir.

Standart ileri beslemeli ağda, bilgi ilk olarak girdi katmanından gizli katmana ardından gizli katmandan çıktı katmanına geçer. Yinelemeli bir sinir ağında ise, gizli katmana giriş hem girdi katmanından hem de bir önceki zamana ait gizli katmanından

yapılır. Gizli katmanın zaman adımlarındaki bu bilgi akışı, ağın geçmiş bilgiler hakkında belleğe sahip olmasını sağlamaktadır (Raschka & Mirjalili, 2017: 542).

Şekil 30’da tek gizli katmanlı ağ ve çoklu gizli katmanlı ağın açık halleri gösterilmiştir;

Şekil 30: Tek Gizli Katmanlı Ağ ve Çoklu Gizli Katmanlı Ağın Açık Gösterimi



Kaynak: Raschka & Mirjalili, 2017: 542

Modelde “ $t > 0$ ” olduğu durumda, gizli katman “ $(h^{(i)})$ ” girdilerini “ $x(t)$ ” giriş katmanından ve gizli katmanın “ $t-1$ ” zamanındaki yani bir önceki değeri “ $h(t-1)$ ”den alır. Ayrıca, çok katmanlı bir RNN söz konusu olduğunda bilgi akışı şu şekilde özetlenebilir (Raschka & Mirjalili, 2017: 543):

- Birinci gizli katman: Burada, gizli katman $h_1^{(t)}$ olarak temsil edilip girdisini x_t veri noktasından ve aynı katmana ait geçmiş zamandaki gizli değerlerinden alır. Geçmiş zaman adımı $h_1^{(t-1)}$ olarak gösterilir.
- İkinci gizli katman: İkinci gizli katman $h_2^{(t)}$ olarak gösterilir ve girdileri, bir önceki gizli katmanın çıktısına ($h_1^{(t)}$) ek olarak geçerli zaman adımında kendi katmanına ait bir önceki gizli birim değerlerinden $h_2^{(t-1)}$ alır.

2.1.7.1. Epoch ve Batch Size

Epoch' un Türkçe karşılığı “dönem” anlamına gelmektedir. Oluşturulan modelin eğitimi sırasında modele ait ağırlıkları güncellemek amacıyla bütün eğitim setini kullandığı tekrar sayısını belirtir (Amidi & Amidi, 2018).

Batch size, tek bir seferde kullanılacak veri noktası sayısını ifade etmektedir (Türk Ulusal Bilim e-Altyapısı, 2023).

2.1.7.2. RNN' de Hesaplama Aktivasyonları


RNN şemasındaki yönlendirilmiş her ok yani diğer bir deyişle kutular arasındaki bağlantılar, bir ağırlık matrisi ile bir ilişkiye sahiptir. Bu ağırlıklar “ t ” ile gösterimi yapılan zamana bağlı değildir; bu nedenle, tüm zaman adımlarında yer alırlar.

Tek katmanlı bir RNN' deki farklı ağırlık matrisleri aşağıdaki gibidir:

- W_{xh} : Giriş katmanı x_t ile gizli katman h arasındaki ağırlık matrisi
- W_{hh} : Gizli katmanlar arasındaki ilişkili ağırlık matrisi
- W_{hy} : Gizli katman ile çıktı katmanı arasındaki ağırlık matrisi

Ağırlık matrislerinin RNN' de kullanımları Şekil 31' de görselleştirilmiştir.

Şekil 31. Bir RNN Şemasındaki Ağırlık Matrisleri Gösterimi



Kaynak: Raschka & Mirjalili, 2017: 544

Aktivasyonların hesaplanması, standart çok katmanlı algılayıcılara ve diğer ileri beslemeli sinir ağlarına çok benzerlik taşır. Gizli katman için net girdi olan z_h ' ye

(ön etkinleştirme), karşılık gelen vektörlerle ağırlık matrislerinin çarpımlarının toplamı alınır ve üstüne yanlılık birimi eklenir;

$$z_h^{(t)} = w_{xh}x^{(t)} + w_{hh}h^{(t-1)} + b_h \quad 2.12$$

Daha sonra, gizli birimlerin "t" zaman adımıdaki aktivasyonları aşağıdaki gibi hesaplanır:

$$h^{(t)} = \Phi_h(z_h^{(t)}) = \Phi_h(w_{xh}x^{(t)} + w_{hh}h^{(t-1)} + b_h) \quad 2.13$$

Burada " b_h ", gizli birimler için sapma vektörüdür ve " Φ_h " gizli katmanın aktivasyon fonksiyonudur.

Birleştirilmiş ağırlık matrisi olan $W_h = [W_{xh}; W_{hh}]$ kullanılmak istenirse gizli birimleri hesaplama formülü aşağıdaki gibi değişecektir:


$$h^{(t)} = \Phi_h\left([W_{xh}; W_{hh}] \begin{bmatrix} x^{(t)} \\ h^{(t-1)} \end{bmatrix} + b_h\right) \quad 2.14$$

Mevcut zaman adımıda gizli birimlerin aktivasyonları hesaplandıktan sonra, çıkış birimlerinin aktivasyonları aşağıdaki gibi hesaplanır:

$$y^{(t)} = \Phi_y(W_{hy}h^{(t)} + b_y) \quad 2.15$$

Daha da açıklığa kavuşturmak için, aşağıdaki şekil bu aktivasyonları her iki formülasyonla hesaplama sürecini göstermektedir:

Şekil 32: Aktivasyonların Hesaplanma Süreci




Kaynak: Raschka & Mirjalili, 2017: 545

Yinelemeli sinir ağı sabit boyutlu girdileri işlemekle sınırlı olmayıp, farklı uzunluklardaki diziler veya çeşitli boyutlardaki görüntüler gibi sinir ağlarıyla hesaplayabileceğimiz olasılıkları genişletebilirler (Vasilev vd., 2019 : 200).

Aşağıdaki şekilde bazı kombinasyonlar verilmiştir:

Şekil 33: RNN' de Girdi – Çıktı Kombinasyonları



Kaynak: Vasilev vd., 2019 : 201

Bire bir: İleri beslemeli sinir ağı ve evrişimli sinir ağı (CNN) gibi sıralı olmayan bir işlemdir. Bir ileri beslemeli ağı ile tek bir zaman adımında RNN uygulamak arasında pek bir fark yoktur (Vasilev vd., 2019 : 200). Sabit boyutlu girdi verilip sabit boyutlu çıktı alınan durum söz konusudur. Örneğin görüntü sınıflandırması için kullanılır (Karpathy, 2015).

Birden çoğa: Bu işlemde tek bir girdiye göre bir dizi oluşturulur. Bir görüntüden altyazı oluşturmak (Vasilev vd., 2019 : 200) ve notalardan müzik türetmek (Amidi & Amidi, 2018) bu duruma örnek olarak verilebilir.

Çoktan bire: Girdi birden büyük ama çıktı da bire eşittir. Duygu sınıflandırması amacıyla kullanılır (Amidi & Amidi, 2018).

Çoktan çoğa (dolaylı): Çoklu sıralı giriş ve çoklu sıralı çıkışa sahiptir (Kayaalp & Süzen, 2020 : 17). Makinelerin dil çevirisi konularında kullanılır. Örneğin RNN okuduğu İngilizce cümleden Fransızca bir cümle çeviri türetir (Karpathy, 2015).

Çoktan çoğa (doğrudan): Her giriş adımı için bir sonuç vardır (Vasilev vd., 2019: 200). Videodaki her bir karenin etiketlenmesi bu duruma örnek verilebilir (Raschka & Mirjalili, 2017 : 540).

2.1.7.3. Kaybolan Gradyan Problemi

Hochreiter, (1991) ve Bengio vd. (1994) çalışmalarından beri derin sinir ağlarında kaybolan gradyan problemi 1990' lardan beri görüldüğü bilinmektedir.


Kaybolan gradyan terimi, bir ileri beslemeli ağda geri yayılan hata sinyalinin son katmandan uzaklığının bir fonksiyon olarak katlanıp azalmasını ifade eder. Bu sorun, tekrarlayan ağlarda gözlenir. Kaybolan gradyan nedeniyle, ileri beslemeli ağlarda çok fazla ekstra katman veya RNN' lerde zaman noktaları eklemek genellikle performansı iyileştirmez (Sussillo & Abbott, 2015 : 1).

Sinir ağlarında geri yayılım durumunda ileri yayılımda yapılan toplama ve çarpma işlemlerinden farklı olarak türev işlemi yapılmaktadır ve türev işleminin sonucunun sıfır çıkma ihtimali vardır. Eğer bu ihtimal gerçekleşip aktivasyon fonksiyonunun türevi sıfır elde edilirse öğrenme gerçekleşmemektedir. Türev ve ağırlıklar güncellendiğinden dolayı ağırlıkların sıfır olması durumunda bilgi kaybı yaşanmaktadır. Bu duruma gradyanların kaybolması ismi verilmektedir (Güney, 2022 : 21-22).

Derin sinir ağlarını eğitmek için kullanılan ana algoritma olan geri yayılım, çıkış kaybindan önceki katmanlara bir geri bildirim sinyali yayarak çalışır. Geri besleme sinyalinin çok fazla sayıda katman yığını boyunca yayılması durumunda, sinyalin zayıflama veya tamamen kaybolma ihtimalleri vardır. Bu ihtimaller gerçekleştiğinde de ağ eğitilemez hale gelir. Böylece kaybolan gradyanlar olarak adlandırılan sorun baş gösterir. Kaybolan gradyan hem derin ağlarda hem de çok uzun diziler boyunca yinelenen ağlarda ortaya çıkar. Çözüm olarak her iki durumda da, uzun bir işlem dizisi aracılığıyla bir geri besleme sinyalinin yayılması gerekmektedir (Chollet, 2018 : 246).

RNN' deki parametreler, ağı besleyen zaman adımları tarafından paylaşılırlar. Böylelikle her bir çıktının gradyan değeri mevcut adımda hesaplanmış işlemlere ek olarak önceki adımların hesaplamalarını da kapsamaktadır. Bunun sonucu olarak da RNN' i eğitmek zorlu bir hal almaktadır. Kısıtlanmış zamanla geri besleme (Truncated Backpropagation Through Time – TBPTT) yöntemi bu soruna çözüm olması amacıyla öne sürülmüştür. TBPTT yöntemi, her bir çıktıdaki zaman serisinin ilk adımına kadar hesaplama zahmetini kısıtlamak için gradyan hesaplamada kullanılan önceki zaman adımlarına sınırlama getirmiştir. Buna ek kısıtlama sebebiyle olarak hesaplama sınırının düşük olması, uzun zaman bağılıklarının ağ tarafından öğrenilmesine engel olmuştur. TBPTT ile konulan kısıtların fazla olması kaybolan ve patlayan gradyanlar problemine sebep olur. Bu probleme çözüm olarak LSTM ve GRU yöntemleri ile kullanılan kapı mekanizmalarıdır (Tokgöz & Ünal, 2018:3).

Şekil 34: Tek Gizli Katmanlı RNN İçin Hata Yüzeyi



Kaynak: Pascanu, Mikolov, & Bengio, 2013 : 5

Şekil 34’ de gradyan inişinin izleyebileceği standart yörüngeler kesintisiz çizgiler ile gösterilmiştir. Kesik çizgili oklar eğer norm bir eşiğin üzerinde olursa ve gradyanlar sabit bir boyuta yeniden ölçeklendirilirse ne olacağını gösterir (Pascanu, Mikolov, & Bengio, 2013 : 5).

Şekil 34 ile ilgili olarak yüksek derecede doğrusal olmayan derin sinir ağıları veya RNN için amaç fonksiyonu, genellikle birkaç parametrenin çarpılmasından kaynaklanan parametre uzayında keskin doğrusal olmama durumları barındırır. Bu doğrusal olmama durumları, bazı yerlerde çok yüksek türevlere neden olur. Parametreler böyle bir uçurum bölgesine yaklaştığında, bir gradyan iniş güncellemesi parametreleri çok uzağa fırlatabilir ve muhtemelen yapılmış olan optimizasyon çalışmasının çoğunu kaybettirebilir. Uzun bir zamansal dizinin her zaman adımında aynı işlemi tekrar tekrar uygulamak sinir ağı optimizasyon algoritmalarının hesaplama grafiğinde aşırı derecede derinleşme meydana getirir ve bu derinleşme nedeniyle de kaybolan gradyan sorunu ortaya çıkmaktadır (Goodfellow, Bengio, & Courville, 2016 : 281-282).

RNN eğitilirken alışagelmış sinir ağlarında olduğu gibi geri yayılım (Backpropagation) yapılması beraberinde büyük bir sorun meydana getirmektedir. Tüm ağırlıkların ayarlamasını sağlayan değer olan gradyan değeri, sinir ağı verileri tüm katmanlarda kullanıldığı için her bir çıktısı yalnızca o anki katmana değil bir önceki katmana da bağlıdır. Birden fazla zaman aralığında geri yayılım işlemi sürekli yenilenir ise sonuç küçülüp kaybolan gradyan problemine sebep olmaktadır. Aksi durumda birden büyük gradyanlar ise patlayan gradyan probleminin sebebidir. Bu probleme çözüm olarak LSTM mimarileri geliştirilmiştir (Metin & Karasulu, 2019 : 4).

2.1.7.4. Stokastik Gradyan İnişi


Donald Hebb, 1949 yılında yayınladığı “*The Organization of Behavior a Neuropsychological Theory*” adlı kitabında nöronların pozitif pekiştirme ile öğrenmelerine inanarak Hebb Öğrenme Teorisini ileri sürmüştür. Bu teori algılayıcı öğrenme algoritmalarının ilk örneği olmakla beraber derin öğrenmeyi destekleyen stokastik gradyan inişi algoritmasının da temellerini oluşturmaktadır. Bu algoritmadaki amaç; Sinir ağındaki parametrelerin en iyi sonuçlarını elde etmek için

arzu edilen davranışı desteklemek ve istenmeyen davranışı zayıflatmaya dayanmaktadır (Zhang, Lipton, Li, & Smola, 2022 : 34).

Stokastik gradyan inişi her örnek için tek tek gradyan hesaplaması yapıp ardından da güncelleme yaptığı için “online” öğrenmeye olanak tanımaktadır. Ancak her örneğe güncelleme yapılması varyansı arttıracığından dolayı gürültülü bir öğrenme eğrisine sahip olacak. Bu nedenle de uç değerlere karşı hassasiyeti vardır. Gürültülü öğrenmeyi önlemek amacıyla öğrenme faktörü ileri tekrarlar da azaltılabilir (Güdelek, 2019: 25).

Gradyan azaltma algoritmasının (Batch Gradient Descent), tüm veri kümesinde gradyan hesabı gerçekleştirmesi iterasyonların uzun zamanlar almasına ve erken yakınsama ile yerel optimumlara yakalanma sorunlarının doğmasına sebep olmuştur. Bu soruna çözüm olarak eğitim setinin sabit değerlere bölündüğü ve bölünen her yığın için toplam hata hesaplanıp ağırlıkların da güncellendiği mini batch descent tekniği ileri sürülmüştür. Mini batch değerinin 1 olarak seçildiği durumlarda stokastik gradyan inişi algoritması uygulanmış olmaktadır. Bu durumda her tekrarda bir örnek için hata hesaplanıp ağırlıklar güncellenir. Böylece de vektörizasyonun getirmiş olduğu hız kaybedilmiş olunur (Gülcü & Kuş, 2019: 508).


Şekil 35: Bir Boyutlu Kayıp Eğrisinde Stokastik Gradyan İnişi (Bir Adet Öğrenilebilir Parametreli)



Kaynak: Chollet, 2018 : 49

Şekil 35’ te görüleceği gibi, adım sayısı olan “Parametre Değeri” için doğru bir değeri seçmek çok önemlidir. Eğer seçilen değeri çok küçük olursa kayıp değerini minimize etmek yani eğride aşağı gitmek için çok fazla tekrar gerekli olacak ve bunun sonucunda bir yerel minimumda (şekilde $t=3$) takılıp kalma sorunu yaşanma olasılığı vardır. Aksi durum olarak eğer seçilen adım faktör değeri çok büyükse, güncellemelerin sonucu eğri üzerinde tamamen rastgele konumlarda olabilme ihtimali vardır.

Şekil 36: İki Boyutlu Kayıp Yüzeyinde Stokastik Gradyan İnişi (İki Adet Öğrenilebilir Parametreli)



Kaynak: Chollet, 2018 : 50

Esasen bir sinir ağındaki her ağırlık katsayısı uzayda serbest boyuttadır ve yalnızca bir boyutlu değil on binlerce hatta milyarlarca boyutta da olabilmektedir. Ancak böyle büyük boyutlardaki alanların görselleştirilmesi zor olacağından dolayı kayıp yüzeyler hakkında fikir sahibi olabilmek için Şekil 36’ de sadece iki boyutlu gradyan inişi görselleştirilmiştir (Chollet, 2018 : 50).

2.1.7.5. Stokastik Gradyan Güncellemesi

Derin öğrenmede, amaç fonksiyonu genellikle eğitim için ayrılan veri setindeki her örnek için kayıp fonksiyonlarının ortalamasıdır. N adet örnekleme sahip bir eğitim veri setinin verildiği bir durumda x' in parametre vektörü olduğu ve i . İndeksin eğitim veri setinden seçilmiş örneğine göre $f_i(x)$ ’ in kayıp fonksiyonu olduğu varsayalım. Sonra buradan hareketle 2.5’ teki amaç fonksiyonu elde edilir:

$$f(x) = \frac{1}{n} \sum_{i=1}^n f_i(x) \quad 2.16$$

Amaç fonksiyonunun x ' teki gradyanı denklem 2.6' daki gibi hesaplanır:

$$\nabla f(x) = \frac{1}{n} \sum_{i=1}^n \nabla f_i(x) \quad 2.17$$


Stokastik gradyan inişi her tekrarda hesaplama yükünü azaltır. Her tekrarda “ i ” rastgele veri örnekleri için $\in \{1, \dots, n\}$ dizisinden eşit olarak örneklenir ve ardından x ' i güncelleştirme amacıyla $\nabla f_i(x)$ hesaplanır. “ η ” öğrenme oranını temsil etmektedir.

$$x \leftarrow x - \eta \nabla f_i(x) \quad 2.18$$

Ek olarak stokastik gradyan $\nabla f_i(x)$ tam gradyan olan $\nabla f(x)$ ' in tarafsız bir tahminidir. Çünkü:

$$E_i \nabla f_i(x) = \frac{1}{n} \sum_{i=1}^n \nabla f_i(x) = \nabla f(x) \quad 2.19$$

Şekil 37: Stokastik Gradyan İnişinde Değişkenlerin Yörüngesi



Kaynak: Zhang, Lipton, Li, & Smola, 2022 : 496

Stokastik gradyanın özündeki rastgelelikten dolayı değişkenlerin yörüngesi dağınıktır. Diğer bir deyişle en düşük seviyeye yaklaşıldığında dahi $\eta \nabla f_i(x)$ ' in etkilediği anlık gradyan sebebiyle belirsizlik mevcuttur. Adım sayısını arttırmak bu soruna çözüm olmayacağı için öğrenme oranını (η) değiştirmek en iyi çözüm olacaktır. Fakat eğer η çok küçük seçilirse bir ilerleme kaydedilmeyecek. Diğer

Bir bellek hücresinde:

i_t = Giriş kapısı

o_t = Çıkış kapısı

f_t = Unutma kapısı

C_t = Bellek hücresi

$\tilde{C}_t$ = Bellek hücrelerinin aday değeri

x_t = Giriş vektörü

h_t = Gizli katman vektörü

W ve U = Ağırlık matrisleri

b = Yanlılık

olarak ifade edildiği bir durumda LSTM kapıları için ileri yayılma denklemleri:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad 2.20$$

$$\tilde{C}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad 2.21$$

Unutma kapısı durum biriminin ağırlığında rol oynamaktadır ve unutma kapısının değeri 0 ile 1 arasında değişmektedir. Eğer sonuç 0 ise ilgili değer modelden atılacak, eğer 1 ise de değer modelde muhafaza edilecek. Unutma kapısı şu şekilde hesaplanır:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad 2.22$$

Bu işlem sayesinde, bellek hücresinin yeni durumu şu şekilde güncellenir:

$$C_t = i_t \tilde{C}_t + f_t C_{t-1} \quad 2.23$$

Bellek hücresinin yeni durumu ile kapının çıkış değeri aşağıdaki gibi hesaplanır:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad 2.24$$

Unutma durumu için denklemlerin güncellenmiş halleri:

$$C_t = f_t c_{t-1} + i_t c_i n_t \quad 2.25$$

$$h_t = o_t \tanh(c_t) \quad 2.26$$

Bir bellek hücresi, girdi ve çıktı için ağırlık parametrelerine ek olarak dahili duruma sahiptir. Bu dahili durum girdi zaman adımlarına maruz bırakılarak oluşturulur. Bu ağırlıklar ve dahili durum şu şekilde açıklanmıştır (Brownlee, 2017: 11):

- **Girdi Ağırlıkları:** Geçerli zaman adımı için girdiyi ağırlıklandırmak için kullanılır.
- **Çıktı Ağırlıkları:** Çıktıyı son zaman adımından ağırlıklandırmak için kullanılır.
- **Dahili Durum:** Bu zaman adımı için çıkışın hesaplanmasında kullanılır.

LSTM' deki üç kapı bellek hücresinde anahtar role sahip olup hücredeki bilgi akışında da oldukça etkilidirler. Bu kapılar aşağıdaki gibi açıklanmaktadır (Persio & Honchar, 2017: 7):

- **Unutma Kapısı:** Hücreden hangi bilgilerin atılacağına karar verir.
- **Giriş Kapısı:** Hangi değerlerin bellek durumunu güncelleyeceğine karar verir.
- **Çıkış Kapısı:** Hücrenin girdisine ve belleğine göre neyin hatırlanıp neyin unutulacağına karar verilen kapıdır.

Bazı LSTM mimarileri şu şekildedir:

- **Vanilla LSTM:** Tek bir LSTM katmanının bellek hücreleri, basit bir ağ yapısında kullanılır.
- **Yığılmış (Stacked) LSTM:** LSTM katmanları, derin ağlarda üst üste istiflenmiş bir haldedir.

- **CNN LSTM:** Görüntüler gibi uzamsal girdilerdeki özellikleri öğrenmek için CNN kullanılır. Ayrıca LSTM de bir görüntü dizisini girdi olarak desteklemek veya bir görüntüye yanıt olarak bir dizi oluşturmak için kullanılabilir.
- **Kodlayıcı-Kod Çözücü (Encoder-Decoder) LSTM:** Bir LSTM ağı, giriş dizilerini kodlarken diğer bir LSTM ağı da kodlamayı bir çıkış dizisine dönüştürür.
- **Çift Yönlü (Bidirectional) LSTM:** Girdi dizileri hem ileri hem de geri sunulur ve öğrenilir.
- **Üretken (Generative) LSTM:** Bu LSTM' ler, girdi dizilerindeki yapı ilişkisini çok iyi öğrenebildiklerinden dolayı yeni makul diziler üretebilme yeteneğine sahiptirler.

LSTM' in başarılı sonuçlar verdiği uygulama alanlarından üç tanesi ile ilgili bilgiler aşağıda yer almaktadır (Brownlee, 2017: XIII, 12):

Otomatik Görsel Altyazısı Oluşturma: Sisteme bir fotoğraf tanıtıldığında sistemin fotoğrafın içeriğini betimleyen bir açıklama oluşturmasıdır. 2014 yılında popüler kazanmaya başladı. Bu yıldan sonra bu konuya ek olarak nesne sınıflandırması ve nesne tespiti konularında da hem başarılı sonuçlar sergiledi hem de çokça kullanılmaya başlandı.

Fotoğraflardaki nesneleri tespit edip ardından bu nesneler için etiketler oluşturduktan sonra, bir diğer adım bu etiketleri tutarlı bir cümle açıklamasına dönüştürmektir. Sistemler, fotoğraflarda nesne tespiti için CNN ve ardından etiketleri tutarlı bir cümleye dönüştürmek için de LSTM' den yararlanır.

Şekil 39' de LSTM tekniği ile görsel altyazı oluşturulmasına dair örnek verilmiştir:

Şekil 39:LSTM ile Görsel Altyazısı Oluşturma



Kaynak: Vinyals, Toshev, Bengio, & Erhan, 2015: 8

Otomatik Metin Çevirisi: Herhangi bir dildeki metinlerin herhangi bir dile çevrilmesidir. Buna örnek olarak girdinin İngilizce bir metnin olması ve çıktının da Fransızca metin olması verilebilir. Burada önemli husus olarak model kelimelerin çevirisini ve çevirinin değiştirildiği bağlamı muhakkak öğrenmelidir. Ayrıca hem ilgili iki dil içerisinde hem de dillerin diğer diller arasındaki cümle uzunlukları farklarını da dikkate alması gerekmektedir. Diğer bir deyişle dokuz kelimeden oluşan bir İngilizce cümlelerin Fransızca karşılığında dokuzdan farklı bir sayıda kelime sayısı olabilmek ihtimali vardır.

Şekil 40’ ta otomatik metin çevirisinin LSTM ile yapılmasına dair bir örnek bulunmaktadır:

Şekil 40: LSTM ile Otomatik Metin Çevirisi


Tip	Cümle
Girilen Model	Ulrich Hackenberg, membre du conseil d'administration du constructeur automobile Audi, affirme qu'il s'agit d'une pratique courante depuis des années pour que les téléphones portables puissent être collectés avant les réunions du conseil d'administration afin qu'ils ne soient pas utilisés comme appareils d'écoute à distance.
Doğru Çıktı	Ulrich Hackenberg, membre du conseil d'administration du constructeur automobile Audi, déclare que la collecte des téléphones portables avant les réunions du conseil, afin qu'ils ne puissent pas être utilisés comme appareils d'écoute à distance, est une pratique courante depuis des années.

Kaynak: Sutskever, Vinyals, & Le, 2014: 7

Otomatik El Yazısı Oluşturma: Bir el yazısı örnekleri verildiğinde, belirli bir kelime veya ifade için yeni ve daha düzenli bir el yazısının üretildiği görevdir. Kalem hareketi ile harfler arasındaki ilişki öğrenilir ve yeni örnekler üretilebilir. Büyüleyici olan, farklı stillerin öğrenilip taklit edilebilmesidir.

LSTM ile otomatik olarak el yazısı oluşturulması Şekil 41’ de verilmiştir:

Şekil 41: LSTM ile Otomatik El Yazısı



Kaynak: Graves, 2014: 33

2.1.9. Kapılı Yinelemeli Hücre (Gated Recurrent Unit – GRU)


2014 yılında Cho ve arkadaşları tarafından geliştirilmiştir. Dahili bellek özelliğini kullanarak kaybolan gradyan ve patlayan gradyan problemine çözüm sunmaktadır. Güncelleme ve sıfırlama kapıları sayesinde de bilgileri hem saklayabilme hem de filtreleme yeteneğine sahiptir (Karadağ, 2022: 54).

GRU’ da bir güncelleme portu ve bir sıfırlama kapısına ek olarak geçitli bir tekrarlama ünitesi de bulunmaktadır. Güncelleme geçidinin görevi, geçmişten gelen bilgilerin ne kadarının geçtiğine karar vermektir. Sıfırlama geçidi de geçmişten gelen bilgilerin ne kadarının atıldığına karar vermekte kullanılır (Şişmanoğlu, Koçer, Önde, & Şahingöz, 2020: 439).

Tekrarlayan sinir ağlarının yeni bir türü olan GRU, çalışma mantığı olarak LSTM’ye benzerliklere sahiptir. Ancak hücre durumundan kopması ve gizli durumu uygulaması GRU’ yu LSTM’ den farklı kılmaktadır (Güney, 2022: 27).

Şekil 42’ de GRU’ nun yapısal halinin görseli verilmiştir:

Şekil 42: GRU Model Yapısı



Kaynak: Haberal, 2020: 26

x_t = Giriş vektörü

h_t = Gizli katman vektörü

r_t = Sıfırlama kapısı

z_t = Güncelleme kapısı

W = Ağırlık

LSTM ile benzer olarak, GRU’ da ayrı bellek hücreleri olmadan birim içindeki bilgi akışını modüle eden geçiş birimleri mevcuttur (Cho, Gülçehre, Bengio, & Chung, 2014: 4).

GRU’ nun “ t ” zaman adımındaki h_t^j aktivasyonu, bir önceki zaman adımı h_{t-1}^j aktivasyonu ile $\tilde{h}_t^j$ aday aktivasyonu arasındaki doğrusal interpolasyondur:

$$h_t^j = (1 - z_t^j)h_{t-1}^j + z_t^j\tilde{h}_t^j \quad 2.27$$

Güncelleme kapısı olan z_t^j ’ nin görevi, birimin aktivasyonunu veya içeriğini ne kadar güncelleyeceğine karar vermektir. Güncelleme kapısı ise şu şekilde hesaplanır:

$$z_t^j = \sigma(W_z x_t + U_z h_{t-1})^j \quad 2.28$$

Aday aktivasyon $\tilde{h}_t^j$, geleneksel tekrarlayan ağ ile benzer şekilde hesaplanır:

$$\tilde{h}_t^j = \tanh(W x_t + U(r_t h_{t-1}))^j \quad 2.29$$

Sıfırlama kapısı olan r_t , sıfıra yakın olduğunda birimin bir giriş dizisini sanki ilk kez okuyormuş gibi etkin bir şekilde hareket etmesini sağlayarak önceden hesaplanan durumu unutmasına izin verir.

Sıfırlama kapısı aşağıdaki gibi hesaplanmaktadır:

$$r_t^j = \sigma(W_r x_t + U_r h_{t-1})^j \quad 2.30$$

İkinci bölümde derin öğrenme ve tezde kullanılan teknikler anlatılmıştır. Üçüncü bölümde bu çalışma hakkında geçmişte yapılan çalışmalar, bu çalışmanın amacı, çalışmanın veri seti, uygulama ve çalışmanın sonucu hakkında bilgiler verilecek.

ÜÇÜNCÜ BÖLÜM

HİSSE SENEDİ FİYAT TAHMİNİ UYGULAMASI

3.1. LİTERATÜR TARAMASI

Kalyoncu (2020) yazdığı yüksek lisans tezinde dört adet teknik ile hisse senedine ait geçmiş fiyat verileri ile hisse senedinin gelecekteki fiyatının tahminini yapmayı amaçlamaktadır. Bunun için iki farklı veri seti üzerinde çalışmasını gerçekleştirmiştir. Birinci veri seti, BİST 30 içerisinde THYAO (Türk Hava Yolları), AKBANK (Akbank), ARCLK (Arçelik), ASELS (Aselsan) ve GARAN (Garanti Bankası) şirketlerine ait 2014 – 2020 yıllarına ait verilerden oluşmaktadır. Bu veri setine derin öğrenme tekniklerinden LSTM tekniği uygulaması yapmıştır. İkinci veri setinde ise Hindistan borsasından Tata Global Beverages şirketine ait 2010 – 2019 yılları arasındaki günlük açılış, kapanış, en yüksek ve en düşük değerleri yer almaktadır. Bu veri setinde ise bu konuda en popüler olan Yapay Sinir Ağları, K – En Yakın Komşular ve Oto-regresif Entegre Hareketli Ortalamalar tekniklerinden faydalanmıştır. Çalışmada performans başarı kriteri olarak RMSE (Root Mean Squared Error) ve MAE seçilmiştir. Sonuçlara göre makine öğrenmesi teknikleri arasında başarı sıralaması başarılıdan başarısız doğru Oto-regresif Entegre Hareketli

Ortalamalar tekniđi ardından Yapay Sinir Ađları tekniđi ve son olarak K – En Yakın Komşular tekniđi şeklinde oluřmuřtur.

Altunbař (2021) derin öğrenme teknikleriyle BİST’ te ait banka endeksi olan XBANK (Borsa İstanbul Banka Endeksi) endeksinin bir gün sonraki güne ait kapanıř deđerinin tahmin çalıřmasını yapmıřtır. XBANK’ ın 04.11.2015 – 04.11.2019 tarihleri arasındaki gúnlük kapanıř, açılıř, en yüksek ve en düşük deđerleri yanısıra teknik gösterge olarak RSI, MACD, Momentum, William, Basit Hareketli Ortalama, Stokastik K ve Stokastik D ve makroekonomik gösterge olarak da Euro kuru, Dolar kuru, Brent petrol, gram altın da 10 gecikmeye kadar deđerleri ile bu çalıřmada yer almıřtır. Endeks resmi tatillerde iřlem görmediđi için kapanıř, açılıř, en yüksek ve en düşük deđeri için dummy(kukla) deđiřkenler oluřturulmuř; buna göre tatil gúnlüklerine 0 deđeri, iř gúnlüklerine 1 eđer atanmıřtır. Metinsel verileri için de internet sitelerinden seçilen tarih aralıđına ait haberlerin bařlıkları kullanılmıřtır. Çalıřma için finansal, metinsel ve finansal-metinsel veri setleri olmak üzere üç adet veri seti hazırlanmıřtır. Her veri seti %70 eđitim ve %30 test seti olarak ayrılmıř, modele katkı sunmayan deđiřkenler Boruta algoritması kullanılarak eđitim setinden çıkarılmıřtır. Analizin sonuçlarına göre üç adet veri seti arasında birleřtirilmiř veri seti olan finansal-metinsel veri seti ve finansal veri seti birbirlerine benzer olarak bařarılı sonuçlar vermemiř, metinsel veri seti ise diđer iki veri setine nazaran daha bařarılı sonuçlar vermiřtir. Hiçbir veri seti bařarılı sonuç vermediđi için bařka bir yöntemle bařvurulmuř ve bundan dolayı ayrıyeten derin öğrenmede kullanılan topluluk öğrenmesi yönteminden faydalanılarak tahmin deđerinin ortalaması alınmıř, gerçek deđerlerle aralarındaki iliřki incelenmiř ve bařarılı sonuçlar elde edildiđi gözlemlenmiřtir. Ortalamaların dađılımları incelendiđinde en çok bozulmanın olduđu Haziran – Aralık 2019 döneminden yola çıkılarak veri setleri bu ilgili dönem dahil ve ilgili dönem hariç olmak üzere tekrar düzenlenmiř ve RMSE’ leri hesaplanmıřtır. Buna göre Haziran – Aralık 2019 döneminde artan siyasi gerginlikler ve politikadaki belirsizliklerin modelin tahmin performansına olumsuz etkidiđi anlařılmıřtır. Siyasi gerginliklerin olduđu zamanlarda XBANK’ a yatırım yapacaklar için metinsel veriler daha faydalı olurken, siyasetin daha stabil olduđu dönemlerde ise finansal ve finansal-metinsel verilerin daha bařarılı tahminler gerçekteřtirdiđi sonuçlar elde edilmiřtir.

Aslan (2020) bu çalıřmada BİST’ te iřlem gören spor kulüplerinden üçünn hisse senedi fiyatı tahminini yapmıřtır. Galatasaray (GSRAY), Fenerbahçe (FENER)

ve Beşiktaş (BJKAS) çalışma için seçilmiş olan üç kulüptür. Analizde kullanılacak tarih aralığı GSRAY için 10.11.2011 ile 21.02.2020, BJKAS için 21.09.2011 ile 21.02.2020 ve FENER için 17.05.2010 ile 21.02.2020 olarak belirlenmiştir. Çalışmada bu üç kulübe ait finansal verilere ek olarak şirketlere ait Kamuyu Aydınlatma Platformu (KAP) içerisindeki bildiri verilerinden elde edilmiş duygu analizi sonuçları da yer almıştır. Derin öğrenme yöntemlerinden olan LSTM yöntemi tahminleme için kullanılırken model performans kriteri olarak da RMSE seçilmiştir. Analiz için Python programlama dilinde gerçekleştirilmiştir. Finansal verilerin yanı sıra duygu analizi sonuçlarından da faydalanıldığında analizde başarılı sonuçlar elde edilmektedir.

Ozan (2021) çalışmasında BİST’ te bulunan ISCTR, VAKBN, GARAN QNBFB ve AKBNK kodlu hisse senetlerinin 31.12.2007 ile 31.05.2021 arası verilerini baz alarak günlük fiyat tahmini yapmıştır. 31.01.2007 ile 28.02.2021 arası, eğitim seti, 01.03.2021 ile 31.03.2021 arası doğrulama seti ve 01.04.2021 ile 31.05.2021 arası da test seti olarak ayrılmıştır. Tahminin başarısını artırma amacıyla hisse senetlerinin verileri yanı sıra ISGYO hisse senedi, AKGRT hisse senedi, Dolar kuru, BIST30 ve BANKX endekslerinin de geçmiş verileri çalışmada yer almıştır. Analiz Google Colab ortamında LSTM ve GRU tekniklerini kullanılarak gerçekleştirilmiştir. Çalışmada iki farklı bilgisayar, iki farklı derin öğrenme modeli ve farklı hipermetrelerden faydalanarak 96 adet farklı model yaratılmış ve sonuç olarak MSE performans kriteri baz alındığında LSTM tekniğinin GRU tekniğine göre daha başarılı tahmin yapıldığı gözlemlenmiştir. Daha sonra beş hisse senedi için LSTM tekniği kullanılarak MSE, MAE ve MRE kriterleri hesaplanmıştır. Nisan 2021 döneminde çalışmadaki 5 farklı hisse senedi arasında en başarılı performans ISCTR’ ye aittir. Mayıs 2021 dönemi içinse GARAN hissesi en başarılı performansa sahiptir.

Güney (2022) çalışmasında derin öğrenme tekniklerinden RNN, LSTM ve GRU tekniklerini kullanarak BİST’ te işlem gören GOLTS adlı hisse senedinin 30, 60, 90 ve 120 günlük fiyat tahminini gerçekleştirmiştir. Veri setinde şirkete ait 02.01.2012 – 31.12.2020 tarihleri arasındaki günlük kapanış fiyatı değerleri yer almaktadır. Analiz için veri seti %70 eğitim ve %30 da test seti olarak bölünmüştür. Model performans kriterleri olarak da MAE, RMSE ve MAPE hesaplanmıştır. Sonuçlara göre en başarılı teknikler sırasıyla GRU, LSTM ve RNN teknikleri olmuştur.

Raço (2019) derin öğrenmeden faydalanarak BIST 30 endeksinin gelecekteki değerlerini öngörme amacıyla bu çalışmayı yapmıştır. Çalışma için seçilen tarih aralığı 01.01.2016 ve 31.12.2018 arasındadır. Veri seti %80 eğitim ve %20 test seti olmak üzere ikiye ayrılmıştır. Analiz için Yapay Sinir Ağları ve Destek Vektör Makineleri teknikleri seçilirken model performans kriteri olarak da MSE seçilmiştir. Tahmini yapılan 5 gün için tahmin sonuçları alandaki diğer çalışmalara nazaran daha başarılıdır.

Demiray (2021) çalışmasında makine öğrenmesi yöntemiyle Microsoft firmasının 2014 – 2019 arasındaki hisse senedi kapanış fiyatlarını tahmin etmeyi hedeflemiştir. Bu amaçla Polinomial Regresyon, ARIMA (Autoregressive Integrated Moving Average), XGBooster, LSTM ve Facebook Prophet yöntemlerini kullanmıştır. Çalışmada hem kısa vadeli hem de uzun vadeli tahminler yapılmıştır. Kısa vade için 5, 10 ve 20 günlük değer tahminleri yapılırken uzun vadeli için 1 yıllık günlük değer tahminleri yapılmıştır. Kısa vade için en başarılı performansı Polinomial Regresyon tekniği göstermiştir. Uzun vadede ise en başarılı sonucu LSTM tekniği vermiştir.

Akşehir (2020) BİST 30 ve BİST 30' da yer alan AKBNK, HALKB, GARAN, ISCTR VAKBN ve YKBANK banka hisselerinin kapanış fiyatlarının bir gün sonraki değerini tahmin etmek için bu çalışmayı gerçekleştirmiştir. Bu çalışma için seçilen tarih aralığı 06.01.2010 – 09.03.2020 arasındadır. Ayrıca çalışmada derin öğrenme tekniklerinden LSTM tekniği kullanılırken modelin performans kriteri olarak da RMSE, MAE ve MAPE değerleri hesaplanmıştır. Tahmin edilen değerlerin grafiği ve gerçek kapanış değerlerine ait grafiğin çakışmıştır ve böylelikle başarılı bir tahmin modeli ortaya konmuştur.

Demirel (2019) çalışmasında tahminleme amacıyla BİST 100 endeksinde bulunan şirketlerin Ocak 2010 – Ocak 2019 arası 2. Seans açılış ve kapanış fiyatlarının günlük olarak verilerini kullanmıştır. Tahminleme için Çok Katmanlı Algıyıcılar, Destek Vektör Makineleri ve LSTM tekniklerinden yararlanmıştır. Sonuç olarak Çok Katmanlı Algıyıcılar ve LSTM tekniklerinin Destek Vektör Makineleri'nden daha başarılı olduğu tespit edilmiştir.

Karadağ (2022) tezinde LSTM ve GRU tekniklerini kullanarak BİST' te bulunan XBANK endeksinin gelecek değerlerini tahmin etmiştir. 04.01.2010 – 31.01.2022 tarih aralığındaki günlük verileri kullanmıştır. Tahmin başarısını arttırmak için ARIMA modeli ve teknik analizde bulunan göstergeleri de analize ekleyerek hibrit

model ortaya çıkarmıştır. Analizlerin sonucunda GRU – hibrit model, oluşturulmuş olan diğer yalnız GRU, yalnız LSTM ve LSTM – hibrit modellere göre daha başarılı sonuçlar vermiştir.

Jiang ve Peng (2016) kelime gömme ve derin öğrenme yöntemleri kullanarak hisse senedi fiyatlarını tahmin etmeyi amaçlamışlardır. Tahmin için kelime gömme yöntemlerinden word2vec seçilirken, Derin öğrenme yöntemlerinden de LSTM ve GRU teknikleri seçilmiştir. Veri seti, “Centre for Research in Security Prices” veritabanından elde edilip 2006 – 2013 yılları arasındaki verileri analizde kullanılmıştır. 01.10.2006 ile 31.12.2012 arası eğitim seti, 01.01.2013 ile 15.06.2013 arası doğrulama seti ve 16.06.2013 ile 31.12.2013 arası da test seti olarak ayrılmıştır. Yazarlara göre finansal haberler hisse senedi fiyat tahmininde başarıyı olumlu olarak etkilemektedir. Bu nedenle derin öğrenme tekniklerinin finansal haberlerle birlikte kullanılmasının başarılı sonuçlar vereceğini söylemektedirler.

Persio ve Honchar (2017) Google şirketinin hisse senedi fiyatının hareketini tahminlemek için RNN, LSTM ve GRU teknikleri ile çalışma yapılmış ve bu teknikler arasından hangisinin daha başarılı olduğu belirlenmeye çalışılmıştır. Veri setinde Google şirketinin 2012- 2016 yılları arası açılış, kapanış, en yüksek, en düşük ve hacmine dair bilgiler değişken olarak bulunmaktadır. Sonuç olarak 5 günlük tahminde doğruluk oranı %72 ile en yüksek olan LSTM tekniğien başarılı teknik olarak belirlenmiştir.

Vinj vd., (2019) Nike, Goldman Sachs, Johnson and Johnson, Pfizer ve JP Morgan Chase and Cho. Gibi Amerikan borsasında işlem gören büyük şirketler çalışmada yer almıştır. Veri setinde ilgili şirketlerin 04.05.2009 ve 04.05.2019 arası günlük açılış, kapanış, en yüksek, en düşük ve hacim verileri yer almaktadır. Çalışmanın amacı Yapay Sinir Ağları ve Rastgele Orman tekniklerini kullanarak ilgili şirketlerin hisse senedi fiyatlarındaki değişimleri tahmin etmek ve teknikler arasından en iyi tahmin yapan tekniği belirlemektir. Bunun için model performans kriterlerinden RMSE ve MAPE’ kriterleri seçilmiştir. Sonuçlara göre en iyi tahmin sonucunu veren teknik Rastgele Orman tekniği olmuştur.

Moghar ve Hamche (2020), RNN ve LSTM tekniklerini kullanarak gelecekteki hisse senedi değerlerini başarılı bir şekilde tahmin etmeyi amaçlamışlardır. Çalışmada New York Borsası’ nda işlem gören GOOGL (Google) ve NKE (Nike) hisselerini

kullanmışlardır. Her bir hisse senedi için olmak üzere iki adet veri seti hazırlanmıştır ve bütün veriler Yahoo Finance’ tan alınmıştır. GOOGL için hazırlanan veri setinin tarih aralığı 19.08.2004 ve 19.12.2019 iken NKE için hazırlanan veri seti aralığı 04.01.2010 ve 19.12.2019 arasındır. Oluşturulan veri setlerinin %80’ i eğitim için %20’ si de test için ayrılmıştır. Analizde 12, 25, 50 ve 100 olmak üzere 4 farklı epoch değeri de hesaplanmıştır. Modellerin başarımı, model performans kriterlerinden MSE ile test edilmiştir. Çalışmanın sonucu olarak her iki teknik de hisse senetlerinin gelecek fiyat tahminlerini başarılı bir şekilde gerçekleştirmiştir.

Mehtab ve Sen (2020) bu çalışmada CNN ve LSTM kullanarak Hindistan Ulusal Borsası’ nda işlem gören NIFTY 50 endeksinin gelecekteki fiyatı hakkında başarılı bir tahmin yapmayı amaçlamıştır. Bunun için endeksin Aralık 2008 ve Temmuz 2020 arası günlük açılış, kapanış, en yüksek ve en düşük fiyatlarından oluşan bir veri seti oluşturulmuştur. Modelin performansını değerlendirmek için model performans kriterlerinden MSE ve MAE hesaplanmıştır. Sonuçlara göre model endeksin gelecekteki fiyatını tahmin etmekte başarılıdır.

Song ve Choi (2023) DAX, DOW ve S&P 500 endekslerinin tek adımlı ve çok adımlı kapanış fiyatlarının tahmin etmekte RNN tabanlı modeller baz alınarak oluşturulan hibrit modellerinin kullanımını test etmek istemişlerdir. CNN – LSTM ve GRU – CNN bu amaçla kullanılan iki hibrit modellerdir. Modellerin başarısını ölçmek için MSE e MAE performans kriterleri hesaplanmıştır. Sonuçlara göre tek adımlı durum klasik makine öğrenmesi modellerine kıyasla MSE değeri açısından %48.1 ve MAE değeri açısından da %40.7 daha başarılıdır. Çok adımlı tahminde ise MSE ve MAE bakımından başarı oranı %81.5’ tir.

Nabipour vd. (2020) makine öğrenimi ile trend tahmini riskini önemli ölçüde azaltmayı amaçlayan bir çalışma yapmıştır. Makine öğrenmesi tekniklerinden Karar Ağaçları, Rastgele Orman, Adaptive Boosting, XGBoost, Destek Vektör Makineleri, Naive Bayes, K-En Yakın Komşular, Lojistik Regresyon ve Yapay Sinir Ağları ve en derin öğrenme tekniklerinden de RNN ve LSTM tekniklerinin yer aldığı çalışmada teknikler başarılarına göre kendi aralarında karşılaştırılmıştır. Veri seti olarak İran Borsa’sından çeşitlendirilmiş finansallar, petrol, metalik olmayan mineraller ve temel metaller olmak üzere dört endeks seçilmiştir. Çalışmanın tarih aralığı Kasım 2009 ve

Kasım 2019 arası olarak belirlenmiştir. Çalışmanın sonucunda en başarılı sonuçlar derin öğrenme teknikleri olan RNN ve LSTM analizleri sonucunda elde edilmiştir.

Chatterjee vd. (2021) bu çalışmada, Hindistan’ daki bilişim teknolojileri sektöründen Infoysys, bankacılık sektöründen ICICI ve sağlık sektöründen de SUN PHARMA hisselerinin Ocak 2004 – Aralık 2019 tarihleri arasındaki verileri ile fiyat tahminlemesi yapılmıştır. Çalışmada daha çok hangi model ile hangi sektörde daha başarılı sonuçlar alınacağı husunda cevaplar aranmıştır. Bu amaçla çalışmada zaman serisi tekniklerinden Holt – Winters Üstel Yumuşatma, ekonometrik tekniklerden ARIMA, makine öğrenmesi tekniklerinden Rastgele Orman ve Çok Değişkenli Uyarlanabilir Regresyon Spline’ leri ve derin öğrenme tekniklerinden de RNN ve LSTM teknikleri kullanılmıştır. Çok Değişkenli Uyarlanabilir Regresyon Spline’ lerin makine öğrenmesi teknikleri arasında en başarılı olurken, derin öğrenme teknikleri arasında ise LSTM tekniği en başarılı teknik olmuştur.

Yussif (2020) çalışmasında Gana Borsası’ ndan kompozit endeksini ele almıştır. Endeksin geçmiş verileri ile endeksin fiyatını tahmin etmeyi amaçlamıştır. Bu amaç için derin öğrenmenin Çok Katman Algılayıcı, CNN ve LSTM tekniklerini kullanmıştır. Veri seti ise endeksin 02.01.2015 ve 31.12.2019 arası günlük değerlerinden oluşturulmuştur. Veri setinde 2015 ve 2019 yılları arası eğitim seti olarak ayrılırken geriye kalan 2019 yılına ait veriler de test seti olarak belirlenmiştir. Çalışmanın sonucuna göre en başarılı teknik CNN olurken CNN’ i LSTM izlemiştir en başarısız teknik de Çok Katmanlı Algılayıcılar olmuştur.

Jiang (2020) bitcoin üzerine fiyat tahmini yaptığı çalışmasında derin öğrenmenin LSTM, GRU ve Çok Katmanlı Algılayıcılar tekniklerini kullanmış ve teknikler kendi aralarında karşılaştırılmıştır. Veri setindeki veriler Ocak 2012 ve Temmuz 2018 arası dakikalık veriler olup Kaggle adlı siteden alınmışlardır. Veri setindeki değişkenler bitcoin cinsinden açılış, kapanış, en yüksek, en düşük, ağırlıklı fiyat ve hacim değişkenleri olurken ayrıca USD için hacim ve ağırlıklı fiyat değişkenleri de yer almaktadır. Çalışmanın sonucuna göre en başarılı tahmin LSTM tekniği tarafından gerçekleştirilmiştir.

3.2. ÇALIŞMANIN AMACI

Yapay zekâ ve derin öğrenme insanoğlunun karşılaştığı sorunları çözmede başarılı ve hızlı çözümler sunmasından dolayı her geçen gün insan hayatının hemen

hemen her alanında daha çok yer kaplamaktadır. Yapay zekâ üzerine ilk çalışmalar 1940' larda basit algoritmalar ve ilkel bilgisayarlardaki hesaplamalarla birlikte atılmıştır. Daha sonra ilerleyen yıllarda bilgisayar teknolojisinin ilerlemesi ile birlikte yapay zekâ teknoloji de artmış ve en zorlu hesaplamalar bile hızlı ve başarılı bir şekilde bilgisayar ortamında gerçekleştirilmeye başlanmıştır. Bu gelişmeler neticesinde yapay zekânın bir alt dalı olan makine öğrenmesi 1980' lerde, makine öğrenmesinin alt dalı olan derin öğrenme ise 2010' lu yıllardan itibaren ortaya çıkmış ve kendine kullanım açısından geniş bir yer bulmuştur.

İnsanoğlu binlerce yıldır para ile iç içedir ve paranın bulunmasından öncesine dayanan ticaret geçmişine sahiptir. Ticarete insanlar için en önem arz eden konu aldığı veya alacağı ürünün fiyatını önceden kestirebilmek ve sonuç olarak kâr edebilmektir. Borsacılık faaliyetleri dünyada 1600' lere, ülkemizde ise 1800' lerin ortasına dayanmaktadır. Kolayca alım-satım yapılabilmesi ve kanunlarla korunan bir yapıda olmasından dolayı da günümüzde birçok yatırımcı tarafından tercih edilmektedir. Ayrıca yatırımcı sayısı arttığı gibi borsada faaliyet gösteren şirket sayısı da gittikçe artmaktadır.

Bu çalışmanın amacı, BİST' te XELKT endeksi baz alınarak, hisse senedi fiyatlarının derin öğrenme tekniklerinden LSTM ve GRU ile tahmin edilmesi ve kullanılan bu iki tekniğin hisse senedi fiyat tahmininde uygulanabilirliğidir. Buna göre BİST' te faaliyet gösterip XELKT endeksi içerisinde bulunan beş şirket, BİST 100, USD/TL kuru ve XELKT değişkenlerinin 02.01.2013 ve 30.12.2022 yılları arasındaki günlük açılış, kapanış, en yüksek ve en düşük değer üzerine yapılmıştır. Tarih aralığının bu tarihler arasında seçilmesinin nedeni aşağıda belirtilen olayların fiyatlar üzerinde etkisinin olduğunun düşünülmesi ve bu etkinin tahmin sonuçlarındaki başarıyı olumsuz yönde etkileyeceğinin varsayılmasıdır. Çünkü Türkiye ekonomisi menkul kıymetler borsası oluşumunun tam anlamıyla oturmadığı ülkelerde yaşanan içsel ve dışsal şoklarda borsa endeksi kolayca etkilenebilmektedir. Bu durum yatırımcıların kısa sürede yatırımlarını çekip başka olasılıklara yönelmesine sebep olmaktadır (Özçalık & Güler, 2018: 303).

- Ocak 2013' te 1,70 TL civarlarında olan dolar kurunun Haziran 2013' teki Gezi Olayları ile 2 TL üzerine çıkmış,

- Şubat 2014’ te dünyanın en büyük enerji üreticilerinden olan ve ülkemizin enerji ihtiyacında büyük rol oynayan Rusya, Ukrayna ile siyasi gerginlik yaşamış,
- 2016 yılının Temmuz ayında ülkemizde darbe girişimi olmuş,
- 2017 Nisan ayında ülkemizde Cumhurbaşkanlığı yönetim sisteminden partili Başkanlık sistemine geçilmiş,
- 2020 yılının başlarında tüm dünyaya COVID – 19 yayılmış bu nedenle neredeyse hayat durma noktasına gelmiş,
- Şubat 2022’ de Rusya ile Ukrayna arasında savaş çıkmış dolayısıyla tüm dünyada enerji krizi boy yaşanmıştır.

Bu çalışma ile birlikte dünyada ve özellikle ülkemizde pek fazla bulunmayan derin öğrenme ile enerji şirketleri hisse senedi tahminine dair literatür doldurulmaya çalışılmış ve ileride bu konuda çalışma yapmak isteyen araştırmacılara yardımcı olması hedeflenmiştir.

3.3. KULLANILAN DEĞİŞKENLER VE YÖNTEMLER

Veriler, Yahoo Finance’ tan alınmıştır. USD/TL harici değişkenler Türkiye özelinde olup Türkiye’ de tatil olan günlerde işlem görmezken, USD/TL’ nin global olması ve Türkiye’ de tatil olan bazı günlerde dünyada işlem görmesinden kaynaklı olarak eksik veri olup olmadığı incelemesi yapılmış ve hisse senedine göre fazlalık olan veriler veri setinden çıkarılmıştır. Ardından uygulama adımına geçilmiştir.

Çalışmada analizler için Google Colab kullanılmıştır. Google tarafından 2017 yılında geliştirilip kullanıma sunulmuştur. Kullanması ücretsiz olan ve kullanmak için kurulumla ihtiyaç duymayan Google Colab, bulut tabanlı Python programlama ortamı sağlamaktadır. Veri analizi, makine öğrenmesi uygulamaları konularında oldukça popülerdir.

Her bir şirket için bir adet olmak üzere toplam beş adet veri seti hazırlanmış, bu veri setlerine şirket verilerine ek olarak BİST 100, USD/TL kuru ve XELKT’ ye ait veriler verilmiştir. Her hisse senedi için kapanış değeri tahmin edilmeye çalışıldığı analizlerde LSTM ve GRU teknikleri olmak üzere 2 adet teknik kullanılmıştır. Diğer araştırmalara daha çok yardımcı olması ve birçok soruyu cevaplayabilmesi amacıyla

analiz olabildiğince çeşitlendirilmiştir. 20, 50, 100 ve 200 olmak üzere 4 farklı sayıda epoch, her epocha uygun olacak şekilde 4 farklı batch size değeri, 30, 60, 90 ve 120 gün olmak üzere 4 farklı sayıda gün ve MSE, MAE ve MAPE olmak üzere de 3 farklı sayıda model performans kriteri hesaplanmıştır.

Bütün veri setlerine uygulanan analizlerde standart olarak veri setinin %80' ini eğitim, %20' si test ve yine %20' si de doğrulama seti olarak ayrılmıştır.

3.3.1. GRU Uygulaması

Python mimarisine göre analizler için başlangıç olarak kütüphanelerin içeri aktarılması gerekmektedir. Şekil 43' de analiz için içeri ktarılan kütüphaneler görülmektedir.

Şekil 43: Analiz İçin Kullanılacak Python Kütüphaneleri

```
[22] #Kütüphanelerin içeriye aktarılması
import math
import pandas_datareader as web
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, GRU
import matplotlib.pyplot as plt
plt.style.use("fivethirtyeight")
```

Şekil 44' de veri setinde yer alan satır ve sütun bilgileri gösterilmektedir.


Şekil 44: Satır ve Sütun Sayısı

```
[24] #Veri setindeki satır ve sütun sayısı
df.shape

(2511, 17)
```

Şekil 45' te AKSEN adlı hisse senedinin kapanış grafiği verilmiştir. 2000. Gün olan 16 Aralık 2020' ye kadar stabil seyreden hisse senedi fiyatı bu tarihten itibaren çok yüksek bir artış göstermiştir.

Şekil 45: AKSEN Hissesinin Tarihsel Kapanış Grafiği



Veri setinin %80' ini eğitim seti olarak ayrılmıştır. Bu işleme dair kod Şekil 46' da görülmektedir.

Şekil 46: Veri Seti İçerisinden Eğitim Setini Ayarlamak

```
#Yalnızca "AKSENKapanis" sütunuyla yeni bir dataframe(veri çerçevesi) oluşturmak
data=df.filter(["AKSENKapanis"])
##Dataframe' i bir numpy dizisine dönüştürmek
dataset=data.values
#Eğitim setinin belirlemek
training_data_len=math.ceil(len(dataset)*.8)
training_data_len
```

2009

Şekil 47' de önce katmanları ardışık olarak eklemeye yarayacak sıralı model oluşturulmuştur. Ardından 50 nörona sahip ilk GRU katmanı modele eklenir ve "return_sequences = True" ile katmanın ardışık bir katmana ait giriş olduğu belirtilir. Daha sonra 50 nörona sahip diğer GRU katmanı modele eklenmiştir, "return_sequences = False" girdisi ile bu katmanın ardından başka katmanın olmayacağı belirtilir. Bu adımdan sonra 25 nöronlu yoğunluk katmanı modele konur. Bu katmanın görevi kendinden önceki GRU katmanlarından kendisine gelen çıktıları alıp ardışık olacak şekilde bağlantılandırır. En son adım olarak hisse senedi fiyatının yalnızca bir tane değeri tahmin edildiği için sadece 1 nörona sahip son yoğunluk katmanı eklenir. Bu 1 nöron çıktı değerine sahiptir ve çıktı olarak tahmin değerini verir.

Şekil 47: GRU Modelinin Kodu

```
#GRU modelinin oluşturulması
model=Sequential()
model.add(GRU(50, return_sequences=True, input_shape=(x_train.shape[1],1)))
model.add(GRU(50,return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
```

Şekil 48’ de görüldüğü gibi modelin kayıp fonksiyonu olarak “mean squarred error” belirlenirken, optimize edici olarak ise diğerlerinden daha başarılı olan “adam” seçilmiştir.

Şekil 48: GRU Modeline Kayıp Fonksiyonu ve Optimize Edici Atanması

```
[50] #Modelin derlenmesi
model.compile(loss='mean_squared_error', optimizer='adam')
```

Bu model için Batch Size sayısı 5 belirlendiği için eğitim seti 5 eşit parçaya bölünmüştür. Buna göre %80’lik bölünmeden sonra 1889 adet gözlem değerine sahip olan eğitim seti 1889’ un da 5’ e bölünmesi sonucu 378 adet gözlem değeri ile eğitim görmektedir. Aynı yeten epoch sayısı 20 belirlendiği için model 378 adetlik eğitim setini 20 kez okuma yapmaktadır. Bu işlemin görselleştirilmiş hali Şekil 49’ da görülmektedir.

Şekil 49: Girilmiş Olan Epoch ve Batch Sayılarına Göre Modelin Eğitilmesi

```
#Modelin eğitilmesi
model.fit(x_train,y_train, batch_size=5, epochs=20)

Epoch 1/20
378/378 [=====] - 27s 64ms/step - loss: 1.3776e-05 - accuracy: 5.2938e-04
Epoch 2/20
378/378 [=====] - 24s 63ms/step - loss: 4.2130e-06 - accuracy: 5.2938e-04
Epoch 3/20
378/378 [=====] - 24s 62ms/step - loss: 4.3085e-06 - accuracy: 5.2938e-04
Epoch 4/20
378/378 [=====] - 23s 62ms/step - loss: 2.5337e-06 - accuracy: 5.2938e-04
Epoch 5/20
378/378 [=====] - 24s 62ms/step - loss: 3.0303e-06 - accuracy: 5.2938e-04
Epoch 6/20
378/378 [=====] - 23s 61ms/step - loss: 2.4317e-06 - accuracy: 5.2938e-04
Epoch 7/20
378/378 [=====] - 23s 62ms/step - loss: 2.1456e-06 - accuracy: 5.2938e-04
Epoch 8/20
378/378 [=====] - 23s 61ms/step - loss: 2.3898e-06 - accuracy: 5.2938e-04
Epoch 9/20
378/378 [=====] - 23s 61ms/step - loss: 2.0277e-06 - accuracy: 5.2938e-04
Epoch 10/20
378/378 [=====] - 23s 62ms/step - loss: 1.9770e-06 - accuracy: 5.2938e-04
Epoch 11/20
378/378 [=====] - 24s 62ms/step - loss: 1.8503e-06 - accuracy: 5.2938e-04
Epoch 12/20
378/378 [=====] - 23s 62ms/step - loss: 2.2245e-06 - accuracy: 5.2938e-04
Epoch 13/20
378/378 [=====] - 23s 62ms/step - loss: 1.9058e-06 - accuracy: 5.2938e-04
Epoch 14/20
378/378 [=====] - 23s 62ms/step - loss: 2.1565e-06 - accuracy: 5.2938e-04
Epoch 15/20
378/378 [=====] - 23s 61ms/step - loss: 1.8020e-06 - accuracy: 5.2938e-04
Epoch 16/20
```

Oluşturulan modelin başarımını gösteren model performans kriterleri Şekil 50’deki kodlarla hesaplanmaktadır.

Şekil 50: MSE, MAE ve MAPE’ nin Sonuçlarının Çıktıları

```
#Ortalama kare hatasının (MSE) hesaplanması
mse=np.mean(tahminler - y_test)**2
mse
```

0.021599029604048397

```
#Hatanın mutlak ortalaması
mae = np.mean(np.abs(y_test - tahminler))
print("MAE: ", mae)
```


MAE: 0.5626282044519068

```
#Ortalama Mutlak Yüzde Hata (MAPE)
mape = np.mean(np.abs((y_test - tahminler) / y_test)) * 100
print("MAPE: ", mape)
```

MAPE: 3.6807672845783457

Mavi çizginin eğitim, kırmızı çizginin doğrulama ve turuncu çizginin tahmini temsil ettiği Şekil 51’ deki grafikte turuncu ve kırmızı çizgiler birbirine ne kadar çok örtüşürse o kadar başarılı tahmin olmuş demektir. Grafiğe göre son 100 güne kadar başarılı bir şekilde gerçekleştirilen tahmin işlemi son 100 gün içerisinde bozulmalar yaşamış ve tahmin başarımı düşmüştür.

Şekil 51: Tahmin Sonucunun Grafiği



Şekil 52’ de test seti ile tahmini yapılmış değerlerin karşılaştırılması amacıyla ilk 5 ve son 5 değeri verilmiştir.

Şekil 52: Gerçek Kapanış Değerleri ve Modelin Tahmin Değerleri

#Geçerli fiyatların ve tahmin edilmiş fiyatların gösterilmesi
valid

	AKSEN	Kapanis	tahminler
2009	3.720000	3.785675	
2010	3.920000	3.865372	
2011	3.850000	4.061842	
2012	4.060000	3.999560	
2013	4.080000	4.210826	
...	...	...	
2506	48.240002	47.509491	
2507	48.400002	46.924160	
2508	46.500000	46.988918	
2509	47.060001	45.591240	
2510	47.000000	45.876606	

502 rows × 2 columns

Analizin gelecek araştırmacılara ışık tutması için olabildiğince çok performans kriteri hesaplanmıştır. Ancak bu çalışmada genel literatürde daha fazla yer aldığı için MSE ve finans alanında çokça tercih edildiği için MAPE değerleri yorumlanacak.

Öncelikle tüm MSE ve MAE değerleri 1' den, MAPE değerleri de %5' ten küçük olduklarından dolayı tüm model performans kriterleri başarılı sonuçlar vermiştir.

- **Epoch değeri 20 olduğu durumlarda:**

AKENR hissesi için MSE ve MAPE açısından en başarılı tahmin 30 günlük tahmin olmuştur.

AKSEN hissesi için MSE 120 günlük tahmin, MAPE açısından ise 30 günlük tahmin daha başarılıdır. MSE' nin bu sonucu modelin genel olarak tahminleri iyi yaptığı gösterirken, MAPE' nin sonucu ise model yüzdelik hataları daha iyi azaltıyor anlamına gelmektedir.

AKSUE hissesi MSE açısından en başarılı tahminini 60 günlük tahminde elde etmiştir. MAPE açısından en başarılı tahmini ise AKSEN' e benzer olarak 120 günlük tahminidir.

AYEN hissesi de AKSUE gibi 60 günlük tahmin ile en düşük MSE değerine sahip olmuştur. En başarılı MAPE değerini ise 30 günlük tahmin sonucunda elde etmiştir.

ZOREN hissesinin en başarılı MSE ve MAPE performansı 90 günlük tahminleridir.

Tablo 2: Epoch' un 20, Batch' ın 5 Olduğu GRU Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	5	MSE	0.0019	0.0349	0.0139	0.2201	0.0048
		MAE	0.0589	0.4423	0.4735	0.5986	0.0847
		MAPE%	2.4720	2.5511	2.2502	3.5587	2.5588
60	5	MSE	0.0068	0.8231	0.0090	0.2185	0.0076
		MAE	0.0886	0.9242	0.4907	0.6200	0.0985
		MAPE%	3.4317	4.6474	2.3793	3.6497	3.0365
90	5	MSE	0.0027	0.3011	0.3714	0.3836	0.0012
		MAE	0.0641	0.7472	0.7102	0.7429	0.0703
		MAPE%	2.6585	3.0160	2.7298	4.0676	2.1104
120	5	MSE	0.0032	0.0215	0.0375	0.7388	0.0087
		MAE	0.0665	0.5626	0.4341	0.9177	0.1065
		MAPE%	2.7432	3.6807	1.9528	5.0021	2.9127

- **Epoch değeri 50 olduğu durumlarda:**

AKENR hissesi için en düşük MSE değeri 120 günlük tahminde elde edilirken MAPE açısından en düşük tahmin 60 günlük tahmin olmuştur.

AKSEN hissesinin en başarılı MSE tahmini 90 günlük tahminidir. MAPE baz alındığında ise en başarılı tahmin 120 günlük tahmin sonucu oluşmuştur.

AKSUE hissesi de AKENR gibi en başarılı MSE' değerine 120 gün tahmininde ulaşmıştır. MAPE için ise en başarılı sonuç 30 günlük tahminde elde edilmiştir.

AYEN hissesi de AKSUE' ye benzer olarak 120 günlük tahmin ile en düşük MSE değerine ulaşmıştır. Ayrıca en düşük MAPE değeri de 120 günlük tahmin sonucu ortaya çıkmıştır.

ZOREN hissesi 30 günlük tahmin ile en başarılı MSE ve MAPE tahminlerini gerçekleştirmiştir.

Tablo 3: Epoch' un 50, Batch' ın 32 Olduğu GRU Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	32	MSE	0.0024	0.1708	0.1813	0.3693	0.0014
		MAE	0.0616	0.5102	0.5529	0.7050	0.0684
		MAPE%	2.5626	2.5474	2.3339	3.9904	2.1052
60	32	MSE	0.0006	0.2347	0.3297	0.3531	0.0020
		MAE	0.0513	0.5674	0.6999	0.6829	0.0710
		MAPE%	2.0979	2.6957	2.8541	3.9729	2.1626
90	32	MSE	0.0019	0.0590	0.2039	0.8921	0.0044
		MAE	0.0586	0.4686	0.5634	0.9807	0.0817
		MAPE%	2.4801	2.7820	2.5639	4.5122	2.6658
120	32	MSE	0.0008	0.1233	0.1279	0.0481	0.0100
		MAE	0.0524	0.4661	0.5245	0.4440	0.1274
		MAPE%	2.2470	2.5101	2.6779	3.0519	4.8483

- Epoch değeri 100 olduğu durumlarda:**

AKENR hissesi için en düşük MSE değeri 60 günlük tahminde elde edilirken MAPE açısından en düşük tahmin 30 günlük tahmin olmuştur.

AKSEN hissesinin en başarılı MSE ve MAPE tahmini 60 günlük tahminleridir.

AKSUE hissesi de AKSEN gibi en başarılı MSE ve MAPE değerlerine 60 günlük tahmininde ulaşmıştır.

AYEN hissesi 120 günlük tahmin ile en düşük MSE değerine ulaşmıştır. Ayrıca en düşük MAPE değeri de 120 günlük tahmin sonucu ortaya çıkmıştır.

ZOREN hissesi 90 günlük tahmin ile en başarılı MSE ve MAPE tahminlerini gerçekleştirmiştir.

Tablo 4: Epoch' un 100, Batch' ın 64 Olduğu GRU Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	64	MSE	0.0009	0.0690	0.5703	0.4853	0.0014
		MAE	0.0525	0.4319	0.8178	0.7523	0.0717
		MAPE%	2.1613	2.3804	3.2015	4.5669	2.1186
60	64	MSE	0.0001	0.0061	0.1024	0.3534	0.0037
		MAE	0.0523	0.4071	0.4834	0.7011	0.0800
		MAPE%	2.2769	2.2802	2.0958	3.9561	2.8437
90	64	MSE	0.0026	0.1789	0.5455	0.2723	0.0003
		MAE	0.0629	0.5158	0.8002	0.6473	0.0642

		MAPE%	2.7059	3.0351	3.1703	3.7255	2.0872
120	64	MSE	0.0002	0.2101	0.3288	0.0581	0.0054
		MAE	0.0539	0.5338	0.6602	0.4601	0.0966
		MAPE%	2.3703	2.7809	2.7179	3.0949	3.4549

- **Epoch değeri 200 olduğu durumlarda:**

AKENR hissesi için en düşük MSE değeri 60 günlük tahminde elde edilirken MAPE açısından da en düşük tahmin 60 günlük tahmin olmuştur.

AKSEN hissesinin en başarılı MSE ve MAPE tahmini 120 günlük tahminleridir.

AKSUE hissesi de AKSEN gibi en başarılı MSE ve MAPE değerlerine 120 günlük tahmininde ulaşmıştır.

AYEN hissesi 30 günlük tahmin ile en düşük MSE değerine ulaşmıştır. Ayrıca en düşük MAPE değeri de 120 günlük tahmin sonucu ortaya çıkmıştır.

ZOREN hissesi 30 günlük tahmin ile en başarılı MSE ve 60 günlük tahmin ile de en başarılı MAPE tahminlerini gerçekleştirmiştir.

Tablo 5: Epoch’ un 200, Batch’ ın 128 Olduğu GRU Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	128	MSE	0.0027	0.2046	0.3454	0.0745	0.0009
		MAE	0.0637	0.5425	0.6656	0.5217	0.0674
		MAPE%	2.6590	2.6080	3.0344	3.3738	2.0866
60	128	MSE	0.0002	0.1803	0.1654	0.1887	0.0010
		MAE	0.0495	0.5083	0.5365	0.5924	0.0671
		MAPE%	2.0569	2.6769	2.3265	3.5008	2.0636
90	128	MSE	0.0004	0.1527	0.0583	0.6734	0.0016
		MAE	0.0500	0.4934	0.4659	0.8714	0.0680
		MAPE%	2.1035	2.5972	2.1110	4.9192	2.1472
120	128	MSE	0.0009	0.0781	0.0015	0.1314	0.0025
		MAE	0.0522	0.4358	0.3877	0.5513	0.0718
		MAPE%	2.1795	2.3880	1.8512	3.3533	2.3462

3.3.2. LSTM Uygulaması

Şekil 53’ den de anlaşılacağı üzere LSTM tekniği için GRU’ dan farklı olarak “from tensorflow.keras.layers import Dense, Dropout, GRU” girdisi yerine “from keras.layers import Dense, LSTM” girdisi yazılmıştır.

Şekil 53: LSTM Uygulaması İçin Kütüphanelerin İçeri Aktarılması

```
#Kütüphanelerin içeriye aktarılması
import math
import pandas_datareader as web
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense, LSTM
import matplotlib.pyplot as plt
plt.style.use("fivethirtyeight")
```

Bir diğer fark ise model oluşturulma adımında yer almaktadır’ de LSTM olan yerlere GRU girdisi yazılır ve GRU tekniği kullanılacağı belirtilmiş olunur. Bu fark Şekil 54’ de görülmektedir.

Şekil 54: LSTM Modeli

```
#LSTM Modelinin Oluşturulması
model=Sequential()
model.add(LSTM(50, return_sequences=True, input_shape=(x_train.shape[1],1)))
model.add(LSTM(50,return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
```

LSTM’ de de GRU gibi sadece MSE ve MAPE model performans kriterleri yorumlanacak.

Öncelikle yine GRU’ daki gibi LSTM’ de de tüm MSE ve MAE değerleri 1’ den, MAPE değerleri de %5’ ten küçük olduklarından dolayı tüm model performans kriterleri başarılı sonuçlar vermiştir.

- **Epoch değeri 20 olduğu durumlarda:**

AKENR hissesi için MSE ve MAPE açısından en başarılı tahmin 120 günlük tahmin olmuştur.

AKSEN hissesi için MSE 90 günlük tahmin, MAPE açısından ise 120 günlük tahmin daha başarılıdır.

AKSUE hissesi MSE ve MAPE açısından en başarılı tahminini 90 günlük tahminlerde elde etmiştir.

AYEN hissesi 30 günlük tahmin ile en düşük MSE değerine sahip olmuştur. En başarılı MAPE değerini ise 60 günlük tahmin sonucunda elde etmiştir.

ZOREN hissesinin en başarılı MSE ve MAPE performansı 90 günlük tahminleridir.

Tablo 6: Epoch' un 20, Batch' ın 5 Olduğu LSTM Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	5	MSE	0.0017	0.2775	0.4235	0.0011	0.0104
		MAE	0.0674	0.3272	0.7541	0.4398	0.1170
		MAPE%	3.1564	3.2006	3.0378	3.3162	4.3599
60	5	MSE	0.0026	0.1886	0.0651	0.0145	0.0052
		MAE	0.0755	0.5722	0.4830	0.4196	0.0862
		MAPE%	3.5948	2.7698	2.5982	2.9811	2.6632
90	5	MSE	0.0021	0.1325	0.0066	0.0012	0.0017
		MAE	0.1036	0.4760	0.3969	0.4488	0.0852
		MAPE%	3.4038	2.7867	1.8419	3.2488	2.3507
120	5	MSE	0.0001	0.0291	0.4676	0.0684	0.0063
		MAE	0.0484	0.4325	0.7547	0.5231	0.0950
		MAPE%	2.0391	2.3575	3.0429	3.3868	2.6731

- Epoch değeri 50 olduğu durumlarda:**

AKENR hissesi için en başarılı MSE tahmini 90 günlük ve MAPE açısından da en başarılı tahmin 120 günlük tahmin olmuştur.

AKSEN hissesi için MSE 90 günlük tahmin, MAPE açısından ise 30 günlük tahmin daha başarılıdır.

AKSUE hissesi MSE ve MAPE açısından en başarılı tahminini 60 günlük tahminlerde elde etmiştir.

AYEN hissesi de AKSUE gibi MSE ve MAPE açısından en başarılı tahminini 60 günlük tahminlerde elde etmiştir

ZOREN hissesinin en başarılı MSE tahminini 120 günlük tahminde elde ederken ve MAPE için en başarılı performansı 90 günlük tahminleridir.

Tablo 7: Epoch' un 50, Batch' ın 32 Olduğu LSTM Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	32	MSE	0.0007	0.0060	0.1060	0.8806	0.0057
		MAE	0.0513	0.4145	0.5034	0.9885	0.0874

		MAPE%	2.1135	2.2211	2.3055	4.9338	3.0188
60	32	MSE	0.0019	0.0049	0.0083	0.1365	0.0057
		MAE	0.0616	0.4856	0.4353	0.5355	0.0899
		MAPE%	2.6309	2.6037	1.9773	3.4050	2.5963
90	32	MSE	0.0001	0.0005	0.2969	0.4262	0.0018
		MAE	0.0516	0.4456	0.7077	0.7517	0.0708
		MAPE%	2.2037	2.4925	2.7530	4.0285	2.1538
120	32	MSE	0.0003	0.4128	0.1091	0.5384	0.0012
		MAE	0.0510	0.6982	0.4945	0.8481	0.0777
		MAPE%	2.0947	3.6171	2.2262	4.2693	2.7792

- **Epoch değeri 100 olduğu durumlarda:**

AKENR hissesi için en başarılı MSE tahmini 60 günlük ve MAPE açısından da en başarılı tahmin 90 günlük tahmin olmuştur.

AKSEN hissesi için MSE 120 günlük tahmin, MAPE açısından ise 90 günlük tahmin daha başarılıdır.

AKSUE hissesi MSE için en düşük hata 30 günlük tahminde elde edilirken, MAPE açısından en düşük hata değeri tahminini 60 günlük tahminlerde elde etmiştir.

AYEN hissesi MSE ve MAPE açısından en başarılı tahminini 90 günlük tahminlerin sonucunda elde etmiştir.

ZOREN hissesi de AYEN gibi MSE ve MAPE açısından en başarılı tahminini 90 günlük tahminlerde elde etmiştir.

Tablo 8: Epoch' un 100, Batch' ın 64 Olduğu LSTM Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	64	MSE	0.0008	0.0312	0.2301	0.4042	0.0008
		MAE	0.0531	0.4808	0.6080	0.8252	0.0623
		MAPE%	2.1500	2.5109	2.5433	4.2925	2.0194
60	64	MSE	0.0002	0.2401	0.2505	0.4805	0.0003
		MAE	0.5410	0.6291	0.6301	0.7928	0.0618
		MAPE%	2.3585	3.1459	2.5188	4.3013	2.0061
90	64	MSE	0.0006	0.1786	0.7270	0.3308	0.0001
		MAE	0.0508	0.4250	0.9086	0.7155	0.0610
		MAPE%	2.1093	2.3508	3.5315	3.8444	1.9985
120	64	MSE	0.0026	0.0073	0.3810	0.3952	0.0002
		MAE	0.0637	0.4355	0.7219	0.7436	0.0702
		MAPE%	2.6803	2.3968	2.8641	3.9296	2.5391

- **Epoch değeri 200 olduğu durumlarda:**

AKENR hissesi MSE ve MAPE açısından en başarılı tahminini 30 günlük tahminlerin sonucunda elde etmiştir.

AKSEN hissesi için MSE 60 günlük tahmin, MAPE açısından ise 120 günlük tahmin daha başarılıdır.

AKSUE hissesi de AKENR hissesine benzer olarak MSE ve MAPE açısından en başarılı tahminini 30 günlük tahminlerin sonucunda elde etmiştir

AYEN hissesi de MSE ve MAPE açısından en başarılı tahminini 30 günlük tahminlerin sonucunda elde etmiştir.

ZOREN hissesi için MSE 60 günlük tahmin, MAPE açısından ise 30 günlük tahmin daha başarılıdır.

Tablo 9: Epoch’ un 200, Batch’ ın 128 Olduğu LSTM Sonuç Tablosu

Gün Sayısı	Batch	Hata Oranları	AKENR	AKSEN	AKSUE	AYEN	ZOREN
30	128	MSE	0.0001	0.0927	0.2221	0.2959	0.0008
		MAE	0.0512	0.4930	0.6130	0.7175	0.0636
		MAPE%	2.1405	2.9676	2.5011	3.8397	2.0686
60	128	MSE	0.0015	0.0001	0.3804	0.8127	0.0006
		MAE	0.0567	0.4432	0.7293	0.9791	0.0718
		MAPE%	2.3253	2.4402	2.8590	4.9415	2.5756
90	128	MSE	0.0007	0.0083	0.4401	0.4853	0.0020
		MAE	0.0520	0.4218	0.7668	0.8653	0.0689
		MAPE%	2.2171	2.3367	3.0358	4.4359	2.2472
120	128	MSE	0.0003	0.1221	0.5574	0.8155	0.0064
		MAE	0.0566	0.4214	0.8418	0.9728	0.0908
		MAPE%	2.5153	2.3169	3.1556	4.9735	3.0298

3.3.3. İki Tekniğin Karşılaştırılması

Bu bölümde LSTM ve GRU arasından hangi tekniğin daha iyi olduğunu anlamak için en başarılı oldukları tahmin sonuçları birbirleriyle karşılaştırılacak.

Tablo 10’ da satır satır şirketlerin ilgili epoch sayısındaki en iyi sonuçları verilmiştir. Bu tabloda GRU ve LSTM sonuçları karşılaştırılacak ilgili satırda eğer LSTM tekniğinin sonucu GRU tekniğinin sonucundan küçük ise en sağdaki “Sonuç” adlı sütunda ilgili satır hücresine 1 değeri atanacak. Toplam 40 adet satır vardır. Dolayısıyla eğer hesaplamaların sonucunda eğer LSTM tekniğinin puanı:

19 ve aşağısı olursa GRU tekniği LSTM tekniğinden daha başarılı,

20 olursa her iki teknik de birbirine üstünlük sağlamamış,

21 ve üzeri olursa da LSTM tekniği GRU' dan daha başarılıdır demektir.

Tablo 10: Sonuçların Karşılaştırılması

Epoch Sayısı	Şirket	Hata Kriterleri	GRU	LSTM	Sonuç
20	AKENR	MSE	0.0006	0.0001	1
		MAPE	2.1966	2.0391	1
20	AKSEN	MSE	0.0215	0.0021	1
		MAPE	2.5511	2.3575	1
20	AKSUE	MSE	0.0090	0.0066	1
		MAPE	1.9528	1.8419	1
20	AYEN	MSE	0.2185	0.0011	1
		MAPE	3.5587	2.9811	1
20	ZOREN	MSE	0.0048	0.0017	1
		MAPE	2.1104	2.3507	0
50	AKENR	MSE	0.0008	0.0001	1
		MAPE	2.0979	2.0947	1
50	AKSEN	MSE	0.0590	0.0005	1
		MAPE	2.5101	2.2211	1
50	AKSUE	MSE	0.1279	0.0083	1
		MAPE	2.3339	1.9773	1
50	AYEN	MSE	0.0481	0.1365	0
		MAPE	3.0519	3.4050	0
50	ZOREN	MSE	0.0014	0.5384	0
		MAPE	2.1052	4.0285	0
100	AKENR	MSE	0.0001	0.0002	0
		MAPE	2.1613	2.1093	1
100	AKSEN	MSE	0.0061	0.0073	0
		MAPE	2.2802	2.3508	0
100	AKSUE	MSE	0.1024	0.2301	0
		MAPE	2.0958	2.5188	0
100	AYEN	MSE	0.0581	0.3308	0
		MAPE	3.0949	3.8444	0
100	ZOREN	MSE	0.0003	0.0001	1
		MAPE	2.0872	1.9985	1
200	AKENR	MSE	0.0002	0.0001	1
		MAPE	2.0569	2.1405	0
200	AKSEN	MSE	0.0781	0.0001	1
		MAPE	2.3880	3.1556	0
200	AKSUE	MSE	0.0015	0.2221	0
		MAPE	1.8512	2.5011	0
200	AYEN	MSE	0.0745	0.2959	0
		MAPE	3.3533	3.8397	0
200	ZOREN	MSE	0.0009	0.0006	1
		MAPE	2.0636	2.0686	0

Hesaplamanın sonucunda LSTM tekniğinin 21 kere 1 değerini almıştır. Bu 40' tan 21 çıkarıldığında 19 sayısı elde edildiği için GRU tekniğinin de 19 puanını aldığını açıklamaktadır. Böylelikle LSTM tekniği ufak bir başarı ile GRU tekniğine karşı daha başarılı olmuştur anlamına gelir yorumu yapılabilir.

Ayrıca en düşük hata değerlerine sahip günler ise şöyledir; 30 günlük tahminler ve 120 günlük tahminler 21' er tane ile en düşük hata kriterine sahip tahminler olmuşlardır. Bu günleri 19' şar hata kriterlerine sahip olan 60 günlük tahminler ve 90 günlük tahminler izlemiştir.

Şirketlere göre kullanılacak teknik, epoch sayısı ve günlük tahmin faktörlerinin hangi kombinasyonunda en az MSE veya MAPE değeri aldığı araştırılmıştır. Buna göre:

AKENR hissesi için MSE bazında en az hatalı tahmin hem LSTM ve hem de GRU teknikleri sonucunda 0.0001 ile elde edilmiştir. Bu sonucu veren modeller LSTM' de 20 epochlu ve 120 günlük ve 200 epochlu ve 30 günlük tahmin parametrelerine sahipken, GRU için de 100 epochlu 60 günlük tahmin parametreleri ile gerçekleşmiştir. AKENR hissesinin model başarımı MAPE bazında değerlendirildiğinde LSTM tekniği uygulanarak 20 epochlu ve 120 günlük tahmin yapan model ile en az hatalı sonuca ulaşılmıştır. Bu model sonucunda elde edilen MAPE değeri 2.0391' dir.

AKSEN hissesinde yapılan analizlerin içerisinde en az hatalı MSE değerini veren analiz LSTM ile gerçekleştirilen 200 epochlu ve 60 günlük tahmin modeli olmuştur. Bu tahmin sonucunda 0.0002' lik hata değeri elde edilmiştir. MAPE açısından en az hatalı tahmin, 2.2211 hata değeri sonuçlu, LSTM ile yapılan 50 epochlu ve 30 günlük olan tahmindir.

AKSUE hissesi içerisindeki analizlerden MSE için en az hata değeri GRU tekniği uygulanan 200 epochlu ve 120 günlük tahmin modeli ile elde edilmiştir. Bu tahmini sonucu 0.0015 çıkmıştır. MAPE' ye göre en az hata değeri 1.8419' dur. Bu çıktı, LSTM tekniği ile yapılan 20 epochlu ve 90 günlük tahmin ile bulunmuştur.

AYEN hissesi açısından en az hatalı değerli MSE tahmini, 20 epochlu ve 30 günlük LSTM tekniği ile yapılan tahmindir. Bu tahmin hata değeri olarak 0.0011 çıktısını vermiştir. Model başarımı açısından MAPE dikkate alındığında ise yine

LSTM tekniđi uygulanmıř, 20 epochlu ve 60 gnlk tahmin en az hata deđerini vermiřtir. Bu tahmin sonucunda 2.9811 deđerı elde edilmiřtir.

ZOREN hissesi iin MSE baz alındıđında en az hatalı deđerli tahmin 0.0001 sonucunu vermiřtir. Bu tahmin LSTM tekniđi ile 100 epoch ve 90 gnlk tahminden oluřmaktadır. MAPE gz nnde bulundurulduđuında en az hata deđerı yine LSTM ile uygulanan 100 epochlu ve 90 gnlk tahmindir. Bu tahminin ıktısı 1.9985

Bu sonulara gre;

MSE deđerlerini baz alan bir yatırımcı AKENR hissesine yatırım yapmak isterse LSTM tekniđi ile 20 epochlu 120 gnlk ve/veya 200 epochlu 30 gnlk ya da GRU tekniđi ile 100 epochlu 60 gnlk tahmin sonucuna gre hareket etmesi daha sađlıklı olacaktır. Eđer MAPE deđerine gre hareket ederse LSTM tekniđi uygulayarak 20 epochlu 120 gnlk tahmin sonucunu dikkate alması gereklidir.

AKSEN hissesi yatırımcısı ise MSE deđerini dikkate alan birisi ise LSTM tekniđi uygulayıp 200 epochlu 60 gnlk bir tahmin gerekleřtirmelidir. MAPE ıktısını baz alan bir yatırımcının LSTM tekniđini kullanıp 50 epochlu model ile 30 gnlk tahmin yapması daha iyi olacaktır.

AKSUE hissesine yatırım yapmayı dřnen bir yatırımcı MSE ıktıları dikkate alarak GRU tekniđi uygulanmıř 200 epochlu 120 gnlk tahmin ile daha bařarılı bir yatırım gerekleřtirecektir. MAPE dikkate alan yatırımcı ise 20 epochlu 90 gnlk bir tahmin modelinin LSTM tekniđi ile tahminlenmesini dikkate alması gerekmektedir.

Bir yatırımcı AYEN hissesine gerekleřtirmek istediđi yatırım iin MSE deđerlerini baz aldıđında LSTM tekniđi uygulanmıř 20 epochlu 30 gnlk tahmin modeline gre hareket etmesi gerekmektedir. MAPE deđerini kıstas olarak alan bir yatırımcı ise LSTM tekniđi ile tahmin edilmiř 20 epochlu 60 gnlk tahmini gz nnde bulundurması gerekmektedir.

ZOREN hissesine yapılacak yatırımdan en iyi sonucu almak amacıyla hem MSE hem de MAPE iin 100 epochlu 90 gnlk tahmin modeline LSTM tekniđi ıktısı dikkate alınmalıdır.

SONUÇ

İlk kez 1950' lerde Alan Turing tarafından temelleri atılan yapay zekanın amaçları insana özgü kabiliyetlerin algoritmalar yardımıyla bilgisayar sistemlerinin de gerçekleştirilmesi ve insanın beyinsel aktivitelerinin tek başına yetmediği konularda insanoğluna yardım etmesidir (Arslan, 2020: 77). Yapay zekâda insanlar gibi bilgisayarların da düşünüp karar verme, sorunları çözme, görüntüleri tanımlama ve öğrenme gibi faaliyetleri gerçekleştirmesi beklenir.

Geleceği öngörmek hayatın her alanında olduğu gibi finans alanında da oldukça zordur. Ancak gelecekteki riskleri ve fiyat tahminlerini önceden bilebilmek yatırımcılar için doğru yatırım yapabilmeleri ve kâr elde edebilmeleri açısından oldukça önem arz etmektedir. Yüzlerce yıldır insanoğlu birbirini etkileyen faktörleri analiz edip ortaya tahminler çıkarmıştır. Bu tahminler bazen tutarlı bazen de yanıltıcı olmuştur. İlk başlarda basit algoritmalar ve ilkel hesaplamalarla işlerini yürütmeye çalışan yatırımcılar ticaretin ve dolayısıyla finansın da globalleşmesiyle daha çok hesap yükünün altına girmiştir. Daha çok hesap yükü de doğal olarak beraberinde doğru tahmin yapabilme zorluğunu getirmiştir. Belli bir zaman sonra eldeki teknikler yetmemiş ve insanoğlu 1950' lerde yapay zekânın ve gelişmiş bilgisayar algoritmalarının ilk temellerini atmıştır.

Bilgisayar işlemcilerinin gelişmesiyle yapay zekâ ile yapılacak faaliyetlerin çeşitliliği de artmıştır. Böylelikle 1980' lerde istatistiksel öğrenme yöntemlerinin de kullanılmasıyla makine öğrenmesi ortaya çıkmış ve verilerin analiz edilmesi ve makinelerin desenleri tanınması imkânı doğmuştur. Zamanla makine öğrenmesi tekniklerinin de eksiklikleri ve zaafı ortaya çıkınca bilim insanları daha gelişmiş teknikler geliştirmeye başladılar ve neticede 1990' lı yılların sonuna doğru LSTM tekniği ve 2010' lu yıllarda da GRU tekniği ile birlikte derin öğrenmenin temelleri atılmış oldu. Derin öğrenme sayesinde büyük veri setleri ile çalışabilme ve veri setlerinden otomatik öğrenme yapabilme imkânı doğmuş ayrıca sınıflandırma ve dil işleme konularında da başarılı performans sonuçları alınmıştır.

Bu çalışmada derin öğrenmenin finans alanındaki başarısı BİST' te uygulama yapılarak araştırılmıştır. BİST' in endekslerinden enerji endeksi olan XELKT' de işlem gören şirketler arasından 5 enerji şirketin günlük hisse senedi fiyatı derin öğrenme ile tahmin edilmeye çalışılmıştır. AKENR, AKSEN, AKSUE, AYEN ve

ZOREN hisseleri, hisse senedi fiyat tahmini için seçilen hisselerdir. Derin öğrenme yöntemlerinden LSTM ve GRU teknikleri bu analizde kullanılmıştır. Veri setinin tarih aralığı 02.01.2013 ile 30.12.2022 arası olarak belirlenmiş ve tüm veriler Yahoo Finance’ tan alınmıştır. Her bir şirketin günlük açılış, kapanış, en yüksek ve en düşük hisse senedi fiyatı değişkenlerine ek olarak hisse senedi fiyatlarına etkisi olduğu düşünülen değişkenlerden “BİST 100”, “USD/TL” kuru ve “XELKT” değişkenlerinin de günlük açılış, kapanış, en yüksek ve en düşük değerleri veri setlerinde yer almıştır. Böylelikle her şirket için ayrı veri seti hazırlanarak toplam 5 adet, 2511 gözlemli ve 17 değişkenli veri setleri oluşturulmuştur.

Veri setlerinin hazırlanmasının ardından ilk adım olarak uygulama yapabilmek amacıyla modeller kurulmuştur. Hem LSTM hem de GRU için oluşturulan modeller, 4 katmanlıdır. İlk katman 50 nöronludur ve dizileri sıralı bir şekilde işlemek amacına uygun olarak ayarlanmıştır. İkinci katman da birinci katman gibi 50 nöronludur ancak birinci katman gibi sıralı veri üretmek yerine son zaman adımında sonuç üretecek şekilde kod girişi yapılmıştır. Üçüncü katman 25 nöronlu bağıl katmandır böylelikle modeldeki daha karmaşık yapıları öğrenmeyi sağlayacak. Son katman olan dördüncü katman ise 1 adet nörona sahiptir ve bu nöron ile nihai sonucu vermektedir.

Modeller oluşturulduktan sonra eğitilmişlerdir. Eğitim için 4 farklı epoch değeri, her epoch için standart Batch değerleri, 4 farklı gün sayısı ve 3 farklı model performans kriteri kullanılmıştır. Kullanılan epoch değerleri sırasıyla 20, 50, 100 ve 200’ dür. Batch değerleri ise epoch’ un 20 olduğu durumda 5, 50 olduğu durumda 32, 100 olduğu durumda 64 ve 200 olduğu durumda 128 olacak şekilde ayarlanmıştır. Tahmini yapılan gün sayıları ise 30, 60, 90 ve 120 gündür. Oluşturulan modellerin başarısını ölçecek olan model performans kriterlerinden MSE, MAE ve MAPE analiz için seçilmiştir. Veri setinin %80’ i eğitim seti, %20’ si doğrulama seti ve yine %20’ si test seti olacak şekilde ayrılmıştır.

Yapılan analizde ilk olarak iki teknik için de model performans kriterlerinden MAE, MSE ve MAPE hesaplanmıştır. Ardından hangi tekniğin hisse senedi fiyatı tahmininde daha başarılı olduğunu anlamak amacıyla şirketlerin epoch değerleri baz alınarak LSTM tekniği sonucunda elde ettiği MSE ve MAPE değerleri ile GRU tekniği sonucunda elde ettiği MSE ve MAPE değerleri iki teknik arasında kıyaslanmıştır. Kıyaslama sonucuna göre ilgili şirket için ilgili epoch değeri baz alındığında hangi

teknik ile daha az hata değeri alınmış ise o teknik diğerine göre daha başarılıdır denmiştir. Ayrıca 4 farklı gün sayısı için tahmin yapıldığından kaç günlük tahminlerin daha başarılı olduğu da hesaplanmıştır.

Model performans kriterlerinin hesaplanmasının ardından her teknik ve her epoch değeri için olmak üzere toplam 8 adet sonuç tablosu oluşturulmuştur. Ancak tablo içerisinde sadece MSE ve MAPE baz alınarak analizler yorumlanmıştır. Hesaplanan bütün değerler literatürde kabul edilen sınırların altında oldukları için kullanılan teknikler hisse senedi tahmini konusunda başarılı kabul edilebilir. Buradan yola çıkarak doğru modellerin kurulabildiği de söylenebilir. Analizde kullanılan iki tekniğin karşılaştırılması sonucunda LSTM tekniğinin, yapılan 40 adet karşılaştırmanın 21'inde GRU'ya göre daha düşük hata değerleri aldığı görülmüştür. Böylelikle LSTM tekniğinin GRU tekniğinden daha başarılı olduğu sonucuna varılabilir. Günlük bazda da 30 günlük ve 120 günlük tahminler, 60 günlük ve 90 günlük tahminlere kıyasla daha başarılı olmuşlardır. Şirketler için en az MSE ve MAPE değerini veren teknik, epoch sayısı ve günlük tahminler kombinasyonları araştırılmıştır. Sonuç olarak;

Tablo 11: Şirketler İçin En Az Hatalı Model Performans Kriterini Veren Modeller

Hisse Senedi	Epoch Sayısı	Günlük Tahmin	Teknik	Model Performans Kriteri	
AKENR	20	120	LSTM	MSE	0.0001
	200	30	LSTM	MSE	0.0001
	100	60	GRU	MSE	0.0001
	20	120	LSTM	MAPE	2.,0391
AKSEN	200	60	LSTM	MSE	0.0002
	50	30	LSTM	MAPE	2.2211
AKSUE	200	120	GRU	MSE	0.0015
	20	90	LSTM	MAPE	1.8419
AYEN	20	30	LSTM	MSE	0.0011
	20	60	LSTM	MAPE	2.9811
ZOREN	100	90	LSTM	MSE	0.0001
	100	90	LSTM	MAPE	1.9985

AKENR hissesi için MSE bazında hem LSTM' de hem de GRU kullanımı, MAPE bazında da LSTM kullanımı daha başarılı olmuştur.

AKSEN hissesinin tahminlerinde en az hatalı tahminler MSE açısından da MAPE açısından da LSTM tekniği ile elde edilmiştir.

AKSUE hissesi için MSE açısından GRU tekniği ile MAPE açısından da LSTM ile en az hatalı tahminin gerçekleştirmiştir.

AYEN hissesi için yapılan tahminlerde en az hatalı MSE ve MAPE değerleri LSTM tekniği ile elde edilmiştir.

ZOREN hissesi de AKSEN gibi hem MSE hem de MAPE için en az hatalı tahminlerini LSTM tekniği ile yapmıştır.

Bu çalışma ile birlikte hisse senedi fiyat tahmini konusunda derin öğrenme tekniklerinden LSTM ve GRU tekniklerinin kullanımının başarılı olduğu, bu iki teknik arasından LSTM performansının GRU' ya göre daha iyi olduğu ve tahminlerde günlük başarılar göz önünde bulundurulduğunda 30 ve 120 günlük tahminlerin 60 ve 90 günlük tahminlere kıyasla daha az hata ile tahmin yaptığı sonuçları ortaya konmuştur. Ayrıca şirketler özelinde hangi teknik, hangi epoch değeri ve kaç günlük tahminler yapılırsa en başarılı sonuçların elde edileceği konusuna da açıklık getirilmiş ve yatırımcılara tavsiyeler verilmiştir. Bu çalışmanın sonunda, çalışmada fiyat tahmini yapılan ilgili hisse senetlerine yatırım yapmayı düşünen birisinin bu çalışmayı dikkate alması sonucunda yatırımından elde edeceği başarıyı arttıracığı söylenebilir.

Eğer bir yatırımcı bu çalışmada bahsedilen şirketler ve endeksler dışında bir şirket veya endeks üzerine tahmin çalışması yapmak isterse, bu çalışmada kullanılan epoch, batch size, aktivasyon fonksiyonu, katman sayısı ve nöron sayısı parametrelerinde ayrıca analiz için seçilen derin öğrenme tekniklerinde çalışmasının amacına uygun olarak değişiklik yapması daha başarılı sonuçlar verebilir.

Mevcut model, gelecekte duygu analizi yöntemi ile hibrit bir hale getirilip model başarımı artırılabilir. Böylelikle oluşan dönemsel tahmin farklılığının insanlar tarafından kaynaklanıp kaynaklanmadığı veya haberlerin hisse senetleri üzerinde etkisi olup olmadığı gibi konular daha kolayca açıklığa kavuşturulabilir. Ayrıca modele başka faktörlerin etkileri merak edilirse enflasyon, elektriğin birim fiyatı ve brent petrol gibi değişkenlerle veri seti genişletilip analiz çeşitlendirilebilir. Bunlara ek olarak matematiksel teknikler olan Heston modeli, Fourier Dönüşümleri yapay sinir ağlarıyla kullanılıp model başarımlarının artırılıp arttırılmadığı test edilebilir.

KAYNAKÇA

Aggarwal, C. (2018). *Neural Networks and Deep Learning*. Springer.

Agrawal, S., & Agrawal, J. (2015). Neural Network Techniques for Cancer Prediction: A Survey. *19th International Conference on Knowledge Based and Intelligent Information and Engineering Systems* (s. 769 - 774). Procedia Computer Science.

Akça, Ö. (2005). *Hisse Senedi Piyasasında Teknik Analiz Yönteminin Güvenilirliğinin Test Edilmesi* (Yüksek Lisans Tezi). Afyonkarahisar: Afyon Kocatepe Üniversitesi.

Akenerji Elektrik Üretim A.Ş. (2023). *2021 Yılı Faaliyet Raporu*. <https://www.akenerji.com.tr/Dosya/Dokuman/Akenerji%20FR.PDF> (Erişim tarihi: 05.03.2023)

Aksa Enerji Üretim A.Ş. (2023). *2021 Yılı Faaliyet Raporu*. <https://aksainvestorrelationscdn.mncdn.com/media/8678/aksa-enerji-2021-faaliyet-raporu.pdf> (Erişim tarihi: 05.03.2023)

Aksu Enerji ve Ticaret A.Ş. (2023). *2021 Yılı Faaliyet Raporu*. http://aksuenerji.com.tr/wp-content/uploads/2022/03/Aksu_Enerji_ve_Ticaret_A__31_12_2021_Y%C3%B6netim_Kurulu_Faaliyet_Raporu-1.pdf (Erişim tarihi: 05.03.2023)

Akşehir, Z. D. (2020). *BİST 30 Endeksinin ve Hisse Senetlerinin Değer Tahmini Üzerine Bir Çalışma* (Yüksek Lisans Tezi). Samsun: Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü.

Aktürk, C., & Talan, T. (2022). *Bilgisayar Bilimlerinde Teorik ve Uygulamalı Araştırmalar*. Efe Akademi.

Altunbaş, C. (2021). *Derin Öğrenme ile Hisse Senedi Piyasası Tahmini* (Yüksek Lisans Tezi). Aydın: Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü.

American Association of Petroleum Geologists (AAPG). (2023). *What Is Petroleum?* <https://www.aapg.org/about/petroleum-geology/petroleum-through-time/what-is-petroleum> (Erişim tarihi: 23.02.2023)

American Petroleum Institute. (2023). <https://www.api.org/news-policy-and-issues/natural-gas-solutions/what-is-natural-gas> (Erişim tarihi: 25.02.2023)

American Public Gas Association. (2023). <https://www.apga.org/apgamainsite/aboutus/facts/history-of-natural-gas#:~:text=The%20first%20commercialized%20natural%20gas,light%20its%20streets%20with%20gas>. (Erişim tarihi: 25.02.2023)

Amidi, A., & Amidi, S. (2018). *VIP Cheatsheet: Recurrent Neural Networks*. <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks> (Erişim tarihi: 03.01.2023)

Arslan, K. (2020). Eğitimde Yapay Zeka ve Uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 71 - 88.

Asher, C. (2021). The Role of AI in Characterizing the DCM phenotype. *Frontiers in Cardiovascular Medicine*, 1-20.

Aslan, B. (2020). *Derin Öğrenme ile Borsa Verileri Üzerine Tahminleme Yapılması* (Yüksek Lisans Tezi). İzmir: Ege Üniversitesi Fen Bilimleri Enstitüsü.

Athaiya, A., Sharma, S., & Sharma, S. (2020). Activation Function in Neural Networks. *International Journal of Engineering Applied Sciences and Technology*, 310 - 316.

Athey, S., & Imbens, G. (2017). The State of Applied Econometrics: Causality and Policy Evaluation. *Journal of Economic Perspectives*, 3 - 32.

Ayen Enerji A.Ş. (2023). 2021 Yılı Faaliyet Raporu. https://ayen.com.tr/uploads/__dokuman/faaliyetraporlari/ayenenerji_2021_faaliyet_raporu_web.pdf (Erişim tarihi: 05.03.2023)

Aytekin, G. K. (2018). Türkiye’ de Sermaye Piyasaları ve Borsaların Gelişim Süreci. *International Journal of Humanities and Education*, 150-176.

Bakkal, M., Bakkal, S., & Öztürk, Ş. Ş. (2012). *Sermaye Piyasalarında Hisse Senetleri ve Hisse Senetlerini Etkileyen Makroekonomik Faktörler*. Hiperlink Yayınları.

Barbosa, E. M., Sigfusson, B., Carlsson, J., & Tzimas, E. (2017). Advantages From Combining CCS with Geothermal Energy. *13th International Conference on Greenhouse Gas Control Technologies* (s. 6666 - 6676). Lausanne: ScienceDirect.

Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning Long-Term Dependencies With Gradient Descent is Difficult. *IEEE Transactions on Neural Networks*, 1 - 35.

Borsa İstanbul. (2023). <https://www.borsaistanbul.com/Dosyalar/25yil/index.html> (Erişim tarihi: 20.03.2023)

Bridgewater, T. (2006). Biomass for Energy. *Journal of the Science of Food and Agriculture*, 1755 - 1768.

Brownlee, J. (2017). *Long Short-Term Memory Networks With Python*. Machine Learnig Mystery

Chatterjee, A., Bhowmick, H., & Sen, J. (2021). Stock Price Prediction Using Time Series, Econometric, Machine Learning, and Deep Learning Models. *IEEE*, 289 - 296.

Cho, K. H., Gülçehre, Ç., Bengio, Y., & Chung, J. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv preprint arXiv:1412.3555*, 1 - 9.

Chollet, F. (2018). *Deep Learning with Python*. New York: Manning Publications Co.

Çakır, B., & Angin, P. (2021). Zamansal Evrişimli Ağlarla Siber Saldırı Tespiti: Karşılaştırmalı Bir Analiz. *Avrupa Bilim ve Teknoloji Dergisi*, 204 - 211.

Çelik, Ş. (2022). Yapay Sinir Ağlarının Farklı Aktivasyon Fonksiyonlarında Uygulaması: Türkiye’de Ördek Popülasyonu Öngörüsü. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 800-811.

Demiray, S. (2021). *Makine Öğrenmesi Algoritmaları ile Hisse Senedi Kapanış Tahmini* (Yüksek Lisans Tezi). İstanbul: İstanbul Aydın Üniversitesi Lisansüstü Eğitim Enstitüsü.

Demirel, U. (2019). *Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları ile Tahmini* (Yüksek Lisans Tezi). Gümüşhane: Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü.

Deng, L., & Yu, D. (2014). *Deep Learning: Methods and Applications*. Redmon, WA: Now Publishers.

Dickson, M., & Fanelli, M. (2003). *Geothermal Energy Utilization and Technology*. UNESCO.

Doğanay, H., & Coşkun, O. (2020). *Enerji Kaynakları*. Ankara: Pegem Akademi Yayınları.

Dunis, C., Middleton, P., Theofilatos, K., & Karathanasopoulos, A. (2016). *Artificial Intelligence in Financial Markets: Cutting Edge Applications for Risk Management, Portfolio Optimization and Economics*. Springer.

Durmuş, B. (2023, Nisan). *Adaboost - Bagging Sınıflandırıcısını İyileştirmeye Yönelik Hibrit Bir Örneklem Algoritması: Sağlık Alanında Bir Uygulama* (Doktora Tezi). Muğla: Muğla Sıtkı Koçman Üniversitesi Fen Bilimleri Enstitüsü.

Ghosh, T. K., & Prelas, M. A. (2009). *Energy Resources and Systems Volume 1: Fundamentals and Non-Renewable Resources*. Springer.

Ghosh, T. K., & Prelas, M. A. (2011). *Energy Resources and Systems Volume 2: Renewable Resources*. Springer.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Graves, A. (2014). Generating Sequences With Recurrent Neural Networks. *arXiv*, 1-43.

Güdelek, M. U. (2019). *Zaman Serisi Analiz ve Tahmini: Derin Öğrenme Yaklaşımı* (Yüksek Lisans Tezi). Ankara: TOBB Ekonomi ve Teknoloji Üniversitesi.

Gülcü, A., & Kuş, Z. (2019). Konvolüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 503 - 522.

Güney, E. N. (2022). *Derin Öğrenmede İstatistiksel Yöntemlerle Hisse Senedi Fiyatı Öngörüsü* (Yüksek Lisans Tezi). Isparta: Süleyman Demirel Üniversitesi.

Haberal, İ. (2020). *Derin Öğrenme Ağları Kullanılarak Protein Metal Bağlanma Yerlerinin Analizi* (Doktora Tezi). Ankara: Başkent Üniversitesi.

He, F. (2021). Applications of Deep Learning Techniques for Pedestrian Detection in Smart Environments: A Comprehensive Study. *Hindawi Journal of Advanced Transportation*, 1-14.

Hochreiter, S. (1991). *Untersuchungen zu dynamischen neuronalen Netzen* (Yüksek Lisans Tezi). Münih: Technical University of Munich.

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation* 9(8), 1735-1780.

International Atomic Energy Agency. (2022). *What is Nuclear Energy? The Science of Nuclear Power*. <https://www.iaea.org/newscenter/news/what-is-nuclear-energy-the-science-of-nuclear-power> (Erişim tarihi: 26.02.2023)

International Energy Agency. (2021). *Turkey 2021 - Energy Policy Review*.

İstanbul Teknik Üniversitesi, Petrol ve Doğal Gaz Mühendisliği Bölümü. (2023).
https://web.itu.edu.tr/~yamanlar/faq_t/ (Erişim tarihi: 23.02.2023)

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications R (2nd Edition)*. Springer.

Jiang, H., & Peng, Y. (2016). Leverage Financial News to Predict Stock Price Movements Using Word Embeddings and Deep Neural Networks. *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, (s. 373-379). ArXiv

Jiang, X. (2020). Bitcoin Price Prediction Based on Deep Learning Methods. *Scientific Research Publishing*, 132 - 139.

Kalyoncu, S. (2020, Temmuz). *Borsa Analizi ve Tahmini İçin Derin Öğrenme Ağları* (Yüksek Lisans Tezi). İstanbul: İstanbul Sabahattin Zaim Üniversitesi Lisansüstü Eğitim Enstitüsü.

Kamuyu Aydınlatma Platformu. (2023). *Endeksler*.
<https://www.kap.org.tr/tr/Endeksler> (Erişim tarihi: 22.03.2023)

, K. (2022). *Hibrit Derin Öğrenme Modelleri ile Hisse Senedi Fiyat Tahmini* (Yüksek Lisans Tezi). Edirne: Trakya Üniversitesi.

Karpathy, A. (2015). *The Unreasonable Effectiveness of Recurrent Neural Networks*. <http://karpathy.github.io/2015/05/21/rnn-effectiveness/> (Erişim tarihi: 03.01.2023)

Kayaalp, K., & Süzen, A. A. (2020). *Derin Öğrenme ve Türkiye'deki Uygulamaları*. İstanbul: İksad Publishing House.

Kholik, A., & Harjoko, A. (2020). Classification of Traffic Vehicle Density Using Deep Learning. *Indonesian Journal of Computing and Cybernetics Systems*, 69 - 80.

Kingma, D., & Ba, J. L. (2017). Adam: A Method for Stochastic Optimization. *ICLR 2015* (s. 1 - 15). International Conference on Learning Representations.

Koç, E., & Kaya, K. (2015). Enerji Kaynakları - Yenilenebilir Enerji Durumu. *Mühendis ve Makina Dergisi*, 36 - 47.

Kramer, O. (2016). *Machine Learning for Evolution Strategies*. Springer.

Krenker, A., Bester, J., & Kos, A. (2011). Introduction to the Artificial Neural Networks. *Artificial Neural Networks - Methodological Advances and Biomedical Applications* (s. 1 - 18). IntechOpen.

Krohn, J., Beyleveld, G., & Bassens, A. (2019). *Deep Learning Illustrated*. AddisonWesley Professional

Kuş, Z. (2019). *Mikrokanonikal Optimizasyon Algoritması ile Konvolüsyonel Sinir Ağlarında Hiper Parametrelerin Optimize Edilmesi* (Yüksek Lisans Tezi). İstanbul: Fatih Sultan Mehmet Vakıf Üniversitesi.

Lowe, D. (1994). Novel Exploitation of Neural Network Methods in Financial Markets. *IEEE World Congress on Computational Intelligence* (s. 3623 - 3628). IEEE International Conference.

Madan, P., & Madhavan, S. (2020). *An introduction to deep learning*. IBM: <https://developer.ibm.com/articles/an-introduction-to-deep-learning/> (Eriřim tarihi: 19.03.2023)

Mason, J. E., Traore, I., & Woungang, I. (2016). *Machine Learning Techniques for Gait Biometric Recognition Using the Ground Reaction Force*. Springer.

McDonald, G. (2011). Georgius Agricola and The Invention of Petroleum. *Bibliothèque d'Humanisme et Renaissance*, 351-363.

Mehtab, S., & Sen, J. (2020). Stock Price Prediction Using CNN and LSTM - Based Deep Learning Models . *DASA*, (s. 1 - 7). Bahrain.

Metin, İ. A., & Karasulu, B. (2019). İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım. *Veri Bilimi Dergisi*, 1 - 10.

Moghar, A., & Hamche, M. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. *IWSMAI 2020* (s. 1168 - 1173). Warsaw: Procedia.

Montasham, J. (2015). Renewable Energies. *International Conference on Technologies and Materials for Renewable Energy, Environment and Sustainability* (s. 1289 - 1297). ScienceDirect.

Moulé, A. J. (2010). Power from Plastic. *Current Opinion in Solid State and Materials Science*, 123 - 130.

MTA. (2023, 05 02). <https://www.mta.gov.tr/v3.0/arastirmalar/jeotermal-enerji-arastirmalari> (Eriřim tarihi: 05.02.2023)

Myttenaere, A. d., Golden, B., Grand, B. L., & Rossi, F. (2016). Mean Absolute Percentage Error for Regression Models. *Neurocomputing*, 38-48.

Nabipour, M., Nayyeri, P., Shahab, H. J., & Mosavi, A. (2020). Predicting Stock Market Trends Using Machine Learning and Deep Learning Algorithms Via Continuous and Binary Data; a Comparative Analysis. *IEEE*, 199 - 212.

Nielsen, M. (2015). *Neural Networks and Deep Learning*. Determination Press.

Ozan, M. (2021). *Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi* (Yüksek Lisans Tezi). Kayseri: Erciyes Üniversitesi Fen Bilimleri Enstitüsü.

Öndeş, T., B. Güngör. (2014). Menkul Kıymet Analizleri, *Sermaye ve Para Piyasaları* (s. 178-196). Erzurum: Atatürk Üniversitesi Açıköğretim Fakültesi.

Özçalık, M., & Güler, S. (2018). Hisse Getirisi, Faiz Oranı ve Dolar Kuru İlişkisi: BİST' te Bir Uygulama. *MCBÜ Sosyal Bilimler Dergisi*, 291 – 305.

Özçalık, M., & Özçalık, S. G. (2020). Turizm Endeksinde Döviz Kuru Etkisi: BİST' te Bir Uygulama. *Ekonomi, Politika & Finans Araştırmaları Dergisi*, 374 - 388.

Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ' ya Genel Bir Bakış. *Takvim-i Vekayi*, 25-36.

Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On The Difficulty of Training Recurrent Neural Networks. *International Conference on Machine Learning*, (s. 1 - 12). Atlanta.

Persio, L. D., & Honchar, O. (2017). Analysis of Recurrent Neural Networks for Short-Term Energy Load Forecasting. *Computational Methods in Sciences and Engineering*, 1 - 4.

Persio, L. D., & Honchar, O. (2017). Recurrent Neural Networks Approach to The Financial Forecast of Google Assets. *International Journal of Mathematics and Computers in Simulation*, 7 - 13.

Petrol ve Doğal Gaz Platformu Derneği (PETFORM). (2020). <https://www.petform.org.tr/arama-uretim-sektoru/petrol-nedir/> (Erişim tarihi: 15.02.2023)

Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning*. Birmingham: Packt Publishing.

Raşo, H. (2019). *Deep Learning Based Stock Market Prediction Using Technical Indicators* (Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Ruder, S. (2017). An overview of gradient descent optimization algorithms. *arXiv*, 1 - 14.

Sayılğan, Ş. (1994). Demokratik Ekonomi ve Borsa. *Marmara İletişim Dergisi*, 27 - 37.

Seetharam, K., Kagiya, N., & Sengupta, P. (2019). Application of mobile health, telemedicine and artificial intelligence to echocardiography. *Echo Research and Practice*, 41-52.

Seyyarer, E., Ayata, F., Uçkan, T., & Karcı, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması Ve Kiyaslanması. *Anatolian Journal of Computer Sciences*, 90-98.

Song, H., & Choi, H. (2023). Forecasting Stock Market Indices Using the Recurrent Neural Network Based Hybrid Models: CNN-LSTM, GRU-CNN, and Ensemble Models. *Applied Sciences*, 1 - 26.

Stevens, E., Antiga, L., & Viehmann, T. (2020). *Deep Learning with PyTorch*. Manning Publications Co.

Sussillo, D., & Abbott, L. F. (2015). Random Walk Initialization for Training Very Deep Feedforward Networks. *Conference on Learning Representations* (s. 1 - 10). arXiv.

Sutskever, I., Vinyals, O., & Le, Q. (2014). Sequence to Sequence Learning with Neural Networks. *arXiv*, 1-9.

Şişmanoğlu, G., Koçer, F., Önde, M. A., & Şahingöz, Ö. K. (2020). Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini. *BEÜ Fen Bilimleri Dergisi*, 434 - 445.

T.C. Enerji Piyasası Düzenleme Kurumu. (2022). *2021 Yılı Doğal Gaz Piyasası Sektör Raporu*. Ankara: EPDK.

T.C. Enerji ve Tabii Kaynaklar Bakanlığı. (2023). <https://enerji.gov.tr/bilgi-merkezi-enerji> (Erişim tarihi: 03.02.2023)

T.C. Resmi Gazete (2005) *Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun*.

T.C. Resmi Gazete. (2012). *Sermaye Piyasası Kanunu*

T.C. Resmi Gazete. (2014). *Borsa İstanbul A.Ş. Borsacılık Faaliyetlerine İlişkin Esaslar Yönetmeliği*.

Tekinay, M. (2021). *Geleceğe Bakış; Bitcoin'in Derin Öğrenme Yöntemiyle Modellenmesi ve Tahmini* (Yüksek Lisans Tezi). İzmir: Dokuz Eylül Üniversitesi.

Thawornwong, S., & Enke, D. (2004). The Adaptive Selection of Financial and Economic Variables for Use With Artificial Neural Networks. *Neurocomputing*, 205 - 232.

Tokgöz, A., & Ünal, G. (2018). Türkiye Elektrik Tüketimi Tahmini İçin RNN Tabanlı Zaman Serisi Yaklaşımı. *IEEE*, 1 - 4.

TÜBİTAK (2021). <https://bilimgenc.tubitak.gov.tr/paranin-icadi> (Erişim tarihi: 15.06.2023)

Tümen, V., Söylemez, Ö. F., & Ergen, B. (2017). Facial Emotion Recognition on a Dataset Using Convolutional Neural Network. *International Artificial Intelligence and Data Processing Symposium (IDAP)*, (s. 1-5). IEEE Malatya.

Türk Ulusal Bilim e-Altyapısı (2023).

<https://docs.truba.gov.tr/education/keras/build/train.html> (Erişim Tarihi: 16.06.2023)

Türkiye Maden Mühendisleri Odası (TMOOB). (2023). *Jeotermal Enerji*. https://www.maden.org.tr/resimler/ekler/20ad4d76fe97759_ek.pdf (Erişim tarihi: 30.03.2023)

Türkiye Petrolleri Anonim Ortaklığı (TPAO). (2021). *Petrol ve Doğal Gaz Sektör Raporu*. TPAO.

Türkiye Taş Kömür İşletmeleri Kurumu. (2023). <https://www.tki.gov.tr/enerji-ve-komur> (Erişim tarihi: 21.02.2023)

Twidell, J., & Weir, T. (2006). *Renewable Energy Resources*. Taylor & Francis.

U.S. Energy Information Administration. (2022). <https://www.eia.gov/energyexplained/hydropower/> (Erişim tarihi: 05.02.2023)

Vasilev, I., Slater, D., Spacagna, G., Roelants, P., & Zocca, V. (2019). *Python Deep Learning*. Birmingham: Packt Publishing.

Vinj, M., Deeksha, C., Tikkiwal, V. A., & Kumar, A. (2019). Stock Closing Price Prediction Using Machine Learning Techniques. *ICCIDS* (s. 599 - 606). Procedia.

Vinyals, O., Toshev, A., Bengio, S., & Erhan, D. (2015). Show and Tell: A Neural Image Caption Generator. *arXiv*, 1-9.

Wang, Z., & Bovik, A. C. (2009). Mean squared error: Love it or leave it? A new look at Signal Fidelity Measures. *IEEE*, 98-117.

Yahoo Finance (2023). <https://finance.yahoo.com/> (Erişim Tarihi: 18.03.2023)

Yapa, K. (2022). *Hisse Senedi Fiyat Tahmininde Ekonometrik ve Makine Öğrenme Yöntemlerinin Karşılaştırılması: BİST Bankacılık Uygulaması* (Doktora Tezi). Uşak: Uşak Üniversitesi Lisansüstü Eğitim Enstitüsü.

Yılmaz, A., & Kaya, U. (2019). *Derin Öğrenme*. İstanbul: İnkılap Kitabevi.

Yuan, J., & Tian, Y. (2019). An Intelligent Fault Diagnosis Method Using GRU Neural Network Towards Sequential Data in Dynamic Processes. *Processes*, 1 - 21.

Yussif, A.-R. B. (2020). Yapay Sinir Ağları İle Borsa Endeksi Tahmini: Gana Borsası Üzerine Bir Uygulama (Yüksek Lisans Tezi). Konya: Selçuk Üniversitesi Sosyal Bilimler Enstitüsü.

Zaheer, R., & Shaziya, H. (2019). A Study of the Optimization Algorithms in Deep Learning. *International Conference on Inventive Systems and Control* (s. 536-539). IEEE.

Zhang, A., Lipton, Z., Li, M., & Smola, A. (2022). *Dive to Deep Learning*. arXiv.

Zielesny, A. (2016). *From Curve Fitting to Machine Learning An Illustrative Guide to Scientific Data Analysis and Computational Intelligence (2nd Edition)* . Springer.

Zorlu Enerji Elektrik Üretim A.Ş. (2023). *2021 Yılı Entegre Faaliyet Raporu*. <https://www.zorluenerji.com.tr/uploads/pdf/pdflist/2022.pdf> (Erişim tarihi: 05.03.2023)