



T.C.

SÜLEYMAN DEMİREL ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

EKONOMETRİ ANABİLİM DALI

**DERİN ÖĞRENMEDE İSTATİSTİKSEL YÖNTEMLERLE
HİSSE SENEDİ FİYATI ÖNGÖRÜSÜ**

Elif Nur GÜNEY

193027024

YÜKSEK LİSANS TEZİ

DANIŞMAN

Dr. Öğr. Üyesi Cüneyt TOYGANÖZÜ

ISPARTA-2022

TEZ SAVUNMA SINAV TUTANAĐI





T.C.

SÜLEYMAN DEMİREL ÜNİVERSİTESİ

Sosyal Bilimler Enstitüsü Müdürlüğü



YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “*Derin Öğrenmede İstatistiksel Yöntemlerle Hisse Senedi Fiyatı Öngörüsü*” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadar bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim.

Elif Nur GÜNEY

25/03/2022



T.C.

SÜLEYMAN DEMİREL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE

ÖĞRENCİ BİLGİLERİ	
Adı-SOYADI	Elif Nur GÜNEY
Öğrenci Numarası	1930227024
Enstitü Ana Bilim Dalı	Ekonometri
Programı	Yüksek Lisans
Programın Türü	(x) Tezli Yüksek Lisans () Doktora
Danışmanın Unvanı, Adı-SOYADI	Dr. Öğr. Üyesi Cüneyt TOYGANÖZÜ
Tez Başlığı	Derin Öğrenmede İstatistiksel Yöntemlerle Hisse Senedi Fiyatı Öngörüsü
Turnitin Ödev Numarası	1767509984

Yukarıda başlığı belirtilen tez çalışmasının a) Kapak sayfası, b) Giriş, c) Ana Bölümler ve d) Sonuç kısımlarından oluşan toplam 59 sayfalık kısmına ilişkin olarak, 21/02/2022 tarihinde tarafımdan Turnitin adlı intihal tespit programından Üniversitemiz Lisansüstü Eğitim ve Öğretim Yönergesininin 14 üncü maddesinde yer alan filtrelemeler uygulanarak alınmış olan ve ekte sunulan rapora göre, tezin/dönem projesinin benzerlik oranı;

Kaynakçalar hariç, alıntılar dahil, 10 kelimeden daha az örtüşme içeren metin kısımları hariç;
% 3'tür.

Danışman tarafından uygun olan seçenek işaretlenmelidir:

(x) Benzerlik oranları belirlenen limitleri aşmıyor ise;

Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporu'nun doğruluğunu onaylarım.

() Benzerlik oranları belirlenen limitleri aşıyor, ancak tez/dönem projesi danışmanı intihal yapılmadığı kanısında ise;

Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporu'nun doğruluğunu onaylar ve Uygulama Esasları'nda öngörülen yüzdelik sınırlarının aşılmasına karşın, aşağıda belirtilen gerekçe ile intihal yapılmadığı kanısında olduğumu beyan ederim.

Gerekçe:

Benzerlik taraması yukarıda verilen ölçütlerin ışığı altında tarafımca yapılmıştır. İlgili tezin orijinallik raporunun uygun olduğunu beyan ederim.

25/03/2022

(İmza)

Dr. Öğr. Üyesi Cüneyt TOYGANÖZÜ

ÖZET

Yapay zeka ve makine öğrenmesinin bir alt kategorisi olan derin öğrenme, finanstan sağlığa, ses tanımadan duygu analizine her alanda uygulaması olan bir öğrenme yöntemidir.

Bu tez çalışmasında önce derin öğrenmenin tarihçesi, temelleri, algoritmaları ve modelleri hakkında bilgiler verilmiş, derin öğrenme modellerinden Yinelemeli Sinir Ağları (RNN), Uzun-Kısa Dönem Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) modelleri karşılaştırılarak bir şirketin hisse senedi günlük kapanış değerleri ile 30, 60, 90, 120 günlük fiyat öngörüsü yapılmıştır. Ayrıca, derin öğrenme uygulamalarında, zaman serisi analizinde kullanılan varsayımların yapılan tahmin veya öngöruları etkilemediği, gereken birim-kök testleri kullanılarak gösterilmiştir.

Kullanılan veri grubundan elde edilen sonuçlar ile Geçitli Tekrarlayan Birim'in (GRU), Uzun-Kısa Dönem Bellek (LSTM) ve Yinelemeli Sinir Ağları'na (RNN) göre daha başarılı tahmin yaptığı gözlemlenmiştir.

Anahtar Kelimeler: Derin Öğrenme, Hisse Senedi Öngörüsü, Yinelemeli Sinir Ağı (RNN), Uzun-Kısa Dönem Bellek (LSTM), Geçitli Tekrarlayan Birim (GRU)

ABSTRACT

Deep learning, a subcategory of artificial intelligence and machine learning, is a learning method that has applications in every field from finance to health, from voice recognition to sentiment analysis.

In this study, information about the history, foundations, algorithms and models of deep learning is given. Then, by comparing deep learning models, Recurrent Neural Networks, Long-Short Term Memory and Gated Recurrent Unit models, the Daily closing values of shares of owned by a company. Price Forecasts were made for 30, 60, 90, 120 days. In addition, in deep learning applications, it has been shown by using necessary Unit-Root Tests that the assumptions used in time series analysis don't affect the forecasts or forecasts made.

With the results obtained from the data set used, it has been observed that the Gated Recurrent Unit (GRU) predicts more successfully than Long-Short-Term Memory (LSTM) and Iterative Neural Networks (RNN).

Keywords: Deep Learning, Stock Price Forecast, Recurrent Neural Network (RNN), Long Short Term Memory (LSTM), Gated Recurrent Unit (GRU)

ÖNSÖZ

Tezin hazırlanma döneminde her konuda yol gösteren, tezimi yönlendiren, derin öğrenmeye karşı ilgimin olmasını sağlayan ve desteklerini esirgemeyen değerli danışmanım Dr. Öğr. Üyesi Cüneyt TOYGANÖZÜ hocama emekleri için sonsuz teşekkürlerimi sunarım.

Tez çalışma süresince yardım ve katkılarından dolayı kıymetli hocam Dr. Öğr. Üyesi Zeynep Hande TOYGANÖZÜ'ye teşekkürü borç bilirim.

Lisans ve yüksek lisans eğitimim boyunca hiçbir zaman bilgilerini ve emeklerini eksik etmeyen kıymetli hocalarım Dr. Öğr. Üyesi Özge GÜNDOĞDU'ya, Prof. Dr. Hakan DEMİRGİL'e ve Dr. Öğr. Üyesi Aliye ATAY'a teşekkürü borç bilirim.

Beni yüksek lisansa teşvik eden ve bu çalışmada yardımlarını esirgemeyen değerli arkadaşım Bilim Uzmanı Fatih ÖZDEMİR'e teşekkürü borç bilirim.

Hayatımın her anında motivasyonumun düşmesine izin vermeyen ve her zaman yanımda olan aileme sevgilerle.

Elif Nur GÜNEY

ISPARTA- 2022

İÇİNDEKİLER

TEZ SAVUNMA SINAV TUTANAĞI	i
YEMİN METNİ	ii
ÖZET.....	iv
ABSTRACT	v
ÖNSÖZ.....	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
KISALTMALAR DİZİNİ	xi
GİRİŞ	1
LİTERATÜR TARAMASI	1

1. BÖLÜM DERİN ÖĞRENME

1. YAPAY SİNİR AĞLARI.....	3
2. DERİN ÖĞRENMENİN GELİŞİMİ	5
3. DERİN ÖĞRENMENİN TEMELLERİ	7
4. DERİN ÖĞRENME MODELLERİNDE ALGORİTMALAR	10
4.1. İleri Yayılım Algoritması	10
4.2. Geri Yayılım Algoritması	12
5. DERİN ÖĞRENME MODELLERİ.....	14
5.1. İleri Besleme Sinir Ağları (Çok Katmanlı Algılayıcılar/MLP).....	14
5.2. Evrişimsel Sinir Ağı (CNN).....	16
5.3. Yinelemeli Sinir Ağı (RNN)	18
5.3.1. Gradyanların Kaybolması	21
5.3.2. Uzun Kısa Süreli Bellek (LSTM)	22
5.3.2.1. LSTM'in Çalışma Mantığı.....	24
5.3.2.2. LSTM'in Özellikleri.....	26
5.3.3. Geçitli Tekrarlayan Birim (GRU)	26
6. MODEL PERFORMANS ÖLÇÜTLERİ	27

2. BÖLÜM ARAŞTIRMANIN ANALİZİ

1. ARAŞTIRMANIN ANALİZİ.....	29
1.1. Araştırmanın Amacı	29
1.2. Araştırmanın Önemi	29
1.3. Araştırmanın Evreni ve Örneklemi	30

1.4. Araştırmanın Yöntemi.....	30
1.5. Araştırmanın Uygulaması	31
1.5.1. Uygulanan Birim Kök Testleri.....	31
1.5.1.1 Augmented Dickey Fuller Testi	31
1.5.1.2 Perron (1989) Tek Kırılmalı Birim Kök Testi	32
1.5.1.3. Zivot ve Andrews (1992) Tek Kırılmalı Birim Kök Testi	33
1.5.2. Araştırmada Kullanılan RNN-LSTM-GRU Modellerinin Öngörü Sonuçları	36
1.6. Araştırmanın Bulguları ve Yorumları	37
SONUÇ.....	50
KAYNAKÇA.....	52
EKLER.....	57
ÖZGEÇMİŞ.....	69

TABLÖLAR DİZİNİ

Tablo 1. Makine Öğrenmesi ile Derin Öğrenme Arasındaki Temel Farklar.....	9
Tablo 2. ADF Test Sonuçları	31
Tablo 3. Serinin Birinci Farkı İçin ADF Test Sonuçları	32
Tablo 4. Perron (1989) Tek Kırılmalı Birim Kök Testi Sonuçları	33
Tablo 5. Zivot ve Andrews (1992) Birim Kök Testi Sonuçları.....	34
Tablo 6. RNN, LSTM ve GRU Model Parametreleri	37
Tablo 7. RNN, LSTM ve GRU Model Performans Sonucu.....	38
Tablo 8. 30 Günlük Hisse Senedi Gerçek ve Tahmin Değerleri	39
Tablo 9. 60 Günlük Hisse Senedi Gerçek ve Tahmin Değerleri	41
Tablo 10. 90 Günlük Hisse Gerçek ve Tahmin Değerleri	44
Tablo 11. 120 Günlük Hisse Gerçek ve Tahmin Değerleri	47

ŞEKİLLER DİZİNİ

Şekil 1. Biyolojik Bir Sinir Hücresi	4
Şekil 2. Yapay Zekâ	8
Şekil 3. Derin Öğrenme Etkisi	10
Şekil 4. Yinelemeli Sinir Ağı Modeli	11
Şekil 5. Yinelemeli Sinir Ağı Topolojisi	13
Şekil 6. Çok Katmanlı Algılayıcılar	15
Şekil 7. Evrimsel Sinir Ağı	17
Şekil 8. Yinelemeli Sinir Ağı'nın Açılımı	19
Şekil 9. Yinelemeli Sinir Ağı Modelleri	20
Şekil 10. LSTM Diyagramı	23
Şekil 11. LSTM 1.Adımı	24
Şekil 12. LSTM 2.Adımı	25
Şekil 13. LSTM 3.Adımı	25
Şekil 14. LSTM 4.Adımı	26
Şekil 15. GRU Diyagramı	27
Şekil 16. Zivot ve Andrews (1992) Birim Kök Testi Kırılma Zamanları-Model A ..	34
Şekil 17. Zivot ve Andrews (1992) Birim Kök Testi Kırılma Zamanları-Model B ..	35
Şekil 18. Göltaş Çimento A.Ş. Verisi	36
Şekil 19. Eğitim İçin Kullanılan Veriler	36
Şekil 20. Test İçin Kullanılan Veriler	37
Şekil 21. RNN Modeli ile 30 Günlük Hisse Senedi Öngörüsü	39
Şekil 22. LSTM Modeli ile 30 Günlük Hisse Senedi Öngörüsü	40
Şekil 23. GRU Modeli ile 30 Günlük Hisse Senedi Öngörüsü	40
Şekil 24. RNN, LSTM ve GRU Modellerin 30 Günlük Hisse Senedi Öngörüsü	41
Şekil 25. RNN Modeli ile 60 Gün Hisse Senedi Öngörüsü	42
Şekil 26. LSTM Modeli ile 60 Gün Hisse Senedi Öngörüsü	43
Şekil 27. GRU Modeli ile 60 Günlük Hisse Senedi Öngörüsü	43
Şekil 28. RNN, LSTM ve GRU Modellerin 60 Günlük Hisse Senedi Öngörüsü Karşılaştırılması	44
Şekil 29. RNN Modeli ile 90 Günlük Hisse Senedi Öngörüsü	45
Şekil 30. LSTM Modeli ile 60 Günlük Hisse Senedi Öngörüsü	45
Şekil 31. GRU Modeli ile 90 Günlük Hisse Senedi Öngörüsü	46
Şekil 32. RNN, LSTM ve GRU Modelleri ile 90 Günlük Hisse Senedi Öngörü Karşılaştırılması	46
Şekil 33. RNN Modeli ile 120 Günlük Hisse Senedi Öngörüsü	47
Şekil 34. LSTM Modeli ile 120 Günlük Hisse Senedi Öngörüsü	48
Şekil 35. GRU Modeli ile 120 Günlük Hisse Senedi Öngörüsü	48
Şekil 36. RNN, LSTM ve GRU Modellerin 120 Günlük Hisse Senedi Öngörü Karşılaştırılması	49

KISALTMALAR DİZİNİ

A.Ş.	: Anonim Şirket
BİST	: Borsa İstanbul A.Ş.
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
GOLTS	: Göltaş Göller Bölgesi Çimento Ticaret ve Sanayi A.Ş.
GPU	: Grafik İşlemci Birimi
GRU	: Gated Recurrent Unit (Geçitli Tekrarlayan Birim)
LSTM	: Long-Short Term Memory (Uzun-Kısa Dönem Bellek)
MAE	: Mean Absolute Error (Hataların Mutlak Ortalaması)
MAPE	: Mean Absolute Percentage Error (Hataların Mutlak Yüzde Ortalaması)
MLP	: Multilayer Perceptron (Çok Katmanlı Algılayıcı)
MSE	: Mean Squared Error (Hata Kareler Ortalaması)
RMSE	: Root Mean Square Error (Hata Kareler Ortalamasının Kökü)
RNN	: Recurrent Neural Network (Yinelemeli Sinir Ağı)
YSA	: Yapay Sinir Ağları

GİRİŞ

Derin öğrenme ve makine öğrenmesi ile çalışan yapay zeka her gün popülaritesini artırmaktadır. Giderek yaygınlaşan yapay zeka teknolojisi ileri tarihlerde insanlık için faydalı ya da zararlı olacağı yönünde tartışmalar olsa bile devamlı yeni teknolojiler ile değişim halinde olduğundan yapay zekadan kaçış da yoktur. Her insan gün içerisinde birçok yapay zekâ teknolojisini kullanmaktadır. Kullanılan teknolojilerin, insanların hayatını kolaylaştıran en büyük yardımcı olduğu bir gerçektir. Birçok alanda kullanılmasının yanı sıra finans alanı için de oldukça önemlidir. Tüm dünya tarafından yapılan hisse senedi öngörüsü, döviz kuru öngörüsü gibi finansal öngörülerde yapay zekâ teknolojilerinden yararlanılmaktadır. Günümüzde yapılan çalışmalarda veri sayısının artması ve teknolojinin ilerlemesiyle geleneksel yöntemlerin kullanılması yerine yapay zeka teknolojisine ayak uydurmak kaçınılmaz hale gelmektedir.

Çoğu insan paralarını yatırım yaparak değerlendirmek istemektedir. Bu yatırımlardan birisi de hisse senedi alımıdır. Hisse senedi ile bir zaman içerisinde kar elde etmek tek hedeftir. Hisse senetleri inişli çıkışlı olabileceğinden dolayı risklerin doğru ölçülmesi gerekmektedir. Teknik ve temel bilgiler ile mantık çerçevesinde değerlendirilmelidir. Değerlendirmelerde hata payının az olması riskin de az olduğunu göstermektedir. Riski düşük olabilecek hisse senedini seçerken oldukça dikkat edilmesi gerekmektedir. Çünkü şirketlerin zarar etme riskleri göz önünde bulundurulmazsa kar elde edilemez. Yapılan çalışmalar incelendiğinde, geçmiş veriler kullanılarak gelecek hakkında farklı yöntemlerden yararlanarak yapılan öngörü çalışmaları bulunmaktadır.

Bu çalışmada literatüre katkı yapacağı inancıyla yapay sinir ağları kullanarak derin öğrenme yöntemleri kullanılmıştır. Derin öğrenme yöntemlerinden yinelemeli sinir ağları (RNN), uzun kısa dönem bellek (LSTM) ve geçitli tekrarlayan birim (GRU) modelleri kullanılarak karşılaştırma yapılmıştır. Bu modellerin seçilmesinin sebebi finans alanında yapılan klasik yöntemlerin aksine son yıllarda popülerlik kazanan yapay zekâ uygulamalarından yapay sinir ağları yöntemleri olmasıdır. Yapay sinir ağları diğer yöntemlerden farklı olarak hata terimlerinde normallik, varyansın sabitliği, ortalamanın 0 olması, öngörü değerleri arasında ilişki olmaması gibi

varsayımlara bağılı değıldir. Yapay sinir ağıları kendi yapısı gereğı doğrusal olmayan, yetersiz, yanlış veya hatalı verileri oldukça muazzam bir biçimde modellemektedir.

Bu tez çalışmasında finansal alanda hisse senedi öngörüsü yaparken karar almada derin öğrenme modellerinin faydalı olup olmadıkları incelenmiştir. İncelenen Göltaş Göller Bölgesi Çimento Sanayi ve Ticaret AŞ'ye ait hisse değerleri öngörüsünde derin öğrenme modellerinden yinelemeli sinir ağı, uzun kısa dönem bellek ve geçitli yinelenen birim modelleri araştırılmıştır.

Çalışmanın birinci bölümünde temel olarak yapay sinir ağlarının meydana gelmesi, özellikleri, kullanım alanları, işleyiş şekli, işlevsel birimlerine, derin öğrenmenin meydana gelişindeki tarihsel süreç, temelleri, derin öğrenmenin daha iyi kavranabilmesi adına makine öğrenmesi ile arasındaki temel farklardan, derin öğrenmenin ileri ve geri yayılım algoritmalarından, derin öğrenmenin ileri beslemeli, evrişimsel, yinelemeli sinir ağlarından uzun kısa dönem bellek ve geçitli tekrarlayan birim modellerinden ve model performans ölçütlerinden bahsedilmiştir.

Son bölümde ise araştırmanın amacı, önemi, evreni, örnekleme, yöntemi ve uygulaması kapsamlı olarak anlatılmıştır. Analizlerin sonucu, sonuç bölümünde yorumlanarak tez çalışması sonlandırılmıştır.

LİTERATÜR TARAMASI

Çetin ve Metlek, 2021 yılında yayımlanan çalışmalarında Türkiye’deki İslami hisse senedi endeksi için endeks tabanlı öznitelikler kullanarak derin öğrenme yöntemlerinden LSTM yardımıyla yeni bir model oluşturmuşlardır (s.296).

Gavcar ve Metin, 2021 yılında yayımlanan çalışmalarında bir firmaya ait Ocak 2016 ve Aralık 2021 dönemleri arasındaki açılış fiyat değerlerini kullanarak geçmiş 60 günlük hisse senedi açılış değeri serileri ile ileriye dönük 61.günün hisse senedi açılış değeri serileri tahminini LSTM kullanarak yapmışlardır (s.9).

Mateus vd. 2021’de yayımlanan çalışmalarında derin öğrenme modelleri olan GRU ve LSTM yardımıyla kâğıt hamur baskı durumunu tahmin etmişlerdir. GRU’nun LSTM’ye göre daha iyi performans sergilediğini belirtmişlerdir.

Unlu vd. 2021 yılında yayımlanan çalışmalarında makine öğrenmesi yöntemleri ile derin öğrenme algoritmalarını karşılaştırarak hisse senedi tahmininde bulunmuşlardır. Elde edilen sonuca göre çok katmanlı algılayıcılar ve uzun kısa dönem bellek, destek vektör makinesine göre daha iyi sonuçlar vermiştir (s.77).

Yusufoğlu vd. ’nin twitter üzerinden finansal tweetlerin LSTM sinir ağı algoritması kullanarak yaptıkları duygu analizi çalışmasında, LSTM tahmin modelleri geliştirerek en iyi performansı belirleyen LSTM sinir ağı tespit etmişlerdir (2021, s. 41).

Yürük, 2021 yılında yayımlanan çalışmasında makine öğrenmesinin bilim dünyasının bir parçası olması ile tahmin tekniklerinin bu alanlarda arttığından bahsetmiştir. Çalışmasında Türk Hava Yolları’nın hisse senedi tahmini için 5 YSA modeli oluşturmuş ve aralarında en iyi performansa sahip olan MLP 5-10-1 ağını elde etmiştir (s.288).

Altan ve Karasu, 2020 yılında yayımlanan çalışmalarında ayırıştırma yöntemlerinin derin öğrenme algoritması ile tanımlanan rüzgâr hızı tahmin modeli başarımına etkisini incelemişlerdir. Elde ettikleri sonuçlara göre EWT-LSTM modelinin rüzgâr hızının anlık değişimlerini tahmin etmede oldukça başarılı olduğunu tespit etmişlerdir (s.852).

Güneş'in 2020 yılında yayımlanan çalışmasında ARIMA ve LSTM modeller karşılaştırılarak bitcoin veri seti fiyat değerleri tahmin edilmiştir. Yapılan bu çalışmada LSTM modelin, ARIMA modele göre daha iyi sonuç verdiği belirlenmiştir (s.30).

Kıymaz'ın 2020'de yaptığı çalışma güneş enerjisi santrallerinde elektrik üretimi tahmini için derin öğrenme ve istatistiksel yöntem kullanılarak yaptığı karşılaştırmayı içermektedir. Elde ettiği sonuçlar incelendiğinde derin öğrenme yöntemi olarak kullandığı LSTM, istatistiksel yöntem olarak kullanılan mevsimsel otoregresif hareketli ortalama (SARIMA)'ya göre gerçek değerlere daha yakın sonuçlar vermektedir (s.58).

Şahingöz vd. (2020) yılında yayımlanan çalışmalarında derin öğrenme yaklaşımları olan LSTM, GRU ve BLSTM modelleri yardımıyla borsada fiyat tahmininde bulunmuşlardır. Elde ettikleri sonuçlara göre eğitilen BLSTM modelin en iyi sonucu verdiğini belirtmişlerdir (s.444).

Yıldırım, yayımlanan çalışmasında Forex verisi hareketlenme yönünü teknik ve makroekonomik göstergeler kullanarak LSTM ile tahmin yapmıştır. Yaptığı tahmin sonucuna göre iki LSTM modelinin öngörülerini başarılı sonuçlar vermiştir (2019, s.62).

Sakarya ve Yılmaz'ın yayımlanan çalışmalarında derin öğrenme mimarisine sahip yığın oto kodlayıcı yardımıyla BİST 30 Endeksinin günlük hareket tahminini %80 doğruluk oranı ile gerçekleştirmişlerdir. Derin öğrenme modellerinin finansal piyasalardaki yatırımlarda karar almak için hayli faydalı olabileceğini ifade etmişlerdir (2019, s.119).

Turan'ın 2019'da yayımlanan çalışmasında LSTM ve GRU modelleri kullanılarak Borsa İstanbul 100 Endeks değeri tahmini yapılmıştır. Turan'a göre iki model birbirine yakın sonuçları verse de GRU'nun model tahminlemede daha iyi performans gösterdiği belirtilmiştir (s.31).

Bayındır'ın 2017'de yayımlanan finansal zaman serilerinin LSTM algoritması ile tahminlenme çalışmasında, LSTM yardımıyla iki farklı nöron modeli kullanılarak en iyi tahminleme yapan model belirlenmiştir (s.61).

1. BÖLÜM

DERİN ÖĞRENME

1. YAPAY SİNİR AĞLARI

İnsanlar doğduğundan itibaren doğa ile birbirinden ayrılamaz olduğu için doğadan esinlenerek fazlasıyla çıkış yolları bulmuştur. Bilhassa gereksinimlerini karşılamak amacıyla yapısı gereği kendiliğinden oluşan doğal kaynaklardan zihin gücünü ve sezgilerini kullanarak yararlanmıştır. Bu yararlanmayla pek çok yöntem geliştirilmiştir. 1950 yılını takiben bilgisayar kullanarak yapılan hesaplamalar sürat ile ilerlediği için geliştirilen bu yöntemler üzerinde ilerlemeler saptanmıştır. Birtakım ilerlemeler canlı varlıklardan ilham alınarak yapılmıştır. Bu canlı varlıkların mekanizmasının matematik ile belirtilmesiyle meydana gelen yöntemlere yapay sinir ağları (YSA) örnek verilebilir (Şen, 2004, s. 7).


“Yapay sinir ağlarının (YSA) birtakım özellikleri dayalı doğrusal bir yöntem olarak girdiler ve çıktılar arasında ön bilgiye gerek duymadan doğrusal olmayan modelleme ve analizleri yapabilmektedir. Bu anlamda en doğru şekilde tahmin etmesi, bu yöntemi, araştırmacılar ve kullanıcılar için giderek daha çekici bir yöntem haline getirmiştir. İlk olarak yapay sinir ağları (YSA) veriye finansal tahminler için oldukça genel ve esnek modelleme araçlarıdır. İkinci olarak yapay sinir ağları (YSA) evrensel işlevsel tahminler olarak bir sürekli fonksiyonu istenen doğrulukta kolayca tahmin edebilmektedirler. Üçüncü ve son olarak yapay sinir ağları (YSA) kolaylıkla genelleme yapabilmektedirler. Örneğin kendilerine sunulan veriyi öğrendikten sonra verinin görünmeyen yani eksik kısmı hakkında örneklemin gürültülü veri içermesi halinde bile kolaylıkla çıkarım yapabilmektedirler. Tüm bu kendine has özellikleri, yapay sinir ağlarını (YSA) birçok tahmin probleminin çözümünde vazgeçilmez hale getirmektedir (Çalışkan Çavdar ve Aydın, 2018, s. 19).”

Yapay sinir ağlarının kullanım alanlarında; incelenen verilerin kendi arasında bağdaşmayacak bir biçimde gruplara ayırarak yapılan yorumlama olan sınıflandırma, birbirine benzeyen girdi bilgilerinin aynı grubun içine eklenmesi anlamına gelen kümeleme, geçmiş veriler incelenerek gelecek hakkında bilgilerin elde edilmesiyle

tahmin yapmak yapay sinir ağlarının kullanım alanlarında yer alır (Şen, 2004, ss. 17-18).

Yapay sinir ağlarında öngörü genel olarak borsa durumu, hava durumu gibi alanlarda yapılmaktadır. Finans alanında kullanımları için kredi değerlendirilmesi, iflas öngörüsü, borsa endeks ve hisse senedi öngörüsü, döviz kuru öngörüsü, finansal krizlerin saptanması örnek olarak verilebilir.

Yapay sinir ağlarının işleyişinde biyolojik bir sinir hücresinden esinlenilmiştir. Biyolojik sinir hücresi Şekil 1’de gösterilmiştir (Yakıt ve Özkan, 2017, s. 288):



Şekil 1. Biyolojik Bir Sinir Hücresi

Bir sinir sisteminin temel işlevsel birimi olan ve bilgi transferini gerçekleştiren nöronlar dendrit, akson, çekirdek ve snaps (bağlantılar) olmak üzere dört bölümden oluşmaktadır. Sinir hücrelerinin birisinin çıkışı ile diğerinin girişi arasında iletişim kurmak snaps bağlantıları sayesinde gerçekleşir. Snapslardan sağlanan verileri hücre gövdesine ileten dendritlerdir. Gövdede eklenen veri uyarı eşiğini geçtiğinde hücreye uyarıda bulunulur ve nakletme yolu olarak tanımlanan aksonlar sayesinde başka hücrelere işaretler iletilir (Şen, 2004, s.9).

Yapay sinir ağlarında birden fazla girdi ile bir çıktının meydana gelmesi, insan vücudunda bulunan sinir hücrelerinde dendritlerin girdileri ve aksonun çıktılarını elde etmesiyle aynıdır (Yakıt ve Özkan, 2017, s. 289).

2. DERİN ÖĞRENMENİN GELİŞİMİ

Derin öğrenmenin kökünü yapay zekaya dayandırmak mümkündür. İnsan beynine benzer bir makine düşleri kurulmuş ve bu düşlerin tomurcuklanması ile yapay zekâ serüveni başlamıştır. Yapay zekâ, yapay adını insan beynindeki sinir ağlarını taklit etmesinden almaktadır. Bu sinir ağları sayesinde, insanların yetenek ve kabiliyetlerini örnek alan makineler gelişmiştir.

İstatistik, mühendislik, felsefe, psikoloji, mantık, biyoloji alanları akıllı makinelerin tasarımı için yardım kaynağı olmuştur. İnsanlar, kendilerine benzer bir beynin bazı özelliklerini otomatikleştirirken bu alanlardan oldukça faydalanmışlardır. İlk yapay zekâ keşifleri ile akıllı makinelerin yapımı için giderek artan uğraşlar olmuştur (Nilsson, 2011, s. 27).

Bu uğraşlardaki araştırmacılar, akıllı makinelere sorunları ortadan kaldırmaya çalışırken, insan zekasının sorunları nasıl ortadan kaldırdığı hakkında da alakadar olduğu için akıllı makinelerle yapılan ilerlemeler genellikle, insanın bilinçsel olarak birbirini izleyen dönemleri ile ilgili teorilere yardım etsin diye tavsiye edilmiştir. Bu sebeple birçok alanda yapılan çalışmalar ile yapay zekâ çalışmaları birbiriyle ilişkili olmuştur. Yapay zekanın temel amacı, başta zekayı gerektiren objeler meydana getirmek ve insanların kendi yetenek ve kabiliyetlerini benzetim yapabilen insan yapıtı objeler yapmaktır. Bunlara ek olarak insan düzeyinde yapay zekâ barındırmasını sağlayan sistemler geliştirmektir (Nilsson, 2011, ss. 73-74)

Evlerde, okullarda, arabalarda, iş yerlerinde, çeşitli aktiviteler ve daha birçok yerde ve alanda yapay zekâ uygulamaları giderek pozitif yönde ilerleme gösterdiği için makine öğrenmesi ve derin öğrenme kavramları ortaya çıkmıştır.

Derin Öğrenmenin tarihi, 1943 senesinde, Warren McCulloch ile Walter Pitts'in sinir ağının ilk matematiksel modelini sunmasıyla başlamıştır. (McCulloch ve Pitts, 1943, s. 116).

1949'a gelindiğinde Hebb tarafından bir makinenin kendi kendine öğrenimi için ilk adım atılmıştır. 1958 senesinde Frank Rosenblatt aracılığıyla eğitilmiş öğrenmenin ilk modeli algılayıcı olarak sunulmuştur. Bu algılayıcıları eğitmek için yararlanılan vektörlerin doğrusal bir biçimde birbirinden farklı olarak iki hipotez olduğunu ispat etmiştir (Haykin, 2009, s. 48).

1950 yılında bilgisayarlarda veri işleme sınırları, hafızaları ve hesap yapma güçleri yeterli olmadığı için ilerleme yapılmamıştır.

1965 senesinde Ivakhnenko ve Lapa tarafından derin öğrenme algoritmalarını daha üst seviyeye çıkarmak için sibernetik tahmin araçları adlı çalışmayı yapmıştır. Bu çalışmada karmaşık denklemlerin aktivasyon işlevleri kullanılmaktadır (Ivakhnenko ve Lapa, 1965)

1980'li tarihlerde Kunihiro Fukushima aracılığıyla, el yazısı tanıma vs. desen tanıma problemlerinde, aşamalı olarak ve çok katmanlı yapay sinir ağı olarak neocognitron tavsiye edilmiştir. Bu tavsiye üzerine dizaynda bilgisayarın öğrenmesinde görsellerden faydalanılmıştır (Fukushima, 1988, ss. 119-120).

Karışık bölümlerde kendiliğinden meydana gelen üç ebatlı nesne tanıma işlemini yapan Cresceptron yöntemi Juyang Weng ve arkadaşları tarafından 1992 senesinde yayımlanmıştır (Weng vd., 1992, s.974).

1995 senesinde Cortes ile Vapnik, emsal bilgileri elde eden iki grup bölümlendirmesi hakkında destek vektör ağlarının gelişmesini sağlamışlardır (Cortes ve Vapnik, 1995, s. 278).

1997 tarihinde Hochreiter Schmidhuber aracılığıyla Uzun Kısa Süreli Hafıza(LSTM) uzun süreli bağımlılık sorunlarını çözümlmek maksatlı tekrarlayan sinir ağı tavsiye edilmiştir (Hochreiter ve Schmidhuber, 1997, s. 1736).

2000'li senelerde, Hinton ile Salakhutdinov'un çalışmalarının neticesinde derin öğrenmeye rağbet artmıştır. Böylelikle çok katmanlı sinir ağının, tek seferde bir katmanının ne şekilde daha çabuk eğitebileceği açıklanmıştır (Hinton ve Salakhutdinov, 2016, s.505).

2012 senesinde Google araştırma grubu aracılığıyla, 16000 işlemci ile bir milyardan çok bağlantıdan meydana gelen yapay desen tanıma algoritmalarının başarımı, insan seviyesine taşınmıştır. 2014 senesinden bu yana Facebook, fotoğraflarda uygulamayı kullanan kişileri kendiliğinden etiket yapsın diye DeepFace isimli derin öğrenme teknolojisini kullanmıştır. Etiketlemeyi gerçekleştirmek için derin öğrenme algoritmaları, 120 milyon parametreyi bir araya getirerek yüz tanıma işlevlerini yapmıştır (Taigman vd., 2014, s. 1705).


AlphaGo, Google'ın DeepMind algoritması, 2016 senesinde Go sanatında yani karmaşık tahta oyununda, milyonlarca simülasyondan faydalanmış ve profesyonel bir oyuncu olmasına rağmen Lee Sedol'u turnuvada 4 -1 yenik duruma düşürmüştür. Derin öğrenme gelişerek günümüze kadar gelmiştir (DeepMind, 2016).

1940'li tarihlerde başlamış olan yapay zekâ teknolojisi, 1980'li tarihlerin ilk zamanlarında görevini makine öğrenmesi olan alt branşına devretmiştir. Makine öğrenmesi, 2010 senesinin ilk zamanlarında eksikliklerini derin öğrenme ile gidermiştir (Kayaalp ve Süzen, 2018, s.10).

3. DERİN ÖĞRENMENİN TEMELLERİ

İnternet kullanımı ilerlediği için bir konu hakkındaki bilgiye erişmek kolaylaşmış ve yapay sinir ağlarının eğitimi için çok fazla veri kümeleri kullanılmıştır. Yapay sinir ağlarının bilgiyi öğrenme hızını güçlendirmek amacıyla geliştirilen yaklaşımlardan birisi derin öğrenmedir. Birden daha çok gizli katmanı kapsayan yapay sinir ağına derin ağ, gösterdiği öğrenme biçimine ise derin öğrenme olarak tanımlanmıştır (Deng ve Yu, 2014, s. 206).

Derin öğrenme basit anlamda, makine öğrenmesinin eksikliklerini gidermek veya makine öğrenmesi ile çözülemeyecek problemleri ortadan kaldırmak amacıyla geliştirilen makine öğreniminin bir alt dalıdır. Temeli bu alana ve aynı zamanda yapay zekaya dayanmaktadır. Temelleri birbirleri ile ilişkili olsa da yapay zekâ, makine öğrenmesi ve derin öğrenme tanımsal olarak birbirlerinden farklılık göstermektedir. Bunun nedeni, makine öğrenmesi yapay zekanın bir alt dalıyken derin öğrenme makine öğrenmesinin bir alt dalıdır. Birbirleri ile olan ilişkileri görsel olarak aşağıdaki şekil yardımıyla ifade edilebilir.



Şekil 2. Yapay Zekâ¹

“Makine öğrenmesi şu temel sorulardan ortaya çıkmaktadır: Acaba bilgisayarların bizim herhangi bir şeyi nasıl yaptığımızın ötesine geçerek belirli bir işlemi kendi kendine yapabilmeyi, öğrenebilmesi mümkün müdür? Bilgisayarların bize sürpriz yapması mümkün müdür? Geliştirilen veriden öğrenmek için elle kurallar oluşturmaktan ziyade bilgisayarlar veriye bakarak bu kuralları kendileri öğrenebilir mi? Bu sorular yeni bir programlama paradigmasına kapı açmıştır. Klasik yapay zekâ programlamada sembolik yaklaşımlar kullanılarak geliştirici girdi olarak kuralları ve verileri ortaya koyar, veriler bu kurallardan geçirilerek bir cevap elde edilir. Makine öğrenmesi, veri ve beklenen çıktıları kullanarak yeni verilere özgün cevaplar üretebilecek kuralları öğrenir (Chollet, 2019, s.5).”

Günümüzde makine öğrenmesi algoritmalarına bağlı olarak çalışan çok fazla alan vardır. Bunlardan bazıları (Uğuz, 2019, s.2):

- Yatırımcıların neye yatırım yapacaklarına karar verirken onun hakkında zamansal bir değerlendirme yaparak tahminleme yapabilir.
- Otonom araçlar ilerlerken çok fazla faktörü analiz edebilir.
- Google çeviri, makine algoritması sayesinde verilen örneği öğrendiği için iyi çeviri sayısını artırmaktadır.
- Sağlık alanında bir hastalığın belirlenmesinde kullanılmaktadır.

¹ **Kaynak:** Sonsuz Teknoloji 2018

- ÖSYM son zamanlarda uyguladığı sınavlarda, doğal dil işleme için sınava giren adayların el yazısını alarak Türkçe el yazısı örnekleriyle dolu büyük veri seti oluşturmaktadır.

Makine öğrenmesinden farklı olarak, derin öğrenmede elde edilen bilgilerin sonuçları birden fazla katman sayesinde öngörü yapılmaktadır. Algoritma yapay sinir ağı yardımıyla çok fazla bilgiyi veri işleme yaparak öngörüyü doğru yapmayı öğrenmektedir. Tablo 1’de farklar daha net bir şekilde gösterilmiştir (Lazzeri vd. 2021).


Tablo 1. Makine Öğrenmesi ile Derin Öğrenme Arasındaki Temel Farklar

	Derin Öğrenme	Makine Öğrenmesi
Veri sayısı	Öngörü yapabilmek için fazla sayıda eğitim verisi kullanır.	Öngörü yapabilmek için az sayıda veri kullanabilir.
Donanım özelliği	Fazla sayıda matris çarpma işlemi yapıldığı için yüksek performanslı makinelerde çalışır. GPU yardımcı olabilir.	Fazla sayıda hesaplama olmadığı için düşük performanslı makinelerde çalışabilir.
Öğrenme yaklaşımı	Öğrenme boyunca ilerleyerek sorunu uçtan uca temelinde çözer.	Öğrenme küçük parçalara ayrılır ve her parçanın sonucunu bir çıktıda tamamlar.
İşlem süresi	Birçok katman içerdiğinden eğitmek uzun sürebilir.	İşlem daha kısa sürer.
Düzeltilme işlemi	Verilerden çok fazla özellik öğrenir ve kendisi başka özellikler oluşturur.	Özelliklerin doğru olarak girilmesi gerekir.
Çıktı	Metin, puan ve ses gibi pek çok şekilde olabilir.	Sayısalıdır.

Kaynak: Lazzeri (2021)

Derin öğrenme tekniği, sınıflandırmayı tanımlayan özellikleri direkt veriden öğrenmektedir. Örneğin, derin öğrenmede bir martının özelliği olarak boy uzunluğunun 32 cm olduğunu tanımlamak gerekmez. Derin öğrenmede martı sinir

ağına girdiğinde, otomatik olarak martının ayırt edici özelliği seçilmektedir. Günümüzde birçok alanda yüksek sayıda veriler kullanıldığı için derin öğrenme modellerini kullanmak avantaj sağlamıştır. Veri sayısının artmasıyla makine öğrenmesi teknikleri performans bakımından iyi sonuçlar vermediği için görüntü sınıflandırma, ses tanıma, doğal dil işleme alanlarında derin öğrenme modelleri geliştirilmiştir.



Şekil 3'e göre veri sayısı arttıkça makine öğrenmede performans önce artıp sonra sabit kalırken derin öğrenmede ise veri sayısı arttıkça performans artmaktadır.

4. DERİN ÖĞRENME MODELLERİNDE ALGORİTMALAR

Derin öğrenme modellerinde temel olarak yapay sinir ağlarındaki ileri yayılım ve geri yayılım algoritması kullanılmaktadır.


4.1. İleri Yayılım Algoritması

İleri yayılım algoritması, sinir ağındaki girdi değerlerinin sırasıyla giriş katmanını, gizli katman ve çıkış katmanına doğru eylemini tamamlaması olarak tanımlanmaktadır (Yılmaz ve Kaya, 2019, s. 11).

Bu eylem, tekrarlayan sinir ağlarında ileri yayılım algoritması yaparken hesaplama işlemlerinin sağa doğru yapıldığını göstermektedir. İleri yayılım

algoritmasını geleneksel olarak gösterilen tekrarlayan sinir ağlarında şekil yardımıyla göstermek mümkündür.

Geleneksel bir tekrarlayan sinir ağı modeli aşağıda Şekil 4'teki gibi gösterilmektedir (Amidi ve Amidi, 2018):



Şekil 4. Yinelemeli Sinir Ağı Modeli²

Şekilde gösterilen harfler a : ağırlık vektörü, x : girdi, y : çıktı ve t : zaman olarak ifade edilir.

Başlangıç zaman aşamasından son zaman aşamasına kadar tüm zaman aşamaları için hesap edilmesi zorunlu olan bir $a^{<t>}$ değeri bulunmaktadır. Öncelikle $a^{<1>}$ değeri hesap edilmektedir. Bu değeri hesaplarken $x^{<1>}$ girdisi ve $a^{<0>}$ vektörünün değeri kullanılmaktadır. Yani, x 'in ilk değeri ile a 'nın sıfırıncı değeri kullanıldığında a 'nın ilk andaki değeri hesaplanmaktadır. a 'nın ilk andaki değerini bulmak demek y 'nin de birinci andaki tahmin değerini hesap etmek demektir. Daha sonra $a^{<2>}$ değeri için, $x^{<2>}$ girdisi ve $a^{<1>}$ vektörünün değeri kullanılmaktadır. Yani, x 'in ikinci değeri ile a 'nın birinci değeri kullanıldığında a 'nın ikinci andaki değeri hesap edilmektedir. a 'nın ikinci andaki değerini bulmak demek y 'nin de ikinci andaki tahmin değerini hesap etmek demektir. Bu işlem süreci son zaman aşamasına gelene kadar bütün zaman aşamaları için tekrarlanmaktadır. Tekrarlanan bu işlem ileri yayılım algoritmasını ifade etmektedir (Kızrak, 2018).

² **Kaynak:** Amidi ve Amidi 2018


4.2. Geri Yayılım Algoritması

Geri yayılma, ağırlıkları güncel hale getirmek amacıyla ağ içerisinde bulunan gradyanları hesap etme işlemi olarak tanımlanmaktadır. Ağ içerisinde katman katman gidilmesine imkân sağlamaktadır. Böylelikle girdi katmanlarına ve ağırlıklara bağlı olarak gradyanların hesap işlemi yapılmaktadır. Bu işlemin yapılması, ağdaki kaybın hesaplanan çıktı değerinden itibaren başlanması ve akabinde çıktı değerinden bir evvelki katman için gradyanların hesaplanabileceğini belirtmektedir (Borges, 2018).

Ağdaki girişe bir sabit ilave ederek etkinleştirme görevini farklı hale getirmeyi mümkün kılan sapma(bias) sapma ve ağırlıkların ayarlamalarını yapan geri yayılım algoritması, hatayı azaltmayı amaçlamaktadır (Roondiwala vd., 2017, s.1755).

Geriye yayılım, belleği olan bir sinir ağının performansını en iyi seviyeye çıkaracak şekilde optimize yaparken gerekli olan türevlerin hesaplanmasına olanak sağlamaktadır (Werbos, 1990, s. 1550).

Bir yinelemeli sinir ağında geri yayılım algoritmasının mimarisi Şekil 5'te gösterilmiştir (Maklin 2019). (input layer: girdi katmanı, hidden layers: gizli katmanlar, output layer: çıktı katmanı, recurrent neural network: yinelemeli sinir ağını ifade etmektedir.)



Şekil 5. Yinelemeli Sinir Ağı Topolojisi³

Geriye yayılım yukarıda da görüldüğü gibi her bir katmanı birbiri ile bağlantılı üç farklı katmana sahiptir. Bunlar, girdileri bir sonraki katmana taşıyan girdi katmanı, bir veya birden daha fazla gizli katman ve en sonda bulunan çıktı katmanıdır (Torkul, O. vd., 2017, s.161).

Gradyanın hesap edilmesi, analitik açıdan basit olmasına rağmen sayısal açıdan hesaplama oldukça maliyetli olabilir. Bu algoritma aracılığıyla bu maliyet en aza indirilmiş ve kolay hale gelmiştir. Hesaplama işlemi maliyetten geriye yani sol yönüne doğru bilgiler oluşturularak yapılmaktadır. Kısaca, geri yayılım, gradyan hesap etmek için kullanılan yöntem olarak ifade edilmektedir (Goodfellow vd., 2018, s.174).

Geri yayılım kullanabilmek için kayıp, yitim (lost) değerinin nasıl hesap edildiğinin de bilinmesi gerekmektedir. Yitim değeri, tahmin değeri ile modelde olan gerçek değerler arasındaki uzaklıktır. Yani, aralarındaki fark alınarak yitim değeri hesabı yapılmaktadır. İleri yayılımda olduğu gibi bu algoritmada da başlangıç zamanından son zaman aşamasına kadar tüm zaman aşamaları için hesap edilmesi zorunlu olan bir $a^{<t>}$ değeri bulunmaktadır. Hesaplama işlemi ileri yayılımdaki süreç ile aynıdır, son adım uygulandıktan sonra geriye yayılım algoritması başlatılmaktadır (Kızrak, 2018).

³ **Kaynak:** Maklin 2019

Geri yayılım algoritmasının öğrenim sürecinde, ağı sunulan veriler girdi katmanı ve gizli katmanında işlenerek çıktılarının hesabı yapılmaktadır. Hesaplanan çıktılar gerçek değerler ile kıyaslanmaktadır. Çıktılardaki hata, ağıdaki bağıntılarına geri yayılmaktadır (Torkul, O. vd., 2017, s.161).

Öğrenme sürecinde, geriye doğru türev alınarak yeni ağırlıklar elde edilmektedir. Daha sonra elde edilen bu ağırlıklar yeniden ileri besleme yapılarak süreç sürdürülmektedir.

5. DERİN ÖĞRENME MODELLERİ


Hızlı bilgisayar işlemcilerinin piyasaya sürülmesi, bilgisayarlara erişimin daha kolay olması, farklı ve karmaşık verilerin meydana gelmesi derin öğrenme yöntemlerini daha çok kullanılır hale getirmiştir. Örneğin, herhangi bir üretim biriminin gerçek zamanlı bir veri analizi yaparken derin öğrenme metotlarını kullanması giderek artmaktadır. Bunlara ek olarak derin öğrenme çok katmanlı yapay sinir ağı sayesinde görüntü, ses ve metin gibi verileri sınıflandırma analizinde de kullanılmaktadır ve bu analizler için modeller geliştirilmiştir.

Çok katmanlı algılayıcılar veya ileri besleme sinir ağları, evrimsel sinir ağı ve yinelemeli sinir ağı olmak üzere üç ana derin model türü vardır.

5.1. İleri Besleme Sinir Ağları (Çok Katmanlı Algılayıcılar/MLP)

İleri besleme sinir ağları veya çok katmanlı algılayıcılar derin öğrenme modelleri olarak örnek verilebilir. Verilen bilginin akış şekline göre ileri besleme olarak tanımlanır. Çok katmanlı algılayıcıların amacı bir f^* fonksiyonunun bir sınıra doğru yaklaşmasını hesap etmektir. Mesela bir bölümleyici için x girdisi $y=f^*(x)$ şeklinde kullanılarak, y grubuna eş tutulur. Çok katmanlı algılayıcı, $y=f(x;\theta)$ eşitliğini ifade etmektedir, buna ek olarak θ değişkeninin değerini öğrenmektedir (Goodfellow vd. 2018:165).

Çok katmanlı algılayıcılar giriş katmanı, bir veya birden daha fazla gizli katman ve çıktı katmanından oluşmaktadır. Her bir katmanda seri olarak nöronu yani işlem birimi vardır. Nöronlar kendinden sonra gelen katmandaki nöronla etkin bir biçimde ilişkilidir (Messikh vd., 2017, s. 3484).



Şekil 6. Çok Katmanlı Algılayıcılar

Yukarıdaki şema sadece bir gizli katmandan oluşan çok katmanlı algılayıcılara örnek olarak gösterilmiştir. Gizli katman veya katmanlardaki her katman vektörel değerlidir. Gizli katman veya katmanların uzunluğu modelin genişliğini verirken tüm katmanları kapsayan uzunluk kullanılan modelin derinliğini verir.

Gizli işlem birimleri sayesinde çok fazla evrensel bilgi ve istatistik oluşur. Karakteristik olarak bir katmanın girdisi, sadece önceki katmanın çıktısından oluşmaktadır (Haykin, 2009, s. 22).

Çok katmanlı algılayıcının mimarisi katman miktarının seçimine, her katmandaki düğümlerin adedine dayanmaktadır. Çok katmanlı algılayıcı ağı öğrenme yöntemi olarak örneklerle öğrenmek için planlanan ve makine öğrenmesinin alt dalı olan gözetimli öğrenmeyi kullanmaktadır.

Çok katmanlı algılayıcının meydana gelmesi yapay sinir ağlarıyla öğrenilemeyen doğrusal olmayan ilişkilere dayanır. Yapay sinir ağları yalnızca doğrusal olan problemlerin sonucuna ulaşmaktadır. Bu sebeple çok katmanlı algılayıcılar gelişmiştir (Öztemel, 2012, s. 19).

Çok katmanlı algılayıcı hata fonksiyonunu en aza indirmeyi hedefler ve bu doğrultuda eğitim algoritmalarıyla eğitilmesi gerekmektedir (Kaltch ve Berndtsson, 2007:309). Çok katmanlı algılayıcılar öğrenme tekniği olarak genelleştirilmiş delta kuralını kullanmaktadır (Öztemel, 2012, s. 19). Çok katmanlı algılayıcının kullandığı

delta kuralı tüm değişkenlere ait noktalara en yakın geçecek olan doğrunun belirlenmesini sağlayan en küçük kareler yöntemine dayanır (Kabalıcı, 2015, s. 49)

Sinir ağlarında en iyi ağı elde etmek için veriler eğitim ve test verileri olarak ayrılmaktadır. Genellikle eğitim süreci için verinin %70'i kullanılır ve geri kalan %30'u test için kullanılır (Amrin ve Satriadi, 2018, s. 608)

Modellerin seçimi, katmanların ağı gönderilmesi, katmanların değerleri, ağırlıkların belirlenmesi, öğrenme değerlerinin tespit edilmesi, modellerin ağı gönderilmesi, ağırlıkları işleme süreçleri, katmanların bilgi sayılarının artmasıyla sistemin büyütülmesi, sonlandırma ölçütünün belirli duruma getirilmesi, katmanların artırılması ve azaltılması çok katmanlı algılayıcıların modelleri en iyi şekilde öğrenmesine etki eden etkenlerdir. Çok katmanlı algılayıcı geliştiricilerinin bu etkenleri en iyi şekilde belirlemesi gerekir ve sorunun elde edilecek sonucu için elverişli yaklaşımı kullanmalıdır (Öztemel, 2012, s. 20).

5.2. Evrişimsel Sinir Ağı (CNN)

Görüntü sınıflandırma, nesne tanıma için kullanılan derin öğrenme modelidir. Evrişim olarak tanımlanan modelin öğrenilen kısmıdır. Filtreler, özellikler evrişim bölümünde sınıflandırma yapılmaktadır.

Evrişimsel sinir ağı mimarisi evrişim katmanları, havuzlama (biriktirme) katmanları ve tam bağlantılı katmanlar olmak üzere çeşitli katmanlardan oluşmaktadır. Bir veya daha fazla tam bağlı katmana ulaşan birkaç evrişim katmanı ve bir biriktirme katmanı yığınının yinelenmesinden meydana gelmektedir (Rikiya vd., 2018, s.612).

Evrişimsel sinir ağı mimarisini oluşturmakta olan katmanlar Şekil 7'de gösterilmiştir (Üzen ve Hanbay, 2020, s.607):



Şekil 7. Evrişimsel Sinir Ağı⁴

Evrişimsel ağın mimarisinde evrişimin ilk değişkeni girdi, sonraki değişkeni kernel olarak tanımlanmaktadır. Son kısım olan çıktı katmanına özellik grafiği de denmektedir (Goodfellow vd., 2018, s.333).

Evrişimsel sinir ağlarında derinlik ve genişlikleri yoluyla kapasitesi belirlenen matematiksel işlem uygulanmaktadır (Krizhevsky vd., 2017, s.85).

Evrişimsel sinir ağı verileri tek boyutlu olan zaman serisi verilerinden veya çift boyutlu olan resimlerden meydana gelmektedir. Evrişimsel sinir ağı verilerini kullanarak çıktı hesabı yapabilmek için evrişim katmanındaki nöronlardan yararlanılmaktadır. Havuzlama katmanı olarak adlandırılan katman eğer yüksek boyutta görüntüler olursa, parametre miktarını düşürmekle görevlendirilmiştir. Tam bağlı katman ise, bir önceki katmandaki bütün nöronlarla tam bağlıdır ve buna ek olarak bölümlene sonucunun hesap işleminin yapıldığı katman olarak ifade edilebilir. Gizli katman aktivasyon işlevi olan ReLu (doğrultulmuş doğrusal birim) fonksiyonu, evrişim sinir ağlarında en sık tercih edilen işlevlerdendir. İyi bir tahmin edici olan ReLu, doğrusal birimler ile çok yakından ilişkili olmaları sebebiyle optimal hale gelmesi basittir. Evrişimsel sinir ağı mimarisinde relu fonksiyonu ve havuzlama katmanlarındaki parametrelere durağan fonksiyon ile eğitim verilmektedir. Fakat evrişim ve tam bağlı katmanlardaki parametrelere, eğimli iniş fonksiyonu uygulanmaktadır (Yılmaz ve Kaya, 2019, s. 33).

Evrişimsel sinir ağlarının etkisi derin öğrenme mimarisinde oldukça önemlidir. Birçok konudaki pratikleri başarılı bir şekilde uygulayan ilk sinir ağlarındandır. Sinir ağlarının gelişiminde etkin rol oynamıştır. Yüksek ölçekli veriler için sinir ağlarının özelleşmesini sağlamıştır. Çift boyutlu görüntü topolojisinde evrişimsel sinir ağı

⁴ **Kaynak:** Üzen ve Hanbay (2020)


mimarisi diğer yaklaşımlar ile kıyaslandığında performansı en iyi olandır. Tek boyutlu birbirini izleyen veriler için yinelemeli sinir ağı geliştirilmiştir (Goodfellow vd., 2018, s. 371).

5.3. Yinelemeli Sinir Ağı (RNN)

İnsanların geçmişte edindiği bilgileri, tecrübeleri hatırlaması önemlidir. Bunun sebebi, yeni karşılaştıkları olaylar veya durumlar karşısında bu geçmişteki bilgilerden faydalanırlar. Karşılaştıkları olaylar veya durumlara önceki bildiklerini ilave ederek devam ederler. Örneğin, bir sürücü ulaşacağı yere giderken kullandığı yolda yol çalışması ile karşılaştıysa daha sonraki gidişinde bir süreliğine o yolu kullanmayıp güzergahı değiştirir. Bunu da bir önceki edindiği bilgi sayesinde yapmaktadır. Yinelemeli sinir ağı, aynı insan beyninin hatırladığı gibi geçmiş bilgilerini hatırlar. Hatırladığı bilgileri yeni bilgiler ile ilişkilendirir.

Yinelemeli sinir ağı, zamana bağlı olarak değişen sıralı modellerdir. Zamana bağlı olarak değişen konuşma tanıma, doğal dil işleme, duygu sınıflandırma gibi alanlarda sıklıkla kullanılmaktadır. Örneğin, Apple Siri ve Google ses aramada bir kişinin sesini tanımlayıp devreye girme özelliği yinelemeli sinir ağılarına dayanmaktadır. Tıpkı insanların sahip olduğu hafıza gibi bir belleği vardır. Bu bellek sayesinde yaygın olarak zaman serileri, finansal veriler, video tanımlama, ses tanıma, hava durumu öngörüsü gibi daha birçok sekans verilerde öngörü ve sınıflandırma yapmak için kullanılmaktadır. Bir bellek desteğiyle geçmiş verileri kullanarak geleceğe yönelik öngörü yapabilmesi yönüyle yapay sinir ağı ve evrimsel sinir ağlarından farklılık göstermektedir. Çünkü yapay sinir ağı ve CNN’de hafıza mantığı yoktur. Bu sebeple diğer algoritmalara kıyasla daha etkili sonuçlar vermektedir (Datai Team, 2020).

Yinelemeli sinir ağının yapısı aşağıdaki Şekil 8’de gösterilmiştir (Feng vd., 2017, s. 682):



Şekil 8. Yinelemeli Sinir Ağının Açılımı⁵

Yinelemeli sinir ağları şekilde de görüldüğü gibi üç katmanın bir araya gelmesiyle oluşmaktadır. Bu katmanlar: girdi katmanı, gizli katman ve çıktı katmanıdır.

x: girdi

h: gizli katman

o: çıktı

w: ağırlık vektörü

Unfold ile, soldaki yinelemeli sinir ağının açılımı gösterilmiştir. Açılım olarak bahsedilen, tüm seri için ağın aynı katman yapısının yineleniştir (Bawa, 2017).

Ağın döngü açılımı, standart bir yinelemeli sinir ağının aynı yapı içerisinde birden daha fazla kopyalanması ve her kopyalanmanın h (gizli katman) durumuna bir önceki için girdi olarak tanımlanmasıdır. Çıktı şu şekilde hesap edilmektedir:

$$a^{(t)} = b_1 + Wh^{(t-1)} + Ux^{(t)}$$

$$h^{(t)} = o(a^{(t)})$$

$$o^{(t)} = b_2 + Vh^{(t)},$$


Burada b_1 ve b_2 sapma (bias) vektörlerini, U, girdi-gizli bağlantı ağırlık matrisini, V gizli-çıktı bağlantı ağırlık matrisini ve W ise gizli-gizli bağlantı ağırlık

⁵ **Kaynak:** Feng vd. 2017

matrisini ifade etmektedir. Genellikle, aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır (Feng, 2017, s. 682).

Yinelemeli sinir ağlarında döngüler, bir zaman dilimi için önceki girdi bilgilerinin kalmasını mümkün kılmaktadır. Bu, geçmişte tanımlanmış olmasına bağlı değildir, ağırlıklarına ve girdi bilgilerine dayanmaktadır (Bengio, 1994, s. 158).

Yinelemeli sinir ağları için aşağıda çeşitli örnekler verilmiştir. Bu örneklerde her bir dikdörtgen vektöre karşılık gelirken dikdörtgenlerin ardından gelen oklar işlemlere karşılık gelmektedir. Giriş vektörlerinin rengi kırmızı, tekrarlayan sinir ağlarının durumunu barındıran renk yeşil ve çıkıştaki vektörlerin rengi ise mavi ile gösterilmiştir.



Şekil 9. Yinelemeli Sinir Ağı Modelleri⁶

One to one, bir tane sabit büyüklüklü girdi katmanı ile bir tane sabit büyüklüklü çıktı katmanının bulunduğu modeli ifade etmektedir. Görüntü sınıflandırma bu modele dayanmaktadır (Karpathy, 2015).

Modelin mantığı basit olarak, örneğin başlangıç 1 olsun, 1 anında bir giriş bulunur ve meydana gelen çıkış da bu 1 anı ile ilgili bir çıkıştır. Yani, yeni veya eski bir an bulunmamaktadır (Kızrak, 2018).

One to many, bir girdi, birden fazla katman ve çıktı ile elde edilmektedir. Bu model ile yazılı bir görüntü işlenerek bu yazılardan sözcükler alınabilir.

⁶ **Kaynak:** Karpathy 2015

Girişin bir ana sahip olup, çıkışlarda o an ve sonraki anlar ile ilgili birden çok doğru değerler üretme işlemine “one to many” denmektedir. Mesela, bir bilgi mevcutken çok fazla notadan meydana gelen bir dizi oluşturulduğu için örnek olarak müzik üretme verilebilir (Kızrak, 2018).

Many to one, birden fazla girdi ve katmandan oluşan fakat çıktı sayısı tek olan bir başka modeldir. Örnek olarak duygu analizi verilebilir. Çünkü, bir konu hakkındaki görüşleri olumlu veya olumsuz olarak tanımlamak için bu model kullanılmaktadır.

Many to many, şekildeki gibi üç giriş katmanı, üç veya daha fazla ara katmanı ve üç çıkış katmanından elde edilen modeldir. Bu modeller makine çevirisi gibi çalışmalarda kullanılmaktadır (Kızrak, 2018).

Günümüzde verileri kullanarak gelecek ile ilgili öngörü ve sınıflandırma yapmak oldukça önem kazanmış ve kayda değer biçimde yaygınlaşmıştır. İnsanlar öngörü ve sınıflandırma yaparak edindikleri bilgiler ile doğru yorumlar yapabilmiş ve böylece mantıklı kararlar verebilmişlerdir.

Kısa dönem bellekleri sayesinde bir önceki düğümde olanları hatırlarlar ve hatırladıkları bilgiyi yeni öğrendikleri bilgilerin üstlerine koyarlar. Geçmiş bilgilerden yararlanarak gelecek için öngörü yapmak çeşitli çalışma alanlarında oldukça yaygın hale gelmiştir (Datai Team, 2020).

Özellikle sıralı bir dizi olarak tanımlanan zaman serilerinde sıklıkla kullanılmaktadır. Mesela hisse senedi fiyatlarının açılış-kapanış değerlerini öngörü yaparken tekrarlayan sinir ağlarını kullanmak verilerde çok daha faydalı bilgiler verir. Finansal verilerde bir uzun öğrenme süresince düğüm taşıyan hücrelerin olması zaman serisi verilerinde oldukça etkili olabilir. Bu serilerin birbirini izlemesi, hesaplama yaparken birbirleriyle bağlantılı olması önemlidir örneğin yarının kapanış fiyatını öngörü yaparken bugünün kapanış fiyatını kullanmak, 30 günün, 60 günün veya 90 günün kapanış fiyatını kullanmaktan daha fazla etkili olmuştur. Bu yüzden sıralı bir dizi olması gerekmektedir (Moroney, 2019).

5.3.1. Gradyanların Kaybolması

Sinir ağında ileri yayılım sırasında toplama ve çarpma işlemleri yapılırken, geriye yayılımda yapılmamaktadır. Bunun yerine türev işlemleri yapılmaktadır. Türev

işlemleri yapılırken türevin sıfır çıkma durumları bulunmaktadır. Eğer aktivasyon fonksiyonunun türevi sıfır olursa öğrenme olmamaktadır. Türevler ile ağırlıklar güncellendiği için ağırlıklar sıfır olduğunda bilgi kaybedilmektedir. Dolayısıyla gerçek ve faydalı çözümler bulunamamaktadır. Bu durum gradyanların kaybolması (vanishing gradients) olarak tanımlanmaktadır.

Yinelemeli sinir ağlarında gradyanların kaybolması sorununun çözüm yolu olarak “uzun kısa süreli bellek” ve “geçitli tekrarlayan birim modelleri” geliştirilmiştir.


5.3.2. Uzun Kısa Süreli Bellek (LSTM)

Yinelemeli sinir ağlarında oluşan sorunlara RNN tek başına çözüm değildir. Oluşan sorunlardan biri yinelemeli sinir ağlarında algoritma yakın geçmişi hatırlarken uzak geçmişi hatırlamamaktadır. Çünkü, RNN kendinden önce gelen kısa belleği hafızasında tutmaktadır. Bu yüzden, RNN’de büyük verilerle çalışmak doğru sonuç vermeyecektir çünkü yinelemeli sinir ağları fazla bilgiyi belleğinde saklayamamaktadır. Uzun bir hafızası bulunan LSTM, RNN’in tek başına yetemediği durumlar için geliştirilmiş özel bir öngörü yöntemidir. Uzun kısa süreli bellek olarak adlandırılan LSTM, hafızasında RNN’e göre daha çok bilgi tutabilmektedir. Meydana gelen bir başka problem ise katman sayısı arttıkça ileri yayılım sinir ağlarında ağırların eğitilememesi sonucu oluşan gradyan yok olması sorunudur. Bu sorun da bilgi kaybedilmemesi için çözülmesi gereken bir problemdir. LSTM, bu problemin de çözümü olmaktadır.

LSTM’nin hücre durumları ve kapılar olmak üzere başrolde oynayan iki tane etkili parametresi vardır. Bu parametrelerden kapı, hücre durumuna bilginin eklenip veya eklenmeyeceğini tanımlayarak bir istek üzerine bilgiyi taşımaktadır (Cura, 2019).

Kapılarda olan bu süreç boyunca LSTM, hücreden, geçmiş gizli durumundan ve girdi durumundan bilgiyi başarılı bir şekilde ilettiği için gradyanların kayıp olmasını önlemektedir. Klasik biçimde olan RNN ve LSTM birbiri ile karşılaştırıldığında gizli katman ile ayrılmaktadır (Yeon, 2019, ss. 715-716).

LSTM ağının diyagramı aşağıda basit bir şekilde gösterilmiştir (Oualil, 2016, s. 1476):



Şekil 10. LSTM Diyagramı⁷

Yukarıdaki diyagramdaki semboller:

X: Okların bir araya gelip gelmeyeceğini gösterir.

+: Bilgilerin toplanmasını ifade eder.

σ : 0 veya 1 değerlerini alan sigmoid katmanıdır.

f : Hiperbolik fonksiyondur.

H_{t-1} : Önceki katmandaki çıktı değerlerini ifade eder.

X_t : Girdi değerleridir.

H_t : Çıktı değerleridir.

C_t : Güncellenmiş hafızadır.

C_{t-1} ile C_t arasındaki bağlantı hafızadır.


Diyagramda soldaki ilk sigmoid katmanından x 'e giden vektör, unutma kapısıdır. Girdi olarak X_t ve H_{t-1} 'i aldıktan sonra gelen bilginin hafızaya eklenip eklenmeyeceğine karar vermektedir. Ortadaki sigmoid ile x 'e bağlantı kuran vektör, girdi kapısıdır. Bu kapıda hangi bilginin hafızada saklanacağı veya saklanmayacağı belirlenmektedir. En sağdaki yani sonda bulunan sigmoid ile en sondaki x bağlantısı ise, çıktı kapısıdır. Çıktı kapısı, hangi bilginin çıktı olacağını veya olmayacağını belirlemektedir.

⁷ **Kaynak:** Oualil (2016)

5.3.2.1. LSTM'in Çalışma Mantığı

Uzun ve kısa vadeli belleği bulunan LSTM'de yukarıda bahsedilen üç kapının olmasının sebebi, LSTM'in hücreye inceleme yapması ve onu muhafaza etmesidir. Bu kapıların çalışması sırasıyla şu şekildedir (Olah, 2015):

İlk olarak, hücreden nelerin geleceğini belirlemektir. Böylece bilgiler eklenecek olanlar ve unutulacak olanlar olarak ayrılacaktır. Hangi bilgilerin ayrılacağına ve hangi verilerin ekleneceğine sigmoid katmanı (σ) karar vermektedir. Sigmoid katmanı bu kararı ilk etapta X_t ve h_{t-1} 'i kullanıp C_{t-1} çıktısını inceleyerek alır. Eğer çıktı sonucu 0 ise bilgiler unutulmaktadır. Eğer çıktı sonucu 1 ise bilgiler eklenmektedir.




Şekil 11. LSTM 1.Adımı⁸

$$f_t = \sigma(W_f \cdot [\square_{t-1}, X_t] + b_f)$$

İkinci olarak, sigmoid güncel olacak bilgileri tespit etmektedir. Ardından, tanh fonksiyonu katmanı tarafından C_t (yeni aday bilgilerin vektörü) meydana gelmektedir. Böylece, yeni bilgilerin eklenip eklenmeyeceği tespit edilecektir.

⁸ Kaynak: Olah (2015).




Şekil 12. LSTM 2.Adımı⁹

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

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

Bir sonraki etapta önceden unutilan bilgiler unutulurken, önceki durum f_t ile çarpılmaktadır. Bu çarpıma i_t ve $\tilde{C}_t$ 'nin çarpımı eklenir. Böylece, hücrenin hangi ölçüde güncel olacağı tanımlanan yeni aday bilgiler belirlenmektedir.




Şekil 13. LSTM 3.Adımı

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

En son aşamaya gelindiğinde, hücreye bağlı bir şekilde filtrelenmiş bir çıktı belirlenmektedir. Bu sebeple hücredeki çıktı olacakların tanımlanması için sigmoid katmanı çalıştırılmaktadır. Ardından tanh fonksiyonu aracılığıyla hücre işleme

⁹ Kaynak: Olah (2015).

girmektedir. Nihai olarak, sadece tanımlanan kısmın çıktısı olması amacıyla sigmoid katmanının çıktısı ile çarpılmaktadır.



Şekil 14. LSTM 4.Adımı¹⁰

$$O_t = \sigma(W_t[h_{t-1}, X_t] + b_o)$$

$$h_t = O_t * \tanh(C_t)$$

5.3.2.2. LSTM'in Özellikleri

LSTM'in diğer algoritmalarla kıyaslandığında bazı avantajları mevcuttur (Hochreiter, 1997, s. 1767).


- Uzun kısa süreli bellek, hücrelerdeki devamlı hata geri yayılımına köprü olma kabiliyetiyle çözüm olmuştur.
- Uzun dönem gecikmelerde gürültüyü yok etmektedir.
- Sınırsız hücre sayısını ele alabilmektedir.
- İki veya daha fazla ayrılan durumları birbirinden ayırt etmeyi hızlı bir şekilde öğrenmektedir.
- Öğrenme oranı, giriş kapısı ve çıkış kapısı sapması gibi parametrelerin geniş aralığında çok iyi çalışmaktadır.

5.3.3. Geçitli Tekrarlayan Birim (GRU)

Gradyanların yok olması problemine karşı Cho ve arkadaşları tarafından 2014 yılında önerilmiştir. Bilgi akışının düzenini sağlamak amacıyla geçitleri

¹⁰ **Kaynak:** Olah (2015).

bulunmaktadır. Bu geçitler seride verilerin kalmasını ya da çıkarılmasını sağlamaktadır. Serideki verilerden öngörü yapmak amacıyla önemli verilerin kalması ve ilgisiz verilerin unutulmasını öğrenebilirler. Tekrarlayan sinir ağlarının yeni bir nesli olan GRU, çalışma mantığı olarak LSTM'ye benzemektedir. GRU'nun LSTM'den farkı, hücre durumundan kopması ve gizli durumu uygulamasıdır. Sıfırlama ve güncelleme kapısı olarak iki geçide sahiptir. Sıfırlama geçidi, eski bilginin ne boyutta unutulacağını belirlemek amacıyla kullanılmaktadır. Güncelleme geçidi ise bilgilerden hangisinin çıkarılacağına ve yeni bilgilerden hangisinin ekleneceğini belirlemektedir (Phi, 2018).



Şekil 15. GRU Diyagramı

Şekil 15'te reset gate, sıfırlama kapısını ifade ederken update gate ise güncelleme kapısını göstermektedir.

6. MODEL PERFORMANS ÖLÇÜTLERİ

Literatürde modeller arasında en iyi modeli seçmek için performans ölçümleri olarak kullanılan istatistikler vardır. Bunlardan genellikle kullanılanlar, hata kareler ortalaması (MSE), hataların mutlak yüzde ortalaması (MAPE), hataların mutlak ortalaması (MAE), hata kareler ortalamasının kökü (RMSE) dür. Modelin iyi olması bu istatistiklerin sıfıra yakın olmasına bağlıdır (Mert ve Çağlar, 2019, s. 39).

MSE, MAPE, RMSE, R^2 ve MAE formülleri sırasıyla şu şekildedir (Özşahin ve Singer, 2019, ss. 1769-1770):

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2 \quad (6.1)$$

$$MAPE = \frac{1}{N} \left(\sum \left[\frac{t_i - td_i}{t_i} \right] * 100 \right) \quad (6.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \quad (6.3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (t_i - td_i)^2}{\sum_{i=1}^N (t_i - t)^2} \quad (6.4)$$

$$MAE = \frac{\sum_{i=1}^N |y_i - x_i|}{N} \quad (6.5)$$

Bu çalışmada performans ölçütleri olarak MSE, MAPE, RMSE, R^2 ve MAE kullanılmıştır.

2. BÖLÜM

ARAŞTIRMANIN ANALİZİ

1. ARAŞTIRMANIN ANALİZİ

Bu bölümde araştırma analizini oluşturan araştırmanın amacından, öneminden, evreni ile örneklemeinden ve kullanılan yöntemden kapsamlı olarak bahsedilmektedir.

1.1. Araştırmanın Amacı

Bu tez çalışmasının amacı, Yinelemeli Sinir Ağları (RNN), geliştirilmiş öngörü yöntemi olan Uzun-Kısa Dönem Bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) modellerinin karşılaştırmasını yaparak literatüre katkıda bulunmaktır. Zaman serilerinde geçmiş bilgilerden yararlanarak gelecek ile ilgili öngörü yaparken GRU'nun LSTM ve RNN'e göre daha iyi sonuçlar verdiğini ortaya koyarak literatüre destek olacağı düşünülmektedir.

1.2. Araştırmanın Önemi

İnsanlarda geçmişten beri ellerinde bulunan para ile yatırım yaparak kısa veya uzun dönemde kar elde etme isteği olmuştur. Bu istek ile borsaya merak uyanmış ve borsada yatırım yapmanın bir çeşidi olan hisse senetlerine olan ilgi de giderek artmıştır. Başarılı bir yatırımcı olmak hayli zordur. Çoğu insan aldıkları hisseler ile kar elde etmek istese de ne yazık ki zarara da uğrama ihtimalleri vardır. Bunun için hisseler alınmadan önce o hisseyle ilgili önceki bilgilerinden yararlanarak riskler ölçülmeli ve gereken analizler yapılmalıdır. Böylelikle kar elde etme ihtimali daha yüksek veya zarara uğrama ihtimali daha az olacaktır. Bu sebeple borsa öngörüsünde kullanılmak üzere pek çok analiz geliştirilmiştir.

Geliştirilen analizlerden biri olan yapay sinir ağları da yıllar içerisinde teknolojiye ayak uydurmuştur ve uydurmaya da devam edecektir. Son zamanlarda temeli yapay sinir ağları ile meydana gelen derin öğrenme yöntemlerinin kullanımı giderek artmaktadır. Bu çalışmada derin öğrenmede kullanılan öngörü yapma yöntemlerinden yinelemeli sinir ağları ile yapılan öngörüler tespit edilmiş olup,

yinelemeli sinir ağlarının kısa dönem bilgiyi iyi bir şekilde hafızada tutarken uzun dönem bilgiyi hafızasında tutamadığı gözlemlenmiştir. Bunun için uzun dönemde yapılan sonuçların çok doğru olmadığı gözlemlenmiştir. Bu sebeple yinelemeli sinir ağlarına alternatif olarak geliştirilen öngörü yöntemi olan uzun kısa dönem bellek kullanılmıştır. Bu çalışma, uzun kısa dönem belleğin hafızasında kısa veya uzun farkı olmadan bilgiyi tuttuğunu ve yinelemeli sinir ağlarına göre daha iyi sonuçlar verdiğini yapılan uygulama sonucunda belirttiği için önemlidir. Bunun sebebi yapılan öngörüler ile yatırımcıların hisse senedi seçmeden önce kar elde etme ihtimalinin yüksek, hiç veya daha az zarara uğrayacak şekilde seçmesine yardımcı olacağının düşünülmesidir.

1.3. Araştırmanın Evreni ve Örneklemi

Türk hisse senetlerinin yer aldığı BİST Metal Harici Mineral Ürünleri'nin içinde bulunan Göltaş Göller Bölgesi Çimento Sanayi ve Ticaret A.Ş. (GOLTS)'nin hisse senetleri kapanış değerleri bu çalışmanın araştırma evrenini oluşturmaktadır.

Çalışmanın örnekleme ise, 02.01.2012 ve 31.12.2020 yılları arasındaki “Göltaş Çimento” şirketinin hisse senetlerinin günlük kapanış değerlerini kapsamaktadır. Veri sayısı 1939'dur

1.4. Araştırmanın Yöntemi

Bu tez çalışmasının araştırmasında 1991'da Guido Von Rossum tarafından geliştirilen, Python bilimsel programlama dili kullanılmıştır. Uygulama için kullanılan Python'da, zaman serilerinin geliştirilmesinde etkili derin öğrenme kütüphanelerinden biri olan Keras ve sayısal analizlerde gelişmesi amacıyla kamu tarafından da değiştirilebilir kodlu olan, bilgilerin diyagramlara dönüşmesini sağlayan derin öğrenme programı Tensorflow'dan yararlanılmıştır. Bunların kullanımı için gerekli ortam Jupiter Not Defteri tarafından sağlanmıştır. Derin öğrenme yöntemleri olan yinelemeli sinir ağları, uzun kısa dönem bellek ve geçitli tekrarlayan modeller kullanılmıştır.

1.5. Araştırmanın Uygulaması

Bu bölümde araştırmanın uygulama kısmı kapsamlı bir şekilde ele alınmıştır. Öncelikle serinin yapısında anlamlı bir kırılma olup olmadığını test etmek amacıyla birim kök testleri uygulanmış ardından derin öğrenme yöntemleri ile öngörü değerleri elde edilmiş ve ardından sonuçlar karşılaştırılmıştır.

1.5.1. Uygulanan Birim Kök Testleri

Bu çalışmada serinin durağan olup olmadığı Augmented Dickey Fuller (ADF) Testi ile incelenmiştir. Yapısal kırılmanın durağanlık üzerindeki etkisi Perron (1989) tek kırılmalı birim kök testi ile Zivot ve Andrews (1992) tek kırılmalı birim kök testi ile belirlenmiştir.

1.5.1.1 Augmented Dickey Fuller Testi

H_0 : Seri birim kök içermektedir.

H_a : Seri birim kök içermemektedir.

Tablo 2. ADF Test Sonuçları

Sabitli Model					
Test İstatistiği	Kritik değerler			SIC	P(Olasılık)
	%1	%5	%10		
-1.526672	-3.43	-2.86	-2.57	0	0.52
Sabitli ve Trendli Model					
Test İstatistiği	Kritik Değerler			SIC	P(Olasılık)
	%1	%5	%10		
-2.139385	-3.96	-3.41	-3.13	0	0.52

Tablo 3. Serinin Birinci Farkı İçin ADF Test Sonuçları

Sabitli Model					
Test İstatistiği	Kritik değerler			SIC	P(Olasılık)
	%1	%5	%10		
-1.526672	-3.43	-2.86	-2.57	0	0.00
Sabitli ve Trendli Model					
Test İstatistiği	Kritik Değerler			SIC	P(Olasılık)
	%1	%5	%10		
-2.139385	-3.96	-3.41	-3.13	0	0.00

Seriye yapılan ADF testinde sabitli model test istatistiği-1.526672 olarak hesaplanmıştır. %1, %5 ve %10 için kritik değerler sırasıyla-3.43,-2.86 ve-2.57 olarak bulunmuştur. Sabitli modelin test istatistiği tüm kritik değerlerden küçük olduğu için yokluk hipotezi reddedilir.

Serinin birinci farkı için yapılan ADF testinde hem sabitli hem de trendli model test istatistiği-2.139385 olarak bulunmuştur. %1, %5 ve %10 için kritik değerler sırasıyla-3.96,-3.41 ve-3.13'tür. Bu sonuçlara göre test istatistiğinin tüm kritik değerlerden küçük olduğu tespit edilmiştir. Dolayısıyla yokluk hipotezi reddedilmektedir.

Serinin birinci farkı alındığında durağan bir seri olduğu hem sabitli modelde hem de sabitli ve trendli modelde gözlemlenmiştir.

1.5.1.2 Perron (1989) Tek Kırılmalı Birim Kök Testi

Ho: Seri birim kök içermektedir.

Ha: Seri birim kök içermemektedir.

Tablo 4. Perron (1989) Tek Kırılmalı Birim Kök Testi Sonuçları

	Model
Test istatistiği	-5.486423
Seçilen Kırılma Tarihi	21/11/2016
Kritik Değerler (%1)	-4.32
Kritik Değerler (%5)	-3.75
Kritik Değerler (%10)	-3.45
P (Olasılık)	0.01
Gecikme Uzunluğu (SIC)	0

Yukarıdaki Perron (1989) birim kök testi sonucuna göre test istatistiği -5.486423 olarak hesaplanmıştır. Bu değer %1 anlamlılık düzeyi için kritik değer ile karşılaştırıldığında $-5.486423 < -4.323972$ olduğundan yokluk hipotezi reddedilir. Serinin 0.01 yanılma düzeyinde durağan olduğu gözlemlenmiştir.

Perron (1989) tek kırılmalı birim kök testi, sıradan bir ADF testinin durağan dışı bulduğu seriyi durağan olarak bulmuştur. 21/11/2016 tarihinde serinin ortalamasında anlamlı bir kırılmanın olduğu tespit edilmiştir.

1.5.1.3. Zivot ve Andrews (1992) Tek Kırılmalı Birim Kök Testi

Model A

Ho: Seri düzeyde yapısal kırılmalı birim kök içerir.

Ha: Seri düzeyde yapısal kırılmalı birim kök içermez.


Model B

Ho: Seri hem düzeyde hem de trendde yapısal kırılmalı birim kök içerir.


Ha: Seri hem düzeyde hem de trendde yapısal kırılmalı birim kök içermez.

Tablo 5. Zivot ve Andrews (1992) Birim Kök Testi Sonuçları

	Model A (Düzeyde Kırılma)	Model B (Düzeyde ve Trendde)
Test istatistiği	-5.732982	-5.815711
Seçilen Kırılma Tarihi	23/11/2016	23/11/2016
Kritik Değerler (%1)	-5.34	-5.57
Kritik Değerler (%5)	-4.43	-5.08
Kritik Değerler (%10)	-4.58	-4.82
P (Olasılık)	0.00	0.00
Gecikme Uzunluğu (SIC)	1	1



Şekil 16. Zivot ve Andrews (1992) Birim Kök Testi Kırılma Zamanları-Model A




Şekil 17. Zivot ve Andrews (1992) Birim Kök Testi Kırılma Zamanları-Model B

Model A’da kırılma zamanı 23/11/2016 olarak bulunmuştur. 23/11/2016 tarihi için test istatistiği minimum düzeydedir. Zivot ve Andrews test istatistiği-5.732982 olarak hesap edilmiştir. Hesap edilen bu istatistik %1, %5 ve %10 için kritik değer ile kıyaslandığında kritik değerlerden küçüktür. Model A için verilen yokluk hipotezi .01, .05 ve .10 yanılma ile reddedilir. Seriyi sıradan bir ADF testi durağan dışı bulurken, düzeyde yapısal kırılma dikkate alındığında serinin durağan olduğu gözlemlenmiştir. Dolayısıyla 23/11/2016 tarihinde bulunan düzeyde kırılmanın anlamlı bir yapısal kırılma olduğu söylenebilir.


Model B’de kırılma zamanı 23/11/2016 olarak bulunmuştur. 23/11/2016 tarihi için test istatistiği minimum düzeydedir. Zivot ve Andrews test istatistiği-5.815711 olarak hesaplanmıştır. Hesaplanan bu istatistik değeri %1, %5 ve %10 için kritik değerleri sırasıyla-5.57,-5.08 ve-4,82 olarak bulunmuştur. Zivot-Andrews test istatistik değeri kritik değerlerden küçük olduğu için Model B için verilen yokluk hipotezi .01, .05, .10 yanılma ile reddedilir. Sıradan bir ADF testi seriyi durağan dışı bulmasına rağmen seri düzeyde ve trendde yapısal kırılma dikkate alındığında durağan bulunmuştur. Bu sebeple 23/11/2016 tarihinde olan düzeyde ve trendde kırılmanın anlamlı bir yapısal kırılma olduğuna ulaşılabilir.

1.5.2. Araştırmada Kullanılan RNN-LSTM-GRU Modellerinin Öngörü Sonuçları


Göлтаş Çimento A.Ş. hisse senetlerinin 02.01.2012-31.12.2020 arası 1939 veriden oluşan günlük kapanış fiyatları grafiği aşağıdaki Şekil 18’de verilmiştir. Veriler %70’i eğitim %30’u test olmak üzere Şekil 19 ve Şekil 20’de verilmiştir.



Şekil 18. Göлтаş Çimento A.Ş. Verisi



Şekil 19. Eğitim İçin Kullanılan Veriler



Şekil 20. Test İçin Kullanılan Veriler

Veri seti toplam 1939 veriden oluşmaktadır. Bu verilerden eğitim için 1357 veri, test için 582 veri kullanılmıştır.

1.6. Araştırmanın Bulguları ve Yorumları

Araştırmada kullanılan modelin her bir katmanında 50 nöron bulunmaktadır. Epoch değeri 200 olarak belirlenmiştir. Model aktivasyon fonksiyonu olarak Relu seçilmiştir. Kayıp fonksiyonu için hata kareler ortalaması tanımlanmıştır. Modeldeki eğitim ve test sayısı %70 eğitim ve %30 test değeri olarak uygulanmıştır.

Tablo 6. RNN, LSTM ve GRU Modeli

RNN – LSTM – GRU	
KATMAN NÖRON SAYISI	50-50-50-50
EPOCH SAYISI	200
AKTİVASYON FONKSİYONU	Relu
KAYIP FONKSİYONU	MSE
EĞİTİM-TEST	%70-%30

Model belirlenirken, daha önce yapılan çalışmaların incelenmesi ile birlikte birçok farklı nöron sayısı, epoch değeri kombinasyonu denenmiştir. Modeli seçerken model performans ölçütleri dikkate alındığından ilk olarak en uygun olarak 50

değerlerinden oluşan dört katman oluşturuldu. Daha sonra, eğitimde en iyi başarımlarını 200 epoch değeri ile sağlandığından epoch 200 alındı. Aktivasyon fonksiyonunun Relu seçilmesinin sebebi, hesaplama yükünün diğer fonksiyonlara göre daha düşük olması, parametreleri diğer fonksiyonlara göre daha hızlı bir şekilde öğreniyor olması ve çok katmanlı ağlarda daha çok kullanılıyor olmasıdır. Kayıp fonksiyonu seçilirken zaman serilerinde uzaklığa dayalı bir fonksiyonun daha uygun olacağından hata kareler ortalaması seçilmiştir. Modeldeki eğitim ve test sayısı tanımlanırken derin öğrenme uygulamalarında genellikle uygulanan %70 eğitim ve %30 test değeri olarak tanımlanmıştır.

Model performans sonuçları aşağıdaki tabloda gösterilmiştir:

Tablo 7. RNN, LSTM ve GRU Model Performans Sonucu

	RNN	LSTM	GRU
MAE	2.363	0.412	0.076
RMSE	2.566	0.653	0.103
MSE	6.585	0.426	0.010
MAPE	0.17	0.02	0.02
R²	0.82	0.98	0.98

Modellerin performans sonucuna göre hataların mutlak ortalaması olan MAE, RNN’de 2.363, LSTM’de 0.412 ve GRU’da 0.076 olarak ölçülerek hataların ortalama büyüklüğünün GRU’da LSTM ve RNN’ye göre daha az çıktığını göstermektedir. Hata kareler ortalamasının kökü olan RMSE, gerçek değerler ve öngörü edilen değerler arasındaki mesafeyi RNN’de 2.566, LSTM’de 0.653 ve GRU’da 0.103 olarak ölçmüştür. Bu ölçüm, GRU’nun LSTM ve RNN’ye göre daha iyi öngörü performansı olduğunu belirtmektedir. Hataların mutlak yüzde ortalamasını temsil eden MAPE, RNN’de %17, GRU’da ve LSTM’de %2 sonucu ile modellerin iyi olduğunu göstermektedir. Belirlilik katsayısı olan R², kullanılan verilerin uyumunu RNN’de %82, LSTM’de ve GRU’da %98 olarak açıklamaktadır.

Aşağıda Göлтаş Çimento AŞ’ye ait hisse senetlerinin 30 günlük kapanış fiyatlarının öngörü sonuçları tablo ve grafik yardımıyla gösterilmiştir.


Tablo 8. 30 Gün Öngörünün Performans Sonuçları

	RNN	LSTM	GRU
MAE	11.25	0.05	0.02
RMSE	14.15	5.29	6.18
MAPE	0.19	0.06	0.07
Gün Sayısı	4	15	11

Tablo 8’de 30 gün için yapılan öngörünün performans sonuçlarına göre gerçek değere en yakın olarak LSTM 15 gün, GRU 11 gün ve RNN 4 gün öngörü sonucunu vermiştir.


30 gün öngörünün performans sonucuna göre hataların mutlak ortalaması olan MAE, RNN’de 11.25, LSTM’de 0.05 ve GRU’da 0.02 olarak ölçülerek hataların ortalama büyüklüğünün GRU’da LSTM ve RNN’ye göre daha az çıktığını göstermektedir. Hata kareler ortalamasının kökü olan RMSE, gerçek değerler ve öngörü edilen değerler arasındaki mesafeyi RNN’de 14.15, LSTM’de 5.29 ve GRU’da 6.18 olarak ölçmüştür. Bu ölçüm, LSTM’nin GRU ve RNN’ye göre daha iyi öngörü performansı olduğunu belirtmektedir. Hataların mutlak yüzde ortalamasını temsil eden MAPE, RNN’de %19, GRU’da %7 ve LSTM’de %6 sonucu ile modellerin iyi olduğunu göstermektedir.

RNN, LSTM ve GRU için 30 günlük öngörü sonucu grafikler yardımıyla Şekil 21’de gösterilmiştir.




Şekil 21. RNN Modeli ile 30 Günlük Hisse Senedi Öngörüsü

Şekil 21’de yeşil renk gerçek değerleri, mavi ise RNN öngörü değerlerini oluşturmaktadır.




Şekil 22. LSTM Modeli ile 30 Günlük Hisse Senedi Öngörüsü

Şekil 22’de yeşil renk gerçek değerleri, mor ise LSTM öngörü değerlerini göstermektedir.



Şekil 23. GRU Modeli ile 30 Günlük Hisse Senedi Öngörüsü

Şekil 23’te verilen GRU öngörü sonucunda yeşil renk gerçek değerleri verirken sarı ise öngörü değerlerini vermektedir.



Şekil 24. RNN, LSTM ve GRU Modellerin 30 Günlük Hisse Senedi Öngörüsü

Şekil 24’te hisse senedi kapanış fiyatlarının gerçek değerleri yeşil, GRU öngörü sonucu sarı, LSTM öngörü sonucu mor ve RNN öngörü sonucu mavi ile gösterilmiştir.

Gerçek değerlere en yakın olan değerler LSTM öngörü sonucu olmuştur. Performans açısından değerlendirilecek olursa LSTM, GRU’ya ve RNN’ye göre daha iyi öngörü yapmıştır.

Aşağıda Göltaş Çimento A.Ş.’ye ait hisse senetlerinin 60 günlük kapanış fiyatlarının öngörü sonuçları tablo ve grafik yardımıyla gösterilmiştir.


Tablo 9. 60 Gün Öngörünün Performans Sonuçları

	RNN	LSTM	GRU
MAE	15.61	3.24	2.94
RMSE	15.61	6.76	6.27
MAPE	0.24	0.08	0.08
Gün Sayısı	4	22	34

Tablo 9’da 60 gün için yapılan öngörünün performans sonuçlarına göre gerçek değere en yakın olarak LSTM 22 gün, GRU 34 gün ve RNN 4 gün öngörü sonucunu vermiştir.


60 gün öngörünün performans sonucuna göre hataların mutlak ortalaması olan MAE, RNN’de 15.61, LSTM’de 3.24 ve GRU’da 2.94 olarak ölçülerek hataların ortalama büyüklüğünün GRU’da LSTM ve RNN’ye göre daha az çıktığını göstermektedir. Hata kareler ortalamasının kökü olan RMSE, gerçek değerler ve öngörü edilen değerler arasındaki mesafeyi RNN’de 15.61, LSTM’de 6.76 ve GRU’da 6.27 olarak ölçmüştür. Bu ölçüm, GRU’nun LSTM ve RNN’ye göre daha iyi öngörü performansı olduğunu belirtmektedir.

Yukarıda tablosu verilen 60 gün için RNN, LSTM ve GRU öngörü sonuçlarının grafiksel gösterimleri aşağıda verilmiştir.




Şekil 25. RNN Modeli ile 60 Gün Hisse Senedi Öngörüsü

Şekil 25’te gerçek değerler yeşil ile gösterilirken RNN öngörü değerleri mavi ile gösterilmiştir.




Şekil 26. LSTM Modeli ile 60 Gün Hisse Senedi Öngörüsü

Şekil 26’da gerçek değerler yeşil ile gösterilirken LSTM öngörü sonuçları mavi ile gösterilmiştir.



Şekil 27. GRU Modeli ile 60 Günlük Hisse Senedi Öngörüsü

Şekil 27’de gerçek değerler yeşil ile gösterilirken GRU öngörü sonuçları mavi ile gösterilmiştir.



Şekil 28. RNN, LSTM ve GRU Modellerin 60 Günlük Hisse Senedi Öngörüsü Karşılaştırılması

RNN, LSTM ve GRU öngörü sonuçlarında, grafikte de görüldüğü gibi gerçek değerlere en yakın olan GRU ve LSTM öngörü sonuçları olmuştur.

Tablo 10. 90 Gün Öngörünün Performans Sonuçları


	RNN	LSTM	GRU
MAE	14.95	3.40	3.38
RMSE	16.67	6.96	6.49
MAPE	0.24	0.08	0.08
Gün Sayısı	4	40	46

Tablo 10’da verilen 90 günlük RNN, LSTM ve GRU öngörü sonuçlarına göre gerçek değerlere en yakın olarak 46 gün öngörü yaparak GRU, onun peşine 40 gün ile LSTM ve son olarak 4 gün öngörü ile RNN olmuştur. 90 gün öngörü sonucunda GRU ve LSTM birbirlerine yakın sayıda gün öngörüyü yapsa da en fazla gerçeğe en yakın öngörüyü yapan GRU olmuştur.

90 gün öngörünün performans sonucuna göre hataların mutlak ortalaması olan MAE, RNN’de 14.95, LSTM’de 3.40 ve GRU’da 3.38 olarak ölçülerek hataların ortalama büyüklüğünün GRU’da LSTM ve RNN’ye göre daha az çıktığını göstermektedir. Hata kareler ortalamasının kökü olan RMSE, gerçek değerler ve öngörü edilen değerler arasındaki mesafeyi RNN’de 16.67, LSTM’de 6.96 ve GRU’da


6.49 olarak ölçmüştür. Bu ölçüm, GRU'nun LSTM ve RNN'ye göre daha iyi öngörü performansı olduğunu belirtmektedir.

90 gün için yapılan RNN, LSTM ve GRU öngörü sonuçlarının grafiksel gösterimi Şekil 29'da verilmiştir.




Şekil 29. RNN Modeli ile 90 Günlük Hisse Senedi Öngörüsü

Şekil 29'da verilen grafikte yeşil renk ile gerçek değerler, mavi ile RNN öngörü sonuçlarını göstermektedir.




Şekil 30. LSTM Modeli ile 60 Günlük Hisse Senedi Öngörüsü

Şekil 30'da yeşil gerçek değerleri, mavi ise LSTM öngörü sonuçlarını vermektedir.



Şekil 31. GRU Modeli ile 90 Günlük Hisse Senedi Öngörüsü

Şekil 30’da yeşil ile gerçek değerler ve mavi ile GRU öngörü sonuçları gösterilmiştir.



Şekil 32. RNN, LSTM ve GRU Modelleri ile 90 Günlük Hisse Senedi Öngörü Karşılaştırılması


Şekil 32’ye bakıldığında gerçek değerlere en yakın LSTM ve GRU görünmektedir. Birbirlerine yakın sonuçları verseler de GRU, LSTM’den 5 gün daha fazla gerçek değerlere yakın öngörü sonucu verdiği için 90 günlük öngörü sonucunda en iyi GRU olmuştur. GRU’yu takiben LSTM gelmiştir. Son olarak GRU ve LSTM’ye göre gerçek değerlere uzak olan RNN olmuştur.

Tablo 11. 120 Gün Öngörünün Performans Sonuçları

Modeller	RNN	LSTM	GRU
MAE	13.79	3.23	3.16
RMSE	15.37	6.33	5.85
MAPE	24.29	8.32	7.62
Gün Sayısı	4	57	59


Tablo 11’de RNN, LSTM ve GRU’nun 120 günlük öngörü sonuçları verilmiştir. Gerçek değerlere en yakın değeri veren 59 yakın öngörü ile GRU olmuştur. İkinci olarak 57 yakın öngörü veren LSTM ve son olarak 4 yakın öngörü ile RNN olmuştur.

120 gün öngörünün performans sonucuna göre hataların mutlak ortalaması olan MAE, RNN’de 13.79, LSTM’de 3.23 ve GRU’da 3.16 olarak ölçülerek hataların ortalama büyüklüğünün GRU’da LSTM ve RNN’ye göre daha az çıktığını göstermektedir. Hata kareler ortalamasının kökü olan RMSE, gerçek değerler ve öngörü edilen değerler arasındaki mesafeyi RNN’de 15.37, LSTM’de 6.33 ve GRU’da 5.85 olarak ölçmüştür. Bu ölçüm, GRU’nun LSTM ve RNN’ye göre daha iyi öngörü performansı olduğunu belirtmektedir.




Şekil 33. RNN Modeli ile 120 Günlük Hisse Senedi Öngörüsü

120 günlük RNN öngörü sonucundaki görselde yeşil gerçek değerleri mavi ise RNN öngörü sonucunu vermektedir. RNN öngörü değerleri gerçek değerlere diğer öngörü modellerinden daha uzaktır.




Şekil 34. LSTM Modeli ile 120 Günlük Hisse Senedi Öngörüsü

Şekil 34’de verilen 120 günlük LSTM öngörüsünde gerçek değeri yeşil, öngörü değerini mavi renk göstermektedir. LSTM, RNN’e göre daha iyi öngörü yapmaktadır.



Şekil 35. GRU Modeli ile 120 Günlük Hisse Senedi Öngörüsü

Şekil 35’de verilen 120 günlük GRU öngörü sonucunda yeşil gerçek değerleri mavi ise öngörü sonuçlarını vermektedir. Bu grafikte GRU’nun gerçek değerlere yakın öngörüler yaptığı söylenebilir.



Şekil 36. RNN, LSTM ve GRU Modellerin 120 Günlük Hisse Senedi Öngörü Karşılaştırılması

Yukarıdaki grafikte gerçek değerler yeşil, LSTM öngörülleri mor, RNN öngörülleri mavi ve GRU öngörülleri sarı ile verilmiştir. Gerçek değere en yakın sonuçları GRU ve LSTM verirken en uzak öngörü değerlerini RNN vermiştir.

SONUÇ

Bu çalışmada derin öğrenme modellerinden olan tekrarlayan sinir ağları, geliştirilmiş bir öngörü yöntemleri olan uzun kısa dönem bellek ve geçitli tekrarlayan birim karşılaştırılması yapılarak modellerin performanslarına göre en iyi öngörüyü yapan yapay sinir ağına değinildi.

Çalışmada 30, 60, 90 ve 120 günlük öngörü yapılarak tekrarlayan sinir ağları, uzun kısa dönem bellek ve geçitli tekrarlayan birimler arasında karşılaştırılma yapılarak aralarındaki en iyi öngörü yapan modelin ortaya konması amaçlandı. Bu amaç doğrultusunda 02.01.2012-31.12.2020 tarihleri arasında BİST Metal Harici Mineral Ürünleri'nde bulunan Göltaş Göller Bölgesi Çimento Sanayi ve Ticaret A.Ş.' ye ait veriler kullanıldı. Zaman serisi olarak kapanış fiyat değerleri alındı. Veri seti eğitim ve test olmak üzere ikiye ayrılarak test verileri öngörü yapıldı.

Öncelikle tekrarlayan sinir ağları, uzun kısa dönem bellek ve geçitli tekrarlayan birimler ile modellendi. Kurulan modelin çalışma ilkeleri belirtildi. Daha sonra bu model performans ölçütleri ile değerlendirildi. Öngörü sonuçları ise şekiller aracılığıyla görselleştirildi. GRU ve LSTM birbirlerine yakın öngörü sonuçlarını verse de gerçek değerlere en yakın öngörü değerlerini GRU, onu takiben LSTM ve en uzak öngörü değerlerini ise RNN'nin yaptığı belirtildi.

Üç model karşılaştırıldığında yinelemeli sinir ağlarında RMSE=2.566, uzun kısa dönem bellekte RMSE=0.653 ve geçitli tekrarlayan birimlerde RMSE=0.103, tekrarlayan sinir ağlarında MAE=2.363, uzun kısa dönem bellekte MAE=0.412 geçitli tekrarlayan birimlerde MAE=0.076, yinelemeli sinir ağlarında MAPE=0.17 uzun kısa dönem bellekte ve geçitli tekrarlayan birimlerde MAPE=0.02, yinelemeli sinir ağlarında $R^2=0.82$ uzun kısa dönem bellekte ve geçitli tekrarlayan birimlerde $R^2=0.98$ çıkmıştır.

Her üç modelin de iyi olduğu MAPE sonucunda görülmektedir. Verilerin birbiriyle ilişkili olduğu belirlilik katsayısında görülmektedir. Çalışmanın uygulamasında kullanılan bir yapay sinir ağı olan uzun kısa dönem bellek ve geçitli tekrarlayan birimlerin model başarısı, tekrarlayan sinir ağlarına göre daha yüksektir. Yinelemeli sinir ağlarındaki gradyan kaybolması ve tekrarlayan sinir ağlarının uzun

bir dönemi belleğinde tutamaması sonucuna çözüm olarak geliştirilen uzun kısa dönem bellek ve geçitli tekrarlayan birimler için etkili bir öngörü yapma yöntemleri olduğu ifade edilebilir.

LSTM tarih bakımından GRU'dan daha eski olmasına rağmen, GRU daha basit hali olarak sonradan yaygınlaşmış ve anlaşılması daha kolay olduğu için daha çok tercih edilmektedir. Her iki modelinde birbirlerine karşı üstün özellikleri bulunmaktadır. Bununla birlikte, farklı problemlerde, farklı modeller ve algoritmalar daha başarılı sonuçlar verebilir. Bu sebeple kombinasyonlarını optimize etmek gerekir. Bu tez çalışması için en iyi öngörü sonucunu veren yöntemin geçitli tekrarlayan birimler olduğu söylenebilir.



KAYNAKÇA

- Altan A. ve Karasu S., (2020), Ayrıştırma Yöntemlerinin Derin Öğrenme Algoritması ile Tanımlanan Rüzgâr Hızı Tahmin Modeli Başarımına Etkisinin İncelenmesi, Avrupa Bilim ve Teknoloji Dergisi No.20, ss.844-853
- Amidi, A. Ve Amidi, S., (2018), “VIP Cheatsheet: Recurrent Neural Networks”, (<https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks>) Erişim Tarihi:01.07.2020
- Amrin, A. ve Satriadi, I., (2018), *Implementasi Jaringan Syaraf Tiruan Dengan Multilayer Perceptron Untuk Analisa Pemberian Kredit*, Jurnal Riset Komputer (JURIKOM) Vol.5, No.6, ss.605-610
- Bayındır, K. (2017), “Financial Time Series Prediction with LSTM Recurrent Neural Networks”, *Natural and Applied Sciences Bahçeşehir University*, Master’s Thesis, Istanbul.
- Bawa, V.S., (2017), “Basic Architecture of Rnn and LSTM”, (<https://pydeeplearning.weebly.com/blog/basic-architecture-of-rnn-and-lstm>) Erişim Tarihi:09.07.2020
- Bengio, Y., Simard, P. ve Frasconi, P., (1994), *Learning Long-Term Dependencies with Gradient Descent is Difficult*, IEEE Transactions on Neural Networks Vol.5, No.2, ss. 157-166
- Borges, P. (2018), “Deep Learning: The Learning Part”, (<https://medium.com/deeplearningbrasil/deep-learning-the-learning-part-a2f68c6319a2>) Erişim Tarihi:18.09.2020
- Chollet, F. (2019), *Python ile Derin Öğrenme*, 1.Baskı Ankara: Buzdağı Yayınevi.
- Cortes, C. ve Vapnik, V., (1995), *Support-Vector Networks*, Machine Learning Vol.20, ss.273-297
- Cura, A., (2019), *Driver Profiling Using Long Short Term Memory (LSTM) and Convolutional neural Network (CNN) Methods*, Master Thesis. Marmara University, Institute for Graduate Studies in Pure and Applied Sciences, Istanbul.
- Çalışkan Çavdar, Ş. ve Aydın, D., (2018), *Finans Alanında Yapay Zekâ ve Ekonometrik Uygulamalar*, 1.Baskı Ankara: Seçkin Yayıncılık.
- Çetin, D.T. ve Metlek, S. (2021), *Türkiye’deki İslami Hisse Senedi Endeksinin, Endeks Tabanlı Öznitelikler Kullanılarak Derin Öğrenme Yöntemi ile Tahmini*, Acta Infologia Vol.5, No.2, ss.287-298

- Datai Team, (2020), “*Deep Learning ve Python: A’dan Z’ye Derin Öğrenme (5)*”, (<https://www.udemy.com/course/deep-learning-ve-python-adan-zye-derin-ogrenme-5/learn/lecture/11793360#content>) Erişim Tarihi:23.12.2020
- DeepMind, (2016), *The Google DeepMind Challenge Match*, (<https://deepmind.com/alphago-korea>) Erişim Tarihi: 20.07.2020
- Deng, L. ve Yu, D. (2014), *Deep Learning: Methods and Applications*, Foundations and Trends in Signal Processing Vol.7, No.3-4, ss.197-387
- Feng, W., vd. (2017), *Audio Visual Speech Recognition with Multimodal Recurrent Neural Networks*, Conference: 2017 International Joint Conference on Neural Networks (IJCNN), pp.681-688
- Fukuskima, K., (1988), *Neocognitron: A Hierarchical Neural Network Capable of Visual Pattern Recognition*, Neural Networks, Vol.1, ss.119-130
- Gavcar E. Ve Metin H.M. (2021), *Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) ile Tahmini*, Ekonomi ve Yönetim Araştırmaları Dergisi Vol.10, No.2, ss. 1-11
- Goodfellow, I., Bengio, Y. ve Courville, A., (2018), *Derin Öğrenme*, 1.Baskı Ankara: Buzdağı Kitabevi.
- Güneş, İ. (2020), “Comparison of ARIMA and LSTM Models for Bitcoin Price Prediction”, *Bahçeşehir University Graduate School of Natural and Applied Sciences*, Master’s Thesis, Istanbul.
- Haykin, S. (2009), *Neural Networks and Learning Machines*, 3.Edition USA: Pearson Education.
- Hinton, G.E., ve Salakhutdinov, R., (2006), *Reducing the Dimensionality of Data with Neural Networks*, Science Vol.313, No.5786, ss.504-507
- Hochreiter, S. ve Schmidhuber, J., (1997), *Long Short-Term Memory*, Neural Computation Vol.9, No.8, ss.1735-1780
- Ivakhnenko A.G. ve Lapa, V.G., (1966), “*Cybernetic Predicting Devices*” 1966.
- Kabalıcı, E. (2015), “*Yapay Sinir Ağları*”, (<https://ekblc.wordpress.com/notlar/bahar-yariyili/esnek-hesaplama-ii/>) Erişim Tarihi:30.06.2020
- Kalteh, A.M. ve Berndtsson, R., (2007), *Interpolating Monthly Precipitation by Self-Organizing Map (SOM) and Multilayer Perceptron (MLP)*, Hydrological Sciences-Journal-des Sciences Hydrologiques Vol.52, No.2, ss.305-317
- Karpathy, A., (2015), “*The Unreasonable Effectiveness of Recurrent Neural Networks*”, (<http://karpathy.github.io/2015/05/21/rnn-effectiveness/>) Erişim Tarihi:03.05.2020

- Kayaalp, K. ve Süzen, A.A., (2018), *Derin Öğrenme ve Türkiye’deki Uygulamaları*, Adıyaman: İksad Kitabevi.
- Kıymaz, Y.E. (2020), “Güneş Enerjisi Santrallerinde Derin Öğrenme Kullanılarak Elektrik Üretimi Tahminin Yapılması”, *Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, Konya.
- Kızrak, M.A. (2018), “Deep Learning A-Z™| Python ile Derin Öğrenme”, (<https://www.udemy.com/course/derin-ogrenmeye-giris/learn/lecture/11937772#overview>) Erişim Tarihi:27.12.2020
- Krizhevsky, A., Sutskever, I. ve Hinton, Geoffrey E., (2017), *ImageNet Classification with Deep Convolutional Neural Networks*, *Communications Of The Acm* Vol.60, No.6, ss.84-90
- Lazzeri, F. vd., (2021), “Deep Learning vs. Machine Learning in Azure Machine Learning”, (<https://docs.microsoft.com/en-us/azure/machine-learning/concept-deep-learning-vs-machine-learning>) Erişim Tarihi:15.04.2021
- Maklin, C. (2019), *LSTM Recurrent Neural Network Keras Example*, (<https://towardsdatascience.com/machine-learning-recurrent-neural-networks-and-long-short-term-memory-lstm-python-keras-example-86001ceaaebc>) Erişim Tarihi: 16.09.2020
- Mateus vd. (2021), *Comparing LSTM and GRU Models to Predict the Condition of a Pulp Paper Press*, *Energies* Vol.14, No.6958, ss. 1
- McCulloch, W.S. ve Pitts, W. (1943), *A Logical Calculus of Ideas Immanent in Nervous Activity*, *Bulletin of Mathematical Biophysics*, Vol.5, ss.115-133
- Mert, M. ve Çağlar A.E. (2019), *Eviews ve Gauss Uygulamalı Zaman Serileri Analizi*, Ankara: Detay Yayıncılık.
- Messikh, N., Bousba, S. ve Bougdah, N., (2017), *The Use of a Multilayer Perceptron (MLP) for Modelling The Phenol Removal by Emulsion Liquid Membrane*, *Journal of Environmental Chemical Engineering* Vol.5, ss.3483-3489
- Moroney, L. (2019), *Sequences, Time Series and Prediction*, (<https://www.coursera.org/learn/tensorflow-sequences-time-series-and-prediction/lecture/nPWNo/week-3-a-conversation-with-andrew-ng>) Erişim Tarihi: 08.09.2020
- Nilsson, N., (2011), *Yapay Zeka Geçmişi ve Geleceği*, 2.Baskı, Çev. Mehmet Doğan, İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Olah, C. (2015), “Understanding LSTM Networks”, (<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>) Erişim Tarihi: 10.09.2020

- Oualil, Y. vd., (2016), *Long-Short Range Context Neural Networks for Language Modeling*, Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, ss.1473-1481
- Özşahin, Ş. ve Singer, H. (2019), *Odun Düzey Pürüzlülüğü Tahmininde Bir Yapay Sinir Ağı Modelinin Kullanılması*, Düzce Üniversitesi Bilim ve Teknoloji Dergisi Vol.7 ss. 1764-1777.
- Öztemel, E., (2012), *Yapay Sinir Ağları*, 3.Baskı İstanbul: Papatya Yayıncılık Eğitim.
- Phi, M., (2018), “Illustrated Guide to LSTM’s and GRU’s: a Step by Step Explanation”, (<https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>) Erişim Tarihi:10.09.2020
- Rikiya, Y. vd., (2018), *Convolutional Neural Networks: An Overview and Application in Radiology*, Insights into Imaging Vol.9 ss.611-629
- Roondiwala, M., Patel, H. ve Varma, S., (2017), *Predicting Stock Prices Using LSTM*, International Journal of Science and Research (IJSR) Vol.6, No.4, ss.1754-1756
- Sakarya, Ş. ve Yılmaz Ü. (2019), *Derin Öğrenme Mimarisi Kullanarak BİST30 Endeksinin Tahmini*, European Journal of Educational & Social Sciences Vol.4, No.2, ss. 108-121
- Sonsuz Teknoloji (2018), “Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki Fark Nedir?”, (<https://www.sonsuzteknoloji.com/yapay-zeka-makine-ogrenme-ve-derin-ogrenme-arasindaki-fark-nedir/>) Erişim Tarihi:29.06.2020
- Şahingöz vd. (2020), *Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini*, BEÜ Fen Bilimleri Dergisi Vol.9, No.1, ss. 434-445
- Şen, Z. (2004), *Yapay Sinir Ağları İlkeleri*, 1.Baskı İstanbul: Su Vakfı Yayınları.
- Taigman, Y. vd., (2014), *DeepFace: Closing the Gap to Human-Level Performance in Face Verification*, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, ss.1701-1708
- Torkul, O. vd., (2017), *Mühendislikte Yapay Zeka ve Uygulamaları*, 1.Baskı Sakarya: Sakarya Üniversitesi Yayınları.
- Turan, S. (2019), “Uzun Kısa Süreli Hafıza ve Geçitli Yinelenen Birim ile Borsa İstanbul 100 Endeks Değeri Tahmini Üzerine Bir Uygulama” *Fen Bilimleri Enstitüsü Yıldız Teknik Üniversitesi*, İstanbul.
- Unlu, R. Vd., (2021), *Predicting Stock Prices Using Machine Learning Methods and Deep Learning Algorithms: The Sample of the Istanbul Stock Exchange*, Gazi University Journal of Science Vol.34, No.1, ss. 63-82

- Uğuz, S. (2019), *Makine Öğrenmesi Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zekâ Ekolü*, 1.Baskı Ankara: Nobel Akademik Yayıncılık Eğitim Danışmanlık Tic. Ltd. Sti.
- Üzen, H. ve Hanbay, K., (2020), *Yaya Özellik Tanıma İçin LM Filtre Temelli Derin Evrimsel Sinir Ağı*, Politeknik Dergisi Vol.23, No.3, ss.605-613
- Yakıt, O. ve Yılmaz, Ö., (2017), *Kurumsal Kaynak Planlama Sistemlerinde Yapay Sinir Ağlarının Değerlendirilmesi Yaklaşımı*, Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi Vol.5 No.2, ss. 287-296
- Yeon, K. (2019), *Ego-Vehicle Speed Prediction Using a Long Short-Term Memory Based Recurrent Neural Network*, International Journal of Automotive Technology, Vol.20, No.4, ss. 713-722
- Yıldırım, D.C. (2019), “Forecasting Directional Movement of Forex Data Using LSTM with Technical and Macroeconomic Indicators”, *The Graduate School of Natural and Applied Sciences Middle East Technical University*, Master’s Thesis, Ankara.
- Yılmaz, A. ve Kaya, U., (2019), *Derin Öğrenme*, 1.Baskı İstanbul: İnkılâp Kitabevi.
- Yusufoğlu, H. vd., (2021), *Twitter Üzerindeki Finansal Tweetlerin LSTM Sinir Ağı Algoritması ile Duygu Analizi*, Veri Bilim Derg, Vol.4, No.3, ss. 28-43
- Yürük, M.F., (2021), *Yapay Sinir Ağları ile Hisse Senedi Fiyat Tahmin Modeli: Türk Hava Yolları Uygulaması*, Journal of Aviation, Vol. 5, No.2, ss. 282-289
- Weng, J., Cohen, P. ve Herniou, M., (1992), *Camera Calibration with Distortion Models and Accuracy Evaluation*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.14, No.10, ss.965-980
- Werbos, P. (1990), *Backpropagation Through Time: What It Does and How to Do It*, Proceedings of the IEEE, Vol.78, No.10, ss.1550-1560

EKLER

Tablo 12. 30 Günlük Hisse Senedi Gerçek ve Öngörü Değerleri

Günler	Gerçek Değerler	RNN Öngörü	LSTM Öngörü	GRU Öngörü
04.01.2021	41.62	33.17	40.34	40.54
05.01.2021	39.89	32.80	39.41	39.16
06.01.2021	39.81	32.99	39.90	40.06
07.01.2021	40.17	32.89	39.75	39.85
08.01.2021	40.96	32.81	39.44	38.91
11.01.2021	40.03	32.74	39.48	38.93
12.01.2021	40.29	34.46	41.26	41.10
13.01.2021	40.29	35.71	42.57	42.35
14.01.2021	39.91	35.65	43.05	42.35
15.01.2021	39.89	36.80	44.24	46.57
18.01.2021	43.87	36.93	44.86	46.43
19.01.2021	46.38	38.94	46.83	50.75
20.01.2021	45.24	39.19	47.75	48.00
21.01.2021	47.55	37.79	45.54	45.65
22.01.2021	47.35	38.52	47.67	51.05
25.01.2021	52.08	38.02	47.42	46.11
26.01.2021	51.83	39.94	49.36	51.02
27.01.2021	46.73	42.32	51.83	50.85
28.01.2021	49.68	45.31	55.14	54.84
29.01.2021	48.84	45.17	56.03	53.68
01.02.2021	53.72	47.45	59.42	62.19
02.02.2021	59.09	50.51	63.59	66.71
03.02.2021	64.96	52.25	67.39	68.70
04.02.2021	62.22	53.62	71.14	72.20
05.02.2021	68.44	52.96	72.11	71.12
08.02.2021	75.25	52.04	72.96	74.80
09.02.2021	79.28	50.32	71.02	69.61
10.02.2021	82.81	50.31	71.81	72.99
11.02.2021	79.83	48.63	68.10	63.79
12.02.2021	78.74	49.00	65.73	63.53

Tablo 13. 60 Günlük Hisse Senedi Gerçek ve Öngörü Değerleri

Günler	Gerçek Değerler	RNN Öngörü	LSTM Öngörü	GRU Öngörü
04.01.2021	41.62	33.17	40.34	40.54
05.01.2021	39.89	32.80	39.41	39.16
06.01.2021	39.81	32.99	39.90	40.06
07.01.2021	40.17	32.89	39.75	39.85
08.01.2021	40.96	32.81	39.44	38.91
11.01.2021	40.03	32.74	39.48	38.93
12.01.2021	40.29	34.46	41.26	41.10
13.01.2021	40.29	35.71	42.57	42.35
14.01.2021	39.91	35.65	43.05	42.35
15.01.2021	39.89	36.80	44.24	46.57
18.01.2021	43.87	36.93	44.86	46.43
19.01.2021	46.38	38.94	46.83	50.75
20.01.2021	45.24	39.19	47.75	48.00
21.01.2021	47.55	37.79	45.54	45.65
22.01.2021	47.35	38.52	47.67	51.05
25.01.2021	52.08	38.02	47.42	46.11
26.01.2021	51.83	39.94	49.36	51.02
27.01.2021	46.73	42.32	51.83	50.85
28.01.2021	49.68	45.31	55.14	54.84
29.01.2021	48.84	45.17	56.03	53.68
01.02.2021	53.72	47.45	59.42	62.19
02.02.2021	59.09	50.51	63.59	66.71
03.02.2021	64.96	52.25	67.39	68.70
04.02.2021	62.22	53.62	71.14	72.20
05.02.2021	68.44	52.96	72.11	71.12
08.02.2021	75.25	52.04	72.96	74.80
9.02.2021	79.28	50.32	71.02	69.61
10.02.2021	82.81	50.31	71.81	72.99
11.02.2021	79.83	48.63	68.10	63.79
12.02.2021	78.74	47.35	65.73	63.53
15.02.2021	74.61	48.29	67.14	63.52
16.02.2021	75.80	46.44	62.02	58.78
17.02.2021	71.67	44.02	56.33	55.17
18.02.2021	68.54	44.17	58.33	60.56
19.02.2021	71.82	43.12	55.16	56.12
22.02.2021	66.25	42.79	54.83	57.38
23.02.2021	59.64	45.00	57.34	59.33
24.02.2021	61.28	46.83	59.07	59.61

25.02.2021	58.89	46.57	59.46	58.07
26.02.2021	58.39	46.39	59.81	59.65
01.03.2021	64.21	47.26	61.09	64.37
02.03.2021	67.64	48.42	62.98	66.56
03.03.2021	66.10	48.46	63.82	64.41
04.03.2021	65.26	48.11	64.19	64.48
05.03.2021	67.59	47.88	64.34	65.81
08.03.2021	70.98	46.87	63.07	63.79
09.03.2021	70.78	45.28	60.24	60.30
10.03.2021	69.78	44.61	59.20	59.96
11.03.2021	69.34	43.26	56.11	54.53
12.03.2021	67.10	45.35	59.43	57.81
15.03.2021	63.07	44.80	58.07	54.98
16.03.2021	61.87	42.86	53.85	51.05
17.03.2021	58.84	42.41	54.25	54.67
18.03.2021	64.71	43.40	55.46	57.94
19.03.2021	62.92	42.62	54.35	54.45
22.03.2021	56.65	42.63	54.52	56.33
23.03.2021	56.40	42.93	54.94	56.46
24.03.2021	59.89	42.57	54.41	54.71
25.03.2021	58.00	42.09	54.01	54.87
26.03.2021	58.14	42.96	55.12	56.53

Tablo 14. 90 Günlük Hisse Senedi Gerçek ve Öngörü Değerleri

Günler	Gerçek Değerler	RNN Öngörü	LSTM Öngörü	GRU Öngörü
04.01.2021	41.62	33.17	40.34	40.54
05.01.2021	39.89	32.80	39.41	39.16
06.01.2021	39.81	32.99	39.90	40.06
07.01.2021	40.17	32.89	39.75	39.85
08.01.2021	40.96	32.81	39.44	38.91
11.01.2021	40.03	32.74	39.48	38.93
12.01.2021	40.29	34.46	41.26	41.50
13.01.2021	40.29	35.71	42.57	42.35
14.01.2021	39.91	35.65	43.05	42.35
15.01.2021	39.89	36.80	44.24	46.57

18.01.2021	43.87	36.93	44.86	46.43
19.01.2021	46.38	38.94	46.83	50.75
20.01.2021	45.24	39.19	47.75	48.00
21.01.2021	47.55	37.79	45.54	45.65
22.01.2021	47.35	38.52	47.67	51.05
25.01.2021	52.08	38.02	47.42	46.11
26.01.2021	51.83	39.94	49.36	51.02
27.01.2021	46.73	42.32	51.83	50.85
28.01.2021	49.68	45.31	55.14	54.84
29.01.2021	48.84	45.17	56.03	53.68
01.02.2021	53.72	47.45	59.42	62.19
02.02.2021	59.09	50.51	63.59	66.71
03.02.2021	64.96	52.25	67.39	68.70
04.02.2021	62.22	53.62	71.14	72.20
05.02.2021	68.44	52.96	72.11	71.12
08.02.2021	75.25	52.04	72.96	74.80
9.02.2021	79.28	50.32	71.02	69.61
10.02.2021	82.81	50.31	71.81	72.99
11.02.2021	79.83	48.63	68.10	63.79
12.02.2021	78.74	47.35	65.73	63.53
15.02.2021	74.61	48.29	67.14	63.52
16.02.2021	75.80	46.44	62.02	58.78
17.02.2021	71.67	44.02	56.33	55.17
18.02.2021	68.54	44.17	58.33	60.56
19.02.2021	71.82	43.12	55.16	56.12
22.02.2021	66.25	42.79	54.83	57.38
23.02.2021	59.64	45.00	57.34	59.33
24.02.2021	61.28	46.83	59.07	59.61
25.02.2021	58.89	46.57	59.46	58.07

26.02.2021	58.39	46.39	59.81	59.65
01.03.2021	64.21	47.26	61.09	64.37
02.03.2021	67.64	48.42	62.98	66.56
03.03.2021	66.10	48.46	63.82	64.41
04.03.2021	65.26	48.11	64.19	64.48
05.03.2021	67.59	47.88	64.34	65.81
08.03.2021	70.98	46.87	63.07	63.79
09.03.2021	70.78	45.28	60.24	60.30
10.03.2021	69.78	44.61	59.20	59.96
11.03.2021	69.34	43.26	56.11	54.53
12.03.2021	67.10	45.35	59.43	57.81
15.03.2021	63.07	44.80	58.07	54.98
16.03.2021	61.87	42.86	53.85	51.05
17.03.2021	58.84	42.41	54.25	54.67
18.03.2021	64.71	43.40	55.46	57.94
19.03.2021	62.92	42.62	54.35	54.45
22.03.2021	56.65	42.63	54.52	56.33
23.03.2021	56.40	42.93	54.94	56.46
24.03.2021	59.89	42.57	54.41	54.71
25.03.2021	58.00	42.09	54.01	54.87
26.03.2021	58.14	42.96	55.12	56.53
29.03.2021	58.89	43.29	55.64	55.39
30.03.2021	57.80	43.77	56.39	56.63
31.03.2021	57.05	45.34	58.14	59.61
01.04.2021	59.19	45.01	58.23	57.47
02.04.2021	59.89	44.06	57.42	58.73
05.04.2021	60.98	43.01	55.56	56.89
06.04.2021	64.66	41.48	52.44	52.49
07.04.2021	62.72	40.80	52.28	49.63

08.04.2021	60.58	42.62	54.48	52.22
09.04.2021	57.70	41.73	53.24	50.00
12.04.2021	54.22	41.42	52.80	50.01
13.04.2021	53.52	40.02	49.48	48.15
14.04.2021	58.84	38.27	46.27	48.67
15.04.2021	56.45	35.81	41.20	43.58
16.04.2021	55.41	35.81	44.18	41.27
19.04.2021	51.43	36.61	44.64	42.60
20.04.2021	47.65	35.94	43.72	41.99
21.04.2021	42.89	35.37	42.51	42.60
22.04.2021	44.47	35.62	43.29	41.99
26.04.2021	46.83	36.10	43.92	40.95
27.04.2021	45.32	37.71	45.43	42.18
28.04.2021	43.51	39.34	47.14	43.98
29.04.2021	44.47	39.21	47.68	47.52
30.04.2021	45.96	39.25	48.24	49.45
03.05.2021	49.72	38.25	48.40	49.28
04.05.2021	52.97	38.81	48.74	50.48
05.05.2021	51.43	38.03	47.77	50.02
06.05.2021	51.13	38.21	48.32	49.79
07.05.2021	50.29	38.67	48.97	47.63
10.05.2021	50.53	38.31	48.43	47.04

Tablo 15. 120 Günlük Hisse Senedi Gerçek ve Öngörü Değerleri

Günler	Gerçek Değerler	RNN Öngörü	LSTM Öngörü	GRU Öngörü
04.01.2021	41.62	33.17	40.34	40.54
05.01.2021	39.89	32.80	39.41	39.16
06.01.2021	39.81	32.99	39.90	40.06
07.01.2021	40.17	32.89	39.75	39.85
08.01.2021	40.96	32.81	39.44	38.91
11.01.2021	40.03	32.74	39.48	38.93
12.01.2021	40.29	34.46	41.26	41.10
13.01.2021	40.29	35.71	42.57	42.35
14.01.2021	39.91	35.65	43.05	42.35
15.01.2021	39.89	36.80	44.24	46.57
18.01.2021	43.87	36.93	44.86	46.43
19.01.2021	46.38	38.94	46.83	50.75
20.01.2021	45.24	39.19	47.75	48.00
21.01.2021	47.55	37.79	45.54	45.65
22.01.2021	47.35	38.52	47.67	51.05
25.01.2021	52.08	38.02	47.42	46.11
26.01.2021	51.83	39.94	49.36	51.02
27.01.2021	46.73	42.32	51.83	50.85
28.01.2021	49.68	45.31	55.14	54.84
29.01.2021	48.84	45.17	56.03	53.68
01.02.2021	53.72	47.45	59.42	62.19

02.02.2021	59.09	50.51	63.59	66.71
03.02.2021	64.96	52.25	67.39	68.70
04.02.2021	62.22	53.62	71.14	72.20
05.02.2021	68.44	52.96	72.11	71.12
08.02.2021	75.25	52.04	72.96	74.80
9.02.2021	79.28	50.32	71.02	69.61
10.02.2021	82.81	50.31	71.81	72.99
11.02.2021	79.83	48.63	68.10	63.79
12.02.2021	78.74	47.35	65.73	63.53
15.02.2021	74.61	48.29	67.14	63.52
16.02.2021	75.80	46.44	62.02	58.78
17.02.2021	71.67	44.02	56.33	55.17
18.02.2021	68.54	44.17	58.33	60.56
19.02.2021	71.82	43.12	55.16	56.12
22.02.2021	66.25	42.79	54.83	57.38
23.02.2021	59.64	45.00	57.34	59.33
24.02.2021	61.28	46.83	59.07	59.61
25.02.2021	58.89	46.57	59.46	58.07
26.02.2021	58.39	46.39	59.81	59.65
01.03.2021	64.21	47.26	61.09	64.37
02.03.2021	67.64	48.42	62.98	66.56
03.03.2021	66.10	48.46	63.82	64.41
04.03.2021	65.26	48.11	64.19	64.48
05.03.2021	67.59	47.88	64.34	65.81

08.03.2021	70.98	46.87	63.07	63.79
09.03.2021	70.78	45.28	60.24	60.30
10.03.2021	69.78	44.61	59.20	59.96
11.03.2021	69.34	43.26	56.11	54.53
12.03.2021	67.10	45.35	59.43	57.81
15.03.2021	63.07	44.80	58.07	54.98
16.03.2021	61.87	42.86	53.85	51.05
17.03.2021	58.84	42.41	54.25	54.67
18.03.2021	64.71	43.40	55.46	57.94
19.03.2021	62.92	42.62	54.35	54.45
22.03.2021	56.65	42.63	54.52	56.33
23.03.2021	56.40	42.93	54.94	56.46
24.03.2021	59.89	42.57	54.41	54.71
25.03.2021	58.00	42.09	54.01	54.87
26.03.2021	58.14	42.96	55.12	56.53
29.03.2021	58.89	43.29	55.64	55.39
30.03.2021	57.80	43.77	56.39	56.63
31.03.2021	57.05	45.34	58.14	59.61
01.04.2021	59.19	45.01	58.23	57.47
02.04.2021	59.89	44.06	57.42	58.73
05.04.2021	60.98	43.01	55.56	56.89
06.04.2021	64.66	41.48	52.44	52.49
07.04.2021	62.72	40.80	52.28	49.63
08.04.2021	60.58	42.62	54.48	52.22

09.04.2021	57.70	41.73	53.24	50.00
12.04.2021	54.22	41.42	52.80	50.01
13.04.2021	53.52	40.02	49.48	48.15
14.04.2021	58.84	38.27	46.27	48.67
15.04.2021	56.45	35.81	41.20	43.58
16.04.2021	55.41	35.81	44.18	41.27
19.04.2021	51.43	36.61	44.64	42.60
20.04.2021	47.65	35.94	43.72	41.99
21.04.2021	42.89	35.37	42.51	42.60
22.04.2021	44.47	35.62	43.29	41.99
26.04.2021	46.83	36.10	43.92	40.95
27.04.2021	45.32	37.71	45.43	42.18
28.04.2021	43.51	39.34	47.14	43.98
29.04.2021	44.47	39.21	47.68	47.52
30.04.2021	45.96	39.25	48.24	49.45
03.05.2021	49.72	38.25	48.40	49.28
04.05.2021	52.97	38.81	48.74	50.48
05.05.2021	51.43	38.03	47.77	50.02
06.05.2021	51.13	38.21	48.32	49.79
07.05.2021	50.29	38.67	48.97	47.63
10.05.2021	50.53	38.31	48.43	46.04
11.05.2021	49.02	37.95	47.77	45.45
12.05.2021	49.64	37.54	46.87	46.91
17.05.2021	51.13	37.13	46.25	47.77

18.05.2021	49.99	35.77	42.76	44.26
20.05.2021	49.04	36.14	44.95	43.76
21.05.2021	47.93	35.61	43.28	42.08
24.05.2021	47.19	35.31	43.17	41.74
25.05.2021	44.05	35.11	42.91	41.10
26.05.2021	45.62	34.90	42.43	40.93
27.05.2021	44.55	35.23	43.27	42.49
28.05.2021	43.87	36.47	44.39	45.24
31.05.2021	43.83	37.08	45.18	46.07
01.06.2021	43.31	37.82	46.11	47.84
02.06.2021	44.51	37.36	46.03	46.00
03.06.2021	47.31	37.07	45.70	47.19
04.06.2021	48.25	36.55	45.19	45.57
07.06.2021	49.50	36.79	45.86	44.43
08.06.2021	47.69	36.09	44.58	43.39
09.06.2021	46.85	35.73	44.00	42.06
10.06.2021	46.12	35.14	42.82	41.44
11.06.2021	47.07	34.86	42.54	41.48
14.06.2021	45.62	34.77	42.65	42.63
15.06.2021	44.61	34.40	41.64	42.39
16.06.2021	43.57	34.59	42.40	43.69
17.06.2021	43.41	34.58	42.12	42.37
18.06.2021	42.46	34.56	42.18	42.23
21.06.2021	43.19	34.21	41.42	40.49

22.06.2021	43.17	33.48	39.51	38.92
23.06.2021	43.11	33.03	39.00	38.65
24.06.2021	42.18	32.14	37.36	37.39



ÖZGEÇMİŞ

Kişisel Bilgiler

Adı ve Soyadı : Elif Nur GÜNEY

Eğitim Durumu:

Lisans Öğrenimi : Süleyman Demirel Üniversitesi, Ekonometri

Y. Lisans Öğrenimi : Süleyman Demirel Üniversitesi, Ekonometri

Yabancı Diller ve Düzeyi

İngilizce: İyi

Bilimsel Yayınlar ve Çalışmalar

Güney, E.N., Toyganözü, C., Toyganözü, Z.H., “Derin Öğrenmede İstatistiksel Yöntemler Üzerine Bir Uygulama” 21. Uluslararası Ekonometri, Yöneylem Araştırması ve İstatistik Sempozyumu (2021), Ankara.