

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**BIST 30 ENDEKSİNİN VE HİSSE SENETLERİNİN DEĞER TAHMİNİ
ÜZERİNE BİR ÇALIŞMA**

Yüksek Lisans Tezi

Zinnet Duygu AKŞEHİR

Danışman
Prof. Dr. Erdal KILIÇ

SAMSUN
2020

TEZ ONAYI

Zinnet Duygu AKŞEHİR tarafından hazırlanan “BIST 30 Endeksinin ve Hisse Senetlerinin Değer Tahmini Üzerine Bir Çalışma” adlı tez çalışması 14/07/2020 tarihinde aşağıdaki jüri tarafından Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman Prof. Dr. Erdal KILIÇ
Bilgisayar Mühendisliği Anabilim Dalı

Jüri Üyeleri

Başkan Prof. Dr. Mustafa ULUTAŞ
Karadeniz Teknik Üniversitesi 
Bilgisayar Mühendisliği Anabilim Dalı

Üye Prof. Dr. Erdal KILIÇ
Ondokuz Mayıs Üniversitesi 
Bilgisayar Mühendisliği Anabilim Dalı

Üye Doç. Dr. Sedat AKLEYLEK
Ondokuz Mayıs Üniversitesi 
Bilgisayar Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım / /2020

Prof. Dr. Ali BOLAT
Enstitü Müdürü

ETİK BEYAN

Ondokuz Mayıs Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

14/07/2020

Zinnet Duygu AKŞEHİR

ÖZET

Yüksek Lisans Tezi

BIST 30 ENDEKSİNİN VE HİSSE SENETLERİNİN DEĞER TAHMİNİ ÜZERİNE BİR ÇALIŞMA

Zinnet Duygu Akşehir

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Erdal KILIÇ

Borsa, menkul kıymetlerin ve diğer sermaye piyasası araçlarının alınıp satılmasına olanak sağlayan platformlar olarak ifade edilmektedir. Bu alım satım işlemleri ile iki fiyat arasındaki farktan kaynaklanan zarar ve kazanç elde edilmektedir. Bu durum, finansal/para piyasalarının tahmininin hem akademik hem de iş dünyasında dikkat çekici bir konu olarak karşımıza çıkmasına olanak sağlamıştır.

Bu tez çalışmasında BIST 30 endeks değerinin ve bu endekste yer alan AKBNK, HALKB, GARAN, ISCTR, VAKBN ve YKBANK banka hisse senetlerinin bir gün sonraki kapanış fiyatı tahmin edilmiştir. Tahmin modelinin geliştirilmesindeki iki önemli aşama, veri kümesinin ve yöntemin belirlenmesidir. İlk aşamada tahmin modeli için fiyat verileri, temel ve teknik göstergelerden meydana gelen veri kümesi oluşturulmuştur. Bu değişkenlerden teknik göstergeler, fiyat verilerinden hesaplanmaktadır ve sayıları çok fazladır. Mevcut olan tüm teknik göstergelerin veri kümesinde kullanılmasının aksine teknik göstergelerde bir indirgeme yapılarak sayıları 16'ya azaltılmıştır. İndirgenen teknik göstergelere ek olarak temel gösterge ve fiyat verilerinin de eklenmesiyle veri kümesi son halini almıştır. İkinci aşamada ise, tahmin modeli için Uzun - Kısa Dönemli Bellek Ağları (LSTM) yöntemi kullanılmıştır. Geliştirilen modelin performansı RMSE, MAE ve MAPE metrikleri ile değerlendirilmiştir. İki farklı tahmin için geliştirilen modelin performansı literatürde yer alan çalışmalarla kıyaslanmıştır. Yapılan tahminlerde genel olarak endeks ve hisse senetlerinin yönü (artış/azalış) doğru tahmin edilmiş olup fiyatların dip ve zirve yaptığı noktalarda tahminleme performansının düşük olduğu gözlemlenmiştir. Bu çalışmada indirgenmiş teknik göstergeler ile geliştirilen tahmin modelinin başarı performansının literatürde yer alan sadece fiyat verileri kullanılarak oluşturulan tahmin modelinin başarı performansından daha iyi olduğu gözlemlenmiştir. Ayrıca bu model ile 10.03.2020 - 10.04.2020 tarihleri arasında gerçek zamanlı tahminleme yapılmıştır. Bu tahminlemelerde genel olarak gerçek zamanlı endeks ve hisse senedi yönleri doğru tahmin edilirken fiyat ve endeks değer değişim miktarlarının tahmininde bazı sapmalar olmuştur. Ancak oluşan bu az sayıdaki sapmalara karşılık, bazı günlere ait tahminlerde modelin tahmin ettiği değerlerin gerçek değerlere çok yakın olduğu görülmüştür.

Haziran 2020, 58 sayfa

Anahtar Kelimeler: Finansal piyasa, Hisse senedi, Teknik ve temel göstergeler, BIST 30, Gerçek zamanlı tahminleme, Uzun - kısa dönemli bellek ağları (LSTM).

ABSTRACT

Master's Thesis

A STUDY ON THE VALUE ESTIMATE OF THE BIST 30 INDEX AND STOCKS

Zinnet Duygu Akşehir

Ondokuz Mayıs University
Institute of Graduate Studies
Department of Computer Engineering

Supervisor: Professor Erdal KILIÇ

The stock exchange expressed as platforms that allow the purchase and sale of securities and other capital market instruments. With these trading transactions, losses, and gains arising from the difference between the two prices obtained. This situation has enabled the forecasting of financial/money markets to come across as a remarkable topic in both the academic and business world.

In the thesis, the BIST 30 index and the price of AKBNK, HALKB, GARAN, ISCTR, VAKBN and YKBK bank stocks in this index have been tried to predict the closing prices of the next day. Two important stages in the development of the prediction model are the determination of the dataset and the method. In the first phase, a data set consisting of price data, basic and technical indicators created for the forecast model. Technical indicators, one of this variables, are calculated from price data and are very numerous. In contrast to the fact that all available technical indicators used in the dataset, their numbers reduced by a reduction in this study. In addition to the 16 technical indicators determined as a result of the reduction, the data set became final with the addition of basic indicators and price data. In the second phase, the method of Long - Short Term Memory Networks (LSTM) is used for the prediction model. The performance of the developed model evaluated by RMSE, MAE, and MAPE metrics. The performance of the forecast model developed for two different predictions has compared to studies in the literature. In general, the direction of the index and stocks (increase/decrease) is estimated correctly and the performance of forecasting is low at the points where prices dip and peak. In this study, it observed that the successful performance of the forecast model developed with reduced technical indicators was better than the successful performance of the forecast models created using only price data in the literature. Also, real-time index and stock price estimations made between 10 March 2020 to 10 April 2020 date with this model. While the real-time index and stock aspects were estimated correctly in these estimates, there were some deviations in the estimation of price and index value change amounts. However, in response to these few deviations, it was often observed that the values predicted by the model were very close to the actual values.

June 2020, 58 pages

Key Words: Financial market, Stock, Technical and basic indicators, BIST 30, Real-time estimation, Long - short term memory (LSTM).

ÖNSÖZ VE TEŞEKKÜR

Yüksek lisans tez çalışmamda desteklerini ve değerli bilgilerini esirgemeyen danışman hocam Sayın Prof. Dr. Erdal Kılıç'a ve değerli hocam Doç. Dr. Sedat Akleylek'e, çalışmalarım boyunca maddi manevi destekleriyle hayatımın hiçbir döneminde beni yalnız bırakmayan annem Sabiha ve babam A.Naci Akşehir'e, aynı süreçleri yaşayan ve tez çalışmam boyunca motive olmama yardımcı canım ablam Kumru Akşehir'e, her zaman olduğu gibi bu süreçte de beni destekleyen ve arkamda duran dayım Prof. Dr. Tevfik Özen 'e, çalışma hayatım boyunca desteklerini esirgemeyen arkadaşlarım Arş. Gör. Kübra Seyhan ve Arş. Gör. Gülcan Yıldız'a teşekkürü borç bilirim.

Haziran 2020, Samsun

Zinnet Duygu Akşehir

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
SİMGELER VE KISALTMALAR.....	vi
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ.....	ix
1. GİRİŞ.....	1
1.1. Önceki Çalışmalar.....	1
1.2. Tez Hazırlama Aşamasında Yapılan Çalışmalar.....	9
1.3. Organizasyon.....	10
2. FİNANSAL PİYASALARDA ANALİZ YÖNTEMLERİ.....	12
2.1. Temel Analiz.....	12
2.2. Teknik Analiz.....	13
2.2.1 Dow teorisi.....	13
2.2.2. Teknik analiz göstergeleri.....	15
2.3. Temel ve Teknik Analizin Karşılaştırılması.....	24
3. YÖNTEM.....	25
3.1. Derin Öğrenme.....	25
3.1.1. Tekrarlayan sinir ağları (Recurrent neural network - RNN).....	26
4. ÖNERİLEN MODEL.....	33
4.1. Kullanılan Veri Kümesi.....	33
4.1.1. Fiyat verileri.....	33
4.1.2. Teknik gösterge verileri.....	33
4.1.3. Temel gösterge verileri.....	34
4.2. Veri Ön işleme.....	35
4.3. LSTM Ağı İçin Hiper Parametre Ayarlamaları.....	35
5. BULGULAR.....	37
5.1. BIST 30 Endeks Tahmini.....	37
5.2. BIST 30 Endeksindeki Banka Hisse Senetlerinin Fiyat Tahmini.....	39
6. SONUÇ VE GELECEK ÇALIŞMALAR.....	45
KAYNAKLAR.....	47
EKLER.....	51
EK 1 AKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ.....	52
EK 2 GARAN HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ.....	53
EK 3 HALKB HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ.....	54
EK 4 ISCTR HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ.....	55
EK 5 VAKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ.....	56
EK 6 YKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ.....	57

EK 7 BIST 30 ENDEKSİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ	58
ÖZ GEÇMİŞ	59



SİMGELER VE KISALTMALAR

SİMGELER

okz	Ortalama kazanç.
oky	Ortalama kayıp.
KF	Kapanış fiyatı.
ED	En düşük değer.
EY	En yüksek değer.
TR_t	t anındaki doğru aralık.
OF	Ortalama fiyat.
$OFHO$	Ortalama fiyatın basit hareketli ortalaması.
SO	Sapmanın ortalaması.
σ	LSTM ağı – Sigmoid fonksiyonu.
W	LSTM ağı – ağırlık matrisi.
b	LSTM ağı – ön gerilim vektörü.
o	LSTM ağı – çıkış kapısı.
f	LSTM ağı – unut kapısı.
i	LSTM ağı – giriş kapısı

KISALTMALAR

ADI	Toplama/Dağıtım Endeksi (Accumulation/Distribution Index)
ANN	Yapay Sinir Ağları (Artificial Neural Network)
ARIMA	Otoregresif Bütünleşik Hareketli Ortalama (Auto Regressive Integrated Moving Average)
ARMA	Otoregresif Hareketli Ortalama (Auto Regressive Moving Average)
ATR	Ortalama Gerçek Aralık (Average True Range)
BB	Bollinger Bantları (Bollinger Bands)
BIST	Borsa İstanbul
BPNN	Geri Yayımlı Sinir Ağları (Back Propagation Neural Network)
CBR	Durum Tabanlı Çıkarsama (Case-based Reasoning)
CCI	Mal Kanal Endeksi (Commodity Channel Index)
CMF	Chaikin Para Akış Göstergesi (Chaikin Money Flow)
CNN	Evrişimsel Sinir Ağları (Convolutional Neural Network)
CO	Chaikin Osilatörü (Chaikin Oscillator)

CPU	Merkezi İşlem Birimi (Central Process Unit)
EMA	Üssel Hareketli Ortalama (Exponential Moving Average)
FFNN	İleri Beslemeli Yapay Sinir Ağları (Feed Forward Neural Network)
GPU	Grafik İşlem Birimi (Graphics Processing Unit)
GRU	Geçitlendirilmiş Özyinelemeli Birim (Gated Recurrent Unit)
KC	Keltner Kanalı (Keltner Channel)
LSTM	Uzun - Kısa Dönemli Bellek Ağları (Long - Short Term Memory)
MACD	Hareketli Ortalamaların Birleşmesi/Ayrılması Göstergesi (Moving Average Convergence/Divergence)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
MASS	Mass Endeksi (Mass Index)
MFI	Para Akış Endeksi (Money Flow Index)
OBV	Denge İşlem Hacmi (On Balance Volume)
RMSE	Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Network)
RSI	Göreceli Güç Endeksi (Relative Strength Index)
SMA	Basit Hareketli Ortalama (Simple Moving Average)
SO	Stokastik Osilatör (Stochastic Oscillator)
SVM	Destek Vektör Makinesi (Support Vector Machine)
WMA	Ağırlıklandırılmış Hareketli Ortalama (Weighted Moving Average)

ŞEKİLLER DİZİNİ

Şekil 3.1. Yapay zekânın alt dalları	25
Şekil 3.2. İleri beslemeli ve tekrarlayan sinir ağı mimarilerinin karşılaştırılması	26
Şekil 3.3. Katmanları zaman boyunca açık hale getirilen genel RNN mimarisi.....	27
Şekil 3.4. Genel RNN mimarisi.	29
Şekil 3.5. LSTM mimarisi.....	29
Şekil 3.6. LSTM ağı - unut kapısı	30
Şekil 3.7. Hücre durumunun güncellenmesi	30
Şekil 3.8. Hücrenin yeni durumunun hesaplanması.....	31
Şekil 3.9. LSTM ağı - çıkış kapısı.....	31
Şekil 4.1. Tanh aktivasyon fonksiyonu	36
Şekil 5.1. BIST 30 endeksinin geliştirilen modeldeki başarısı	38
Şekil 5.2. AKBNK hisse senedinin geliştirilen modeldeki başarısı.....	40
Şekil 5.3. GARAN hisse senedinin geliştirilen modeldeki başarısı.....	41
Şekil 5.4. HALKB hisse senedinin geliştirilen modeldeki başarısı	41
Şekil 5.5. ISCTR hisse senedinin geliştirilen modeldeki başarısı.....	42
Şekil 5.6. VAKBN hisse senedinin geliştirilen modeldeki başarısı.....	42
Şekil 5.7. YKBNK hisse senedinin geliştirilen modeldeki başarısı.....	43

ÇİZELGELER DİZİNİ

Çizelge 5.1. Önerilen hisse senedi tahmin modelinin başka bir model (Raşo ve Demirci, 2019) ile karşılaştırılması.	38
Çizelge 5.2. BIST 30 endeksinin kapanış ve gerçek zamanlı tahmin değerleri	39
Çizelge 5.3. Önerilen hisse senedi tahmin modelinin başka bir model (Tekin ve Çanakoğlu, 2019) ile karşılaştırılması.....	40
Çizelge 5.4. Hisse senetlerinin kapanış ve gerçek zamanlı tahmin değerleri	44



1. GİRİŞ

Mevcut verileri analiz edip bu analize dayalı gelecekteki davranışın tahmin edilmesi her dönemin ilgi çekici konuları arasında yer almaktadır. Özellikle de kâr getirisi sağlayan para/finansal piyasalarda bu tahminleme modelinin uygulanması hem akademik hem de iş dünyasının en önemli konularından biri haline gelmiştir.

Para piyasaları karmaşık bir yapıya sahiptir. Bu karmaşıklığın sebebi olarak, piyasalardaki belirsizlik ve hareketlilik (oynaklık), siyasi olaylar, genel ekonomik durum, diğer ülke piyasalarındaki hareketler, yatırımcıların beklentileri gibi pek çok siyasi, sosyal ve ekonomik faktörler sayılabilir. Tüm bu faktörler, tahmin modellerinin para piyasalarında uygulanarak gelecekteki davranışın net bir şekilde belirlenmesini oldukça güç bir hale getirmektedir (Kara vd, 2011). Belirtilen bu faktörler yatırımcıların psikolojilerini etkileyerek arz ve taleplerde değişiklikler meydana getirmekte ve bunun sonucunda piyasada doğrusal olmayan dalgalanmalar yaratmaktadır. Bu dalgalanmalar da para piyasalarındaki gelecek davranışın tahmin edilebilirliğini güçleştirmektedir. Bu durum karşısında, geleneksel yöntemlerden daha başarılı tahminler üretilebilen yöntemlerin belirlenmesi araştırmacılar için önemli bir araştırma konusu olmuştur. Yapılan araştırmalar sonunda, son zamanlarda popülerliği artan derin öğrenme yöntemlerinin para piyasaları tahmininde başarılı sonuçlar verdiği ortaya çıkmıştır.

Para piyasaları davranışlarının tahmininde iki önemli aşama söz konusudur. Bunlardan birincisi davranış (hareketi) etkileyen en baskın ya da temel faktörlerin neler olduğunun, başka bir deyişle geliştirilecek tahmin modelinde kullanılacak girdi değişkenlerinin belirlenmesidir. İkincisi ise tahmin modelinde kullanılacak olan yöntemin belirlenmesi olarak karşımıza çıkmaktadır.

1.1. Önceki Çalışmalar

Para piyasaları; hisse senetleri, endeksler, vadeli işlem sözleşmeleri gibi finansal varlıklardan meydana gelmekle birlikte tüm bu varlıklar finansal zaman serileri olarak ele alınmaktadır. Finansal varlıkları etkileyen çok fazla faktörün bulunması ve bu faktörlerin de finansal varlıkların fiyatları üzerinde doğrusal olmayan davranışlara sebep olmasından dolayı finansal zaman serilerinde tahmin yapmak oldukça güçtür.

Bu doğrultuda, finansal zaman serileri tahmininde genel olarak zaman serileri analizlerinden Otoregresif Hareketli Ortalamalar modelleri ARMA/ARIMA; yapay zekâ tekniklerinden Regresyon, Karar Ağaçları, Destek Vektör Makineleri ve Yapay Sinir Ağlarının sıklıkla kullanılmasıyla beraber son yıllarda derin öğrenme yöntemlerinin de ön plana çıktığı gözlemlenmektedir. Ayrıca, finansal zaman serileri kapsamında yapılan çalışmalar incelendiğinde genel olarak borsa ve hisse senedi endekslerinin değer ve yön tahminleri üzerine yoğunlaştığı görülmektedir.

Diler, IMKB 100 endeksinin bir gün sonraki yönünü Yapay Sinir Ağları (Artificial Neural Network - ANN) algoritmalarından hatayı geriye yayma algoritmasını kullanarak tahmin etmeye çalışmıştır. Analiz dönemi, 1990 yılı başından 11 Kasım 2003'e kadar olan dönem olarak belirlenmiştir. Modelin oluşturulması sırasında, algoritmanın parametrelerinin belirlenmesi için 15 farklı deneme yapılmıştır. Bu denemelerin sonucunda 10 gizli katmanın kullanılması, momentum katsayısının 0,1 ve öğrenme parametresinin 0,08 olması gerektiği kanaatine varılmıştır. Çalışmada girdi değişkenleri olarak 10 günlük basit hareketli ortalama (Simple Moving Average - SMA), 5 ve 10 günlük ağırlıklandırılmış hareketli ortalama (Weighted Moving Average - WMA), 10 günlük momentum, stokastik gösterge (%K), göreceli güç endeksi (Relative Strength Index - RSI), hareketli ortalamanın birleşmesi/ayrılması (Moving Average Accumulation/Distribution - MACD) teknik göstergeleri kullanılmış ve IMKB 100 endeksinin günlük getiri değerleri belirlenmiştir. IMKB 100 endeksinin bir gün sonraki yönü geliştirilen bu model ile %60,81 oranında doğru tahmin edilmiştir (Diler, 2003).

Kim tarafından gerçekleştirilen çalışmada, KOSPI endeksinin günlük yönünü tahmin etmek için girdi değişkenlerinde 12 adet teknik gösterge kullanan Destek Vektör Makinesi (Support Vector Machine - SVM) yöntemi kullanılmıştır. Geliştirdiği bu modelin analiz dönemini Ocak 1989 - Aralık 1998 olarak belirlemiştir. Ayrıca modelin performansını Geri Yayılım Sinir Ağları (Back Propagation Neural Network - BPNN) ve Durum Tabanlı Çıkarsama (Case-based Reasoning - CBR) yöntemleri ile karşılaştırmıştır. Geliştirmiş olduğu modelin her iki yönüme oranla daha iyi performans gösterdiği belirtilmiştir (Kim, 2003).

Karaatlı ve arkadaşları, IMKB 100 endeks değerini, regresyon ve çok katmanlı yapay sinir ağı modelini kullanarak tahmin etmeye çalışmıştır. Analiz dönemi Ocak 1960 - Aralık 2002 şeklinde belirlenmiş olup veriler aylık olarak ele alınmıştır.

Çalışmada kullanılan bağımsız girdi değişkenleri; hazine bonosu faiz oranı, cumhuriyet altın fiyatı, enflasyon oranı, sanayi üretim endeksi, tasarruf mevduatı faiz oranı, döviz kuru ve zaman değişkenleri iken bağımlı değişken ise IMKB 100 endeksinin bir gün sonraki değeri seçilmiştir. Oluşturulan ANN modelinde 3 gizli katman kullanılmış olup bu katmanların nöron sayıları sırasıyla 7, 3 ve 3 şeklindedir. Modellerin performansı ortalama karesel hatanın karekökü (Root Mean Square Error - RMSE) metriği ile değerlendirilmiştir. ANN modelinin RMSE değeri 1311,65 iken regresyon modelinin ise 2002,5625 olarak hesaplanmıştır. Dolayısıyla RMSE değerlerine bakıldığında ANN modelinin daha başarılı olduğu görülmüştür (Karaatlı vd, 2005).

Altay ve Satman, IMKB 30 endeksini tahmin etmek için ANN ve regresyon yöntemlerini kullanmıştır. Her bir yöntem için verileri hem günlük hem de aylık olarak ele alıp toplamda dört farklı model geliştirilmiştir. Modeller karşılaştırıldığında verilerin günlük ve aylık olarak ele alınması durumları için regresyon modelinin daha başarılı olduğu görülmüştür. Ayrıca ANN yöntemi kullanılarak oluşturulan modellerin genel olarak endeks yönünü doğru tahmin ettiği belirtilmiştir (Altay ve Satman, 2005).

Sui vd (2007), Shangay borsası endeksinin yönünü SVM yöntemi ile tahmin etmeye çalışmıştır. Analiz dönemi 28 Nisan 1997 - 12 Eylül 2006 olarak belirlenmiştir. Çalışmada girdi değişkenleri olarak Alexander filtresi, RSI, para akış endeksi (Money Flow Index - MFI), Bollinger bantları (Bollinger Bands - BB), Chaikin osilatörü (Chaikin Oscillator - CO), MACD, Stokastik %K, A/D (Accumulation/Distribution) osilatörü ve Williams' %R teknik göstergeleri kullanılmıştır. Bu teknik göstergelerle yapılan tahmin çalışmasında %54,25 başarı oranı elde edilmiştir.

Akel ve Bayramoğlu (2008), IMKB 100 endeks tahminini gerçekleştirmek için ANN yöntemi ile bir model geliştirmiştir. Geliştirilen bu modelin analiz dönemi 4 Ocak 1999 - 28 Şubat 2001 olarak belirlenmiştir. Modele verilecek girdi kümesi ise USD/TL kuru, IMKB işlem hacmi, merkez bankası döviz rezervleri, merkez bankası bir aylık mevduat faiz oranı ve altın borsası değişkenlerinden oluşturulmuştur. Oluşturulan modelin performansını değerlendirmek için ortalama mutlak yüzde hata (Mean Absolute Percentage Error - MAPE) metriği kullanılmış olup IMKB 100 endeks tahmini için bu değer 1,12 olarak elde edilmiştir.

Kutlu ve Badur (2009), İleri Beslemeli Yapay Sinir Ağları (Feed Forward Neural Network - FFNN) yaklaşımı ile IMKB 100 endeksinin tahmin edilebileceğini öne

sürerek bu doğrultuda bir çalışma gerçekleştirmiştir. Çalışmada 2 Temmuz 2001 - 13 Temmuz 2006 tarihleri arasındaki veriler kullanılmıştır. Model girdi değişkenleri olarak önceki günün endeks, Amerikan doları, gecelik faiz oran değerlerine ek olarak önceki günün Fransa, Almanya, İngiltere, S&P 500, Brezilya ve Japonya borsa endeks değerleri kullanılmıştır. Bu girdi değişkenlerine haftanın günlerini temsil eden beş kukla değişkeni de eklenmiştir. Bu değişkenler kullanılarak üç farklı model oluşturulmuştur. Oluşturulan modeller ve bu modellerde kullanılan girdi değişkenleri şu şekildedir:

- ✓ Model 1 : Önceki günün endeks değeri, Amerikan doları ve gecelik faiz oranı değerleri
- ✓ Model 2 : Model 1'in girdi değişkenleri + beş kukla değişkeni
- ✓ Model 3 : Model 2'nin girdi değişkenleri + Fransa, Almanya, İngiltere, Brezilya, Japonya ve S&P 500 endeks değerleri

Oluşturulan üç model ile IMKB 100 endeksinin bir gün sonraki değeri tahmin edilmeye çalışılmış ve modellerin performansı belirlilik katsayısı metriği R^2 ile değerlendirilmiştir. Yapılan değerlendirmeler sonunda Model 1'in belirlenen analiz dönemi için en yüksek R^2 değerine sahip olduğu (0,92), dolayısıyla bu modelin daha başarılı tahminler yaptığı gösterilmiştir (Kutlu ve Badur, 2009).

Yakut vd (2014), 3 Ocak 2005 - 31 Aralık 2012 tarihleri arasındaki verileri ele alarak BIST 100 endeks değerini tahmin etmeye çalışmıştır. Tahmin işlemlerini gerçekleştirmek için FFNN ve SVM yöntemleri kullanılmıştır. Çalışmada girdi değişkenleri geçmiş üç günün BIST 100 endeks değerleri, gecelik faiz oranları, USD/TL kuru ve Japonya, Brezilya, İngiltere, Fransa, Almanya borsasının bir gün önceki endeks değeri şeklinde belirlenmiştir. Bu girdi değişkenleri kullanılarak her bir yöntem için 9 farklı model oluşturulmuştur. FFNN ile gerçekleştirilen tahminde 0,972 R^2 değerine sahip Model 1 ve Model 2'nin daha başarılı bir tahmin yaptığı raporlanmıştır. SVM ile yapılan tahminde ise 0,977 R^2 değerine sahip Model 3'ün diğer modellere göre daha başarılı bir tahmin yaptığı gösterilmiştir.

Inthachot vd (2015), girdi değişkenlerinde 10 teknik gösterge kullanan ANN ve SVM yöntemleri ile Tayland borsasının endeksini tahmin etmeye çalışmıştır. Her iki modelin tahmin performansı değerlendirildiğinde ANN ile oluşturulan modelin daha başarılı tahminler yaptığı görülmektedir.

Gündüz vd (2017), Borsa İstanbul'da işlem gören üç hisse senedinin (GARAN, THYAO, ISCTR) günlük değişim yönlerini derin sinir ağlarından Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN) yöntemini kullanarak tahmin etmeye çalışmıştır. Oluşturdukları model için analiz dönemi Ocak 2011 - Aralık 2015 olarak belirlenmiştir. Tahmin modeli için iki farklı veri kümesi oluşturulmuştur. Veri kümesinin ilki hisse senetlerinin açılış, kapanış, en yüksek, en düşük değerleri ve bu değerlerden hesaplanan teknik göstergeler ile oluşturulmuştur. Ardından dolar ve altın fiyatlarındaki değişimin bu hisse senetleri üzerinde bir etkisinin olup olmadığını belirlemek amacıyla ikinci bir veri kümesi oluşturulması kanaatine varılmıştır. Bu veri kümesi, dolar ve altın fiyatlarına ek olarak bu fiyatlardan hesaplanan 29'ar (altın ve dolar için) teknik göstergeden meydana gelmektedir. Bu iki veri kümesi ile yapılan deneyler sonucunda (iki veri kümesinin ayrı ayrı ve beraber kullanılması) fiyat özniteliklerine ek olarak dolar - altın özniteliklerinin de kullanılmasının her üç hisse senedi için de sınıflandırma performansını arttırdığı gösterilmiştir.

Gao vd (2017) yapmış oldukları çalışmada, Uzun - Kısa Dönemli Bellek Ağları (Long - Short Term Memory - LSTM) yöntemi ile S&P 500'ün bir gün sonraki kapanış fiyatını tahmin etmeye çalışmıştır. Oluşturulan modelde girdi değişkenleri olarak S&P 500'ün 3 Ocak 2000 - 10 Kasım 2016 tarihleri arasındaki işlem verileri (gün içi en düşük, gün içi en yüksek, açılış, kapanış, hacim ve düzeltilmiş fiyat değerleri) kullanılmıştır. LSTM yöntemiyle oluşturulan modelin performansı Hareketli Ortalama (Moving Average - MA), Üssel Hareketli Ortalama (Exponential Moving Average - EMA) ve SVM yöntemleri ile oluşturulan modellerle kıyaslanmıştır. Bu dört model ile yapılan tahminler incelendiğinde LSTM modelinin daha başarılı tahminler yaptığı görülmüştür.

Nelson vd (2017), BM&F Bovespo borsasında yer alan IBovespo indeksindeki beş hisse senedinin (BOVA11, BBDC4, CIEL3, ITUB4 ve PETR4) gelecek 15 dakika içindeki fiyatının, şu ankinden daha yüksek olup olmayacağını LSTM yöntemi ile belirlemeye çalışmıştır. Girdi değişkenleri kümesi, beş hisse senedinin 2008 - 2015 yılları arasındaki fiyat verileri ve bu fiyat verilerinden hesaplanan teknik göstergeler olmak üzere toplam 180 öznitelikten oluşmaktadır. LSTM yöntemi ile bu beş hisse senedinin bir sonraki yön tahmini için %53 - 55 oranında doğruluk değerleri elde edilmiştir.

Selvin vd (2017) yapmış oldukları çalışmada, NSE borsasında listelenen üç şirkete (Infosys, TCS, Cipla) ait hisse senetlerinin fiyatlarını tahmin etmeye çalışmıştır. Tahmin işlemini gerçekleştirmek için derin öğrenme yöntemlerinden Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN), LSTM ve CNN kullanılırken zaman serisi analizi yöntemlerinden ise Otoregresif Bütünleşik Hareketli Ortalamalar (Auto Regressive Integrated Moving Average - ARIMA) modeli kullanılmıştır. Bu modellerin girdi değişkenleri, hisse senetlerinin Haziran 2014 - Temmuz 2015 tarihleri arasındaki fiyat verilerinden oluşmaktadır. Oluşturulan dört modelin performansı karşılaştırıldığında derin öğrenme modellerinin ARIMA modelinden daha başarılı olduğu gözlemlenirken, derin öğrenme modellerinden CNN'in ise daha başarılı olduğu raporlanmıştır.

Parmar vd (2018), bir şirkete ait hisse senedinin gelecekteki değerini LSTM ve regresyon yöntemleriyle tahmin etmeye çalışmıştır. Bu modeller için belirlenen veri kümesi; hisse senedinin açılış, kapanış, en yüksek, en düşük ve hacim değerlerini içeren yaklaşık 900.000 kayıttan meydana gelmektedir. Oluşturulan modeller karşılaştırıldığında LSTM modelinin regresyon modelinden daha başarılı olduğu belirtilmiştir.

Hossain vd (2018), S&P 500 endeksinin bir gün sonraki kapanış fiyatını tahmin etmek için hibrit bir model önermiştir. Önermiş oldukları bu hibrit model, LSTM ve Geçitlendirilmiş Özyinelemeli Birim (Gated Recurrent Unit - GRU) yöntemlerinden meydana gelmektedir. Çalışmada kullanılan veri kümesi, 66 yıllık S&P 500 verilerinden (açılış, kapanış, hacim değerleri ve tarih) oluşmaktadır. Önerilen hibrit modelin başarısı ise 0,00098 MSE olarak hesaplanmıştır.

Du vd (2019), Apple hisse senedinin bir gün sonraki kapanış fiyatını tahmin etmek için LSTM yöntemini kullanan bir model oluşturmuştur. Oluşturulan modele iki farklı girdi değişken kümesi verilerek tahmin performansları kıyaslanmıştır. Girdi kümelerinin ilki, Apple hisse senedinin kapanış fiyatlarından oluşurken ikincisi ise kapanış fiyatına ek olarak açılış, gün içi en yüksek, gün içi en düşük ve hacim değerleri ile birlikte diğer faktörlerden meydana gelmektedir. İki farklı girdi değişken kümesi ile oluşturulan modellerin performansları karşılaştırıldığında birden fazla değişkenden meydana gelen ikinci girdi kümesi kullanılarak yapılan tahminlerin daha başarılı olduğu görülmüştür.

Tekin ve Çanakoğlu (2019) BIST 30 şirketlerine ait verilere zaman serisi modellerinden ARIMA'yı, makine öğrenmesi algoritmalarından Lojistik Regresyon, Çok Katmanlı Algılayıcı, Rassal Orman, Rastgele Karar Ağaçlarını ve derin öğrenme yöntemlerinden de LSTM'i uygulayarak bu şirketlere ait hisse senetlerinin fiyatlarını tahmin etmeye çalışmıştır. Oluşturulan tahmin modellerinde girdi değişkenleri olarak sadece hisse senedi fiyat verileri kullanılmıştır. Modellerin performansı MAE ve RMSE metrikleri ile değerlendirilmiş olup ARIMA modelinin LSTM modelinden daha başarılı olduğu ve makine öğrenmesi yöntemleri ile oluşturulan modellerden ise regresyon modelinin daha iyi tahminler yaptığı sonucu elde edilmiştir.

Raço ve Demirci (2019) BIST 30'un gelecek beş işlem günü için endeks değerlerini derin öğrenme yöntemiyle tahmin etmeye çalışmıştır. Analiz dönemi 1 Ocak 2016 - 11 Nisan 2018 olarak belirlenmiş olup verilerin ilk %80'ini eğitim, kalan %20'sini ise test kümesi olarak kullanmıştır. Modelin girdi değişkenleri ise BIST 30 fiyat verilerine ek olarak bu fiyat verilerinden hesaplanan teknik göstergelerden meydana gelmektedir. Modelin sonuçları değerlendirildiğinde literatürde yer alan benzer çalışmalardan daha başarılı sonuçlar elde edildiği raporlanmıştır.

Ünal ve Aladağ (2019), yapmış oldukları çalışmada LSTM, FFNN ve ARIMA yöntemleriyle BIST 100 endeksini tahmin etmeye çalışmıştır. Belirlenen LSTM, FFNN yöntemleri için tek ve iki gizli katmana sahip toplam dört model geliştirilmiştir. Modellerin performansı RMSE ve MAPE metrikleri ile değerlendirilmiştir. Sonuçlar değerlendirildiğinde iki gizli katman içeren FFNN ve LSTM modellerinin tahmin performansının daha başarılı olduğu görülmüştür.

Alhazbi vd (2020), Katar borsasının günlük yönünü derin öğrenme yöntemlerinden CNN ile tahmin etmeye çalışmıştır. Bu tahmini gerçekleştirirken petrol fiyatı gibi dış etkenlerin borsa yönünü etkileyip etkilemedikleri de araştırılmıştır. Bu etkiyi incelemek için iki farklı veri kümesi oluşturulmuştur. Birinci veri kümesi sadece Katar borsasının fiyat verilerinden meydana gelirken ikinci veri kümesi ise bu fiyat verisine ek olarak petrol fiyatı, S&P 500 ve Nikkei indeks verilerinden meydana gelmektedir. Analiz dönemi 1 Ocak 2014 - 31 Aralık 2018 şeklinde belirlenmiş olup verilerin %80'i eğitim geriye kalan %20'si ise test verisi olarak ele alınmıştır. Katar borsasının bir gün sonraki yönünün tahmini için geliştirilen modele her iki veri kümesi uygulanarak tahmin performansları değerlendirilmiştir. Sadece Katar borsası fiyat verileri kullanıldığında doğruluk oranı %67,1 elde edilirken

diğer veri kümesi ile %74 doğruluk oranına ulaşılmıştır. Katar borsası fiyat verilerine ek olarak dış etkenlerin de eklenmesiyle oluşturulan veri kümesinin tahmin performansını yaklaşık %7 oranında arttırdığı belirtilmiştir.

Vijh vd (2020), makine öğrenmesi tekniklerinden ANN ve Rassal Orman yöntemlerini kullanarak New York borsasında yer alan beş hisse senedinin bir gün sonraki kapanış fiyatını tahmin etmeye çalışmıştır. Çalışmada 4 Mayıs 2009 - 4 Mayıs 2019 tarihleri arasındaki veriler ele alınmıştır. Girdi değişkenlerinde, hisse senedi fiyat verileri, gün içi yüksek ve düşük değer arasındaki fark, açılış ve kapanış değeri arasındaki fark, 7, 14 ve 21 günlük hareketli ortalama ve 7 günlük standart sapma değeri kullanılmıştır. Her iki yöntemle oluşturulan tahmin modellerinin performansı RMSE ve MAPE metrikleri ile değerlendirilmiştir. ANN ile geliştirilen tahmin modelinin performansının rassal orman ile geliştirilen modele oranla daha başarılı olduğu belirtilmiştir.

Yukarıda incelenen yurt içi ve yurt dışı borsa endeks ve hisse senedi fiyat tahmin çalışmaları göz önüne alındığında girdi değişkenleri ve kullanılan yöntemlerde farklılıkların olduğu görülmüştür. Tahmin modellerinin girdi değişkenleri incelendiğinde çalışmaların genelinde borsa ve hisse senedi fiyat verilerinin kullanıldığı (açılış, kapanış, gün içi en yüksek, gün içi en düşük ve hacim değerleri) görülürken çalışmaların bazılarında ise bu fiyat verilerine ek olarak farklı teknik göstergelerin kullanıldığı tespit edilmiştir. Tahmin modelinde kullanılan yöntemler incelendiğinde ise bu çalışmaların çoğunda sadece borsa ve hisse senedi fiyat verileri kullanılıp bu veriler doğrusal olmayan veriler kabul edildiği için tahminlemede de doğrusal olmayan veriler için geliştirilmiş olan destek vektör makinesi, yapay sinir ağları gibi yöntemler daha çok tercih edilmiştir. Son yıllarda yapılan çalışmalar incelendiğinde ise derin öğrenme yöntemlerinden özellikle LSTM'in ön planda olduğu görülmüştür.

Yapılan literatür araştırmaları göz önünde bulundurulduğunda bu tez çalışması kapsamında gerçekleştirilecek tahmin modeli için LSTM yönteminin kullanılmasına karar verilmiştir. Bu kararın verilmesinde:

- ✓ Son yıllardaki borsa endeks/hisse senedi fiyat tahmin çalışmalarında LSTM yönteminin ön planda olması,
- ✓ LSTM'in, kullanılan veri kümesi üzerinden öznetelik çıkarımını sağlayan algoritmalar ailesinden olması,

- ✓ LSTM modelinin hızlı olması,
- ✓ Zaman serileri ile çalışılması,
- ✓ Uzun süreli bağımlılıkların, geliştirilecek bu tahmin modeli açısından önemli bir etkiye sahip olması,
- ✓ Sahip olduğu hafıza sayesinde hangi bilgilerin saklanıp hangilerinin saklanmayacağı kararını verebilmesi gibi durumlar etkili olmuştur.

Tez çalışması kapsamında geliştirilecek model için LSTM yönteminin kullanılması kararı verildikten sonraki aşama ise bu tahmin modelinde kullanılacak girdi değişkenlerinin belirlenmesidir. Yapılan literatür çalışmaları genellikle fiyat verilerini girdi değişkeni olarak ele alırken bu tez kapsamında fiyat verilerine ek olarak teknik ve temel göstergelerin de girdi değişkenleri kümesinde yer alması gerektiği düşünülmüştür. Bu doğrultuda teknik göstergeler incelendiğinde sayıca çok fazla oldukları ve aslında bu teknik göstergelerin tamamının tahmin modeli için yeterli öneme sahip olmadığı görülmüştür. Bu sebeple ilk önce teknik göstergelerde indirgeme yoluna gidilmiştir. Teknik göstergelerdeki gerekli indirgemelerin yapılması ile girdi değişkenleri kümesi oluşturulmuştur. Böylece tahmin modeli için önemli olan, yöntem ve girdi değişkenlerinin belirlenme aşamaları tamamlanmıştır.

Bu doğrultuda tez çalışması kapsamında LSTM yöntemi ve belirlenen girdi değişkenleri kümesi kullanılarak bir tahmin modeli geliştirilmiştir. Geliştirilen bu model ile iki farklı tahmin gerçekleştirilmiştir. Bunlar:

- ✓ BIST 30 endeksinin,
- ✓ BIST 30 endeksinde yer alan AKBNK, GARAN, HALKB, ISCTR, VAKBN ve YKBANK banka hisse senetlerinin bir gün sonraki kapanış fiyatlarının tahmin edilmesidir.

1.2. Tez Hazırlama Aşamasında Yapılan Çalışmalar

Bu tezin tamamlanmasına kadar gerçekleştirilen çalışmalar üç başlık altında toplanmıştır:

- ✓ BIST 30 endeksinde yer alan beş banka hisse senedinin bir gün sonraki kapanış fiyatının Karar Ağacı ve Çoklu Regresyon yöntemiyle tahmin edilmesi.

- ✓ İlk çalışmadaki makine öğrenmesi tekniklerine ek olarak Rassal Orman yönteminin de eklenerek BIST 30 endeksinde yer alan beş banka hisse senedinin bir gün sonraki kapanış fiyatının tahmin edilmesi.
- ✓ BIST 30 endeksinde yer alan iki banka hisse senedinin bir gün sonraki kapanış fiyatının LSTM modeli ile tahmin edilmesi.

BIST 30 endeksinde yer alan beş banka hisse senedinin kapanış fiyatının tahmin edilmesinde makine öğrenmesi tekniklerinden Karar Ağacı ve Çoklu Regresyon yöntemlerinden oluşan iki model geliştirilmiştir. Oluşturulan bu iki model için iki farklı veri kümesi kullanılmıştır. Birinci veri kümesi 46 teknik ve 4 temel gösterge olmak üzere toplam 50 göstergeden oluşmaktadır. İkinci veri kümesi ise bu 46 teknik gösterge üzerinde bir öznetelik azaltma çalışması yapılarak belirlenen 29 teknik ve 4 temel göstergeden oluşan toplam 33 göstergeyi içermektedir. Her iki veri kümesinde temel ve teknik göstergelere ek olarak hisse senetlerinin fiyat verileri de kullanılmıştır. Her iki modelde bu iki farklı veri kümesi kullanılarak AKBNK, GARAN, HALKB, ISCTR ve YKBANK hisse senetlerinin bir gün sonraki kapanış fiyatı tahmin edilmiş ve modellerin performansları (Akşehir ve Kılıç, 2019a) çalışmasında değerlendirilmiştir.

Akşehir ve Kılıç (2019a), çalışmadaki modellere ek olarak makine öğrenmesi tekniklerinden Rassal Orman modelinin de eklenmesi ile bu çalışma genişletilmiştir. Oluşturulan üçüncü model, önceki modelde kullanılan iki farklı veri kümesini temel olarak geliştirilmiş ve bu model ile beş banka hisse senedinin bir gün sonraki kapanış fiyatı tahmin edilmiştir. Modellerin tahmin başarıları Akşehir ve Kılıç (2019b)'ın çalışmasında karşılaştırılmıştır.

Son olarak, BIST 30 endeksinde yer alan AKBNK ve GARAN hisse senetlerinin bir gün sonraki kapanış fiyatı, geliştirilen LSTM modeli ile tahmin edilmiştir. Bu modelde girdi değişkenleri olarak hisse senedi fiyat verileri ile 29 teknik ve 4 temel gösterge kullanılmıştır. İki hisse senedi için oluşturulan modelin tahmin performansı ve başarı grafiği Akşehir vd (2020) çalışmasında verilmiştir.

1.3. Organizasyon

Bölüm 2'de, finansal piyasaların analizinde kullanılan iki önemli analiz türü olan temel ve teknik analiz kavramlarından bahsedilmiştir. Ardından teknik analizin temel varsayımlarından ve teknik analizin temeli kabul edilen Dow Teorisi'nin temel ilkelerinden bahsedilip teknik analizde kullanılan göstergelere değinilmiştir.

Uygulama kısmında geliřtirdiđimiz tahmin modellerinde kullanılan gstergelere deđinilmiř ardından bu gstergelerin nasıl hesaplandıđı ve yorumlandıđı hakkında bilgi verilmiřtir.

Blm 3’te, derin đrenme yntemi detaylandırılarak RNN’den bahsedilmiřtir. Ayrıca RNN’in zelleřmiř hali olan LSTM yntemi detaylandırılarak genel zellikleri aıklanmıřtır.

Blm 4’te, tez kapsamında nerilen tahmin modelinden bahsedilmiřtir. ncelikle uygulamada gerekleřtirilecek iki model iin kullanılan veri kmesi hakkında bilgi verilmiřtir. Ardından bu iki tahmin modeli iin belirlenen Uzun - Kısa Dnemli Bellek Ađları ynteminin hiper parametreleri ele alınmıřtır.

Blm 5’te, geliřtirilen iki tahmin modeli ile elde edilen analiz sonuları tablolar ve grafikler kullanılarak yorumlanmıřtır.

Son blmde ise uygulama sonucunda elde edilen bulgular deđerlendirilmiř ve yapılması dřnlen gelecek alıřmalardan sz edilmiřtir.

2. FİNANSAL PİYASALARDA ANALİZ YÖNTEMLERİ

Genel olarak finansal piyasa değerleri ekonomik parametreler, siyasi olaylar, yatırımcı hareketleri gibi birçok belirsiz faktörün etkisi altında kalmaktadır. Bu sebeple piyasanın eğilimini ve analizini tahmin etmek zordur. Yatırımcılar da piyasa hareketleri karşısında finansal piyasaları iyi tanıyarak kazançları en üst düzeye çıkarmak, zarara uğramayıp kâr fırsatlarını kaçırmamak için çeşitli analizlerden yararlanmaktadır. Yatırımcıların en çok tercih ettikleri analizler ise temel ve teknik analizdir. Bu analizlerde, geçmiş verilerden yola çıkılarak mevcut durum ve gelecekle ilgili somut verilere ilişkin tahminlerin yapılması amaçlanmaktadır (Civan, 2007).

Bu bölümde finansal piyasa analizlerinde yaygın olarak kullanılan temel ve teknik analiz kavramları detaylandırılmıştır. Ardından, en eski ve en bilinen teknik analiz teorilerinden bir tanesi olan Dow Teorisi hakkında bilgi verilip teknik analiz göstergelerine değinilmiştir. Uygulama kapsamında oluşturulan modellerde girdi kümesinde yer alan teknik analiz göstergeleri açıklanarak bu göstergelerin nasıl hesaplandığı ve yorumlandığı hakkında genel bilgiler verilmiş, son olarak temel ve teknik analizin karşılaştırılması yapılmıştır.

2.1. Temel Analiz

Temel analiz, analiz edilecek olgunun yönünü tahmin etmek için kullanılan yöntemlerden bir tanesidir. Olguya ait geçmiş fiyat hareketlerinin gelecekteki fiyat hareketlerini tahmin etmek için kullanılamayacağı esasına dayanmaktadır. Olgunun performansını etkileyen faktörler temel göstergeler olarak adlandırılmaktadır. Temel analiz, bu temel göstergelerin tespit edilip olguya ait gerçek değer bulunmasını ve mevcut piyasa değeri ile karşılaştırma yapılmasını sağlamaktadır (Avşar ve Avşar, 2010).

Temel göstergeler, ithalat, ihracat, faiz oranı, döviz kurları, enflasyon oranı gibi birçok farklı makroekonomik faktörden etkilenmektedir. Ayrıca bu faktörlere arz talep ilişkisi ve piyasa psikoloji üzerinde etkisi olduğu düşünülen haberler de eklenmektedir. Temel analizi gerçekleştirmek için bu olguları etkileyen faktörlerin yani temel göstergelerin iyi tespit edilmesi gerekmektedir. Örneğin, bir hisse senedinin fiyat tahmininde temel analizden yararlanılacaksa o hisse senedi ve ait olduğu firma

hakkındaki her türlü bilginin değerlendirilmesi gerekmektedir. Bu bilgiler de firmanın varlıkları, gelir ve gider durumu, büyüme potansiyeli gibi değerleri içermektedir (Büyükdere, 2002).

2.2. Teknik Analiz

Finansal piyasaların analizinde sıklıkla kullanılan diğer bir yöntem ise teknik analizdir. Teknik analiz, bir hisse senedinin veya endeksin geçmiş fiyat verilerini kullanarak bu olguların gelecekteki fiyatını tahmin etmeyi amaçlamaktadır. Bu analiz yapılırken olgunun fiyat, işlem miktarı gibi verileri grafiklere aktarılmaktadır. Bu grafikler yardımıyla olgunun geçmişteki davranışlarına bakılarak gelecekteki olası gidişatı tahmin edilmeye çalışılmaktadır.

Teknik analizciler, finansal piyasalardaki bir olguya ait fiyat hareketlerinin tamamen rastgele olmadığını ve geçmişte meydana gelen davranışların gelecekte de tekrar edeceği varsayımını kabul etmektedir (Birgili, 1994). Teknik analize göre bir olguya ait analiz gerçekleştirilirken ekonomik faktörlerin incelenmesi zorunlu değildir. Teknik analizde önemli olan olgunun trendi, arz - talebi yani piyasadaki fiyatı ve işlem miktarıdır.

Özetlemek gerekirse teknik analiz, fiyat her şeyin göstergesidir felsefesini temel almaktadır. Bir olgunun piyasa fiyatına etki yapabilecek politik etkiler, psikolojik durum gibi tüm faktörlerin aslında olgunun fiyatını etkilediği düşüncesiyle bu olgunun gelecekte nasıl bir davranışta bulunacağını yani hareketin (trendin) ne olacağını tahmin etmeyi hedeflemektedir.

2.2.1 Dow teorisi

Dow Teorisi, en eski ve en bilinen teknik analiz teorilerinden bir tanesidir. Jones & Company'nin kurucularından olan Charles Henry Dow bu teorisi üzerine detaylı bir yazı yazmamakla birlikte William Peter Hilton tarafından 1922 yılında, Dow'un 1900 - 1902 yılları arasında yayınlanan makalelerinden bir derleme yaparak Dow Teorisi ortaya atılmıştır (Karan, 2011). Dow Teorisi'ndeki amaç, finansal piyasalardaki bir olgunun, örneğin hisse senedinin, fiyatının gidiş yönünü (trendini) belirlemektir. Bunu belirlerken de olgunun kısa vadeli fiyat hareketlerini göz ardı ederek genel yönünü tahmin etmeye çalışmaktır. Kısaca Dow Teorisi'nin temel hedefi doğru zamanda

trendin yönünü doğru tahmin edebilmektir. Bu kapsamda Dow Teorisi teknik analizin temelini oluşturmaktadır.

Dow Teorisi, altı varsayımı temel almaktadır. Bu varsayımlar şu şekildedir (Türkiye Sermaye Piyasası Aracı Kuruluşlar Birliği, 2011):

- ✓ Ortalamalar her faktörü içerir ve yansıtır.

Teknik analizin temel varsayımlarından olan ortalamalar (endeksler), finansal piyasalardaki bir olgunun arz ve talebini etkileyecek; yatırımcıların düşünceleri, ekonomik durum, politik olaylar, doğal afetler gibi her türlü faktörü içermektedir.

- ✓ Piyasalarda üç temel trend söz konusudur. Bunlar şu şekildedir:

- Birincil (Ana) trend: Birkaç aydan birkaç yıla kadar sürebilen, uzun süre devam eden trendlerdir.
- İkincil trend (Tepki hareketi): Üç hafta ile üç ay arasında devam eden trendlerdir.
- Üçüncül trend: Üç haftadan az olan ufak dalgalanmalardır.

- ✓ Ana trend üç aşamadan geçer.

- Fiyatların çok düşük seviyelerden yükselmeye başladığında yatırımcıların alıma geçtiği toplama (biriktirme) dönemi.
- Fiyatların hızla artmaya devam ederken bunu fark eden yatırımcıların alıma geçtiği boğa piyasası dönemi.
- Hisse senetlerinin akıllı yatırımcılar tarafından elden çıkarıldığı ayı piyasası (dağıtım) dönemi.

- ✓ Ortalamalar veya piyasa göstergeleri birbirlerini doğrulamalıdır.

Piyasa hareketlerini kontrol eden çeşitli ortalamalar tarafından üretilen trend değişim sinyalleri tutarlı olmalıdır.

- ✓ İşlem hacmi (miktarı) trendi desteklemelidir.

Fiyatlar mevcut bir ana trendin yönünde hareket ederken işlem hacmi artar, fiyatlar azaldığında işlem hacmi de azalır.

- ✓ Piyasa yönünün tersine döndüğüne dair sinyal alınıncaya kadar mevcut trend geçerlidir.

2.2.2. Teknik analiz göstergeleri

Teknik analiz göstergeleri, fiyat verisi ve işlem hacmi gibi değerleri kullanarak finansal olgunun yönü hakkında bir fikir veren matematiksel modellerle ifade edilen teknik analiz araçlarıdır.

Sayıda çok fazla teknik gösterge olmakla beraber bu göstergeler verdikleri bilgiler açısından momentum, trend, oynaklık ve güç göstergeleri olmak üzere dört ana başlık altında toplanmaktadır. Bu bölümde tezin uygulama kısmında geliştirilen modellerin girdi değişkenleri kümesinde yer alan teknik göstergeler açıklamaları ile birlikte nasıl hesaplandıklarına dair genel bir bilgi verilmiş olup bu göstergelerin nasıl yorumlandığına değinilmiştir.

Momentum göstergeleri

Finansal olgunun, belirlenen süre içerisindeki değişiminin hızını ölçen teknik analiz göstergeleridir. Bu tez çalışmasında kullanılan momentum göstergeleri şunlardır:

Göreceli Güç Endeksi (Relative Strength Index - RSI)

Teknik analiz göstergeleri arasında en sık kullanılan göstergelerden bir tanesidir. Bu gösterge herhangi bir senedin veya endeksin bünyesi içindeki gücünün kendisine göre karşılaştırılmasından ibarettir. Kısaca özetlemek gerekirse hisse senedi fiyatının yükselişte olduğu günler ile düşüşte olduğu günlerin kuvvetini karşılaştıran aşırı alım - satım göstergesidir. RSI hesaplanırken (2.1) numaralı denklem kullanılmaktadır.

$$RSI = 100 - \left[\frac{100}{1 + \frac{okz}{oky}} \right] \quad (2.1)$$

Burada; *okz* değeri belirlenen periyodun ortalama kazancını *oky* ise ortalama kaybını ifade etmektedir.

RSI değeri 0 - 100 arasında değer almakla birlikte referans değerleri genellikle 30 ve 70 olarak ele alınmaktadır. RSI değeri, 30'un altına düştüğünde aşırı satım bölgesi olarak kabul edildiğinden ilk yukarı doğru hareketle alım yapılmalıdır, 70 değerinin üstüne çıktığında ise aşırı alım bölgesi olarak kabul edildiğinden ilk aşağı doğru hareketle satım yapılmalıdır şeklinde yorumlanmaktadır. Hesaplamalarda da genellikle 14 günlük RSI değeri kullanılmaktadır (Çağırman, 1999).

Para Akış Endeksi (Money Flow Index - MFI)

Bir hisse senedine girmekte ya da hisse senedinden çıkmakta olan paranın gücünü ölçen teknik göstergedir. RSI'dan temel farkı MFI'nın hacim bilgisini de değerlendirmesidir. MFI (2.2), (2.3) ve (2.4) numaralı denklemler yardımıyla hesaplanmaktadır.

$$\text{Para akışı} = \text{Ortalama fiyat} \times \text{İşlem hacmi} \quad (2.2)$$

$$\text{Para Oranı} = \text{Pozitif para akışı} / \text{Negatif para akışı} \quad (2.3)$$

$$MFI = 100 - \left(\frac{100}{1 + \text{Para Oranı}} \right) \quad (2.4)$$

Öncelikle son günün ortalama fiyatı ile bir önceki günün ortalama fiyatı karşılaştırılır. Son günün ortalama fiyatı daha yüksekse yani fark pozitifse hisse senedine para girişi olduğu, fark negatifse yani son günün ortalama fiyatı daha düşükse hisse senedinden para çıkmakta olduğu kabul edilmektedir. Belirlenen periyot boyunca farkın pozitif olduğu durumlardaki para akışlarının toplamı pozitif para akışını, farkın negatif olduğu durumlardaki para akışlarının toplamı ise negatif para akışını oluşturmaktadır.

0 – 100 arasında değer alan MFI göstergesi 20 ve 80 referans değerlerine sahiptir. MFI değeri 80 seviyesinin üzerine çıktığında aşırı alıma, 20 referans değerinin altına düştüğünde ise aşırı satıma işaret etmektedir. Aşırı alım ve aşırı satım bölgesi, var olan trendin tersine dönme ihtimalinin yüksek olduğu bölgeler olarak nitelendirilmektedir (Çağırman, 1999).

Stokastik Osilatör (Stochastic Oscillator - SO)

Bir senedin kapanış fiyatını, verilen bir periyot içinde seyrettiği fiyat aralığı ile karşılaştıran bir teknik göstergedir. Fiyatların ilgili zaman diliminde genel yöne uygun olarak kapanacağını varsaymaktadır. Başka bir deyişle, eğer fiyatlar yükseliyorsa kapanış fiyatı seçilen periyot içindeki en yüksek fiyata doğru gitme eğiliminde olacaktır. Eğer fiyatlar düşüyorsa bu sefer en düşük fiyata doğru gitme eğiliminde olacaktır. Stokastik osilatör (2.5) numaralı denklem yardımıyla hesaplanmaktadır.

$$SO(\%K) = (100 \times (KF - ED)) / (EY - ED) \quad (2.5)$$

Denklemden belirtilen *KF* son günkü kapanış fiyatını, *ED* belirlenen periyot içindeki en düşük değeri ve *EY*'de bu periyottaki en yüksek değeri ifade etmektedir.

Bu gösterge için göz önünde bulundurulacak 20 ve 80 olmak üzere iki referans seviyesi mevcuttur. Referans seviyesinin 80 - 100 olduğu bölge aşırı alım, 0 - 20 olduğu bölge ise aşırı satım bölgesi olarak tanımlanmaktadır. Bu gösterge; 80 referans değerine ulaşan ancak geçemeyen ya da 80 referans değerini geçtikten sonra dönüp bu seviyenin altına inen bir stokastik değer ürettiği sinyal sat sinyalidir, 20 referans değerine kadar düşen ancak buradan dönen ya da 20 referans değerinin altına indikten sonra toparlanıp bu değer üstüne çıkan bir stokastik değer ürettiği sinyal al sinyalidir şeklinde yorumlanmaktadır (Günak, 2007).

Williams' %R Göstergesi

Williams' %R teknik göstergesi, stokastik osilatördeki gibi periyot içindeki kapanışları, periyot içindeki en yüksek ve en düşük değere olan yakınlıkları ile değerlendirmektedir. Stokastik osilatörden farklı olarak -100 ile 0 arasında hareket eden noktalara sahiptir. Williams' %R teknik göstergesi (2.6) numaralı denklem yardımıyla hesaplanmaktadır.

$$\%R = (-100 \times (EY - KF)) / (EY - ED) \quad (2.6)$$

-20 ve -80 değerleri bu teknik göstergenin referans değerleri olarak kabul edilmektedir. %R değeri -80 referans değerinin altına düşerse aşırı satım olduğunun sinyalini vermektedir. Eğer bu değer -20 çizgisinin üzerinde çıkarsa aşırı alım olduğunun göstergesidir.

Alım ve satım yapan yatırımcılar, aşırı alım veya aşırı satım olduğu durumlarda trendin değişeceğine dair bir sinyal beklemektedir ve alım - satım işlemlerini bu sinyallerden sonra yapmaları büyük kazançlar sağlamaları açısından faydalı olmaktadır (Çağırman, 1999).

Oynaklık göstergeleri

Fiyatlardaki oynaklığı ölçen göstergelerdir. Oynaklığın değişmesi fiyatların da yön değiştireceği anlamına gelmektedir. Kısaca oynaklık göstergeleri, fiyatlardaki iniş çıkışların ne derece agresif olduklarını ölçmektedir.

Ortalama Gerçek Aralık (Average True Range - ATR)

Fiyatlardaki dalgalanmanın boyutunu ölçen bir göstergedir. ATR değerinin artıyor olması fiyatlardaki hareketliliğin arttığını aksi durumda ise fiyatlardaki

dalgalanmanın düştüğünü göstermektedir. ATR teknik göstergesi (2.7), (2.8) ve (2.9) numaralı denklemler yardımıyla hesaplanmaktadır.

$$TR_t = Maks(|EY_t - ED_t|, |EY_t - KF_{t-1}|, |ED_t - KF_{t-1}|) \quad (2.7)$$

$$ATR_0 = TR_0 \quad (2.8)$$

$$ATR_t = \frac{((n-1) \times ATR_{t-1} + TR_t)}{n} \quad (2.9)$$

(2.7) numaralı denklemde n periyodu TR_t ise t anındaki doğru aralığı ifade etmektedir.

Fiyatlar aniden düşmeye ya da yükselmeye başladığında ATR göstergesinin değeri artmaktadır. Eğer fiyatlar belli bir değer etrafında dalgalanıyorsa bu değer düşmektedir (Günak, 2007).

Bollinger Bantları (Bollinger Bands - BB)

Fiyatlardaki dönüş noktalarını belirlemek ve oynaklığı ölçmek için kullanılan teknik göstergedir. Fiyat barlarının yaklaşık %88 - 90' ı bollinger bantları içerisindedir. Geri kalan kısım ise bollinger bantlarının dışında kalmaktadır. Bollinger bantları üç banttandır meydana gelmektedir. Bu bantlar (2.10), (2.11) ve (2.12) numaralı denklemler yardımıyla hesaplanmaktadır.

$$Orta\ bant = 20\ Günlük\ hareketli\ ortalama \quad (2.10)$$

$$Üst\ bant = Orta\ bant + (2 \times Standart\ sapma) \quad (2.11)$$

$$Alt\ bant = Orta\ bant - (2 \times Standart\ sapma) \quad (2.12)$$

Yükseliş trendi mevcutsa genelde üst bantta taşma, düşüş trendi mevcutsa alt bantta taşmalar meydana gelmektedir. Bantların daralması, ortalamadan az sapıldığını ifade etmektedir. Bu durum fiyatta bir hareketlenme olacağını gösterir fakat bu muhtemel hareketin yönü hakkında bilgi vermemektedir. Bantların genişlemesi ise oynaklığın arttığını göstermektedir. Bu durum fiyatlardaki hareketlenmenin yakın zamanda biteceğine dair bir işarettir şeklinde yorumlanmaktadır.

Jonh Bollinger, bollinger bantlarının özellikle güç ve birazda momentum göstergeleri ile kullanıldığında daha uyumlu ve daha yüksek başarı yüzdeli çalıştığını vurgulamaktadır. Çünkü Bollinger bantları tek başına direkt olarak al - sat durumunu ifade eden sinyallere sahip değildir (Çağırman, 1999).

Keltner Kanalı (Keltner Channel - KC)

Oynaklık göstergelerinden biri olan Keltner Kanalı, üç banttan (çizgi/zarf) meydana gelmesi sebebiyle Bollinger bantlarına oldukça benzemektedir. İki teknik gösterge arasındaki temel fark, mevcut bu üç bandın hesaplanmasından kaynaklanmaktadır. BB'nin hesabında standart sapma ve hareketli ortalama kullanılırken KC'de ise ATR ve EMA kullanılmaktadır. KC bantları (2.13), (2.14) ve (2.15) numaralı denklemler aracılığı ile elde edilmektedir.

$$\text{Orta bant} = 20 \text{ Günlük üstel hareketli ortalama} \quad (2.13)$$

$$\text{Üst bant} = \text{Orta bant} + (2 \times \text{ATR}) \quad (2.14)$$

$$\text{Alt bant} = \text{Orta bant} - (2 \times \text{ATR}) \quad (2.15)$$

(2.13), (2.14) ve (2.15) numaralı denklemlerde KC bantlarının hesabında yaygın olarak kullanılan EMA periyodu ve ATR katsayı değerleri verilmiş olup bu değerler değişkenlik gösterebilmektedir.

Kanalın açısı, trendin yönünün belirlenmesine yardımcı olmaktadır. Yükselen hareket sergileyen kanal, fiyatlarda yükselmenin olacağını işaret ederken düşüş yönlü bir kanalın ise fiyatlarda da düşme eğiliminin olacağını göstergesidir şeklinde yorumlanmaktadır.

Güç göstergeleri

Piyananın gücünü ölçmeye yarayan teknik analiz göstergeleridir. Bu tez çalışmasında kullanılan güç göstergeleri şunlardır:

Toplama/Dağıtım Endeksi (Accumulation/Distribution Index - ADI)

Toplama/Dağıtım Endeksi, işlem hacmi ve fiyatlardaki hareketliliği birleştirerek fiyattaki mevcut trendin devam edip etmeyeceği konusunda bilgi veren teknik analiz göstergesidir. Bu gösterge hesaplanırken (2.16) numaralı denklemden faydalanılmaktadır.

$$ADI = \left[\frac{(KF-ED)-(EY-KF)}{(EY-ED)} \right] \times \text{İşlem hacmi} \quad (2.16)$$

(2.16) numaralı denklemden son günün ve bir önceki günün ADI değeri hesaplanır ve karşılaştırılır. Eğer son günün ADI değeri daha yüksekse başka bir deyişle $ADI_t - ADI_{t-1}$ farkı pozitif ise hisse senedinin toplandığı (alındığı), fark

negatif ise yani son günün ADI değeri daha düşükse bu durumda hisse senetlerinin satıldığı (dağıtıldığı) şeklinde yorumlanmaktadır (Çağırman, 1999).

Denge İşlem Hacmi Göstergesi (On Balance Volume - OBV)

OBV öncelikle, fiyatlardaki değişim ile işlem hacminde meydana gelen değişimi karşılaştırmakta ve hisse senedine para girişi olup olmadığını belirlemeye çalışan teknik göstergedir. Bu karşılaştırma sonucunda üç durum ortaya çıkmaktadır:

- ✓ Bugünkü kapanış fiyatı dünki kapanış fiyatına eşitse;

$$OBV_t = OBV_{t-1}$$

- ✓ Bugünkü kapanış fiyatı dünki kapanış fiyatından daha düşük ise;

$$OBV_t = OBV_{t-1} - \text{Bugünkü işlem miktarı}$$

- ✓ Dünki kapanış fiyatı bugünkü kapanış fiyatından daha düşükse;

$$OBV_t = OBV_{t-1} + \text{Bugünkü işlem miktarı}$$

Hisse senetleri bir önceki güne göre yüksek seviyede kapanırsa işlem hacmi pozitif, düşük kapanırsa işlem hacmi negatif olarak kabul edilmektedir. OBV, işlem hacminin pozitif olma durumunun fiyatlarda arttırıcı, negatif olma durumunun ise fiyatlarda azaltıcı etkiye sahip olacağı esasına dayanmaktadır. Fiyatla OBV göstergesi arasında meydana gelecek bir uyumsuzluğun ise mevcut trendin yön değiştireceği anlamına geldiği şeklinde yorumlanmaktadır (Çağırman, 1999).

Chaikin Para Akış Göstergesi (Chaikin Money Flow - CMF)

Belirli bir periyot boyunca para akış hacmini ölçmek için kullanılan CMF göstergesi, ADI göstergesini baz almaktadır. CMF göstergesi hesaplanırken (2.17) ve (2.18) numaralı denklemlerden yararlanılmaktadır.

$$A_i = \sum_{i=1}^n ADI_i \quad B_i = \sum_{i=1}^n \text{İşlem hacmi}_i \quad (2.17)$$

$$CMF = A_i / B_i \quad (2.18)$$

(2.17) ve (2.18) numaraları denklemlerden de anlaşılacağı üzere CMF göstergesi, belirlenen bir periyot için (genellikle $n = 21$ seçilmekte) ADI değerleri toplamının bu periyottaki toplam işlem hacmine bölünmesi ile elde edilmektedir.

CMF göstergesi yorumlanırken sıfır referans çizgisi göz önüne alınmaktadır. CMF, sıfır referans değerinin üzerine çıktığında olumlu bir gidişatın olduğu ve al sinyalinin verildiği, bu değer altına düştüğünde ise gidişatın olumsuz olduğu ve sat sinyalinin verildiği şeklinde ifade edilmektedir.

Trend göstergeleri

Mevcut trendin nereye kadar devam edeceğini başka bir deyişle fiyatların istikrarlı bir şekilde aşağı veya yukarı yönde gidip gitmediklerini anlamaya yarayan göstergelerdir.

Üssel Hareketli Ortalama (Exponential Moving Average - EMA)

EMA, adından da anlaşılacağı üzere hareketli ortalama çeşitlerinden bir tanesidir. Fakat EMA'nın diğerlerinden farkı, son günlük fiyat değerlerine daha fazla ağırlık vererek gecikme miktarını azaltmaya çalışmaktadır. EMA'nın hesaplanma adımları şu şekildedir (Perşembe, 2002):

- ✓ 1. Adım: Öncelikle üssel hareketli ortalama için bir periyot belirlenir. Periyot belirlendikten sonra kapanış fiyatları üzerinden bu periyot kadar basit hareketli ortalama alınır.
- ✓ 2. Adım: Kapanış fiyatları ile hesaplanan basit hareketli ortalamanın farkı alınır.
- ✓ 3. Adım: 2. adımda hesaplanan fark değeri üssel bir değer ile çarpılır.
- ✓ 4. Adım: 1. adımda hesaplanan basit hareketli ortalama ile 3. adımda hesaplanan değer toplanarak belirlenen periyot için üssel hareketli ortalama değeri elde edilmiş olur.

Hareketli Ortalamaların Birleşmesi/Ayrılması Göstergesi (Moving Average Convergence/Divergence - MACD)

MACD göstergesi, içeriğinde bulunan iki üssel hareketli ortalamanın (genellikle 12 ve 26 günlük EMA seçilmekte) birbirlerine yakınlaşıp uzaklaşarak oluşturduğu sinyalleri inceleyip trendin yönünü tahmin etmeye çalışmaktadır. MACD (2.19) numaralı denklem yardımıyla hesaplanmaktadır.

$$MACD = EMA(12) - EMA(26) \quad (2.19)$$

MACD göstergesinin sınırları yoktur. Bu gösterge için ayrıca MACD çizgisinin 9 günlük hareketli ortalaması alınarak sinyal çizgisi elde edilmektedir. Bu sinyal çizgisi (2.20) numaralı denklem yardımıyla elde edilmektedir.

$$S = EMA(MACD(9)) \quad (2.20)$$

Sinyal çizgisini MACD eğrisinin yukarı doğru kesişi al sinyali üretirken aşağı doğru kesişi sat sinyali üretmektedir şeklinde yorumlanmaktadır (Çağırman, 1999).

Mass Endeksi (Mass Index - MASS)

Mass endeksi, fiyatların yüksek ve düşük seviyeleri arasındaki farkın açılmasını veya daralmasını yani fiyatlardaki dalgalanmanın boyutunu ölçerek trendin yön değiştireceği durumları tespit etmeye yarayan teknik göstergelerden bir tanesidir. MASS' in, bir hareketin başlangıcını değil, aslında var olan yükseliş ya da düşüş hareketinin bitiş noktasını tespit etmeyi amaçlayan bir gösterge olduğu söylenmektedir.

MASS endeksinde 26,5 ve 27 olmak üzere iki önemli seviye mevcuttur. Bu seviyeler mevcut hareketin bitiş noktasının yorumlanmasını sağlamaktadırlar. MASS endeksi 27 seviyesini üstüne çıkmasının ardından 26,5 seviyesinin altına düşüyorsa var olan hareketin yani trendin yön değiştireceği şeklinde yorumlanmaktadır.

Mal Kanal Endeksi (Commodity Channel Index - CCI)

CCI göstergesi, fiyatların ortalamadan ne kadar saptığını istatistiksel olarak ifade etmekte ve trend yapan piyasalarda son derece etkili bir şekilde kullanılmaktadır. CCI göstergesi şu şekilde hesaplanmaktadır:

- ✓ İlk olarak günlük ortalama fiyat, (2.21) numaralı denklem aracılığıyla hesaplanmaktadır.

$$OF = (EY + ED + KF) / 3 \quad (2.21)$$

- ✓ Ortalama fiyatın hesaplanmasının ardından öncelikle belirlenen periyot için ortalama fiyatın basit hareketli ortalaması (*OFHO*) alınmaktadır.
- ✓ Elde edilen bu değerler aracılığıyla sapma hesaplanmakta ve hesaplanan sapmanın ortalaması (*SO*) alınmaktadır.
- ✓ Son olarak da CCI değeri (2.22) numaralı denklem yardımıyla hesaplanmaktadır.

$$CCI = (OF - OFHO) / (SO \times 0,015) \quad (2.22)$$

Referans değerleri 100 ve -100 olarak belirlenmektedir. Bu değerler dışına çıkıldığında sapmanın yüksek olduğu kabul edilmektedir. 0,015 sabitinin amacı CCI eğrisini zamanın %70 - 80'inde 100 ile -100 sınırları dahilinde tutmaktır.

CCI göstergesi 100 değerini aşağı yönde keserse sat, -100 değerini yukarı yönde keserse al sinyali ürettiği varsayılmaktadır. Bu durumda 100 referans değeri ve üzeri aşırı alım, -100 ve altı ise aşırı satım bölgesi olarak adlandırılmaktadır.

Ichimoku Göstergesi

Ichimoku bulutları olarak da adlandırılan Ichimoku göstergesi, finansal piyasaların momentum ve eğilimini ölçen, trendin ve destek - direnç seviyelerinin belirlenmesine yardımcı olan teknik göstergelerden bir tanesidir. Japon gazeteci Goichi Hosoda tarafından geliştirilen bu gösterge sayesinde tek bir görüntü (grafik) ile trend belirlenebilmektedir. Fakat bu görüntü, çok fazla parametre içerdiğinden dolayı ilk bakışta çok karmaşık olduğu izlenimini vermektedir. Aslında bu parametreler birbirlerinden çok kolay bir şekilde ayırt edilebildiği için görüntüden trendin ne olacağı ve piyasa dönüşleri hakkında bilgiler kolaylıkla çıkarılabilmektedir (Teknik Analiz, 2019).

Aroon Göstergesi

Tushar Chande tarafından geliştirilen teknik gösterge, fiyat değişimlerinde bir trendin var olup olmadığını tespit etmeye çalışmaktadır. Aroon göstergesi temelinde Aroon up ve Aroon down alt göstergelerinden meydana gelmekte olup 0 ve 100 arasında değerler almaktadır.

Belirlenen periyot boyunca fiyatlarda yeni bir en yüksek seviyeye ulaşıldığında Aroon up 100 değerini alırken bu periyotta fiyatlarda yeni bir en düşük seviyeye ulaşıldığında ise Aroon down 100 değerini almaktadır. Aroon up ve Aroon down göstergeleri sırasıyla (2.23) ve (2.24) numaralı denklemler yardımıyla hesaplanmaktadır.

$$Aroon\ up = \left[\frac{n - [\max(H_i)]}{n} \right] \times 100 \quad (2.23)$$

$$Aroon\ down = \left[\frac{n - [\min(L_i)]}{n} \right] \times 100 \quad (2.24)$$

Denklemlerde; belirlenen periyot n , belirlenen periyot boyunca en yüksek seviyeye ulaşıldığı andan bugüne geçen süre $\max(H_i)$ ile ifade edilirken en düşük seviyeye ulaşıldığı andan bugüne geçen süre ise $\min(L_i)$ ile ifade edilmektedir.

Aroon göstergesi yorumlanırken dört seviyeye dikkat edilmektedir: 0 - 30 - 70 - 100. Aroon up değeri 70 - 100 aralığında iken Aroon down 0 - 30 aralığında bir değere sahipse yukarı yönlü bir trendin var olacağının habercisidir şeklinde yorumlanmaktadır. Eğer Aroon down değeri 70 - 100 aralığında bir değere sahipken Aroon up değeri 0 - 30 aralığında ise bu durumda trendin aşağı yönlü olacağı yorumu yapılmaktadır (Günak, 2007).

2.3. Temel ve Teknik Analizin Karşılaştırılması

Temel ve teknik analiz kıyaslandığında, teknik analiz olguya ait fiyatları incelerken temel analiz ise bu fiyat hareketlerindeki nedenleri incelemektedir. Bu durumda temel analizin gerçekleştirilmesi daha zordur.

Temel analiz, piyasa psikolojisi gibi pek çok faktörün ele alınmasından dolayı bu faktörlerin kısa - orta vadede beklentileri karşılayamamaktadır. Dolayısıyla bu analiz tekniği daha çok uzun vadeli tahminlerde tercih edilmektedir. Teknik analiz yöntemi ise, genellikle tahmin süresi bir yıldan kısa bir süreyi kapsadığında tercih edilmektedir.

Temel analizin uygulanması için iyi bir ekonomi ve finans bilgisine ihtiyaç duyulmaktadır çünkü analiz yapılırken piyasa fiyatlarındaki hareketliliğe neden olan faktörler araştırılıp yorumlanmaktadır. Fakat teknik analize bakıldığında, bu faktörlerin zaten piyasa fiyatlarına yansıdığı düşünülerek analiz yapılmakta ve bu doğrultuda bir fiyat tahmini gerçekleştirilmektedir.

Her iki yönetime de bakıldığında kendi disiplinleri içerisinde geçmiş bilgilerden faydalanarak bir tahminde bulunulması amaçlanmaktadır. Temel ve teknik analiz arasındaki asıl farklılaşan nokta, teknik analizle sadece olgunun geçmiş fiyat hareketleri incelenirken temel analizde ise olgunun gerçek değerinin (piyasadaki konumu, olguya ait şirketin finansal verileri gibi bilgiler) belirlenmeye çalışılmasıdır.

3. YÖNTEM

Bu bölümde ilk olarak derin öğrenme kavramına değinilerek Tekrarlayan Sinir Ağları genel hatlarıyla açıklanmıştır. Bölüm sonunda ise tezin uygulama kısmının temelini oluşturan Uzun - Kısa Dönemli Bellek Ağları yöntemi detaylandırılmıştır.

3.1. Derin Öğrenme

Yapay zekanın alt dallarından biri olan derin öğrenmenin temelini sinir ağları oluşturmaktadır. Bunlar çok sayıda katmana sahip sinir ağlarının kullanılarak veriler üzerinden öznelik öğrenimini (çıkarımını) sağlayan bir algoritmalar ailesi olarak tanımlanabilmektedir. Yapay zekâ ile derin öğrenme ilişkisi Şekil 3.1’de verilmiştir (Chollet, 2017).



Şekil 3.1. Yapay zekânın alt dalları

Derin öğrenme ya da derin sinir ağları ile yapay sinir ağları arasındaki temel farklardan biri de katman sayılarının farklılığıdır. Derin sinir ağlarındaki katman sayısı yapay sinir ağlarındakinden kat kat fazladır. Derin öğrenme yönteminin adındaki “derin” kavramı da buradan gelmektedir. Bu durum karşısında, yapay sinir ağlarındaki katman sayısını arttırarak da derin öğrenme gerçekleştirilebilir mi sorusu akla gelmektedir. Bu soruya, evet katman sayıları arttırılabilir cevabı verilebilir ancak yapay sinir ağlarının kullanıldığı 1990’lı yıllarda bu sayı arttırıldığında modeli eğitebilmek için gerekli donanım (merkezi işlem birimi (Central Process Unit - CPU), grafik işlem birimi (Graphics Processing Unit - GPU) gibi) bu yıllarda mevcut değildi.


Teknolojinin gelişmesiyle birlikte gerekli donanımlar sağlanarak bilgisayarların performansının ve veri miktarının artması sonucunda derin öğrenme kavramı ortaya çıkmıştır.

Derin sinir ağları, mimarisinde barındırdığı çok fazla sayıdaki katman arasında karmaşık ilişkileri öğrenebilme becerisine sahipken aynı zamanda bir veri kümesinin sahip olduğu özelliklerden hangilerinin daha anlamlı olduğuna karar verebilmesi özelliğiyle (otomatik öznitelik çıkarım) de ön plana çıkmaktadır (Patterson ve Gibson, 2017). Bu otomatik öznitelik çıkarabilme yeteneğinden dolayı makine öğrenmesi yöntemlerinden ayrılmakta olup doğal dil işleme, sesli asistan, sürücüsüz otomobiller, bilgisayarla görü, tavsiye sistemleri gibi pek çok alanda yaygın olarak kullanılmaktadır.

3.1.1. Tekrarlayan sinir ağları (Recurrent neural network - RNN)


Tekrarlayan sinir ağları, geleneksel bir sinir ağından farklı olarak mimarilerinde döngüler mevcut olup sıralı bilgi kullanma mantığına dayanmaktadır (Elman, 1990). Geleneksel sinir ağlarında, girdilerin hem kendi aralarında hem de çıktılar ile birbirinden bağımsız olduğu varsayımıyla hareket edilmektedir. Fakat RNN’de ise sıralı bilgilerin kullanılmasına bağlı olarak girdilerin kendi aralarında bir sıra bağımlılıkları mevcut olup aynı zamanda elde edilen çıktılar da önceki hesaplamalara bağlıdır (Alam, 2018).

Şekil 3.2’de FFNN ile RNN mimarileri ifade edilmiştir. Görsellerden anlaşılacağı üzere RNN’ler en az bir geri besleme döngüsüne sahip olup sıralı bilgilerin ya da ardışık zaman serilerinin modellenmesini sağlamaktadır.



Şekil 3.2. İleri beslemeli ve tekrarlayan sinir ağı mimarilerinin karşılaştırılması

RNN mimarisinin daha iyi anlaşılması üzerine genellikle cümle içerisinde kullanılacak bir sonraki kelimenin tahmin edilebilmesi örneği verilmektedir. Bunun için son kelimedenden önce kullanılan sözcüklerin bilinmesi gerekmektedir ki bir sonraki kelime tahmin edilebilsin. Çünkü cümlede kullanılan kelimeler arasında bir bağ-ilişki mevcuttur. Bu örnekten yola çıkılırsa özetle, RNN mimarileri sıralı bilgilerin her bir ögesi için (cümledeki sözcükler gibi) aynı görevi önceki çıktılara bağlı olarak yerine getirmektedir. Bu durum RNN mimarilerinin tekrarlayan (recurrent) sinir ağları olarak tanımlanmasına olanak sağlar. Bu yaklaşımı içeren RNN mimarisi Şekil 3.3'te görselleştirilmiştir.



Şekil 3.3. Katmanları zaman boyunca açık hale getirilen genel RNN mimarisi.

RNN mimarileri, sıralı-ardışık veriler arasında ilişkileri kurup yorumlayabilmesinden dolayı çeviri, ses tanıma, dil modelleme, el yazısı tanıma gibi pek çok uygulamada yaygın olarak kullanılmaktadır (Mikolov vd, 2010). Fakat RNN mimarileri ile bu uygulamalar gerçekleştirilirken iki temel problem karşımıza çıkmaktadır:


- ✓ *Uzun Bağımlılık Problemi:* RNN ağları, sahip oldukları mimari sayesinde geçmişle bağlantı kurarak verileri anlamlandırıp yorumlama özelliğine sahiptir. Fakat çok fazla geçmişe gidildiğinde bu işlemi yerine getiremeyip geçmişle gerekli bağlantıyı kuramamaktadır. Bu durumda, uzun bağımlılık problemi olarak adlandırılan sorun ortaya çıkmaktadır (Olah, 2015).
- ✓ *Kaybolan Gradyan Problemi:* Sinir ağlarında, geri yayılım ile önceki katmanların ağırlıklarının güncellenmesini zorlaştıran problemlerden biri de katman sayılarının fazlalığıdır. Geri yayılım sürecinde önceki katmanların

ağırlıkları hesaplanırken kısmi türevden faydalanılmaktadır. Bu kısmi türev yardımıyla da gradyan değerleri hesaplanmaktadır. Fakat katman sayısı arttığında, geri yayılım sürecinde belli bir noktadan sonra gradyan değerleri sifıra yaklaşıp zamanla ağırlıklar güncellenemeyecektir. Bu durumda da ağırlık öğrenmesi zorlaşacaktır. Bu problem kaybolan gradyan (vanishing gradyan) problemi olarak tanımlanmaktadır. Derin sinir ağlarında çok fazla sayıda geri yayılım işlemi gerçekleştirildiği için bu problemle çok sık karşılaşılmaktadır (Young vd, 2018).


Uzun – kısa dönemli bellek ağları (Long - short term memory - LSTM)

Hocreiter ve Schmidhuber tarafından 1997 yılında, özellikle RNN'deki uzun bağımlılık problemini gidermek amacıyla RNN'in özel bir yapısı olan Uzun - Kısa Dönemli Bellek Ağları (LSTM) tanıtılmıştır (Hocreiter ve Schmidhuber, 1997). LSTM, RNN'in bir diğer problemi olan kaybolan gradyan sorununu da çözmektedir. Bu ağ mimarisi, temel olarak RNN'deki uzun bağımlılık problemini gidermek amacıyla ortaya atılmıştır. Çünkü, LSTM ağının kullanılmasının dışında sigmoid fonksiyonundan farklı bir aktivasyon fonksiyonu kullanılarak da kaybolan gradyan probleminin üstesinden gelinebilmektedir.

LSTM de RNN gibi birbirini tekrarlayan modüllerden meydana gelmektedir. Fakat iki ağın mimarisi karşılaştırıldığında temel farkın katman sayıları olduğu görülmektedir. Şekil 3.4'te ifade edilen RNN mimarisi genellikle tanh katmanı içeren tek bir katmana sahip olurken Şekil 3.5'teki LSTM mimarisi RNN'den farklı olarak birbirini izleyen dört katmandan meydana gelmektedir. LSTM, sahip olduğu bu dört katmanı kullanarak, bilginin uzun süreler boyunca ağ tarafından hatırlanmasını sağlamaktadır.




Şekil 3.4. Genel RNN mimarisi.



Şekil 3.5. LSTM mimarisi

Şekil 3.4 ve Şekil 3.5'te verilen ağ mimarilerinde dikdörtgen kutular RNN ve LSTM ağ katmanlarını, pembe daireler vektör eklemesi gibi noktasal işlemleri ve siyah çizgiler de vektör iletimini ifade etmektedir.


LSTM ağı, diğer sinir ağlarının sahip oldu girdi ve çıktı kapılarından farklı olarak bir de unutma kapısına sahiptir. Bu unutma kapısı sayesinde bilginin ne kadarının unutulacağı ve ne kadarlık kısmının bir sonraki aşamaya aktarılacağı, kısaca hangi bilgilerin saklanıp saklanmayacağı kararını vermektedir. Bu işlemi gerçekleştirmek için 0 - 1 arasında değer üreten sigmoid katmanına sahiptir. Sigmoid katmanının ürettiği değerin 1 olması bilginin tamamının aktarılması gerektiğini ifade ederken, 0 ise hiçbir şekilde bilginin aktarılmaması anlamına gelmektedir. Şekil 3.6'da LSTM ağına ilk aşaması olan unut kapısı gösterilmiş olup (3.1) numaralı denklemde matematiksel yapısı verilmiştir.



Şekil 3.6. LSTM ağı - unut kapısı

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.1)$$

İkinci aşama ise hangi bilgilerin saklanacağı kararının verilmesidir. Bu aşamada ilk olarak girdi kapısı yani ikinci sigmoid katmanı ile hangi değerlerin güncelleneceği belirlenmektedir. Sigmoid katmanının peşine gelen tanh katmanı ile de yeni aday değerlerinin bir vektörü olan $\tilde{C}_t$ oluşturulmaktadır. Ardından bu iki değer birleştirilerek yeni saklanacak olan değer oluşturulmaktadır. Bu işlemlerin matematiksel ifadesi (3.2) ve (3.3) numaralı denklemlerde verilmiş olup yeni saklanacak değerin oluşturulmasına ilişkin görsel Şekil 3.7’de verilmiştir.



Şekil 3.7. Hücre durumunun güncellenmesi


$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.3)$$

Bundan sonraki aşamada ise ilk aşamada elde edilen unut kapısından gelen vektör değeri, ikinci aşamada elde edilen i_t ve $\tilde{C}_t$ değerlerinden yola çıkılarak hücrenin

yeni durum bilgisi hesaplanmaktadır. Bu bilgi hesaplanırken (3.4) numaralı denklemden faydalanılarak hücrenin yeni durumunun hesaplanmasına ilişkin görsel Şekil 3.8’de verilmiştir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.4)$$




Şekil 3.8. Hücrenin yeni durumunun hesaplanması

Bu üç aşamanın sonunda hangi bilgilerin unutulup hangilerinin unutulmayacağı kararı verilerek hücrenin yeni durum bilgisi güncellenir. Son aşamada ise hücrenin çıkış değeri h_t , (3.5) ve (3.6) numaralı denklemler yardımıyla hesaplanmaktadır. Hücrenin çıkış durumunun hesaplanmasına ilişkin görsel ise Şekil 3.9’da verilmiştir.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.5)$$

$$h_t = o_t * \tanh(C_t) \quad (3.6)$$



Şekil 3.9. LSTM ağı - çıkış kapısı

Yukarıdaki şekillerde ve denklemlerde ifade edilen σ sigmoid fonksiyonunu, i giriş kapısını, f unut kapısını, o çıkış kapısını, W ağırlık matrisini, b ise ön gerilim vektörünü temsil etmektedir.



4. ÖNERİLEN MODEL

Bu bölümde, tez kapsamında LSTM yöntemi ile gerçekleştirilen tahmin modelinin detayları verilmiştir. Bu detaylar verilirken ilk önce modelde kullanılacak olan veri kümesine değinilerek veri önışlemenin nasıl yapıldığı kısaca açıklanmıştır. Son olarak ise tahmin modelinde kullanılan LSTM yönteminin hiper parametrelerinin nasıl belirlendiğı detaylandırılmıştır.

4.1. Kullanılan Veri Kümesi

Bu tez çalışması kapsamında 6 Ocak 2010 - 9 Mart 2020 tarihleri arasındaki işlem günlerini kapsayan zaman serisi verileri kullanılmaktadır. Uygulama kısmında geliştirilen iki farklı tahmin modeli için kullanılan veri kümesi genel hatlarıyla; fiyat verileri, teknik ve temel gösterge değeri olmak üzere üç alt kümeden oluşmaktadır.

4.1.1. Fiyat verileri

Fiyat verileri, borsa endeksi ve hisse senedi fiyat tahmini çalışmalarında kullanılan veri kümelerinin vazgeçilmezlerindendir. Bu fiyat verileri, tahmin edilmek istenen olgunun (borsa endeksi, hisse senedi fiyatı gibi) açılış, kapanış, gün içi en yüksek, gün içi en düşük ve işlem hacmi değeriyle meydana gelmektedir.

Bu tez çalışması kapsamında iki farklı olgunun (hisse senedi fiyatı, BIST 30 endeksi değeri) bir gün sonraki kapanış değeri tahmin edilmesi için iki model geliştirilmiştir. Dolayısıyla bu modeller için kullanılan veri kümesinde değışiklik gösteren kısım sadece fiyat verileridir. Bu fiyat verileri borsaistanbul.com internet sitesinden elde edilmiştir.

4.1.2. Teknik gösterge verileri

Tezin birinci bölümünde de ifade edildiğı gibi; literatürde yer alan hisse senedi fiyat ve borsa endeksi tahmin çalışmaları için geliştirilen modellerin çoğunda teknik gösterge verilerinden yararlanılmadığı, çok az sayıda çalışmada ise bu verilerden yararlanıldığı görülmektedir. Teknik göstergelerin fiyat verileri üzerinden hesaplanması ve fiyatlardaki geçmiş hareketlerin (dalgalanmaların) gelecekte de yaşanacağı varsayımını kabul etmesinden dolayı tahmin modelleri için oluşturulan veri

kümesinde teknik gösterge verilerinin de yer alması daha doğru tahminleme modelleri oluşturulmasına olanak sağlayabilir.

Teknik göstergeler, sayıca çok fazla oldukları için öncelikle bu tez kapsamında bir indirgeme yoluna gidilmiştir. Teknik göstergeler üzerindeki bu indirgeme, aşağıda belirtilen iki adım doğrultusunda gerçekleştirilmiştir.

- ✓ İlk önce borsa endeksi ve hisse senedi fiyat tahmini konuları üzerine literatürde yer alan ve veri kümelerinde teknik göstergelerin de yer aldığı çalışmalar incelenmiştir. İncelemelerin ardından, bu tahmin çalışmalarında kullanılan teknik göstergelerin bir listesi çıkarılmıştır.
- ✓ Teknik göstergelerin yer aldığı listenin oluşturulmasının ardından bu teknik göstergeler üzerine detaylı araştırmalar yapılmıştır. Araştırmalar yapılırken “Kullanılacak teknik gösterge, geliştireceğimiz tahmin modeli için bir anlam taşımakta mıdır?” sorusuna yanıt aranmıştır. Verilen yanıt, “Evet” ise bu teknik gösterge değeri veri kümesine eklenmekte “Hayır” ise veri kümesine eklenmemektedir.

Teknik göstergelerde yapılan indirimler sonucunda veri kümesine, tezin ikinci bölümünde detaylandırılan 4 momentum, 3 oynaklık, 6 trend ve 3 güç göstergesi olmak üzere toplam 16 teknik gösterge dahil edilmiştir.

4.1.3. Temel gösterge verileri

Tez çalışmasında kullanılan veri kümesinin bir diğer alt kümesi ise temel gösterge verileridir. Bu temel gösterge verileri BIST 100 endeksi, S&P 500 endeksi, USD/TL kuru, brent petrol ve Ishares MSCI (Morgan Stanley Capital International) Turkey ETF kapanış değerlerinden meydana gelmektedir.

BIST 100 endeksi Borsa İstanbul’da işlem gören işlem hacmi bakımından en yüksek 100 hisse senedinin performansını ölçmek için kullanılan bir temel gösterge olurken S&P 500 veya Standard & Poor’s 500 olarak adlandırılan endeks ise, 500 büyük Amerikan şirketlerinin hisselerinden oluşmaktadır.

Ishares MSCI Turkey ETF ise Türkiye’de yatırım yapılabilirliği izlemek amacıyla BIST 100’de işlem gören, Garanti Bankası, Akbank, İş Bankası, Halk Bankası, Bim, Koç Holding, Sabancı Holding, Tüpraş, Ereğli Demir Çelik, Turkcell olmak üzere 10 hisse senedinden oluşmaktadır.

4.2. Veri Önışleme

Öncelikle 6 Ocak 2010 - 9 Mart 2020 tarihleri arasındaki işlem günlerine ait temel gösterge verileri stooq.com, fiyat verileri ise borsaistanbul.com internet adresinden çekilerek bu veriler zaman serisi indeksine sahip veri çerçevesi olarak birleştirilip kaydedilmiştir. Ardından oluşturulan bu veri kümesine, fiyat verilerinden hesaplanan teknik gösterge verileri de eklenmiştir.

Oluşturulan veri kümesi incelenerek işlem günü olmayan veya boş satırın olduğu günlere (hafta sonları ve resmî tatil günleri) ait veriler, veri kümesinden çıkarılmayıp bir üst satırdaki değerler ile doldurulmuştur.

4.3. LSTM Ağı İçin Hiper Parametre Ayarlamaları


Hiper parametreler konusundaki en büyük zorluk, bu parametrelerin veri kümesine ve probleme bağılı olarak değışkenlik göstermesine ek olarak probleme bağılı oluşturulan model için en iyi sonucu verecek standart parametre değerlerinin olmamasıdır. Bu sebeple, geliştirilen model için en uygun hiper parametre değerlerinin seçilmesi, uygulama aşamasının önemli adımlarından bir tanesidir. Genellikle hiper parametre seçimleri, öğrenme modelini tasarlayan kişinin deneyim ve sezgilerine göre değışiklik göstermektedir.

Bu tez kapsamında geliştirilen LSTM modeli için hiper parametre değerleri, çeşitli denemeler sonucunda şu şekilde belirlenmiştir:

- ✓ **Veri Kümesinin Bölünmesi:** Geliştirilen model için, veri kümesinin ilk %75'i eğitim geri kalanı ise test verisi olarak ele alınmıştır.
- ✓ **Katman ve Nöron Sayısı:** Tahmin modeli için sırasıyla 250, 125, 50 ve 20 nörona sahip dört tane LSTM katmanı kullanılmıştır.
- ✓ **Seyreltme (Dropout) Değeri:** Modelin eğitim sürecinde aşırı öğrenme durumunun önüne geçmek için kullanılan bu değer ile bazı nöronlar pasif hale getirilmektedir. Bu değer de diğeri hiper parametre değeri gibi çalışılan probleme göre değışkenlik göstermekle beraber bu tez kapsamında geliştirilen model için 0,1 olarak ele alınmıştır.
- ✓ **Mini-batch Boyutu:** Eğitim sürecinde, kullanılan veri kümesinin aynı anda işlenmesi durumunda gereken zaman ve bellek kullanım maliyetini az da olsun indirmek için bu hiper parametre kullanılmaktadır. Bu parametre ile

birlikte veri kümesinin tümünün aynı anda işlenmesi yerine veri kümesi küçük alt gruplara ayrılmaktadır. Modelin eğitimi de bu alt gruplar üzerinden gerçekleştirilmektedir. Tez kapsamında geliştirilen model için mini-batch boyutu 32 olarak belirlenmiştir.

- ✓ **Öğrenme Katsayısı:** Sinir ağlarının önemli parametrelerinden olan öğrenme katsayısı değeri, geliştirilen bu model için varsayılan değer olan 0,01 seçilmiştir.
- ✓ **Tur (Epoch) Sayısı:** Eğitim sürecinin, tüm veri kümesi üzerinde belirlenen bu tur sayısı kadar gerçekleştirilmesi sağlanmaktadır. Tez kapsamında geliştirilen tahmin modeli için tur sayısı 85 olarak belirlenmiştir.
- ✓ **Aktivasyon Fonksiyonu:** Geliştirilen tahmin modelinde, bir ağ içindeki düğümün girdi sinyalini bir çıktı sinyaline dönüştüren aktivasyon fonksiyonu olarak 'tanh' fonksiyonu seçilmiştir. tanh fonksiyonunun grafiksel gösterimi Şekil 4.1'de verilmiştir.



Şekil 4.1. Tanh aktivasyon fonksiyonu

- ✓ **Zaman Adımı (Time Step):** Time step ya da sliding window olarak adlandırılan zaman adımı, her bir giriş verisinin kaç günlük geçmiş gözlem değerini içereceği bilgisini vermektedir. Tez kapsamında geliştirilen model için zaman adımı değeri 7 olarak belirlenmiştir. Bu, her bir giriş verisinin geçmiş 7 günün verilerini de içerdiği anlamına gelmektedir.
- ✓ **Optimizasyon Algoritması:** Geliştirilen tahmin modelinde, üretilen çıktı ile gerçek değer arasındaki farkın yani hata değerinin minimum olabilmesini sağlayan optimizasyon algoritmalarından adam optimizasyon algoritması tercih edilmiştir.

5. BULGULAR

Bu bölümde LSTM yöntemiyle BIST 30 endeksi ve bu endekste yer alan altı banka hisse senedinin fiyat (AKBNK, GARAN, HALKB, ISCTR, YKBNK, VAKBN) tahmini için geliştirilen iki modelin ve yapılan gerçek zamanlı tahminlemenin sonuçları incelenmiştir.

Her iki tahmin modeli için kullanılan veri kümesi 6 Ocak 2010 - 9 Mart 2020 tarihleri arasındaki verilerden meydana gelmekte olup bu verilerin 1915'i eğitim, 638'i ise test kümesini oluşturmaktadır. Ayrıca oluşturulan model ile 10 Mart - 10 Nisan 2020 tarihleri arasındaki 24 iş gününü kapsayan gerçek zamanlı fiyat/endeks tahmini yapılmıştır.

Geliştirilen modellerin performansı, literatürde sıklıkla kullanılan Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE), Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Ortalama Karesel Hatanın Karekökü (Root Mean Square Error - RMSE) metrikleri ile değerlendirilmiştir. RMSE, MAE ve MAPE metrikleri sırasıyla (5.1), (5.2) ve (5.3) numaralı denklemler yardımıyla hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2} \quad (5.1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - A_i| \quad (5.2)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{P_i - A_i}{A_i} \right| \quad (5.3)$$

Yukarıdaki denklemlerde belirtilen n veri sayısını, P tahmin edilen değeri, A ise gerçek değeri ifade etmektedir.

5.1. BIST 30 Endeks Tahmini

İndirgenmiş teknik göstergeler kullanılarak geliştirilen LSTM tahmin modeli ile BIST 30 endeksinin bir gün sonraki kapanış fiyatı tahmin edilerek modelin MAPE değeri 1,05 olarak elde edilmiştir. Ayrıca önerilen modelin performansı ile girdi kümesinde teknik göstergeleri kullanarak BIST 30 endeksini tahmin etmeye çalışan Raşo ve Demirci'nin (2019) önerdiği modelin performansı Çizelge 5.1'de


karşılaştırılmıştır. İki modelin MAPE değeri karşılaştırıldığında, önermiş olduğumuz modelin performansının diğer modele oranla az da olsa daha başarılı olduğu görülmüştür.

Çizelge 5.1. Önerilen hisse senedi tahmin modelinin başka bir model (Raşo ve Demirci, 2019) ile karşılaştırılması.

	Önerilen Model	Raşo ve Demirci'nin Önerdiği Model
MAPE Değeri	1,05	1,0676

BIST 30 endeksinin bir gün sonraki kapanış değeri tahmini için geliştirilen LSTM modelinin test verisi üzerindeki başarı grafiği Şekil 5.1'de verilmiştir. Şekil incelendiğinde iki eğrinin genellikle çakiştığı görülmekte, bu durum geliştirilen modelin başarılı olduğunu göstermektedir.

Ayrıca BIST 30 endeksinin, geliştirilen model ile elde edilen 10 Mart - 9 Nisan 2020 tarihleri arasındaki 24 günlük gerçek zamanlı fiyat tahminleme sonuçları Çizelge 5.2'de verilmiştir.



Şekil 5.1. BIST 30 endeksinin geliştirilen modeldeki başarısı

Çizelge 5.2. BIST 30 endeksinin kapanış ve gerçek zamanlı tahmin değerleri

TARİH	BIST 30 Endeksi	
	Kapanış Değeri	Tahmin Değeri
10.03.2020	121995,38	130641,97
11.03.2020	122029,82	128829,91
12.03.2020	113773,66	128026,45
13.03.2020	115849,00	125036,82
16.03.2020	106609,03	124203,86
17.03.2020	105853,55	119807,33
18.03.2020	104134,10	116402,39
19.03.2020	103549,16	113620,99
20.03.2020	103726,57	111545,16
23.03.2020	101409,71	111276,85
24.03.2020	107401,04	108199,01
25.03.2020	106604,27	111094,45
26.03.2020	109734,88	109823,41
27.03.2020	105539,78	112543,58
30.03.2020	105353,96	110612,61
31.03.2020	106790,67	109981,10
01.04.2020	106148,10	110477,31
02.04.2020	106662,99	109160,90
03.04.2020	106466,96	110564,76
06.04.2020	109225,48	109470,50
07.04.2020	109869,99	111772,81
08.04.2020	110842,66	112223,91
09.04.2020	114413,17	113188,64

BIST 30 endeksi için gerçek zamanlı tahminleme sonuçları incelendiğinde 24 iş gününün altısında (çizelgede koyu renkle belirtilen günler) kapanış değerine çok yakın tahminlerin yapıldığı gözlemlenmiştir. Bununla birlikte 13 gün için fiyat yönünün doğru tahmin edildiği görülmüştür.

5.2. BIST 30 Endeksindeki Banka Hisse Senetlerinin Fiyat Tahmini

LSTM yöntemi kullanılarak geliştirilen tahmin modeli ile BIST 30 endeksinde yer alan AKBNK, GARAN, HALKB, ISCTR, VAKBN ve YKBNK hisse senetlerinin bir gün sonraki kapanış fiyatı tahmin edilmiştir.


İndirgenmiş teknik göstergeler, fiyat verileri ve temel göstergelerden meydana gelen veri kümesi ile gerçekleştirilen BIST 30 hisse senedi fiyat tahmin modelinin RMSE ve MAE değerleri Çizelge 5.3'te verilmiştir. Ayrıca önerilen modelin performansı, Tekin ve Çanakoğlu (2019)'nun sadece fiyat verilerini kullanarak

geliştirdiği tahmin modeli ile karşılaştırılmıştır. Bu karşılaştırma sonucunda özellikle ISCTR hisse senedinde hem RMSE hem de MAE performans metriklerinde ciddi başarıların elde edildiği görülmüştür. Bununla birlikte diğer beş hisse senedinden GARAN dışında AKBNK, HALKB, ISCTR ve YKBNK hisse senetlerinde sadece bir metrik üzerinden yüksek başarı elde edilmiştir.


Çizelge 5.3. Önerilen hisse senedi tahmin modelinin başka bir model (Tekin ve Çanakoğlu, 2019) ile karşılaştırılması

Hisse Senetleri	Önerilen Model		Tekin ve Çanakoğlu'nun Önerdiği Model	
	RMSE Değeri	MAE Değeri	RMSE Değeri	MAE Değeri
<i>AKBNK</i>	0,243	0,188	0,266	0,186
<i>GARAN</i>	0,430	0,314	0,339	0,146
<i>HALKB</i>	0,368	0,282	0,362	0,317
<i>ISCTR</i>	0,175	0,132	0,396	0,219
<i>VAKBN</i>	0,199	0,155	0,827	0,149
<i>YKBNK</i>	0,117	0,087	0,123	0,004


AKBNK, GARAN, HALKB, ISCTR, VAKBN ve YKBNK hisse senetlerinin bir gün sonraki fiyat tahmini için geliştirilen LSTM modelinin test verisi üzerindeki başarı grafikleri sırasıyla Şekil 5.2 - 5.7 aralığında verilmiştir. Başarı grafikleri incelendiğinde genellikle iki eğrinin üst üste çakıştığı görülmektedir. Bu durum hisse senetleri üzerindeki tahmin işleminin başarılı olduğunu göstermektedir.




Şekil 5.2. AKBNK hisse senedinin geliştirilen modeldeki başarısı




Şekil 5.3. GARAN hisse senedinin geliştirilen modeldeki başarısı




Şekil 5.4. HALKB hisse senedinin geliştirilen modeldeki başarısı



Şekil 5.5. ISCTR hisse senedinin geliştirilen modeldeki başarısı



Şekil 5.6. VAKBN hisse senedinin geliştirilen modeldeki başarısı



Şekil 5.7. YKBNK hisse senedinin geliştirilen modeldeki başarısı

Ayrıca AKBNK, GARAN, HALKB, ISCTR, VAKBN ve YKBNK hisse senetlerinin geliştirilen model ile elde edilen 10 Mart - 10 Nisan 2020 tarihleri arasındaki 24 günlük gerçek zamanlı fiyat tahminleme sonuçları Çizelge 5.4'te verilmiştir. Tahminleme sonuçları incelendiğinde çizelgede koyu renkle ifade edilen kapanış ve tahmin değerlerinin birbirine oldukça yakın olduğu görülmüştür. Buna ek olarak 24 günlük gerçek zamanlı tahminlemede AKBNK hisse senedinde 11, GARAN hisse senedinde 12, HALKB hisse senedinde 10, ISCTR hisse senedinde 13, VAKBN hisse senedinde 6 ve YKBNK hisse senedinde 13 gün için fiyat yönünün doğru tahmin edildiği gözlemlenmiştir.

Çizelge 5.4. Hisse senetlerinin kapanış ve gerçek zamanlı tahmin değerleri

TARİH	AKBNK		GARAN		HALKB		ISCTR		VAKBN		YKBNK	
	Kapanış Değeri	Tahmin Değeri	Kapanış Değeri	Tahmin Değeri	Kapanış Değeri	Tahmin Değeri	Kapanış Değeri	Tahmin Değeri	Kapanış Değeri	Tahmin Değeri	Kapanış Değeri	Tahmin Değeri
10.03.2020	6,87	7,04	9,34	9,45	5,55	6,59	5,65	5,87	5,03	5,18	2,26	2,29
11.03.2020	6,87	6,92	9,34	9,35	5,55	6,39	5,65	5,76	5,03	5,07	2,26	2,24
12.03.2020	6,31	6,85	8,74	9,19	5,09	6,19	5,26	5,70	4,66	4,99	2,14	2,22
13.03.2020	6,43	6,50	9,03	8,89	5,31	6,08	5,37	5,53	4,89	4,84	2,20	2,19
16.03.2020	6,09	6,53	8,19	8,89	4,93	6,04	5,05	5,48	4,43	4,86	2,03	2,23
17.03.2020	6,07	6,37	8,29	8,59	5,11	5,78	5,14	5,29	4,62	4,68	2,03	2,17
18.03.2020	5,91	6,22	8,08	8,50	5,03	5,70	5,03	5,27	4,57	4,68	1,99	2,12
19.03.2020	5,68	6,12	7,57	8,29	5,00	5,59	4,90	5,13	4,56	4,62	1,91	2,10
20.03.2020	5,57	5,91	7,46	8,12	5,02	5,49	4,85	5,05	4,70	4,61	1,90	2,06
23.03.2020	5,41	5,89	6,92	7,99	4,66	5,36	4,55	4,99	4,36	4,64	1,76	2,06
24.03.2020	5,74	5,72	7,58	7,76	4,98	5,04	4,83	4,84	4,67	4,51	1,91	2,01
25.03.2020	5,58	5,90	7,50	7,84	4,93	5,12	4,75	4,92	4,64	4,58	1,87	2,07
26.03.2020	5,72	5,76	7,95	7,76	5,02	5,05	4,85	4,86	4,73	4,56	1,95	2,06
27.03.2020	5,54	5,83	7,87	7,95	4,90	5,12	4,70	4,92	4,51	4,65	1,88	2,07
30.03.2020	5,50	5,70	8,02	7,91	4,95	5,05	4,68	4,81	4,52	4,52	1,89	2,05
31.03.2020	5,62	5,64	8,17	8,01	5,03	5,14	4,73	4,78	4,58	4,52	1,89	2,04
01.04.2020	5,45	5,66	7,81	7,98	4,97	5,13	4,62	4,75	4,53	4,49	1,87	2,02
02.04.2020	5,44	5,50	7,56	7,87	4,96	5,13	4,61	4,66	4,51	4,46	1,86	1,98
03.04.2020	5,40	5,56	7,54	7,82	4,94	5,19	4,57	4,67	4,47	4,47	1,83	1,98
06.04.2020	5,57	5,46	7,75	7,73	5,06	5,08	4,76	4,60	4,58	4,42	1,87	1,96
07.04.2020	5,59	5,63	7,82	7,81	5,05	5,33	4,75	4,74	4,52	4,49	1,90	1,99
08.04.2020	5,64	5,66	7,87	7,79	5,04	5,37	4,73	4,72	4,43	4,44	1,89	1,98
09.04.2020	6,00	5,66	8,45	7,85	5,24	5,37	5,03	4,71	4,64	4,41	2,03	1,98
10.04.2020	6,11	5,81	8,63	8,03	5,29	5,62	5,09	4,87	4,68	4,55	2,05	2,00

6. SONUÇ VE GELECEK ÇALIŞMALAR

Finansal/para piyasalarının kesin bir şekilde tahmin edilebilmesi fiyatlardaki hareketlilik, belirsizlik, yatırımcıların beklentileri gibi pek çok faktörden dolayı oldukça zor bir problemdir. Fakat bu problemin üstesinden gelmek adına, fiyatlardaki bu hareketliliğin göstergesi olarak düşünülen temel ve teknik gösterge gibi pek çok değerlerden faydalanılmaktadır. Finansal/para piyasalarının tahmini kapsamında yapılan diğer çalışmalardan farklı olarak bu tez kapsamında kullanılan veri kümesi; fiyat verileri, temel ve teknik göstergelerden meydana gelmektedir. Ayrıca teknik göstergelerin sayıca fazla olmasından dolayı ilk önce bu teknik göstergelerde bir indirgeme yoluna gidilmiştir. İndirgeme yapılırken, her bir teknik gösterge detaylı bir şekilde incelenerek bu teknik göstergenin geliştirilen tahmin modeli için yeterli öneme sahip olup olmadıklarına karar verilmiştir. İndirgenen teknik göstergeler ve diğer değişkenlerle beraber oluşturulan veri kümesi kullanılarak LSTM yöntemi ile BIST 30 endeksi ve bu endekste yer alan AKBNK, GARAN, HALKB, ISCTR, VAKBN ve YKBANK banka hisse senetlerinin bir gün sonraki kapanış değeri tahmin edilmiştir. Buna ek olarak, geliştirilen model ile gerçek zamanlı tahminleme de yapılmıştır.

Her iki modelin başarı grafikleri incelendiğinde kapanış ve tahmin değerlerini ifade eden iki eğrinin genellikle çakıştığı gözlemlenmiştir. Bu çakışma, geliştirilen tahmin modelinin başarılı olduğunu ifade etmektedir. Grafiklere bakıldığında borsa endeks/fiyat değerlerinin dip ve zirve yaptığı noktalarda tahmin değeri ile kapanış değerlerindeki çakışmanın daha az olduğu görülürken fiyat yönünün genel olarak doğru tahmin edildiği sonucu elde edilmiştir.

Önerilen model ile gerçekleştirilen BIST 30 endeks tahmininin, Raşo ve Demirci (2019) tarafından yapılan çalışmadan daha başarılı olduğu görülmüştür. BIST 30 endeksinde yer alan altı banka hisse senedinin fiyat tahmininde ise GARAN hisse senedi dışında diğer hisse senetlerinin fiyat tahmininin Tekin ve Çanakoğlu (2019) tarafından yapılan çalışmadan daha başarılı olduğu gözlemlenmiştir.

Gerçek zamanlı tahminler incelendiğinde ise genel olarak fiyat yönünün doğru tahmin edilmesi ile birlikte bazı günlerde tahmin değerlerinin kapanış değerine çok yakın olduğu gözlemlenmiştir. Ayrıca gerçek zamanlı tahminlemede seçilen tarih aralığı yaşanan küresel Covid19 salgınına denk gelmesi sebebiyle fiyatlarda

beklenmedik hareketlenmeler oluşmuştur. Bu nedenle modelin performansı beklenen düzeyde olamamıştır.

Gelecekte yapılması planlanan çalışmalar:

- ✓ Kullanılacak teknik göstergeleri indirgemek için sistematik bir yöntemin geliştirilmesi,
- ✓ Hisse senedi fiyatının/endeksin gün sonu kapanış fiyatının tahmin edilmesinin yanı sıra borsadaki bir işlem gününü çeşitli zaman periyotlarına bölünerek ve o periyotlardaki hareketlenmeler göz önüne alınarak bir tahmin modelinin geliştirilmesi,
- ✓ Model performans başarımını arttırmak için özellikle fiyatların zirve ve dip yaptığı durumlarda oluşan düşük başarı durumunu çözmek için yeni çözüm yöntemlerinin geliştirilmesi,
- ✓ Tahmin modelinde kullanılan fiyat verileri, teknik ve temel göstergelere ek olarak bu konu kapsamında yayınlanan haberlerden çıkarılan özniteliklerin de eklenmesi ile bir tahmin modelinin geliştirilmesi olarak belirlenmiştir.

KAYNAKLAR

- Afşar, A. ve Afşar, M. 2010. *Finansal ekonomi SPK lisanslama sınavlarına uyumlu*. Detay Yayıncılık, Ankara.
- Akel, V. ve Bayramoğlu, M. F. 2008. Kriz Dönemlerinde Yapay Sinir Ağları ile Finansal Öngöründe Bulunma: İMKB 100 Endeksi Örneği. International Symposium on International Capital Flows and Emerging Markets, 24-27 Nisan, 24-28, Balıkesir, Türkiye.
- Akşehir, Z. D. and Kılıç, E. 2019a. Prediction of Bank Stocks Price with Reduced Technical Indicators. 2019 4th International Conference on Computer Science and Engineering (UBMK), 11-15 September, 206-210. IEEE, Samsun, Turkey.
- Akşehir, Z. D. ve Kılıç, E. 2019b. Makine öğrenmesi teknikleri ile banka hisse senetlerinin fiyat tahmini. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 12:2, 30-39.
- Akşehir, Z. D., Kılıç, E., Akleyek, S., Döngül, M., and Coşkun, B. Stocks Prediction via Long Short-Term Memory. 2020. 5th International Conference on Internet of Things, Big Data and Security, Prague, Czech Republic.
- Alam, S. 2018. Recurrent Neural Networks in Electricity Load Forecasting. Degree Project in Computer Science and Engineering, Second Cycle, 30 Credits, Stockholm, Sweden.
- Alhazbi, S., Said, A. B., & Al-Maadid, A. 2020. Using Deep Learning to Predict Stock Movements Direction in Emerging Markets: The Case of Qatar Stock Exchange. In 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIOT), 440-444. IEEE.
- Altay, E. ve Satman, M. H. 2005. Stock market forecasting: Artificial neural network and linear regression comparison in an emerging market. *Journal of Financial Management and Analysis*, 18:2, 18-33.
- Birgili, E. 1994. Tasarrufların yönlendirilmesinde hisse senedi verimlilik analizi ve değerlendirilmesi. Doktora Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, İzmir.
- Büyükdere, S. 2002. Teknik analiz yöntemiyle hisse senedi değerlemesi. Yüksek Lisans Tezi, Sakarya Üniversitesi Sosyal Bilimler Enstitüsü, Sakarya.
- Chollet, F. 2017. Deep learning with python. *Manning Publications*, 1:56, 196-207.
- Civan, M. 2007. *Sermaye piyasası analizleri ve portföy yönetimi*. Gazi Kitabevi, Ankara.
- Çağırman, H. 1999. *Finans piyasalarında bermuda şeytan üçgeni*. Siyasal Kitabevi, Ankara.

- Diler, A. İ. 2003. İMKB ulusal-100 endeksinin yönünün yapay sinir ağları hatayı geriye yayma yöntemi ile tahmin edilmesi. *İMKB Dergisi*, 7:25-26, 66-82.
- Du, J., Liu, Q., Chen, K. and Wang, J. 2019. Forecasting Stock Prices in Two Ways Based on LSTM Neural Network. 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 15-17 March, 1083-1086, IEEE, Chengdu, China.
- Elman, J. L. 1990. Finding Structure in Time. *Cognitive Science*, 14:2, 179-211.
- Gao, T., Chai, Y. and Liu, Y. 2017. Applying Long Short Term Memory Neural Networks for Predicting Stock Closing Price. 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS), 24-26 November, 575-578, IEEE, Beijing, China.
- Gunduz, H., Cataltepe, Z. and Yaslan, Y. 2017. Stock Market Direction Prediction Using Deep Neural Networks. 2017 25th Signal Processing and Communications Applications Conference (SIU), 15-18 May, 1-4. IEEE, Antalya, Turkey.
- Günak, N. 2007. *İleri teknik analiz uygulamaları*. Literatür Yayıncılık, İstanbul.
- Hochreiter, S. and Schmidhuber, J. 1997. Long short term memory. *Neural Computing*, 9:8, 1735-1780.
- Hossain, M. A., Karim, R., Thulasiram, R., Bruce, N. D. and Wang, Y. 2018. Hybrid Deep Learning Model for Stock Price Prediction. 2018 IEEE Symposium Series on Computational Intelligence (SSCI), 18-21 November, 1837-1844. IEEE, Bangalore, India.
- Inthachot, M., Boonjing, V. and Intakosum, S. 2015. Predicting SET50 Index Trend Using Artificial Neural Network and Support Vector Machine. International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems, 01 May, 404-414, Springer, Switzerland.
- Kara, Y., Boyacioglu, M. A., and Baykan, Ö. K. 2011. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with Applications*, 38:5, 5311-5319.
- Karaatlı, M., Güngör, İ., Demir, Y. ve Kalaycı, Ş. 2005. Hisse senedi fiyat hareketlerinin yapay sinir ağları yöntemi ile tahmin edilmesi. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 3:3, 38-48.
- Karan, M. B. 2011. *Yatırım analizi ve portföy yönetimi*. Gazi Kitabevi.
- Kim, K. 2003. Financial time series forecasting using support vector machines. *Neurocomputing*, 55, 307-319.
- Kutlu, B. ve Badur, B. 2009. Yapay sinir ağları ile borsa endeksi tahmini. *Yönetim*, 20:63, 25-40.

- Mikolov, T., Karafiat, M., Burget, L., Cernocky, J. and Khudanpur S. 2010. Recurrent neural network based language model. *Interspeech*, 1045-1048.
- Nelson, D. M., Pereira, A. C. and de Oliveira, R. A. 2017. Stock Market's Price Movement Prediction with LSTM Neural Networks. 2017 International Joint Conference on Neural Networks (IJCNN), 14-19 May, 1419-1426). IEEE, Anchorage, AK, USA.
- Olah, C. 2015. Understanding LSTM Networks. colah.github.io: colah.github.io/posts/2015-08-Understanding-LSTMs/ (Eriřim Tarihi: 15.05.2020).
- Parmar, I., Agarwal, N., Saxena, S., Arora, R., Gupta, S., Dhiman, H. and Chouhan, L. 2018. Stock Market Prediction Using Machine Learning. 2018. First International Conference on Secure Cyber Computing and Communication (ICSCCC), 574-576. IEEE.
- Patterson, J. and Gibson, A. 2017. *Deep learning: A practitioner's approach*. O'Reilly Press, ISBN:978-1-491-91425-0, 41-114, 125-165.
- Perřembe, A. 2002. Teknik analiz mi dedin? Hadi canım sen de! (Üçüncü Baskı). Scala Yayıncılık, İstanbul.
- Rařo, H. ve Demirci, M. 2019. Predicting the Turkish stock market BIST 30 index using deep learning. *Uluslararası Mühendislik Arařtırma ve Geliřtirme Dergisi*, 11: 1, 253-265.
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K. and Soman, K. P. 2017. Stock Price Prediction Using LSTM, RNN and CNN-Sliding Window Model. 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI), 13-16 September, 1643-1647, IEEE, Udupi, India.
- Sui, X., Hu, Q., Yu, D., Xie, Z. and Qi, Z. A. 2007. Hybrid Method for Forecasting Stock Market Trend Using Soft-Thresholding De-Noise Model and SVM. *Springer Verlag Berlin Heidelberg*, 387-394.
- Tekin, S. and Çanakoęlu, E. 2019. Analysis of Price Models in Istanbul Stock Exchange. 2019 27th Signal Processing and Communications Applications Conference (SIU), 24-26 April, 1-4, IEEE, Sivas, Turkey.
- Teknikanaliz, <http://www.borsanaliz.com/> (Eriřim Tarihi: 15.05.2020).
- Türkiye Sermaye Piyasası Aracı Kuruluşlar Birlięi. 2011. *Sermaye piyasası faaliyetleri ileri düzey lisans eęitimi, analiz yöntemleri*. TSPAKB, İstanbul.
- Unal, B. and Aladag, C. H. 2019. Stock exchange prediction via long short-term memory networks. *Proceedings Book*, 246.
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599-606.

Yakut, E., Elmas, B. ve Yavuz, S. 2014. Yapay sinir ağıları ve destek vektör makineleri yöntemleriyle borsa endeksi tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19:1, 139-157.

Young, T., Hazarika, D., Poria, S. and Cambria, E. 2018. Recent Trends in Deep Learning Based Natural Language Processing. *IEEE Computational Intelligence Magazine*, 55-75.



EKLER

- EK 1 AKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI
TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**
- EK 2 GARAN HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI
TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**
- EK 3 HALKB HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI
TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**
- EK 4 ISCTR HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI
TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**
- EK 5 VAKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI
TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**
- EK 6 YKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI
TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**
- EK 7 BIST 30 ENDEKSİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN
DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ**

EK 1 AKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	6.8699994	7.037656
2020-03-11 00:00:00	6.8699994	6.920614
2020-03-12 00:00:00	6.3099995	6.8526993
2020-03-13 00:00:00	6.4299994	6.5042315
2020-03-16 00:00:00	6.09	6.5327415
2020-03-17 00:00:00	6.07	6.36732
2020-03-18 00:00:00	5.9099994	6.218114
2020-03-19 00:00:00	5.68	6.122504
2020-03-20 00:00:00	5.57	5.913868
2020-03-23 00:00:00	5.41	5.891503
2020-03-24 00:00:00	5.74	5.715599
2020-03-25 00:00:00	5.58	5.899727
2020-03-26 00:00:00	5.72	5.7584558
2020-03-27 00:00:00	5.54	5.828526
2020-03-30 00:00:00	5.5	5.6953664
2020-03-31 00:00:00	5.62	5.6366377
2020-04-01 00:00:00	5.45	5.6594357
2020-04-02 00:00:00	5.44	5.4962025
2020-04-03 00:00:00	5.4	5.5586557
2020-04-06 00:00:00	5.57	5.458444
2020-04-07 00:00:00	5.59	5.6316776
2020-04-08 00:00:00	5.64	5.6644998
2020-04-09 00:00:00	6.0	5.6563416
2020-04-10 00:00:00	6.11	5.8051376

EK 2 GARAN HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Gerçek_Zamanlı_Tahminleme - DataFrame

Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	9.34	9.447924
2020-03-11 00:00:00	9.34	9.346512
2020-03-12 00:00:00	8.74	9.192515
2020-03-13 00:00:00	9.03	8.893998
2020-03-16 00:00:00	8.19	8.88862
2020-03-17 00:00:00	8.289999	8.586535
2020-03-18 00:00:00	8.079999	8.502514
2020-03-19 00:00:00	7.57	8.28912
2020-03-20 00:00:00	7.46	8.115952
2020-03-23 00:00:00	6.92	7.9915094
2020-03-24 00:00:00	7.5799994	7.7567945
2020-03-25 00:00:00	7.4999995	7.840898
2020-03-26 00:00:00	7.9499993	7.7611156
2020-03-27 00:00:00	7.8699994	7.9506845
2020-03-30 00:00:00	8.02	7.9062104
2020-03-31 00:00:00	8.17	8.007453
2020-04-01 00:00:00	7.809999	7.9810305
2020-04-02 00:00:00	7.56	7.872025
2020-04-03 00:00:00	7.54	7.821819
2020-04-06 00:00:00	7.75	7.733739
2020-04-07 00:00:00	7.8199997	7.7812705
2020-04-08 00:00:00	7.8699994	7.789751
2020-04-09 00:00:00	8.45	7.846456
2020-04-10 00:00:00	8.63	8.031007

Format Resize ☒ Background ☒ Column r Save and Clo Close

EK 3 HALKB HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Gerçek_Zamanlı_Tahminleme - DataFrame

Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	5.5500007	6.59483
2020-03-11 00:00:00	5.5500007	6.389273
2020-03-12 00:00:00	5.09	6.18713
2020-03-13 00:00:00	5.31	6.0769525
2020-03-16 00:00:00	4.93	6.03564
2020-03-17 00:00:00	5.11	5.7789536
2020-03-18 00:00:00	5.03	5.695259
2020-03-19 00:00:00	4.9999995	5.5926948
2020-03-20 00:00:00	5.02	5.4875674
2020-03-23 00:00:00	4.66	5.357093
2020-03-24 00:00:00	4.98	5.0417566
2020-03-25 00:00:00	4.93	5.121363
2020-03-26 00:00:00	5.02	5.0458946
2020-03-27 00:00:00	4.9	5.144499
2020-03-30 00:00:00	4.95	5.1322436
2020-03-31 00:00:00	5.03	5.1309743
2020-04-01 00:00:00	4.97	5.1886654
2020-04-02 00:00:00	4.96	4.9780564
2020-04-03 00:00:00	4.9399996	5.1288795
2020-04-06 00:00:00	5.0600004	5.082955
2020-04-07 00:00:00	5.05	5.327762
2020-04-08 00:00:00	5.04	5.3712854
2020-04-09 00:00:00	5.2400002	5.371094
2020-04-10 00:00:00	5.29	5.6240396

Format Resize ☒ Background ☒ Column r Save and Clo: Close

EK 4 ISCTR HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Gerçek_Zamanlı_Tahminleme - DataFrame		
Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	5.65	5.8666368
2020-03-11 00:00:00	5.65	5.76153
2020-03-12 00:00:00	5.26	5.700638
2020-03-13 00:00:00	5.37	5.52505
2020-03-16 00:00:00	5.05	5.48362
2020-03-17 00:00:00	5.14	5.289815
2020-03-18 00:00:00	5.03	5.271834
2020-03-19 00:00:00	4.9	5.1302605
2020-03-20 00:00:00	4.85	5.0479827
2020-03-23 00:00:00	4.55	4.9855475
2020-03-24 00:00:00	4.83	4.838705
2020-03-25 00:00:00	4.75	4.9243255
2020-03-26 00:00:00	4.85	4.862597
2020-03-27 00:00:00	4.7	4.921684
2020-03-30 00:00:00	4.68	4.8146205
2020-03-31 00:00:00	4.73	4.781612
2020-04-01 00:00:00	4.62	4.7503834
2020-04-02 00:00:00	4.61	4.6598797
2020-04-03 00:00:00	4.57	4.6723237
2020-04-06 00:00:00	4.76	4.6000595
2020-04-07 00:00:00	4.75	4.7423058
2020-04-08 00:00:00	4.73	4.7227106
2020-04-09 00:00:00	5.03	4.7155437
2020-04-10 00:00:00	5.09	4.8682275

Format
Resize
☒ Background
☒ Column r
Save and Clo
Close

EK 5 VAKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Gerçek_Zamanlı_Tahminleme - DataFrame

Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	5.03	5.1845665
2020-03-11 00:00:00	5.03	5.0660496
2020-03-12 00:00:00	4.66	4.990448
2020-03-13 00:00:00	4.89	4.8409576
2020-03-16 00:00:00	4.43	4.8570185
2020-03-17 00:00:00	4.62	4.6841803
2020-03-18 00:00:00	4.57	4.6811333
2020-03-19 00:00:00	4.56	4.6190777
2020-03-20 00:00:00	4.7	4.609883
2020-03-23 00:00:00	4.36	4.636436
2020-03-24 00:00:00	4.67	4.511825
2020-03-25 00:00:00	4.64	4.581479
2020-03-26 00:00:00	4.73	4.5594697
2020-03-27 00:00:00	4.51	4.653655
2020-03-30 00:00:00	4.52	4.5194364
2020-03-31 00:00:00	4.58	4.519466
2020-04-01 00:00:00	4.53	4.4876375
2020-04-02 00:00:00	4.51	4.463074
2020-04-03 00:00:00	4.47	4.47242
2020-04-06 00:00:00	4.58	4.4219418
2020-04-07 00:00:00	4.52	4.48562
2020-04-08 00:00:00	4.43	4.4403515
2020-04-09 00:00:00	4.64	4.4140453
2020-04-10 00:00:00	4.68	4.5508404

Format Resize ☒ Background ☒ Column ☐ Hide and Close Close

EK 6 YKBNK HİSSE SENEDİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	2.26	2.2865765
2020-03-11 00:00:00	2.26	2.2438083
2020-03-12 00:00:00	2.14	2.2214754
2020-03-13 00:00:00	2.2	2.1871183
2020-03-16 00:00:00	2.03	2.2280903
2020-03-17 00:00:00	2.03	2.1666224
2020-03-18 00:00:00	1.99	2.1224198
2020-03-19 00:00:00	1.91	2.095512
2020-03-20 00:00:00	1.9	2.060378
2020-03-23 00:00:00	1.76	2.0574975
2020-03-24 00:00:00	1.91	2.010145
2020-03-25 00:00:00	1.8699999	2.0680833
2020-03-26 00:00:00	1.95	2.0577617
2020-03-27 00:00:00	1.8800001	2.0738912
2020-03-30 00:00:00	1.89	2.0523317
2020-03-31 00:00:00	1.89	2.040941
2020-04-01 00:00:00	1.8699999	2.0178711
2020-04-02 00:00:00	1.86	1.9776193
2020-04-03 00:00:00	1.8299999	1.9842602
2020-04-06 00:00:00	1.8699999	1.9575316
2020-04-07 00:00:00	1.9	1.9860054
2020-04-08 00:00:00	1.89	1.9801085
2020-04-09 00:00:00	2.03	1.9838607
2020-04-10 00:00:00	2.05	1.9976435

EK 7 BIST 30 ENDEKSİNİN KAPANIŞ VE GERÇEK ZAMANLI TAHMİN DEĞERLERİNİ GÖSTEREN EKRAN GÖRÜNTÜSÜ

Gerçek_Zamanlı_Tahminleme - DataFrame		
Index	Kapanış Değeri	Tahmin Değeri
2020-03-10 00:00:00	121995.375	130641.97
2020-03-11 00:00:00	122029.82	128829.914
2020-03-12 00:00:00	113773.66	128026.445
2020-03-13 00:00:00	115849.0	125036.82
2020-03-16 00:00:00	106609.03	124203.86
2020-03-17 00:00:00	105853.55	119807.33
2020-03-18 00:00:00	104134.1	116402.39
2020-03-19 00:00:00	103549.164	113620.99
2020-03-20 00:00:00	103726.57	111545.16
2020-03-23 00:00:00	101409.71	111276.85
2020-03-24 00:00:00	107401.04	108199.01
2020-03-25 00:00:00	106604.27	111094.45
2020-03-26 00:00:00	109734.88	109823.414
2020-03-27 00:00:00	105539.78	112543.58
2020-03-30 00:00:00	105353.96	110612.61
2020-03-31 00:00:00	106790.67	109981.1
2020-04-01 00:00:00	106148.1	110477.305
2020-04-02 00:00:00	106662.99	109160.9
2020-04-03 00:00:00	106466.96	110564.76
2020-04-06 00:00:00	109225.484	109470.5
2020-04-07 00:00:00	109869.99	111772.805
2020-04-08 00:00:00	110842.664	112223.914
2020-04-09 00:00:00	114413.17	113188.64

Format
Resize
☒ Background
☒ Column
Save and Close
Close

ÖZ GEÇMİŞ

Adı ve Soyadı : Zinnet Duygu AKŞEHİR

Doğum Yeri : Çayeli

Doğum Tarihi : 10.03.1994

Yabancı Dili : İngilizce

Eğitim Durumu

- Lise : Artvin Anadolu Öğretmen Lisesi (2012)
Lisans : Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü (02/2017)
Yüksek Lisans : Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı (09/2017 – 07/2020)

Çalıştığı Kurum/Kurumlar ve Yıl

Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Bölümü Araştırma Görevlisi / (Nisan 2018 – Halen)

Yayınlar

- 1) Akşehir, Z. D., Oruç, Y., Elibol, A., Akleylek, S. and Kılıç, E. 2018. On the Analysis of Work Accidents Data by Using Data Preprocessing and Statistical Techniques. The 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), 19-21 October, 1-6, IEEE, Ankara, Turkey.
- 2) Pekel, E., Akşehir, Z. D., Meto, B., Akleylek, S. and Kılıç, E. 2018. A Bayesian Network Application in Occupational Health and Safety. The 3rd International Conference on Computer Science and Engineering (UBMK), 20-23 September, 239-243, IEEE, Sarajevo, Bosnia-Herzegovina.
- 3) Akşehir, Z. D. and Kılıç, E. 2019. Prediction of Bank Stocks Price with Reduced Technical Indicators. The 4th International Conference on Computer Science and Engineering (UBMK), 11-15 September, 206-210, IEEE, Samsun, Turkey.
- 4) Akşehir, Z. D. and Kılıç, E. 2019. Makine öğrenmesi teknikleri ile banka hisse senetlerinin fiyat tahmini. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 12:2, 30-39.
- 5) Akşehir, Z. D., Pekel, E., Akleylek, S., Kılıç, E. and Yalçın, O. 2019. İş sağlığı ve güvenliği sektöründe Bayes ağları uygulaması. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 12:1, 47-59.
- 6) Akşehir, Z. D., Kılıç, E., Akleylek, S., Döngül, M. and Coşkun, B. 2020. Stocks Prices Prediction with Long Short-term Memory. The 5th International Conference on Internet of Things, Big Data and Security (IoTBDs), 7-9 May, Proceeding Books, 221-226, Prague, Czech Republic. doi: 10.5220/0009351602210226
- 7) Akşehir, Z. D. and Aslan, S. (2020). Paralel Parçacık Sürü Optimizasyon Algoritmasında Göç Zamanının Etkisi. The 28th IEEE Conference on Signal Processing and Communications Applications (SIU), 5-7 October, Gaziantep, Turkey. (Kabul edildi)