



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

İŞLETME ANABİLİM DALI

DOKTORA PROGRAMI

**BORSA ENDEKSİ TAHMİNİNDE DERİN ÖĞRENME VE
GELENEKSEL YÖNTEMLERİN KARŞILAŞTIRMASI: G7 VE E7
ÜLKELERİNDE BİR UYGULAMA**

DOKTORA TEZİ

Lütfiye SÖNMEZ

Danışman: Prof. Dr. Mihriban COŞKUN ARSLAN

TOKAT-2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Mihriban COŞKUN ARSLAN danışmanlığında hazırlamış olduğum “Borsa Endeksi Tahmininde Derin Öğrenme Ve Geleneksel Yöntemlerin Karşılaştırması: G7 Ve E7 Ülkelerinde Bir Uygulama” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

19/06/2025

Lütfiye SÖNMEZ

JÜRİ KABUL VE ONAY

Lütfiye SÖNMEZ tarafından hazırlanan “**Borsa Endeksi Tahmininde Derin Öğrenme Ve Geleneksel Yöntemlerin Karşılaştırması: G7 Ve E7 Ülkelerinde Bir Uygulama**” adlı tez çalışmasının savunma sınavı 19/06/2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü İşletme Anabilim Dalın’ da Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)**İmzası**

Üye (Başkan) :

Üye :

Üye :

Üye :

Üye :

ONAY

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

Lisansüstü Eğitim Enstitüsü Müdürü

İTHAF



Aileme...

TEŞEKKÜR

Doktora tez sürecinde bilgi birikimi, deneyimi ve değerli katkılarıyla yol gösteren danışmanım Sayın Prof. Dr. Mihriban COŞKUN ARSLAN' a en içten teşekkürlerimi sunarım. Tez izleme komitesinde değerli zamanlarını ayırarak yapıcı eleştirileriyle katkı sağlayan Sayın Prof. Dr. Salih BARIŞIK ve Sayın Doç. Dr. Oktay ÖZKAN' a, ayrıca savunma jürimde yer alan, içten yaklaşımları ve kıymetli görüşleriyle tezime değer katan Sayın Prof. Dr. Süleyman Serdar KARACA ve Sayın Dr. Öğr. Üyesi Nizamettin BAŞARAN' a teşekkürlerimi iletmek isterim.

Bu zorlu ve bir o kadar da kıymetli süreçte en başından itibaren yanımda olan, sabrıyla, sevgisiyle ve desteğiyle bana güç veren canım eşime en derin teşekkürlerimi sunmak istiyorum. Her anımda yanımda oluŖun, sessizce verdiđin destek ve içtenlikle hissettirdiđin güven sayesinde bu yolculuđu tamamlamak benim için mümkün oldu. Varlıđın, bu sürecin en kıymetli parçasıydı. Ayrıca, hayatım boyunca inancını ve dualarını benden esirgemeyen aileme sonsuz teşekkürler...

ÖZET

BORSA ENDEKSİ TAHMİNİNDE DERİN ÖĞRENME VE GELENEKSEL YÖNTEMLERİN KARŞILAŞTIRMASI: G7 VE E7 ÜLKELERİNDE BİR UYGULAMA

Sönmez, Lütfiye

Doktora, İşletme Anabilim Dalı

Tez Danışmanı: Prof. Dr. Mihriban COŞKUN ARSLAN

Haziran 2025, xx + 276 sayfa

Çalışmanın amacı gelişmiş (G7) ve gelişmekte olan (E7) ülkelerine ait seçilmiş borsa endekslerini tahmin etmek ve geleneksel ile derin öğrenme tabanlı modellerin performanslarını karşılaştırmalı olarak analiz etmektir. Bu doğrultuda geleneksel istatistikî yöntemlerden ARIMA ve Derin öğrenme tabanlı modellerden ise LSTM modeli kullanılarak farklı ülke dinamiklerine sahip piyasalarda tahmin başarısı değerlendirilmiştir. Modelleme sürecinde bağımlı değişken olarak ilgili borsa endekslerinin kapanış fiyatları, bağımsız değişken olarak ise literatürde genel kabul görmüş on teknik gösterge (MA, WMA, MACD, CCI, RSI, Skolastik %K, Skolastik %D, Williams' %R, Momentum, A/D) ve üç makro ekonomik gösterge (Altın ONS fiyatı, Bren petrol fiyatı ve DXY) kullanılmıştır.

Çalışmada kullanılan veri seti 2006-2022 dönemine ait günlük verilerden oluşmakta olup ilgili veriler investing.com ve yahoo.finance adreslerinden temin edilmiştir. Modellerin tahmin performansları her bir ülke için MAE, MSE, RMSE ve MAPE hata ölçütleri kullanılarak değerlendirilmiştir. Elde edilen analiz sonuçları genel olarak LSTM modelinin ARIMA modeline göre kıyasla daha düşük tahmin hataları ürettiğini ve özellikle volatilitesi yüksek piyasalarda uzun vadeli bağımlılıkları yakalama kabiliyeti sayesinde daha yüksek tahmin performansı sergilediği ortaya konulmuştur. Bununla birlikte belirli piyasalarda ARIMA modelinin LSTM modeline rekabetçi bir performans sergilediği gözlemlenmiştir. ARIMA modeli, MOEX ve Shanghai Composite endekslerinde LSTM modeli ile karşılaştırılabilir bir doğrulukta performans göstermiştir. Bu bulgu, ülkeler arası yapısal farklılıkların ve veri seti özelliklerinin tahmin performansını etkilediğini ortaya koymaktadır. Sonuçlar, finansal tahmin çalışmalarında model seçiminin önemine işaret etmekte ve yüksek volatiliteli piyasalarda derin öğrenme yaklaşımlarının avantajlarını vurgulamaktadır.

Anahtar Kelimeler: Borsa Endeksi, ARIMA, LSTM, G7, E7

ABSTRACT

COMPARISON OF DEEP LEARNING AND TRADITIONAL METHODS IN STOCK INDEX FORECASTING: AN APPLICATION IN G7 AND E7 COUNTRIES

Sönmez, Lütfiye

Doctorate's Degree, Business Administration Scientific

Advisor: Prof.Dr. Mihriban COŞKUN ARSLAN

June 2025, xx + 276 pages

The purpose of this study is to predict selected stock market indices of developed (G7) and emerging (E7) countries and to comparatively analyze the performance of traditional and deep learning-based models. In this regard, prediction success was evaluated in markets with different country dynamics using ARIMA from traditional statistical methods and LSTM model from deep learning-based models. In the modeling process, the closing prices of the relevant stock market indices were used as the dependent variable, while ten technical indicators widely accepted in the literature (MA, WMA, MACD, CCI, RSI, Stochastic %K, Stochastic %D, Williams' %R, Momentum, A/D) and three macroeconomic indicators (Gold ounce price, Brent oil price, and DXY) were used as independent variables.

The dataset used in the study consists of daily data for the period 2006-2022, and the relevant data were obtained from investing.com and yahoo.finance. The prediction performance of the models was evaluated using MAE, MSE, RMSE, and MAPE error metrics for each country. The analysis results generally revealed that the LSTM model produces lower prediction errors compared to the ARIMA model and exhibits higher prediction performance, particularly in high-volatility markets, due to its ability to capture long-term dependencies. However, it was observed that the ARIMA model exhibited competitive performance compared to the LSTM model in certain markets. The ARIMA model demonstrated comparable accuracy performance to the LSTM model in the MOEX and Shanghai Composite indices. This finding reveals that structural differences between countries and dataset characteristics affect prediction performance. The results highlight the importance of model selection in financial forecasting studies and emphasize the advantages of deep learning approaches in high-volatility markets.

Key Words: Stock Index, ARIMA, LSTM, G7, E7

İÇİNDEKİLER

Etik Sözleşme	i
Jüri Kabul Ve Onay	ii
İthaf	iii
Teşekkür.....	iv
Özet.....	v
Abstract	vi
İçindekiler	vii
Tablolar Listesi.....	xii
Şekiller Listesi.....	xiv
Kısaltmalar	xviii
Giriş	1
1. BÖLÜM: FİNANSAL PİYASALAR VE BORSA	4
1.1 Finansal Piyasaların Tanımı Ve İşlevleri	4
1.2 Finansal Piyasaların Sınıflandırılması	7
1.2.1. Para ve Sermaye Piyasaları	7
1.2.2. Birincil ve İkincil Piyasalar	8
1.2.3. Organize ve Tezgah Üstü Piyasalar	8
1.2.4. Spot ve Vadeli Piyasalar	9
1.2.5. Üçüncül ve Dördüncül Piyasalar	10
1.2.6. Ulusal ve Uluslararası Piyasalar.....	10
1.3 Finansal Piyasa Enstürmanları (Araçları)	11
1.3.1. Hisse Senetleri.....	12
1.3.2. Tahviller	13
1.3.3. Varlığa Dayalı Menkul Kıymetler (VDMK).....	14
1.3.4. Finansman Bonoları	15
1.3.5. Banka Bonoları ve Banka Garantili Bonolar.....	16
1.3.6. Gelir Ortaklığı Senetleri	17
1.3.7. Gayrimenkul Sertifikaları.....	17
1.3.8. Menkul Kıymet Dışındaki Sermaye Piyasası Araçları.....	18
1.4 Borsalar Ve Borsa Endeksleri	18
1.4.1. Borsa Kavramı.....	19

1.4.2.	Borsanın Gelişimi.....	20
1.4.3.	Borsanın İşlevleri ve Ekonomiye Etkileri	21
1.4.4.	Gelişmiş ve Gelişmekte Olan Borsalar	22
1.4.5.	Borsa Endeksi ve Seçilmiş Ülke Endeksleri	25
1.4.5.1	G7 Ülkeleri ve Seçilmiş Borsa Endeksleri	27
1.4.5.2	E7 Ülkeleri ve Seçilmiş Borsa Endeksleri.....	33
1.4.6.	Borsa Endeks Tahmininde kullanılan Yöntemler	39
1.4.6.1	Temel Analiz	40
1.4.6.2	Teknik Analiz	42
1.4.6.3	Matematiksel ve İstatistiksel Yöntemler.....	43
1.4.6.4	Makine Öğrenme Yöntemleri.....	43
2.	BÖLÜM:YAPAY ZEKA, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME.....	45
2.1	Yapay Zeka Kavramı Ve Gelişimi.....	45
2.2	Yapay Zeka Yaklaşımları.....	48
2.2.1.	İnsan Gibi Düşünme (Bilişsel Modelleme) Yaklaşımı	48
2.2.2.	İnsan Gibi Davranma (Turing Testi) Yaklaşımı	49
2.2.3.	Rasyonel Düşünme (Düşünce Kanunları) Yaklaşımı.....	49
2.2.4.	Rasyonel Davranma (Zeki Ajan) Yaklaşımı	50
2.3	Finans Alanında Yapay Zeka Uygulamaları	50
2.3.1.	Metin Madenciliği ve Ses Tanıma	50
2.3.2.	Anomali Tespiti.....	51
2.3.3.	Portföy Yönetimi ve Danışmanlık.....	51
2.3.4.	Piyasa Duygu ve Haber Analizi	51
2.3.5.	Algoritmik Al-Sat.....	52
2.3.6.	Kredi Değerlendirilmesinde YZ Kullanımı.....	52
2.3.7.	Zaman Serisi Tahmini ve Analizi.....	53
2.3.8.	Hedge Fon Stratejileri	53
2.4	Makine Öğrenmesi	53
2.4.1.	Makine Öğrenmesi Fonksiyonları	55
2.4.1.1	Sınıflandırma	55
2.4.1.2	Anomali Saptama.....	55
2.4.1.3	Sayısal Tahmin (Bağlanım)	56
2.4.1.4	Kümeleme (Clustering).....	56
2.4.1.5	Birliktelik Kuralı (Association Rule)	56
2.4.1.6	Boyut İndirgeme (Dimensionality Reduction).....	57

2.4.2.	Makine Öğrenme Türleri.....	57
2.4.3.	Denetimli Öğrenme (Supervised Learning)	57
2.4.4.	Denetimsiz Öğrenme (Unsupervised Learning).....	58
2.4.5.	Pekiştirmeli Öğrenme (Reinforcement Learning).....	58
2.5	Derin Öğrenme.....	58
2.6	Derin Öğrenme Mimarileri	63
2.6.1.	Evrişimli Sinir Ağı (Convolutional Neural Network, CNN)	63
2.6.2.	Tekrarlayan Sinir Ağı (Recurrent Neural Network, RNN).....	63
2.6.3.	Uzun Kısa Süreli Bellek Ağı (Long Short-Term Memory Network, LSTM).....	66
2.6.4.	Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory Network, Bi-LSTM).....	67
2.6.5.	Gated Recurrent Unit (GRU)	68
2.6.6.	Generatif Çekişmeli Ağlar (Generative Adversarial Networks, GAN) ..	69
2.6.7.	Derin İnanç Ağı (Deep Belief Network, DBN).....	69
2.6.8.	Otoenkoder (Autoencoder).....	69
2.6.9.	Hibrit Mimariler	70
3.	BÖLÜM: UYGULAMADA KULLANILAN TAHMİN YÖNTEMLERİ, TEKNİK GÖSTERGELER VE İLGİLİ LİTERATÜR TARAMASI	71
3.1	Otoregresif Entegre Hareketli Ortalama Modeli (Arıma).....	71
3.2	Uzun Kısa Süreli Bellek (Lstm).....	75
3.3	Modellerin Değerlendirme Kriterleri	78
3.4	Endeks Tahmininde Girdi Değişkeni Olarak Kullanılan Teknik Göstergeler	79
3.4.1.	Hareketli Ortalama (Moving Average, MA).....	80
3.4.2.	Ağırlıklı Hareketli Ortalama (Weighted Moving Average, WMA).....	81
3.4.3.	Hareketli Ortalamalar Yakınlaşma-Uzaklaşma Göstergesi (Moving Average Convergence Divergence, MACD)	82
3.4.4.	Mal Kanalı Endeksi (Commodity Channel Index, CCI)	83
3.4.5.	Göreceli Güç Endeksi (Relative Strength Index, RSI).....	84
3.4.6.	Stokastik %K (Stochastic %K)	85
3.4.7.	Stokastik % D (Stochastic % D)	86
3.4.8.	Williams'ın %R Göstergesi (Williams' %R).....	86
3.4.9.	Momentum Göstergesi (Momentum Indicator - MOM).....	87
3.4.10.	Birikim /Dağıtım Göstergesi (Accumulation/Distribution, A/D Line) ...	88
3.5	Borsa Endeks Tahminine İlişkin Literatür Taraması	89
3.5.1.	Borsa Endeks Tahminine İlişkin Türkiye' de Yapılan Çalışmalar	89

3.5.2.	Borsa Endeks Tahminine İlişkin Yurt Dışında Yapılan Çalışmalar	95
4.	BÖLÜM: BORSA ENDEKS TAHMİN UYGULAMASI.....	106
4.1	Uygulamanın Amacı	106
4.2	Veri Seti	107
4.2.1.	Analizde Kullanılan Ülkeler ve Borsa Endeksleri	107
4.2.2.	Girdi Değişkenleri ve Veri Hazırlama Süreci	110
4.3	Arıma (Box-Jenkins) Yöntemi İle Endeks Tahmini	113
4.3.1.	G7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin Arıma Modeli İle Tahmini	114
4.3.1.1	Amerika (S&P 500) Endeksi Tahmin Analizi	115
4.3.1.2	Kanada (S&P/TSX) Endeksi Tahmin Analizi.....	121
4.3.1.3	Almanya (DAX) Endeksi Tahmin Analizi	127
4.3.1.4	Fransa (CAC40) Endeksi Tahmin Analizi.....	133
4.3.1.5	İngiltere (FTSE100) Endeksi Tahmin Analizi	139
4.3.1.6	İtalya (FTSE MIB) Endeksi Tahmin Analizi	145
4.3.1.7	Japonya (NIKKEI 225) Endeksi Tahmin Analizi.....	151
4.3.2.	E7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin Arıma Modeli İle Tahmini	157
4.3.2.1	Çin (SHANGHAI COMPOSITE) Endeksi Tahmin Analizi.....	157
4.3.2.2	Hindistan (NIFTY50) Endeksi Tahmin Analizi	164
4.3.2.3	Brezilya (BOVESPA) Endeksi Tahmin Analizi	170
4.3.2.4	Meksika (S&P/BMV IPC) Endeksi Tahmin Analizi	176
4.3.2.5	Endonezya (IDX COMPOSITE) Endeksi Tahmin Analizi.....	182
4.3.2.6	Rusya (MOEX) Endeksi Tahmin Analizi.....	188
4.3.2.7	Türkiye (BIST100) Endeksi Tahmin Analizi.....	194
4.3.3.	Arıma Modeli İle Gerçekleştirilen Tahminlerin Genel Değerlendirilmesi 200	
4.4	Lstm Modeli Yöntemi İle Endeks Tahmini	202
4.4.1.	G7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin LSTM Modeli İle Tahmini	204
4.4.1.1	Amerika (S&P 500) Endeksi Tahmin Analizi	205
4.4.1.2	Kanada (S&P/TSX) Endeksi Tahmin Analizi.....	207
4.4.1.3	Almanya (DAX) Endeksi Tahmin Analizi	210
4.4.1.4	Fransa (CAC40) Endeksi Tahmin Analizi.....	212
4.4.1.5	İngiltere (FTSE100) Endeksi Tahmin Analizi	215
4.4.1.6	İtalya (FTSEMIB) Endeksi Tahmin Analizi	217

4.4.1.7 Japonya (NIKKEI 225) Endeksi Tahmin Analizi.....	220
4.4.2. E7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin LSTM Modeli İle Tahmini	222
4.4.2.1 Çin (SHANGHAI COMPOSITE) Endeksi Tahmin Analizi.....	222
4.4.2.2 Hindistan (NIFTY50) Endeksi Tahmin Analizi	225
4.4.2.3 Brezilya (BOVESPA) Endeksi Tahmin Analizi	228
4.4.2.4 MEKSIKA (S&P/BMV IPC) Endeksi Tahmin Analizi.....	231
4.4.2.5 ENDONEZYA (IDX COMPOSITE) Endeksi Tahmin Analizi	234
4.4.2.6 RUSYA (MOEX) Endeksi Tahmin Analizi	237
4.4.2.7 TÜRKİYE (BIST100) Endeksi Tahmin Analizi	240
4.4.3. LSTM Modeli İle Gerçekleştirilen Tahminlerin Genel Değerlendirilmesi.	243
4.5 Arıma Ve Lstm Modeli İle Yapılan Tahminlerinin Karşılaştırılması.....	245
SONUÇ VE ÖNERİLER.....	247
KAYNAKÇA	251
ÖZGEÇMİŞ	276

TABLOLAR LİSTESİ

Tablo 2.1. Biyolojik Sinir sistemi ve Yapay Sinir Sistemi	61
Tablo 3.1. Başarı Metrikleri	78
Tablo 4.1. Analizde Kullanılan Ülkeler ve Borsa Endeksleri	108
Tablo 4.2. Analizde Kullanılan Girdi Değişkenleri	111
Tablo 4.3. Belirlenen Teknik Göstergeler ve Formülleri	112
Tablo 4.4. ADF Birim Kök Test Sonuçları	116
Tablo 4.5. Tanımlayıcı İstatistikler	118
Tablo 4.6. S&P 500 Endeks Tahmini Başarı Metrikleri	120
Tablo 4.7. ADF Birik Kök Test Sonuçları	122
Tablo 4.8. Tanımlayıcı İstatistikler	124
Tablo 4.9. S&P/TSX Endeks Tahmini Başarı Metrikleri.....	126
Tablo 4.10. ADF Birik Kök Test Sonuçları	128
Tablo 4.11. Tanımlayıcı İstatistikler	130
Tablo 4.12. DAX Endeks Tahmini Başarı Metrikleri	132
Tablo 4.13. ADF Birik Kök Test Sonuçları	134
Tablo 4.14. Tanımlayıcı İstatistikler	136
Tablo 4.15. CAC40 Endeks Tahmini Başarı Metrikleri.....	139
Tablo 4.16. ADF Birim Kök Test Sonuçları	140
Tablo 4.17. Tanımlayıcı İstatistikler	142
Tablo 4.18. FTSE100 Endeks Tahmini Başarı Metrikleri	144
Tablo 4.19. ADF Birim Kök Testi	146
Tablo 4.20. Tanımlayıcı İstatistikler	148
Tablo 4.21. FTSE MIB Endeks Tahmini Başarı Metrikleri.....	151
Tablo 4.22. ADF Birim Kök Testi	152
Tablo 4.23. Tanımlayıcı İstatistikler	154
Tablo 4.24. NIKKEI 225 Endeks Tahmini Başarı Metrikleri	157
Tablo 4.25. ADF Birim Kök Testi	159
Tablo 4.26. Tanımlayıcı İstatistikler	161
Tablo 4.27. ARIMA (5,0,4) SHANGHAI Composite Endeks Tahmini Başarı Metrikleri....	164
Tablo 4.28. ADF Birim Kök Testi	165
Tablo 4.29. Tanımlayıcı İstatistikler	167
Tablo 4.30. NIFTY50 Endeks Tahmini Başarı Metrikleri	170

Tablo 4.31. ADF Birim Kök Testi	171
Tablo 4.32. Tanımlayıcı İstatistikler	173
Tablo 4.33. BOVESPA Endeks Tahmini Başarı Metrikleri.....	176
Tablo 4.34. ADF Birim Kök Testi	177
Tablo 4.35. Tanımlayıcı İstatistikler	179
Tablo 4.36. S&P/BMV IPC Endeks Tahmini Başarı Metrikleri.....	182
Tablo 4.37. ADF Birim Kök Testi	183
Tablo 4.38. Tanımlayıcı İstatistikler	185
Tablo 4.39. IDX Composite Endeks Tahmini Başarı Metrikleri	188
Tablo 4.40. ADF Birim Kök Testi	189
Tablo 4.41. Tanımlayıcı İstatistikler	191
Tablo 4.42. MOEX Endeks Tahmini Başarı Metrikleri	194
Tablo 4.43. ADF Birim Kök Testi	195
Tablo 4.44. Tanımlayıcı İstatistikler	197
Tablo 4.45. BIST100 Endeks Tahmin Başarı Metrikleri	200
Tablo 4.46. MAPE Kriterinin Sınıflandırılması.....	201
Tablo 4.47. ARIMA Modeli Seçilmiş Borsa Endeksleri ve MAPE Değerleri	201
Tablo 4.48. LSTM Model Parametreleri	204
Tablo 4.49. S&P 500 Endeks Tahmin Başarı Metrikleri	207
Tablo 4.50. S&P/TSX Endeks Tahmini Başarı Metrikleri.....	209
Tablo 4.51. DAX Endeks Tahmini Başarı Metrikleri	212
Tablo 4.52. CAC40 Endeks Tahmini Başarı Metrikleri.....	214
Tablo 4.53. FTSE100 Endeks Tahmini Başarı Metrikleri	217
Tablo 4.54. FTSEMIB Endeks Tahmini Başarı Metrikleri.....	219
Tablo 4.55. LSTM NIKKEI Endeks Tahmini Başarı Metrikleri	222
Tablo 4.56. LSTM SHANGHAI Composite Endeks Tahmini Başarı Metrikleri.....	225
Tablo 4.57. LSTM NIFTY50 Endeks Tahmini Başarı Metrikleri	228
Tablo 4.58. LSTM BOVESPA Endeks Tahmini Başarı Metrikleri	231
Tablo 4.59. LSTM S&P/BMV IPC Endeks Tahmini Başarı Metrikleri	234
Tablo 4.60. LSTM IDX Composite Endeks Tahmini Başarı Metrikleri.....	237
Tablo 4.61. LSTM MOEX Endeks Tahmini Başarı Metrikleri	240
Tablo 4.62. LSTM BIST100 Tahmini Başarı Metrikleri	242
Tablo 4.63. Seçilmiş Borsa Endeksleri ve MAPE Değerleri	244
Tablo 4.64. LSTM ve ARIMA Modellerinin MAPE Performansları	245

ŞEKİLLER LİSTESİ

Şekil 1.1. Finansal Sistemde Fon Akışı.....	6
Şekil 2.1. Yapay Zeka Süreçleri ve Konumu	47
Şekil 2.2. Biyolojik Sinir Hücresi	61
Şekil 2.3. Yapay Sinir Hücresi	61
Şekil 2.4. RNN Yapısı.....	65
Şekil 2.5. RNN Yapısı (Açık Hali)	65
Şekil 2.6. Tek Katmanlı RNN yapısı.....	66
Şekil 2.7. Çift Yönlü LSTM Yapısı (Bi-LSTM).....	68
Şekil 3.1. İlk LSTM Mimarisi	75
Şekil 3.2. Uzun Kısa Süreli Bellek (LSTM) Ağı Mimari Yapısı	76
Şekil 3.3. İleri Beslemeli LSTM Yapısı.....	77
Şekil 4.1. G7 ve E7 Ülkelerinin Endeks Kapanış Verileri	109
Şekil 4.2. S&P 500 Endeksi Kapanış Verileri.....	115
Şekil 4.3. Durağan Hale Getirilmiş Değişkenler.....	117
Şekil 4.4. Değişkenler Arası Korelasyon	118
Şekil 4.5. ARIMA (2,1,2) S&P 500 Artıkların Histogram Grafiği.....	119
Şekil 4.6. ARIMA (2,1,2) S&P 500 Tahmin Grafiği	120
Şekil 4.7. S&P/TSX Endeksi Kapanış Verileri	121
Şekil 4.8. Durağan Hale Getirilmiş Değişkenler.....	123
Şekil 4.9. Değişkenler Arası Korelasyon	124
Şekil 4.10. Artıkların Histogram Grafiği	125
Şekil 4.11. ARIMA (2,1,0) S&P/TSX Tahmin Grafiği	126
Şekil 4.12. Almanya DAX Endeksi Kapanış Verileri.....	127
Şekil 4.13. Durağan Hale Getirilmiş Değişkenler.....	129
Şekil 4.14. Değişkenler Arası Korelasyon	130
Şekil 4.15. Artıkların Histogram Grafiği	131
Şekil 4.16. ARIMA (1,1,5) DAX Endeks Tahmin Grafiği	132
Şekil 4.17. Fransa CAC40 Endeksi Kapanış Verileri	133
Şekil 4.18. Durağan Hale Getirilmiş Değişkenler.....	135
Şekil 4.19. Değişkenler Arası Korelasyon	136
Şekil 4.20. Artıkların Histogram Grafiği	137
Şekil 4.21. ARIMA (0,1,1) CAC40 Endeks Tahmin Grafiği.....	138

Şekil 4.22. İngiltere FTSE100 Endeksi Kapanış Verileri	139
Şekil 4.23. Durağan Hale Getirilmiş Değişkenler	141
Şekil 4.24. Endeksle Değişkenler Arası Korelasyon.....	142
Şekil 4.25. Artıkların Histogram Grafiği	143
Şekil 4.26 ARIMA (3,1,5) FTSE100 Endeks Tahmin Grafiği.....	144
Şekil 4.27. İtalya FTSE MIB Endeksi Kapanış Verileri	145
Şekil 4.28. Durağan Hale Getirilmiş Değişkenler	147
Şekil 4.29. Endeksle Değişkenler Arası Korelasyon.....	148
Şekil 4.30. Artıkların Histogram Grafiği	149
Şekil 4.31. ARIMA (0,1,1) FTSE MIB Endeks Tahmin Grafiği	150
Şekil 4.32. Japonya (NIKKEI 225) Endeksi Kapanış Verileri.....	152
Şekil 4.33. Durağan Hale Getirilmiş Değişkenler	153
Şekil 4.34. Endeksle Değişkenler Arası Korelasyon.....	154
Şekil 4.35. Artıkların Histogram Grafiği	155
Şekil 4.36. ARIMA (3,1,4) NIKKEI 225 Endeks Tahmin Grafiği	156
Şekil 4.37. SHANGHAI Composite Endeksi Kapanış Verileri	158
Şekil 4.38. Durağan Hale Getirilmiş Değişkenler	160
Şekil 4.39. Değişkenler Arası Korelasyon	161
Şekil 4.40. Artıkların Histogram Grafiği	162
Şekil 4.41. ARIMA (5,0,4) SHANGHAI Composite Endeks Tahmin Grafiği.....	163
Şekil 4.42. NIFTY50 Endeksi Kapanış Verileri	164
Şekil 4.43. Durağan Hale Getirilmiş Değişkenler	166
Şekil 4.44. Değişkenler Arası Korelasyon	167
Şekil 4.45. Artıkların Histogram Grafiği	168
Şekil 4.46. ARIMA (2,1,5) NIFTY50 Endeks Tahmin Grafiği	169
Şekil 4.47. BOVESPA Endeksi Kapanış Verileri	171
Şekil 4.48. Durağan Hale Getirilmiş Değişkenler	172
Şekil 4.49. Endeksle Değişkenler Arası Korelasyon.....	173
Şekil 4.50. Artıkların Histogram Grafiği	174
Şekil 4.51. ARIMA (2,1,2) BOVESPA Endeks Tahmin Grafiği.....	175
Şekil 4.52. S&P/BMV IPC Endeksi Kapanış Verileri	176
Şekil 4.53. Durağan Hale Getirilmiş Değişkenler	178
Şekil 4.54. Endeksle Değişkenler Arası Korelasyon.....	179
Şekil 4.55. Artıkların Histogram Grafiği	180

Şekil 4.56. ARIMA (2,1,2) S&P/BMV IPC Endeks Tahmin Grafiği	181
Şekil 4.57. Endonezya (IDX Composite) Endeksi Kapanış Verileri	183
Şekil 4.58. Durağan Hale Getirilmiş Değişkenler	184
Şekil 4.59. Endeksle Değişkenler Arası Korelasyon.....	185
Şekil 4.60. Artıkların Histogram Grafiği	187
Şekil 4.61. IDX Composite Endeks Tahmin Grafiği	187
Şekil 4.62. Rusya (MOEX) Endeksi Kapanış Verileri	189
Şekil 4.63. Durağan Hale Getirilmiş Değişkenler	190
Şekil 4.64. Endeksle Değişkenler Arası Korelasyon.....	191
Şekil 4.65. Artıkların Histogram Grafiği	192
Şekil 4.66. MOEX Endeks Tahmin Grafiği	193
Şekil 4.67. Türkiye (BIST100) Endeks Kapanış Verileri	195
Şekil 4.68. Durağan Hale Getirilmiş Değişkenler	196
Şekil 4.69. Endeksle Değişkenler Arası Korelasyon.....	197
Şekil 4.70. Artıkların Histogram Grafiği	198
Şekil 4.71. ARIMA (1,1,3) BIST100 Endeks Tahmin Grafiği	199
Şekil 4.72. LSTM Akış Diyagramı	203
Şekil 4.73. LSTM S&P 500 Tahmin Grafiği	205
Şekil 4.74. Artıkların Histogram Grafiği	206
Şekil 4.75. Loss Fonksiyon Grafiği.....	206
Şekil 4.76. LSTM S&P/TSX Endeksi Tahmin Grafiği	208
Şekil 4.77. Artıkların Histogram Grafiği	208
Şekil 4.78. Loss Fonksiyon Grafiği.....	209
Şekil 4.79. LSTM DAX Endeksi Tahmin Grafiği	210
Şekil 4.80. Artıkların Histogram Grafiği	211
Şekil 4.81. Loss Fonksiyon Grafiği.....	211
Şekil 4.82. LSTM CAC40 Endeksi Tahmin Grafiği	213
Şekil 4.83. Artıkların Histogram Grafiği	213
Şekil 4.84. Loss Fonksiyon Grafiği.....	214
Şekil 4.85. LSTM FTSE100 Endeks Tahmin Grafiği	215
Şekil 4.86. Artıkların Histogram Grafiği	216
Şekil 4.87. Loss Fonksiyon Grafiği.....	216
Şekil 4.88. LSTM FTSEMIB Endeks Tahmin Grafiği	218
Şekil 4.89. Artıkların Histogram Grafiği	218

Şekil 4.90. Loss Fonksiyon Grafiği.....	219
Şekil 4.91. LSTM NIKKEI 225 Endeks Tahmin Grafiği	220
Şekil 4.92. Artıkların Histogram Grafiği	221
Şekil 4.93. Loss Fonksiyon Grafiği.....	221
Şekil 4.94. LSTM SHANGHAI Composite Endeks Tahmin Grafiği	223
Şekil 4.95. Artıkların Histogram Grafiği	224
Şekil 4.96. Loss Fonksiyon Grafiği.....	224
Şekil 4.97. LSTM NIFTY50 Endeks Tahmin Grafiği	226
Şekil 4.98. Artıkların Histogram Grafiği	226
Şekil 4.99. Loss Fonksiyon Grafiği.....	227
Şekil 4.100. LSTM BOVESPA Endeks Tahmin Grafiği	229
Şekil 4.101. Artıkların Histogram Grafiği	229
Şekil 4.102. Loss Fonksiyon Grafiği.....	230
Şekil 4.103. LSTM S&P/BMV IPC Endeks Tahmin Grafiği	232
Şekil 4.104. Artıkların Histogram Grafiği	232
Şekil 4.105. Loss Fonksiyon Grafiği.....	233
Şekil 4.106. LSTM IDX Composite Endeks Tahmin Grafiği.....	235
Şekil 4.107. Artıkların Histogram Grafiği	235
Şekil 4.108. Loss Fonksiyon Grafiği.....	236
Şekil 4.109. LSTM MOEX Endeks Tahmin Grafiği	238
Şekil 4.110. Artıkların Histogram Grafiği	238
Şekil 4.111. Loss Fonksiyon Grafiği.....	239
Şekil 4.112. LSTM BIST100 Endeks Tahmin Grafiği.....	241
Şekil 4.113. Artıkların Histogram Grafiği	241
Şekil 4.114. Loss Fonksiyon Grafiği.....	242

KISALTMALAR

BIST	Borsa İstanbul
NASDAQ	Natronla Association of Security Dealers Automated Quotation System
NYSE	NewYork Stock Exchange
SPK	Sermaye Piyasası Kurulu
VIOP	Vadeli İşlem ve Opsiyon Borsası
VDMK	Varlığa Dayalı Menkul Kıymetler
B3	Brezilya Borsası
E7	Emerging 7
G7	Group of Seven
GSYİH	Gayrisafi Yurtiçi Hasıla
AMEX	Amerikan Borsası
CHX	Chicago Borsası
S&P	Standard and Poor' s
LSE	Londra Menkul Kıymet Borsası
S&P500	Standard & Poor's 500
S&P/TSX Composite	Standard & Poor's Toronto Stock Exchange
DAX	Deutscher Aktienindex
CAC40	Cotation Assistée en Continu
FTSE100	Financial Times Stock Exchange 100 Index
FTSEMIB	Financial Times Stock Exchange Milano Indice di Borsa
NIKKEI 225	Tokyo Stock Exchange 225
SHANGHAI Composite	Shanghai Stock Exchange Composite Index
NIFTY50	National Stock Exchange Fifty
BOVESPA	Bolsa de Valores de São Paulo
S&P BMV IPC	Standard & Poor's Bolsa Mexicana de Valores Índice de Precios y Cotizaciones
IDX Composite	Indonesia Stock Exchange Composite Index
MOEX	Moscow Exchange Index
TSE	Tokyo Borsası
SSE	Şanghay Menkul Kıymet Borsası

CSRC	Çin Menkul Kıymetler Düzenleme Komisyonu
NSE	Hindistan Ulusal Menkul Kıymetler Borsası
ETF	Borsa Yatım Fonu
AR	Autoregressive
MA	Moving Average
I	Integration
ARMA	Otoregresif Hareketli Ortalama
ARIMA	Otoregresif Entegreli Hareketli Ortalama
YZ	Yapay Zeka
ML	Machine Learning
DL	Deep Learning
DJIA	Dow Jones Industrial Average
CETIP	Central de Custódia e de Liquidação Financeira de Títulos
CVM	Securities and Exchange Commission
JSX	Jakarta Stock Exchange Index
SSX	Santiago Stock Exchange Index
YSA	Yapay Sinir Ağları
ZAML	Zest Automated Machine Learning
NLP	Natural Language Processing
GPU	Graphics Processing Unit
CNN	Convolutional Neural Network
MV	Machine Vision
NN	Neural Network
CV	Computer Vision
RNN	Recurrent Neural Network
LSTM	Long Short-Term Memory
GRU	Gated Recurrent Unit
GAN	Generative Adversarial Networks
DBN	Deep Belief Network
AIC	Akaike Information Criterion
BIC	Bayesian Information Criterion
ACF	Autocorrelation Function
PACF	Partial Autocorrelation Function

EKK	En Küçük Kareler
Bi-LSTM	Bidirectional Long Short-Term Memory
ADF	Augmented Dickey-Fuller
WMA	Weighted Moving Average
MACD	Moving Average Convergence Divergence
CCI	Commodity Channel Index
RSI	Relative Strength Index
MOM	Momentum Indicator
A/D	Accumulation/Distribution Indicator
RMSE	Root Mean Square Error
MSE	Mean Square Error
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
DXY	US Dollar Index

GİRİŞ

İnsanoğlunun en temel arzularından biri, geleceği öngörebilmek ve bu doğrultuda stratejiler geliştirerek, belirsizliklerin oluşturabileceği risklere karşı kendini hazırlıklı ve güvende hissetmektir. Geleceği anlamının ve ona yön verebilmenin anahtarı, geçmişten elde edilen tecrübeler ve bu tecrübelerden süzülen bilgilerin doğru analiz edilmesinde yatmaktadır. Bilinmeyen bir geleceği tahmin edebilmenin yolu, bilinen girdiler ve çıktılar ışığında mevcut veri setini kullanarak gelecekteki olasılıkları modellemekten geçmektedir. Bu yaklaşım, yalnızca doğa bilimleri ve mühendislik alanlarında değil, sosyal bilimlerden ekonomiye kadar pek çok disiplinde hem teorik hem de pratik açıdan büyük bir önem taşımaktadır.

Finansal piyasalar açısından bakıldığında, gelecekteki varlık değerlerinin nasıl bir değişim göstereceğini öngörmek ve bu öngörüler doğrultusunda kararlar alarak stratejiler geliştirmek, bireysel ve kurumsal yatırımcılar için kritik bir rol oynamaktadır. Bu öngörülerin doğruluğu ölçüsünde, yatırımcıların pozisyonları kâr sağlayabilir ve finansal getiriler artırılabilir. Ancak, finansal piyasalardaki fiyat hareketlerinin dinamik ve çoğu zaman karmaşık yapısı, geleneksel yöntemlerin yanı sıra daha gelişmiş tekniklerin de kullanımını gerektirmektedir. Bir insanın, aynı anda pek çok veriyi derinlemesine analiz ederek bu veri setinden sağlıklı ve tutarlı bir öngöründe bulunması, artan veri yoğunluğu ve karmaşıklık göz önüne alındığında giderek daha güç hale gelmektedir. Bu kapsamda, geçmişteki verilere dayalı olarak geleceği modelleme ve tahmin etme gerekliliği, yalnızca insan aklının sınırlarını aşan bir problem olmaktan çıkarak, yapay zeka, makine öğrenmesi ve derin öğrenme gibi teknolojilerin çözüm sunduğu bir alan haline gelmiştir. Özellikle finansal piyasalarda, geçmiş fiyat hareketlerinden, işlem hacimlerinden ve makroekonomik göstergelerden elde edilen verilere dayanarak gelecekteki fiyat hareketlerini tahmin etmek, doğru stratejilerin geliştirilmesine olanak tanımaktadır. Bu tür tahmin modelleri, yalnızca bireysel yatırımcılar için bir avantaj sağlamakla kalmayıp, aynı zamanda finansal sistemin genel işleyişi ve istikrarı açısından da büyük önem taşımaktadır.

Bu tez çalışmasında, G7 (Gelişmiş) ve E7 (Emerging) ülkelerine ait seçilmiş borsa endeksleri için tahmin modellerinin performansları karşılaştırmalı olarak analiz edilmiştir. Tahmin modelleri olarak geleneksel istatistiksel bir yöntem olan Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) modeli ile derin öğrenme tabanlı Uzun Kısa Dönemli Bellek (LSTM) modeli kullanılmıştır. İlgili modellerde bağımlı değişken olarak ilgili ülkelerin seçilmiş borsa endekslerinin kapanış fiyatı kullanılırken bağımsız değişken olarak ise teknik ve makroekonomik değişkenler kullanılmıştır. Çalışmanın temel hedeflerinden biri, bu iki modelin farklı ülke piyasalarındaki performanslarını analiz ederek, ülkeler arasındaki yapısal farklılıkların tahmin doğruluğu üzerindeki etkisini ortaya koymaktır. Çalışma, farklı ekonomik ve piyasa dinamiklerine sahip ülkelerin borsa endekslerini incelemeyi hedefleyerek, G7 ve E7 ülkelerinin endekslerini kapsamına almıştır. G7 ülkeleri, genellikle istikrarlı ve gelişmiş finansal piyasa yapılarıyla dikkat çekerken, E7 ülkeleri hızlı büyüyen ancak daha volatil ve karmaşık piyasa koşullarına sahiptir. Bu iki farklı ülke grubu üzerinden yapılan analiz, yöntemlerin farklı piyasa dinamikleri altındaki performansını kıyaslamaya olanak sağlamış ve sonuçların genelleştirilebilirliğini artırmıştır. Finansal piyasaların küresel ekonomik göstergeler üzerindeki kritik rolü dikkate alındığında, bu çalışma hem akademik literatüre hem de yatırım stratejilerinin geliştirilmesine katkı sunmayı hedeflemektedir. Geleneksel yöntemler, özellikle finansal zaman serilerinin doğrusal yapısını modellemede başarılı olmakla birlikte, piyasalardaki doğrusal olmayan karmaşık ilişkileri açıklamada yetersiz kalabilmektedir. Buna karşın, LSTM gibi derin öğrenme modelleri, büyük veri setlerindeki karmaşık örüntüleri ve doğrusal olmayan ilişkileri analiz etmede üstün bir performans göstermektedir. Bu kapsamda, her iki yöntemin birlikte ele alınması, farklı metodolojik perspektiflerden piyasa hareketlerini anlamaya olanak sağlamaktadır.

Bu çerçevede, söz konusu çalışma dört bölümden oluşmaktadır.

Tezin ilk bölümünde finansal piyasalar ve finansal yatırım araçlarına ilişkin temel bilgiler sunulmuş, ardından G7 ve E7 ülkelerinin borsa yapıları ele alınarak çalışmada kullanılan borsa endekslerine dair detaylı açıklamalara yer verilmiştir. İlgili borsaların yapısal özellikleri ve seçilmiş endekslerin ekonomik önemine kapsamlı bir şekilde değinilmiştir.

İkinci bölümde, yapay zeka kavramı genel hatlarıyla ele alınmış, finans alanında yapay zeka uygulamalarına değinilmiş ve makine öğrenmesi ile derin öğrenme yöntemleri hakkında temel bilgiler verilmiştir.

Üçüncü bölümde, çalışmanın metodolojik çerçevesi kapsamında kullanılan tahmin modelleri olan ARIMA (Oto regresif Entegre Hareketli Ortalama) ve LSTM (Uzun Kısa Vadeli Bellek) modellerinin teorik temelleri detaylı bir şekilde açıklanmıştır. Model uygulamalarında kullanılan teknik göstergeler, hesaplama yöntemlerine dair bilgilere yer verilmiştir. Ayrıca, modellerin değerlendirme kriterleri ayrıntılı olarak ele alınmış ve çalışma kapsamında gerçekleştirilen kapsamlı literatür taraması sunulmuştur.

Dördüncü bölümde, G7 ve E7 ülkelerine ait seçilmiş borsa endeksleri için tahmini ARIMA ve LSTM modeli ile analiz edilerek araştırma kapsamında elde edilen bulgular değerlendirilip, modellerin genel karşılaştırması yapılmıştır. Son olarak ise sonuç ve değerlendirmeye yer verilerek gelecekteki araştırmalara yönelik öneriler sunulmuştur.

1. BÖLÜM: FİNANSAL PİYASALAR VE BORSA

Finansal piyasalar, ekonomik aktivitelerin merkezinde yer alır ve küresel ekonominin işleyişinde kritik bir rol oynar. Bu piyasalar, sermaye akışını kolaylaştırarak, kaynakların daha verimli bir şekilde dağıtılmasını sağlar ve ekonomik büyüme ile kalkınmayı destekler. Finansal piyasalar, yatırımcılar ile sermaye talep edenler arasındaki etkileşimi mümkün kılarak, bireysel ve kurumsal yatırımcıların tasarruflarını değerlendirmelerine, riskleri yönetmelerine ve geleceğe yönelik planlar yapmalarına olanak tanır.

Bu çerçevede, borsalar, finansal piyasaların önemli bileşenini oluşturur. Borsalar, hisse senetleri, tahviller, türev ürünler ve diğer finansal araçların alım satımının gerçekleştirildiği organize ve düzenlenmiş piyasalardır. Bu piyasalar, yatırımcılara likidite sağlar, fiyat keşfi sürecine katkıda bulunur ve finansal varlıkların fiyatlarının belirlenmesine yardımcı olur.

Günümüzde borsaların rolü, teknolojinin ve küreselleşmenin etkisiyle önemli ölçüde genişlemiştir. Yatırımcılar, dünyanın dört bir yanındaki piyasalara erişim sağlamakta ve anlık veri akışları sayesinde daha bilinçli yatırım kararları alabilmektedir. Bununla birlikte, finansal piyasalarda ve borsalarda yaşanan dalgalanmalar, küresel ekonomik sistem üzerindeki etkilerini artırmış, bu da piyasa analizlerinin ve öngörülerinin önemini daha da pekiştirmiştir.

Bu bölümde, ilk olarak finansal piyasa kavramı detaylı bir şekilde ele alınacaktır. Ardından, finansal piyasaların genel özellikleri ve sınıflandırılması hakkında bilgi verilecektir. Devamında, sermaye piyasalarının ve borsaların gelişimi incelenecek ve çalışmada yer alacak ülkelerin seçilmiş borsa endeksleri hakkında bilgi sunulacaktır.


1.1 FİNANSAL PİYASALARIN TANIMI VE İŞLEVLERİ

Piyasa, alıcıların ve satıcıların bir araya gelerek mal veya hizmetlerin fiyatının belirlendiği bir ortam olarak ifade edilebilir. Ayrıca, arz ve talebin buluştuğu ve değişimin gerçekleştiği mekânlar olarak da açıklanabilir. Bu tür piyasalara verilebilecek en somut örneklerden biri borsalardır. Genel olarak piyasalar, alıcılar ve satıcıların belirli bir

ihtiyacı karşılamak üzere bir araya gelerek etkileşime geçmeleri sonucunda değişim sürecinin gerçekleştiği yerler olarak tanımlanır (Seyidoğlu, 2005, s.285).

Finansal piyasalar ise fon fazlası olan tasarruf sahiplerinden fon ihtiyacı olanlara fonların transfer edildiği piyasalar olarak tanımlanmaktadır (Mishkin, 2007, s.3). Bu piyasalarda fonların el değiştirmesi fon talep edenlerin fon arz edenlere bir belge vermesiyle gerçekleşir. Bu nedenle finansal piyasalar finansal varlık olarak ifade edilen kıymetli evrak niteliğindeki bu belgelerin alınıp satıldığı piyasalardır (Korkmaz & Ceylan, 2006, s.1).

Piyasaların etkin bir şekilde işlemesi için bir finansal sisteme ihtiyaç duyulmaktadır. Bu sistem, tahvil, bono ve hisse senedi gibi menkul kıymetlerin işlem gördüğü finansal piyasalar ve bu işlemlere aracılık eden finansal kuruluşlardan oluşmaktadır. Hane halkı, özel sektör şirketleri ve hükümetler ve yabancılar finansal piyasalarda alım-satım yapan katılımcılardır. Bu piyasalara fon sağlayan katılımcılar fazla veren birimler olarak adlandırılırken, fon talep edenler açık veren birimler olarak ifade edilir (Günel, 2012, s.19). Finansal sistemde fon transferleri dolaylı veya doğrudan gerçekleştirilebilir. Bir işletme, ihtiyacı olan fonu herhangi bir finansal aracı kullanmadan doğrudan yatırımcılara finansal varlık satarak sağlıyorsa bu dolaysız, finansal aracılar kullanarak sağlıyorsa bu dolaylı finansman olarak adlandırılır. Finansal sistem, yazılı kurallar veya geleneklere dayalı olarak işler. Hükümetler, yasa ve yönetmeliklerle piyasaların hukuki çerçevesini belirler, işleyişini düzenler ve denetim kurumları aracılığıyla piyasaların denetimini gerçekleştirirler (Korkmaz & Ceylan, 2006, s.1-2). Finansal sistemin işleyişi şematik bir biçimde Şekil 1.1.' de gösterilmiştir.



Şekil 1.1. Finansal Sistemde Fon Akışı

(Mishkin, 2007, s.24)

Şekil 1.1.' de görüldüğü gibi finansal araçların alınıp satıldığı finansal piyasaların temel işlevi, fonların arz edenlerden fon talep edenlere akışını sağlamak ve bu sayede ekonomideki fon sıkışıklığını zaman ve mekân açısından gidermektir (Orhan & Erdoğan, 2007, s.27). Finansal piyasaların finans faaliyetleri içerisinde üstlenmiş olduğu bir takım rolleri şu şekilde özetleyebiliriz (Karan, 2021,s.6-7);

- Finansal varlıkların fiyatını oluşturma (Fiyat belirleme rolü): Finansal piyasalar, alıcı ve satıcıları bir araya getirerek finansal varlıkların fiyatlarını veya bu varlıkların sağlanması gereken getirileri belirler.
- Likidite sağlama rolü: Alıcı ve satıcıların kolayca pazara girmelerini, finansal varlıkların pazar fiyatından alım satımının gerçekleşmesini ve dolayısıyla para akışını kolaylaştırmayı sağlar.
- Bilgi ve araştırma maliyetlerini azaltma rolü: Finansal piyasalar, firmalar ve ekonomik olaylarla ilgili bilgiye erişimi kolaylaştırarak araştırma ve haber alma maliyetlerini düşürür. Piyasalarda işlem gören firmaların mali durumu, performansı ve geleceğe yönelik beklentileri gibi bilgiler sürekli olarak kamuoyuna açıklanır ve bu bilgiler yatırımcılar tarafından kolayca erişilebilir hale

gelir. Bu sayede, yatırımcılar daha bilinçli kararlar alabilir ve piyasadaki belirsizlikler azalır.

- Risk paylaşma rolü: finansal piyasalar sayesinde yatırımcılar çok çeşitli yatırım araçlarını tercih ederek riskin dağılması ve dolayısıyla risk yönetimi açısından önemli avantajlar sağlar.

1.2 FİNANSAL PİYASALARIN SINIFLANDIRILMASI

Finansal piyasalar incelendiğinde literatürde çeşitli kriterlere göre sınıflandırılma yapıldığı görülmektedir (Karan 2021; Konuralp 2005; Korkmaz ve Ceylan 2006; Sarıkamış 2000). Literatürdeki çalışmalar doğrultusunda finansal piyasalar şu şekilde sınıflandığı görülmektedir:

1. Para ve Sermaye Piyasaları
2. Birincil ve İkincil Piyasalar
3. Organize ve Tezgah Üstü Piyasalar
4. Spot ve Vadeli Piyasalar
5. Üçüncül ve Dördüncül Piyasalar
6. Ulusal ve Uluslararası Piyasalar

1.2.1. Para ve Sermaye Piyasaları

Finansal piyasalar sağlanan fonların sürelerine göre para piyasaları ve sermaye piyasaları olmak üzere ikiye ayrılmaktadır. Para piyasaları kısa vadeli yani genellikle bir yıldan daha kısa süreli fon arz ve talebinin karşılaştığı piyasalardır. Sermaye piyasaları ise bir yıldan uzun vadeli fonların arz ve talebinin karşılaştığı piyasalar olarak ifade edilmektedir. Para piyasaları genel olarak işletmelerin işletme sermayesi ihtiyaçlarını finanse etmek için kullanılırken sermaye piyasaları işletmelerin sabit sermaye yatırımlarının finansmanı için başvurulanan piyasalardır. Para ve sermaye piyasası enstrümanları da birbirinden farklılık göstermektedir. Bir yıldan kısa vadeli tasarruf hesapları, çek, bono (hazine ve finansman bonoları), poliçe, repo sözleşmeleri,

ticari senetler, vadeli döviz alım satım sözleşmeleri para piyasası enstrümanları arasında yer alırken hisse senedi tahvil gibi vadesi bir yılı aşan varlıklar sermaye piyasası araçları arasında yer almaktadır. İki piyasa arasındaki bir diğer fark ise para piyasalarında yatırım süresi kısa olduğundan dolayı getiri ve risk düşük iken, sermaye piyasalarında getiri ve risk daha yüksektir. Para piyasalarının en belirgin kurumunu ticari bankalar oluştururken, Borsalar sermaye piyasası pazarı olarak ifade edilmektedir (Konuralp, 2005, s.19; Korkmaz & Ceylan, 2006, s.10).

1.2.2. Birincil ve İkincil Piyasalar

Finansal enstrümanların piyasada işlem görme durumuna göre finansal piyasalar birincil ve ikincil piyasa olmak üzere ikiye ayrılmaktadır. Birincil piyasa bir şirketin ilk defa ihraç ettiği menkul kıymetlere ilişkin piyasalar olarak ifade edilmektedir. Örneğin, bir anonim şirketin fon toplamak amacı ile hisse senedi veya tahvil ihraç ederek bunları ilk elden satması birincil piyasalarda gerçekleşmektedir. İkincil piyasalar ise daha önce ihraç edilmiş olan menkul araçların alınıp satıldığı ikinci el piyasalardır. Örneğin, Borsa İstanbul (BIST) bir ikincil piyasadır (Karan, 2021,s.20). Sonuç olarak, finansal varlıklar birincil piyasalarda yalnızca bir kez ihraç edilip satılabilirken bu süreçten sonra, bu varlıkların alım satımı ikincil piyasalarda gerçekleşmektedir. İkincil piyasalar böylece yatırımcılara likidite sağlayarak en önemli işlevini yerine getirmiş olmaktadır (Konuralp, 2005, s.19).

1.2.3. Organize ve Tezgah Üstü Piyasalar

Örgütlenme şekillerine göre finansal piyasaları organize piyasalar ve tezgah üstü piyasalar olmak üzere tasnif etmekte mümkündür. Organize piyasalar alıcı ile satıcıyı belli bir fiziksel mekanda buluşturan ve işlemlerini gerçekleştirmesi için belli kural ve düzenlemeler içeren, üyeleri olan ve yalnız kendisine kote edilmiş menkul varlıkların alım satımının yapıldığı pazarlar organize olmuş piyasalar olarak adlandırılmaktadır. Örneğin, BIST organize olmuş bir piyasadır. Bu piyasalardaki işlemler Sermaye Piyasası Kanunu (SPK) hükümleri ve SPK'nın tebliğlerinde öngördüğü kural ve düzenlemeler çerçevesinde gerçekleşmektedir. Ayrıca bu piyasa da yalnızca borsa üyeleri işlem yapabilir ve sadece Kurul kaydına alınmış ve borsaya kota edilmiş menkul araçların alım satımı yapılabilmektedir. BIST, Tokyo ve New- York Menkul Kıymetler Borsası (NYSE)

organize piyasalara örnek verilebilir (Konuralp, 2005, s.20). Tezgah üstü piyasalarda ise, çok sayıda finansal kurum telefon, fax, telex ve bilgisayarlar aracılığı ile birbirine bağlanarak ya da iletişim kurarak bir piyasa oluşturmaktadırlar. Bu tür piyasaya ABD'deki NASDAQ (National Association of Security Dealers Automated Quotation System) Borsası, Londra para piyasası ile Kapalıçarşı piyasası örnek olarak gösterilebilir. NASDAQ piyasasındaki işlemler o kadar gelişmiştir ki günümüzde organize piyasa olan NYSE'nin işlem hacminden daha yüksek işlem hacmine ulaşmıştır (Karan, 2021, s.20).

1.2.4. Spot ve Vadeli Piyasalar

Finansal piyasalar işlemin gerçekleşme zamanı açısından Spot ve Vadeli piyasalar olarak gruplandırılmaktadır.

Spot piyasalar, işlemlerin anında gerçekleştirildiği, finansal varlıkların hemen teslim edilip ödemenin yapıldığı, aynı zamanda nakit piyasalar olarak da bilinen piyasalardır. Bu piyasalarda 'hemen teslim ve ödeme' ifadesi, piyasanın şartlarına bağlı olarak farklı zaman dilimlerini ifade edebilir. Örneğin, bazı durumlarda bu ifade işlemin yapıldığı günü, diğer durumlarda ise işlemin yapıldığı tarihten itibaren birkaç gün sonrasını kapsayabilir. Spot piyasalarda işlemler genellikle hızlı bir şekilde gerçekleştirilir, ancak bu hızın tanımı piyasa kurallarına göre değişmektedir. Örneğin, Borsa İstanbul'da (BİST), teslim ve ödemeye ilişkin T+2 ifadesi kullanılır. Bu ifade, işlemin yapıldığı tarihten itibaren iki iş günü içinde teslimat ve ödemenin tamamlanacağı anlamına gelmektedir.

Vadeli piyasalarda, anlaşmalar bugünden yapılır, ancak yükümlülükler gelecekte belirlenen bir tarihte yerine getirilmektedir. Vadeli piyasalar, standart bir varlığı belirli bir kalite, miktar, vade ve teslim yeri şartlarına göre almak veya satmak üzere alıcı ve satıcılar tarafından yapılan anlaşmaları içerir. Teslim süresi haftalar veya hatta aylar sonra olabilmektedir. Bu piyasalarda Takasbank, alıcı ve satıcı arasında karşı taraf olarak işlem yapmaktadır (Örten & Örten, 2001, s. 287). BİST ve Londra Borsası spot piyasalara örnek olarak gösterilebilirken, Chicago Merchantile Exchange, Chicago Board of Trade ve London International Financial Futures and Option Exchange, vadeli piyasalara örnektir. BİST bünyesinde faaliyet gösteren Vadeli İşlemler ve Opsiyon Pazarı (VIOP) ise ülkemizin tek organize vadeli (türev) piyasasıdır (Karan, 2021, s.20).

1.2.5. Üçüncül ve Dördüncül Piyasalar

Üçüncül piyasalar, borsaya kayıtlı menkul kıymetlerin borsa dışında alınıp satılmasıyla oluşan piyasalardır (Sarıkamış, 2000, s. 71). Bu piyasaların yapısı, organize olmamış sermaye piyasasına benzer. Piyasadaki aracılar, farklı yerlerde pazar oluşturmaya çalışırlar ve borsadaki menkul kıymetlerden oluşan büyük stoklara sahiptirler. Bu piyasalardaki aracılar, organize borsalardaki acentelerin rakibi konumundadır. Bu durum, acentelerin komisyon oranlarının azalmasına yol açabilmektedir (Francis, 1986, s. 44).

Menkul araçların alım satımında aracılardan bulunmadığı piyasalar dördüncül piyasalar olarak adlandırılmaktadır. Bu tür piyasalarda özellikle sigorta şirketleri, yatırım fonları vb. kurum ve kişiler alım satım faaliyetlerini gerçekleştirirler. Bu piyasalarda alım ve satım işlemleri, çoğunlukla doğrudan pazarlık yöntemiyle oluşmaktadır. Yani, alıcılar ve satıcılar arasında doğrudan iletişim kurularak, her iki tarafın da ihtiyaç ve beklentilerine uygun şekilde anlaşmalar sağlanmaktadır. Bu yöntem, işlem maliyetlerini önemli ölçüde azaltmaktadır. Dördüncül piyasalarda, fiyatların tırmanış aşamasına geçtiği blok alım satım işlemleri de kendinden söz ettirmektedir (Tükenmez, Susmuş ve Özkan, 1999, s. 40).

1.2.6. Ulusal ve Uluslararası Piyasalar

Ulusal finansal piyasalar, yalnızca belirli bir ülkenin sınırları içinde ihraç edilen menkul kıymetlerin işlem gördüğü piyasalardır. Bu piyasalarda işlem gören menkul kıymetler, ülkenin kendi mali düzenlemeleri ve kuralları çerçevesinde alınıp satılır. Buna karşın, uluslararası finansal piyasalar, farklı ülkelerin veya yabancı şirketlerin ihraç ettiği menkul kıymetlerin işlem gördüğü piyasalardır. Londra, Tokyo, New-York, gibi büyük finansal merkezler hem ulusal hem de uluslararası piyasalar tanımına uygun piyasalardır. Bu piyasalarda hem ulusal hem de uluslararası katılımcılar borç alıp verme faaliyetlerini gerçekleştirebilmektedir. Örneğin, ABD'deki bir şirket için Eurodolar piyasası veya Euro tahvil piyasaları uluslararası finansal piyasalar olarak nitelendirilir. Benzer şekilde, Türkiye'deki bir şirketin ya da Hazine'nin Tokyo piyasasında ihraç ettiği borçlanma araçları, uluslararası finansal piyasa işlemlerine örnek teşkil eder. Euro tahviller, ulusal para birimi cinsinden ihraç edilip, ulusal sınırlar dışında başka bir ülkede satılan

tahvillerdir. Bu tür tahvillerin işlem gördüğü piyasalar Europazar olarak isimlendirilir. Bu piyasalarda genellikle çok uluslu şirketler, hükümetler veya Dünya Bankası gibi kuruluşlar tarafından ihraç edilen finansal varlıklar işlem görmektedir. Europazarlar, genellikle hükümetlerin yasal düzenlemeleri ve kısıtlamalarından bağımsız oldukları için hızlı bir şekilde gelişmiştir. Bu pazarlardaki katılımcılar, telefon, teleks ve bilgisayar gibi elektronik haberleşme araçları ile birbirlerine bağlıdır. Uydu haberleşme teknolojisinin devreye girmesi ve finansal piyasalardaki serbestleşme (deregulation) düzenlemelerinin artmasıyla birlikte, bu piyasaların büyümesi hızlanmış ve işlem hacmi önemli ölçüde artmıştır (Konuralp, 2005, s. 20-21).

1.3 FİNANSAL PİYASA ENSTRÜMANLARI (ARAÇLARI)

Finansal piyasa araçları, yatırımcıların sermaye birikimlerini değerlendirmelerine, borçlanma ihtiyaçlarını karşılamalarına ve finansal risklerini yönetmelerine olanak tanıyan çeşitli enstrümanları kapsamaktadır. Bu araçlar, finansal piyasalarda likidite sağlamak ve ekonomik büyümeyi desteklemek için kritik bir rol oynamaktadır. Farklı yatırımcı profillerine hitap eden finansal araçlar, risk ve getiri açısından çeşitli özellikler sunarak yatırımcılara portföylerini çeşitlendirme fırsatı tanımaktadır. Diğer bir ifadeyle finansal araçlar, yatırımcının risk toleransı, getiri beklentisi ve yatırım süresi gibi faktörlere bağlı olarak farklı stratejilerle kullanılabilir. Aşağıda, finansal piyasalarda sermaye piyasası araçları olarak nitelendirilen menkul kıymetler ve diğer sermaye piyasası araçlarının temel özellikleri ele alınacaktır.

Menkul kıymetler; ortaklık veya alacaklılık hakları sağlayan, belirli bir meblağı temsil eden, yatırım aracı olarak kullanılan, dönemsel gelir getiren, seri halde çıkarılan, misli nitelikte ve aynı ibareleri taşıyan, şartları Sermaye Piyasası Kurulu (SPK) tarafından belirlenen değerli evraklardır (Uludağ & Arıcan, 1999, s. 128).

Diğer sermaye piyasası araçları ise menkul kıymetler dışında kalan ve SPK tarafından koşulları belirlenen evraklardır. Ancak nakit (nakit) ile çek, bono, poliçe ve mevduat sertifikaları bu kapsama dahil değildir (Konuralp, 2005, s. 31).

1.3.1. Hisse Senetleri

Hisse senetleri, anonim ortaklıkların ihraç ettiği ve belirli ortaklık sermayesine katılma payını temsil eden, yasal şekil şartlarına uygun olarak düzenlenmiş kıymetli evrak niteliğine sahip senetlerdir. Literatürde esham, aksiyon, pay senedi veya sadece hisse olarak da adlandırılır (Apak 1995)

Sermayesi paylara bölünmüş komandit şirketler de hisse senedi ihraç edebilir; ancak bu tür şirketlerin hisse senetleri halka arz edilerek satılamamaktadır. Hisse senedi, işletmelerde sahipliği gösteren bir belgedir. Bu senet sayesinde pay sahibi, şirket yönetime katılma, oy kullanma ve iptal davası açma gibi ortaklık haklarına, ayrıca kar payı (temettü), tasfiyen pay alma, hazırlık dönemi faizi ve rüçhan hakkı gibi mali haklara sahip olabilmektedir (Konuralp, 2005, s. 32).

Sermaye piyasası araçları arasında özel bir yere sahip olan hisse senetleri, şirketin iktisadi varlıkları üzerindeki mülkiyet hakkını temsil eden menkul kıymetlerdir. Hisse senedi ihraç etme yetkisine sahip sermaye şirketlerinin sermayesi belirli paylara bölünür ve her bir pay karşılığında sermaye sağlayanlara hisse senedi verilir. Bir şirketin esas sermayesi veya çıkarılmış sermayesi, dolaşımdaki hisse senetlerinin üzerinde yazılı nominal değerlerin toplamına eşittir. Bir şirketin hisse senedini satın alan yatırımcılar, şirketin tüm faaliyet ve finansal risklerine katlanmak zorunda kalmakla birlikte, yukarıda bahsedilen ortaklık ve mali haklara da sahip olma imkânına kavuşmaktadırlar (Dağlı, 2009, s.5).

Hisse senetlerini, dolanım kabiliyeti, satış şekli ve karşılığının ödenme şekli gibi çeşitli kriterler açısından aşağıdaki şekilde sınıflandırmak mümkündür (Dağlı, 2009, s.9; Korkmaz & Ceylan, 2006, s. 184-185).

1. Tedavül bakımından (Dolanım kabiliyeti) açısından
 - Nama yazılı hisse senetleri
 - Hamiline yazılı hisse senetleri
2. Bedellerinin tamamen ödenmiş olup olmaması açısından
 - Bedeli tamamen ödenmiş
 - Bedeli tamamen ödenmemiş hisse senetleri
3. Sahiplerine sağladıkları çıkar açısından

- Adi hisse senetleri
- İmtiyazlı hisse senetleri
- 4. Sermaye artışlarına göre
 - Bedelli hisse senetleri
 - Bedelsiz hisse senetleri
- 5. İhraç edilme şekillerine göre
 - Primli hisse senetleri
 - Primsiz hisse senetleri

Bunlara ek olarak, hisse senedi olmamakla birlikte hisse senedinin birçok özelliğini taşıyan menkul kıymetler de vardır. Bu menkul kıymetler, hisse senedi türevleri olarak da adlandırılır. (Karan, 2021, s. 322). Bunlar:

- Kar Zarar Ortaklığı Belgeleri
- Katılma İntifa Senetleri
- Oydan Yoksun Hisse Senetleri

1.3.2. Tahviller

Tahviller, anonim şirketler veya iktisadi kamu kuruluşları tarafından ödünç para bulmak amacıyla ihraç edilen, itibari değeri eşit ve ibareleri aynı olan uzun vadeli senetlerdir (Berk, 2007, s. 50). Tahvil, sahibine alacak hakkı tanıyan bir menkul kıymettir. Tahviller, hisse senetlerine göre daha az risk taşıdıklarından, riski sevmeyen yatırımcılar için çekici bir yatırım aracı olarak kabul edilirler. İşletme açısından bakıldığında, tahvillerin maliyetinin genellikle daha düşük olması ve faiz ödemelerinin vergi matrahından düşülebilmesi, ortalama fon maliyetinin azalmasına katkıda bulunmaktadır (Korkmaz & Ceylan, 2006, s. 202).

Tahvillerin vadesi, anonim ortaklıklar tarafından 2 yıldan kısa olmamak üzere serbestçe belirlenebilir. Vadenin başlangıç tarihi olarak satış süresinin son günü esas alınır. Anapara ödemesi, vade sonunda tek seferde yapılabileceği gibi, ilk yılın bitiminden başlayarak vade sonuna kadar yıllık eşit taksitler halinde de gerçekleştirilebilir (Rodoplu, 1993, s. 163).

İhraç eden kuruluşlar, faiz belirleme yöntemlerini ve esaslarını izahname, sirküler ve tahvil metninde açıkça belirtmek suretiyle değişken faizli tahvil ihraç edebilirler (SPK

Tahvil Yönetmeliği, 1992). Uygulanacak faiz oranına ilişkin esaslar, SPK'ya başvurmadan önce anonim ortaklık tarafından belirlenmeli ve bu bilgiler izahname ve sirkülerde yer almalı, ayrıca tahvil üzerinde açıklanmalıdır. Yasal bir zorunluluk olmadıkça, tahvilin vadesi boyunca bu esaslarda herhangi bir değişiklik yapılamamaktadır. Faiz ödemeleri, 3 aylık, 6 aylık veya 1 yıllık dönemler halinde kuponlara bağlanır ve bu kupon ödemeleri ile anapara ödemeleri mutlaka bir banka aracılığıyla gerçekleştirilmektedir. İlgili bankanın, faiz tutarlarının belirlenen yöntemlere uygun olarak hesaplanıp hesaplanmadığını kontrol etme sorumluluğu bulunmaktadır (Konuralp, 2005, s. 33-34).

Tahvil, yatırımcılar için düşük riskli, sabit faiz geliri sağlayan ve işletme üzerinde sınırlı kontrol sunan uzun vadeli bir menkul kıymettir. Tahvil ihraç eden şirketler açısından tahvilin çeşitli avantajları ve dezavantajları mevcuttur. Tahvillerin maliyeti belli ve sınırlıdır; tahvil sahipleri şirketin karına ortak olmadıkları için işletme sahipleri, yönetim ve denetim yetkilerini tahvil sahipleriyle paylaşmak zorunda kalmazlar. Ayrıca, faiz ödemeleri vergi matrahından düşülebilir, bu da işletmeye vergi avantajı sağlamaktadır. Ancak, tahvillerin bazı dezavantajları da mevcuttur. İşletmenin gelirleri düzenli değilse, faiz ödemelerini karşılamakta zorlanabilir, bu da işletme için risk oluşturmaktadır. Aşırı borçlanma, finansal kaldıraç etkisiyle olumlu sonuçlansa bile hisse senetlerinin değerini düşürebilmektedir. Tahvillerin uzun vadeli olması, bu süre zarfında planlar ve beklentilerde değişiklikler olması durumunda risk yaratabilmektedir. Ayrıca, tahvillerde vade uzun olduğundan, işletme için kısa vadeli borçlara göre daha ağır hükümler içermektedir (Korkmaz & Ceylan, 2006, s. 211).

1.3.3. Varlığa Dayalı Menkul Kıymetler (VDMK)

Varlığa Dayalı Menkul Kıymetler (VDMK), işletmelerin ve bankaların, gelecekteki alacaklarını menkul kıymetlere çevirip bu kıymetleri alım satım işlemlerine konu yapabilmelerini sağlar. Teorik olarak, işletmeler düzenli nakit akışlarına dayanarak VDMK ihraç edebilirler. Genellikle, alacaklara karşılık gelen bu kıymetler kısa vadeli borç senetleri olarak ihraç edilir. VDMK'ler esasen sermaye piyasası aracı olmasına rağmen, ülkemizde daha çok kısa vadeli çıkarılmakta ve para piyasası aracı olarak değerlendirilmektedir. Genel olarak, menkul kıymetler işletme bilançolarının pasif

tarafına dayanarak ihraç edilirken, VDMK'ler bilançonun aktif tarafına bağlı olarak ihraç edilmektedir (Korkmaz & Ceylan, 2006, s. 225).

SPK'nın 31 Temmuz 1992 tarih ve 21301 sayılı tebliğine göre menkul kıymet ihracında teminat olabilecek alacaklar şunlardır:

- Tüketici Kredileri
- Konut Kredileri
- Finansal kiralama sözleşmelerinden doğan alacaklar
- İhracat işlemlerinden doğan alacaklar ve diğer alacaklar

Sermaye Piyasası ve Borsa Temel Bilgiler Kılavuzu'na göre, Varlığa Dayalı Menkul Kıymet (VDMK) ihraç edebilecek kuruluşlar şunlardır (Sermaye Piyasası ve Borsa Temel Bilgiler Kılavuzu 1992):

- Bankalar
- Finansal kiralama yetkisine sahip kuruluşlar
- Genel finans ortaklıkları
- Gayrimenkul yatırım ortaklıkları
- Finansman şirketleri

1.3.4. Finansman Bonoları

Finansman bonosu, anonim şirketlerin kısa vadeli finansman ihtiyaçlarını karşılamak amacıyla, SPK kaydına alınmak suretiyle aracı kurumlar veya doğrudan yatırımcılara sunulan, emre veya hamiline yazılı borç senetleri olarak tanımlanabilir (Doğukanlı & Canbaş, 1997, s. 72).

Finansman bonolarının vadesi, ihraç eden kurum tarafından belirlenir ve bu süre 30 günden az, 364 günden fazla olamaz (Sermaye Piyasası Araçları 2024).

Bonoların vadesi, satışa sunuldukları ilk gün itibarıyla başlar ve bono iskonto esasına göre satılır. Finansman bonolarının nominal değeri anapara ve faizi içerir.

Hamiline yazılı finansman bonoları, sahibinin isteği üzerine başka kişilere devredilebilir. Finansal piyasaların büyümesi ve entegrasyonu nedeniyle, Euro cinsinden finansman bonolarının ihracı giderek artmaktadır (Korkmaz & Ceylan, 2006, s. 227-228).

Finansman bonoları taşıdıkları teminatlara göre beş gruba ayrılmaktadır

- A Tipi: Garanti kaydı taşımayan finansman bonoları
- B Tipi: İhraççıya karşı taahhüt edilmiş banka kredisiyle desteklenmiş finansman bonoları
- C Tipi: Banka garantisi taşıyan finansman bonoları
- E Tipi: Hazine garantisi taşıyan finansman bonoları
- F Tipi: Bir anonim ortaklığın müşterek borçlu ve müteselsil kefil sıfatıyla ödeme vaadini ihtiva eden finansman bonoları

Halka arz edilen finansman bonoları, emre veya hamiline yazılı olarak çıkarılabilir ve halka arz işlemleri aracı kuruluşlar aracılığıyla gerçekleştirilmelidir. Halka arz edilmeksizin satışa sunulan finansman bonoları ise yalnızca emre yazılı olarak ihraç edilebilir. Finansman bonoları, ikincil piyasalarda serbestçe alınıp satılabilir. Emre yazılı finansman bonolarının devri için, senedin arka yüzüne beyaz ciro yapılması ve teslim edilmesi yeterlidir (Konuralp, 2005, s. 38-39).

1.3.5. Banka Bonoları ve Banka Garantili Bonolar

Banka bonoları, kalkınma ve yatırım bankaları tarafından sermaye piyasalarından fon temini amacıyla ihraç edilen kıymetli evraklardır. Bu menkul kıymetler, Sermaye Piyasası Kurulu (SPK) kaydına alındıktan sonra en az 60 gün ve en fazla 720 gün vadeli olarak piyasaya sürülmektedir. Emre veya hamiline yazılı olarak düzenlenen bu bonolar için satış işlemi sırasında vade süresi belirlenir ve bu süre, bono üzerine yazılır (Parasız, 2000, s. 243).

Bonoların ihraç kararı, özel sektöre mensup bankaların genel kurulları devlet bankalarında ise, yönetim kurulları tarafından alınır.

Banka garantili bonolar, anonim ortaklıkların bankalardan kredi kullanmaları sonucu, borçlu sıfatıyla düzenleyip alacaklı bankaya verdikleri emre yazılı senetlerdir. Bu senetler, krediyi kullandıran banka tarafından kendi garantisi altında ve SPK kaydına alındıktan sonra, en az 60 gün ve en fazla 720 gün vadeli menkul kıymetler olarak ihraç edilirler. SPK' lu 14 Temmuz 1992 tarihinde Resmi Gazete' de yayımlanan Seri III, No. 12 Tebliği ile banka bonoları ve banka garantili bonoların ihracına ilişkin düzenlemeleri belirlemiştir. Bu tebliğ hükümlerine göre, bonolar halka arz edilerek veya halka arz edilmeksizin satılmak üzere ihraç edilebilir, ancak ihraç edilen tüm bonoların SPK'ya kaydettirilmesi zorunludur. Bonolar, banka tarafından belirlenen vadeye uygun olarak iskonto oranları ile hesaplanmış fiyat üzerinden satışa sunulur (Seri III, Tebliğ No.12, Md.12).

1.3.6. Gelir Ortaklığı Senetleri

Gelir Ortaklığı Senetleri, Hazine tarafından geliri Kamu Ortaklığı Fonu'na aktarılmak üzere ihraç edilen ve köprü, baraj, elektrik santrali, karayolu, demiryolu, telekomünikasyon sistemleri ile sivil kullanıma yönelik deniz ve hava limanları gibi kamuya ait altyapı projelerinin gelirlerine gerçek ve tüzel kişilerin ortaklık hakkı tanıyan finansal araçlardır. Bu senetler, ulaşım, haberleşme ve enerji sektörlerindeki kamuya ait altyapı tesislerinin gelirlerine dayanmaktadır. Gelir Ortaklığı Senetleri sahipleri, bu tesislerin mülkiyeti veya işletmesi ile herhangi bir ilişkiye sahip değildir. Hukuki statüsü itibarıyla, bu senetler adlarındaki "ortaklık" ibaresine rağmen, değişken faizli tahvil niteliği taşımaktadır. Dolayısıyla, yatırımcılara sabit değil, proje gelirlerine bağlı olarak değişken bir getiri sunmaktadır (www.borsaistanbul.com/tr).

1.3.7. Gayrimenkul Sertifikaları

Gayrimenkul sertifikaları, ihraççıların bedellerini inşa edilecek ve edilmekte olan gayrimenkul projelerinin finansmanında kullanmak üzere çıkardıkları hamiline yazılı menkul kıymetlerdir. Daha geniş bir ifadeyle, gayrimenkul projeleri başlatan veya mevcut projelerine devam eden şirketler, bu projelerin bağımsız bölümlerini küçük birimlere, yani sertifikalara, bölerek yatırımcılara sunmaktadırlar. Yeterli sayıda sertifika satın alan yatırımcılar, tapu devri yoluyla ilgili bağımsız bölümün sahibi olma hakkını elde ederler. Sertifikaları, bağımsız bölüm mülkiyetini elde etmeye yetecek sayıda olmayan

yatırımcılar ise, gayrimenkul projesinin muhtemel değer artışından faydalanma imkânına sahip olurlar. Bu tür sertifikalar, yatırımcılara hem mülkiyet hakkı hem de değer artışı kazancı sağlayan, Borsa İstanbul'da işlem gören bir sermaye piyasası aracıdır (Gayrimenkul Sertifikaları 2024).

1.3.8. Menkul Kıymet Dışındaki Sermaye Piyasası Araçları

Menkul kıymetler kapsamına girmeyen ve Sermaye Piyasası Kurulu (SPK) tarafından belirlenen koşullara tabi olan değerli evraklardır. Ancak, nakit para, çek, poliçe, bono ve mevduat sertifikaları bu düzenlemelerin dışında tutulmaktadır (SPK Kanunu Md.3/b). Örneğin, opsiyon sözleşmeleri veya menkul kıymetler ile kıymetli madenlere dayalı vadeli işlem sözleşmeleri gibi finansal araçlar da bu kategoriye girmektedir (Konuralp, 2005, s. 41). Bu tür finansal araçlar, yatırımcılara belirli koşullar altında finansal varlıkların gelecekteki fiyat hareketlerine ilişkin işlem yapma imkanı tanır. Vadeli işlem sözleşmeleri ve opsiyonlar, finansal piyasalarda risk yönetimi ve spekülasyon amacıyla yaygın olarak kullanılmaktadır. Bu enstrümanlar, yatırımcılara hem koruma hem de getiri sağlama potansiyeli sunar, ancak aynı zamanda karmaşık ve riskli yapıları nedeniyle dikkatli bir analiz ve bilgi gerektirmektedir.

1.4 BORSALAR VE BORSA ENDEKSLERİ

Finansal piyasaların bel kemiğini oluşturan borsalar, modern ekonomilerin temel yapı taşlarından biridir. Küresel ekonomi üzerinde büyük bir etkiye sahip olan borsalar, sermaye akışını düzenleyerek ekonomik büyümeyi teşvik eder ve yatırımcılara çeşitli fırsatlar sunar. Borsalar, şirketlerin sermaye artırma süreçlerinde kritik bir rol oynarken, aynı zamanda bireysel ve kurumsal yatırımcılar için geniş bir yatırım yelpazesi sağlar.

Borsa endeksleri, finansal piyasalarda önemli bir rol oynayan, belirli bir grup hisse senedinin performansını ölçen göstergelerdir. Bir ülkenin ekonomik sağlığını ve piyasa dinamiklerini anlamak için kritik bir araç olan borsa endeksleri, yatırımcıların ve analistlerin piyasa trendlerini izlemesine, kıyaslamalar yapmasına ve yatırım stratejilerini şekillendirmesine yardımcı olur. Endeksler, piyasaların genel yönünü belirlerken, yatırımcılar için de bir referans noktası oluştururlar.

1.4.1. Borsa Kavramı

Modern finansal sistemde borsalar, hisse senedi, tahvil gibi menkul kıymetlerin el değiştirdiği ikincil piyasalar olarak adlandırılan piyasalar arasında, merkezi bir platformda önceden belirlenmiş kurallar çerçevesinde işlem gören organizasyonlar olarak tanımlanmaktadır (Bal, 2014, s. 3).

Borsa kavramı, 6362 Sayılı Sermaye Piyasası Kanunu'nun 3. Maddesinde ise şu şekilde tanımlanmaktadır. Anonim şirket yapısında kurulan, sermaye piyasası araçlarının, döviz işlemlerinin, kıymetli madenler ile taşların ve Kurul tarafından uygun görülen diğer finansal varlıkların, sözleşme ve belgelerin serbest rekabet koşulları altında alım satımının güvenli bir şekilde gerçekleşmesini sağlayan organizasyonlardır. Bu yapılar, piyasa işleticisi tarafından yönetilen veya doğrudan kendisi tarafından işletilen, alım-satım emirlerini bir araya getirerek sonuçlandıran ya da bu süreci kolaylaştıran, fiyatların belirlenmesi ve ilan edilmesini sağlayan, Kanun çerçevesinde yetkilendirilmiş ve düzenli olarak faaliyet gösteren pazar yerleridir. Bu pazarların en belirgin özelliği, borç verenler ile borç alanları doğrudan karşı karşıya getirmesidir. Menkul kıymet borsalarında, fon akışı şeffaf bir ortamda ve standart yöntemler kullanılarak sağlandığı için yatırımcılar, risk alımını oldukça kolay ve düşük maliyetle gerçekleştirebilmektedir. Yatırımcıların risk alabilme yeteneği, ekonomilerin büyümesi için kritik bir öneme sahiptir. Bu mekanizma sayesinde, fon transferleri etkin bir şekilde gerçekleştirilecek ve tasarruflar verimli yatırımlara yönlendirilebilecektir (Karan, 2021, s. 41).

Borsa teriminin kullanımı ve yaygınlaşması, 13. yüzyılın sonlarına dayanmaktadır. Bu dönemde, bir grup tüccar, "Hotel Des Bourses" adlı handa toplanarak mallar limana ulaşmadan önce malların numuneleri üzerinden ticaret yapmaya başlamıştır. Bu uygulama, malların belirli kurallar çerçevesinde mübadele edildiği alanların "borsa" olarak adlandırılmasına yol açmıştır (Doğan 2011).

Borsalar, finansal varlıklar veya çeşitli emtiaların fiyatlarının belirlendiği ve bu varlıkların alım satımının gerçekleştirildiği ticaret platformlarıdır. Ancak, günümüzde "borsa" denildiğinde genellikle ilk olarak menkul kıymetler borsası akla gelmektedir. Menkul kıymetler borsası, özellikle hisse senetleri, tahviller ve diğer finansal araçların alım satımının yapıldığı organize bir piyasa olarak öne çıkmaktadır (Işık 2012, s.216).

Genel olarak fiziksel bir mekânla özdeşleşen borsalar, günümüzdeki teknolojik ilerlemeler sayesinde artık faaliyetlerini belirli bir mekâna bağlı kalmaksızın sürdürebilmektedir (Ceylan ve Korkmaz 2017, s.63).

1.4.2. Borsanın Gelişimi

Menkul kıymet borsalarının ilk örnekleri, Fransa'nın Lyon şehrinde ortaya çıkmış, ardından borsa merkezleri Paris, Anvers ve Amsterdam üzerinden Kuzey Avrupa'ya yayılmıştır. Modern borsaların temelini atan ilk şirket ise, 1600'lü yılların başında kurulan Hollanda Doğu Hindistan Şirketi'dir. Bu şirketin hisse senetlerinin işlem görmesiyle Anvers ve sonrasında Amsterdam, Avrupa'da borsa faaliyetlerinin öncü merkezleri haline gelmiştir. İngiltere' nin yükselişiyle birlikte, 1700' lü yıllardan itibaren Londra, Avrupa'nın önde gelen finans ve borsa merkezi olarak önem kazanmıştır. 19. yüzyılın sonlarına gelindiğinde ise, Amerika Birleşik Devletleri ve özellikle New York, küresel finans dünyasında belirgin bir rol üstlenmiştir. İkinci Dünya Savaşı'nın ardından yaşanan hızlı ekonomik büyüme, 1950'lerden itibaren menkul kıymet borsalarının dünya genelinde yaygınlaşmasını ve gelişmesini hızlandırmıştır. 1990'larla birlikte, borsaların gelişimi küresel bir nitelik kazanmıştır. Bu dönüşümün arkasında, dünya pazarlarının globalleşmesi, iletişim teknolojilerindeki ilerlemeler, bilgisayar teknolojisinin gelişmesi, birçok ülkede finansal kurumların piyasaya girişinin kolaylaştırılması ve doğrudan finansman olanaklarının artması gibi faktörler yatmaktadır (Karan, 2021, s. 41).

Sermaye piyasalarındaki bu hızlı gelişimin arkasında, 1980'lerden itibaren ABD ve diğer gelişmiş ülkelerin öncülüğünü yaptığı küreselleşme dalgası yer almaktadır. Bu dönemde, küreselleşme süreci, sermaye piyasalarının kaçınılmaz bir şekilde bu dönüşümün itici gücü haline gelmesine yol açmıştır. Ekonomide küreselleşmenin ilk adımı, sermaye piyasalarının liberalleştirilmesiyle atılmıştır. 21. yüzyıla gelindiğinde ise, ülkelerin sermaye hareketlerine yönelik kısıtlamaları kaldırmaları, sermaye akışının hızlanmasına ve küresel finans piyasalarının kayda değer bir şekilde büyümesine katkı sağlamıştır. Her ne kadar 2008 finansal krizi Amerika Birleşik Devletleri ve Avrupa pazarlarında ciddi sıkıntılara yol açmış olsa da, bu süreçte Çin ve Hindistan gibi gelişmekte olan ülkelere gözlenen ekonomik büyüme, küresel piyasalarda olumlu bir etki yaratmıştır. Bu yeni ekonomik dinamik, dünya genelinde sermaye akışlarını ve

finansal piyasaların yapısını yeniden şekillendirmiştir, böylece sermaye piyasaları küresel ekonominin en önemli unsurlarından biri haline gelmiştir (Karan 2021, 42).

1.4.3. Borsanın İşlevleri ve Ekonomiye Etkileri

Sermaye piyasalarının etkinliğini artıran borsalar, hem mikro hem makro düzeyde ekonomik büyümeye katkıda bulunarak finansal gelişmenin temel unsurlarından biri olarak kabul edilmektedirler. Borsalar yerel ölçekte ülkelerin ekonomik gelişimine önemli katkılar sunmaktadır. Bu borsalar aracılığıyla, halkın birikimleri şirketlere sermaye olarak yönlendirilmekte, böylece bankacılık sisteminden alınan yüksek faizli ve kısa vadeli krediler yerine, şirketler için daha düşük riskle uzun vadeli finansman sağlanmaktadır. Bu finansman, yatırım projelerine dönüştüğünde, ulusal ekonominin büyümesine katkıda bulunmaktadır. Örneğin, Borsa İstanbul'un kurulmasından bu yana gerçekleştirilen halka arzlar, ekonomiye milyarlarca dolarlık kaynak kazandırmıştır. Ayrıca, borsaya açılan şirketlerin piyasa değerleri artmış ve bu şirketlerin öz sermaye yapıları güçlenmiştir. Bu süreç hem şirketlerin sürdürülebilir büyümesine hem de genel ekonomik istikrarın sağlanmasına önemli ölçüde katkı sağlamaktadır. Bu doğrultuda menkul kıymet borsalarının temel ekonomik işlevlerini şu şekilde özetleyebiliriz (Aytekin, 2018; Karan, 2021, s. 42; Karlı, 2004, s. 217):

- Ekonominin Barometresi Olma
- Ekonomiye Kaynak ve İşlerlik Yaratma
- Likidite Sağlama
- Fiyat Oluşturma
- Şeffaf Yatırım Ortamı Sağlama
- Sermaye Mülkiyetini Geniş Bir Tabana Yayma
- Güvenilirlik, Koruyuculuk (Risk Yönetimi), Gözetimcilik ve Düzenleyicilik Sağlama

Borsalar, küresel ölçekte de iktisadi, sosyal ve politik yaşamın dinamiklerini yansıtan bir barometre işlevi görmektedir. Ekonomik koşullar, toplumsal değişimler ve

politik gelişmeler, borsalar üzerinde anında etkilerini göstermektedir. Borsalarda yatırımcılar hem kısa hem de uzun vadeli stratejilerle piyasada yer alırken, spekülasyon, arbitraj ve riskten korunma gibi işlemler, borsaların likiditesini ve işlem derinliğini artırarak piyasaların genişlemesine katkıda bulunmaktadır. Menkul kıymet borsaları, bulundukları ülkenin ekonomik ve yasal yapısına göre çeşitlilik arz etmektedirler. Bu borsalar, kotasyon sistemleri, yönetim ve denetim yapıları, uygulanan ihale yöntemleri, üye profilleri ve kullanılan endeksler gibi unsurlar açısından birbirlerinden farklılıklar ve birbirine benzerlikler gösterebilmektedir. Bu farklılıklar, borsaların yerel ekonomik koşullara uyum sağlama kapasitesini ve ulusal piyasalarda oynadıkları rolü belirlemektedir (Karan, 2021, s. 53-54).

Menkul kıymet borsaları, tarihsel olarak başlangıçta yatırımcıların ve aracılarının bir araya geldiği gayri resmi toplantı alanlarında şekillenmiş, zaman içerisinde ise kurumsallaşarak yasal düzenlemeler çerçevesinde faaliyet gösteren organize piyasalara dönüşmüştür. Günümüzde, özellikle ekonomik ve finansal altyapısı güçlü olan gelişmiş ülkeler başta olmak üzere, dünya genelinde farklı ölçeklerde ve işleyiş yapısına sahip birçok menkul kıymet borsası faaliyet göstermektedir. Bu borsalar, genel olarak ülkelerin ekonomik kalkınma düzeyleri, piyasa derinliği, yatırımcı tabanı ve düzenleyici yapıları gibi kriterler doğrultusunda gelişmiş ve gelişmekte olan piyasalar şeklinde iki temel kategoride sınıflandırılmaktadır. Bu sınıflandırma, yalnızca yapısal farklılıkları ortaya koymakla kalmayıp, aynı zamanda piyasaların risk profili, likidite düzeyi ve yatırım çekiciliği açısından da önemli farklılıkları yansıtmaktadır. Bu tez kapsamında, hem gelişmiş hem de gelişmekte olan ülke borsalarına ilişkin genel yapısal özellikler özetlenmiş ve analizlerde dikkate alınan ülkelerin sermaye piyasalarına ilişkin temel bilgiler sunulmuştur

1.4.4. Gelişmiş ve Gelişmekte Olan Borsalar

Gelişmiş borsalar, sanayileşmiş ülkelerde uzun bir geçmişe sahip, köklü finansal piyasalar olarak öne çıkmaktadır. Bu borsalar, genellikle Amerika, Avrupa ve Uzak Doğu gibi ekonomik olarak güçlü merkezlerde toplanmış olup, bu ülkelerin ekonomik sistemlerinde merkezi bir rol üstlenmektedirler. Sermaye piyasaları ve borsalar, liberal ekonomik yapılar içerisinde işlev görmektedir ve piyasa ekonomisinin özgür işleyişinin bir

parçası olarak kabul edilmektedir. Bu nedenle, sermaye piyasalarının en gelişmiş olduğu ülkeler aynı zamanda sanayi alanında da ileri düzeyde gelişmiş ülkelerdir (Ökte 1994).

Gelişmiş borsalar, diğer piyasalardan işlem hacmi, halka açık şirketlerin sayısı, bireysel ve kurumsal yatırımcıların piyasaya katılım oranı, aracı kurumların çeşitliliği ve finansal araçların genel yapısı gibi çeşitli kriterler açısından ayrılmaktadır. Bu borsalar, ayrıca sıkı yasal düzenleme ve denetim mekanizmaları ile desteklenmekte olup, geniş kapsamlı yasal çerçevelerle güvence altına alınmaktadır. Dolayısıyla, gelişmiş borsalar, finansal sistemin istikrarını ve şeffaflığını sağlamak amacıyla daha gelişmiş düzenleyici yapılarla donatılmıştır. Bu durum, söz konusu borsaların ulusal ve uluslararası yatırımcılar için güvenli ve cazip bir yatırım ortamı sunmasına olanak tanımaktadır (Karşlı, 1989, s. 29).

Örneğin, NYSE ve Londra Borsası gibi gelişmiş borsalar, dünyadaki en büyük piyasa değerine sahip şirketleri bünyesinde barındırmaktadır. NYSE, 2023 yılı itibarıyla, yaklaşık 2.400 şirketin işlem gördüğü ve toplam piyasa değeri 30 trilyon doların üzerinde olan bir borsa olarak öne çıkmaktadır (United States Archives, 2023). Bu borsaların hisse senetlerinin pazar değeri, dünya genelindeki yatırımcıların güvenli liman olarak gördüğü varlıkları içerir ve bu borsaların günlük işlem hacmi milyarlarca doları bulmaktadır.

Gelişmekte olan borsalar, 1980'li yıllardan itibaren küresel yatırımcıların dikkatini çekmeye başlayan ve hızla büyüme gösteren Asya, Güney Amerika ve Doğu Avrupa gibi bölgelerdeki menkul kıymet borsaları olarak tanımlanabilir. Ancak, gelişen borsaların tanımı sabit bir nitelik taşımaz; farklı bağlamlarda ve farklı kriterlere göre çeşitli anlamlar kazanabilir. Bu borsalar, genellikle ekonomik kalkınmanın hızla devam ettiği, ancak hala gelişme sürecinde olan ülkelerde bulunmaktadır. Örneğin, Latin Amerika'da Arjantin, Brezilya, Şili, Kolombiya, Meksika ve Venezuela gibi ülkelerin borsaları; Asya'da ise Güney Kore, Filipinler, Tayvan, Çin, Hindistan, Endonezya, Malezya, Pakistan ve Tayland gibi ülkelerin borsaları bu kategoriye dâhildir. Avrupa'da Portekiz, Türkiye ve Yunanistan; Afrika'da ise Nijerya ve Zimbabwe, gelişen borsalar arasında sayılabilecek diğer önemli örneklerdir (Ökte 1994).

Gelişmekte olan borsalar, ekonomik büyüme potansiyeline sahip, ancak henüz gelişmiş piyasaların olgunluğuna erişmemiş ülkelerde bulunur. Gelişmekte olan borsa

kavramını tanımlarken kullanılan kriterlerin hiçbirisi tek başına bu borsaların dinamiklerini tam anlamıyla açıklamaya yeterli değildir. Ancak, gelişmekte olan borsaların belirli ortak özelliklere sahip olma eğiliminde oldukları gözlemlenmektedir. Bu borsalar, coğrafi olarak farklı bölgelerde bulunsalar bile, genellikle gelişmiş borsalara kıyasla birbirlerine daha fazla benzerlik göstermektedirler. Gelişmekte olan borsaların ayırt edici bazı özellikleri arasında, düşük piyasa kapitalizasyonu, hızlı ve zaman zaman sürdürülemez düzeydeki büyüme oranları, yabancı yatırımları düzenleyen fakat genellikle çok katı olmayan yasal çerçeveler ve yüksek düzeyde piyasa yoğunlaşması yer almaktadır. Bu borsalar, genellikle az sayıda büyük şirketin baskın olduğu, yabancı sermaye çekme kapasitesi olan, ancak küresel ekonomik dalgalanmalara karşı daha kırılgan yapılara sahiptirler (Sesit 1993).

Örneğin, 2023 yılı itibarıyla Brezilya Borsası (B3), yaklaşık 400 şirketi bünyesinde barındırmakta olup, toplam piyasa değeri 1 trilyon doların altında kalmaktadır (Brazil Archives, 2023). Gelişmekte olan borsaların toplam pazar değerleri, gelişmiş piyasalara kıyasla görece düşük seviyelerde bulunmasına rağmen, bu borsalar genellikle daha yüksek büyüme hızları sergilemektedirler. Özellikle Çin, Hindistan ve Brezilya gibi ülkelerdeki hızlı ekonomik büyüme, bu ülkelerin borsalarına olumlu bir şekilde yansımakta ve bu piyasaların çekiciliğini artırmaktadır. Dolayısıyla, gelişmekte olan borsalar hem risk hem de fırsat içeren yatırım alanları olarak nitelendirilmektedir.

Gelişmiş ve gelişmekte olan borsalar arasındaki temel farklar, piyasa derinliği, likidite, işlem gören şirketlerin sayısı ve piyasa değeri gibi faktörlerde kendini göstermektedir. Gelişmiş borsalar daha fazla likiditeye, daha yüksek sayıda işlem gören şirkete ve daha büyük bir piyasa değerine sahiptir. Buna karşın, gelişmekte olan borsalar yüksek büyüme potansiyeline sahip olmakla birlikte, genellikle daha fazla risk içermektedir. Özetle, gelişmiş ve gelişmekte olan borsalar, dünya ekonomisinin farklı segmentlerinde yer alan, kendine özgü dinamikleri olan finansal piyasalardır. Her iki borsa tipi de ulusal ekonomiler için kritik roller üstlenmekte olup, küresel yatırımcılar için çeşitlendirilmiş yatırım portföyleri oluşturma açısından farklı avantajlar sunmaktadır. Bu borsaların yapısal farklılıkları, yatırımcıların karar alma süreçlerinde dikkate alınması gereken önemli faktörleridir.

1.4.5. Borsa Endeksi ve Seçilmiş Ülke Endeksleri

Endeks, birden fazla değişkenin hareketlerinin oransal olarak ölçülmesine olanak sağlayan istatistiksel bir araç olarak ifade edilmektedir (Çulha 2019). Endeksler, karmaşık finansal ve ekonomik olayları tek bir sayısal ölçüde özetleyen ve dönüştüren özel göstergelerdir. Bu göstergeler, çeşitli verileri bir araya getirerek zaman içindeki değişimleri ve eğilimleri analiz etme imkânı sunmaktadır. Birden fazla değişkenin dinamiklerini entegre eden endeksler, genellikle karmaşık sistemlerin işleyişini ve genel durumunu daha anlaşılır hale getirmektedir. Bu işlev, karar vericiler, araştırmacılar ve finansal piyasalarda faaliyet gösteren profesyoneller için önemli bir avantaj sağlamaktadır (Amenc & Le Sourd, 2005, s.70-72; Fabozzi, 2015, s. 589). Dolayısıyla endeksler, veri analizi ve karar verme süreçlerinde önemli bir araç olarak işlev görmektedir, çeşitli ekonomik ve finansal analizlerin uygulanabilirliğini artırmaktadır.

Borsa endeksleri, bir ülkenin ekonomik performansını sürekli olarak izleyen ve değerlendiren kritik göstergeler olarak rol oynamaktadır. Borsalardaki hareketleri izlemek ve değerlendirmek amacıyla, her borsa kendi dinamiklerine uygun bir veya birden fazla endeks oluşturabilmektedir. Bir ülkede birden fazla menkul kıymet borsası bulunduğu, bu borsaları kapsayan genel bir ulusal endeks de geliştirilmesi mümkündür. Endekslerin doğru bir şekilde yorumlanabilmesi için, bu endekslerin özelliklerinin titizlikle belirlenmesi gerekmektedir. Endekslerin sahip olduğu bu özellikler, onların performansını daha derinlemesine anlamamıza ve değerlendirmemize olanak tanımaktadır (Karan, 2021, s. 65).

Borsa endekslerinin belli başlı kullanım alanları şu şekilde özetlenebilir (Bolak, 1994, s.66; Karaşin, 1987, s.150; Sarıkamış, 1995, s.269):

- Endeksler, hisse senedi fiyatlarındaki zaman içindeki toplu değişimleri yansıtarak piyasa performansının genel bir resmini sunmaktadır.
- Piyasa portföylerinin getirisini hesaplamak için endeksler önemli bir referans noktası olarak kullanılmaktadır. Bu sayede hem kurumsal hem de bireysel yatırımcılar, belirli bir dönem boyunca sahip oldukları portföylerin performansını piyasanın genel performansı ile karşılaştırma olanağı elde etmektedirler.

- Endeksler, hisse senedi piyasasındaki gelişmeler ile genel ekonomik göstergelerdeki değişiklikler arasında karşılaştırma yapılmasına imkân vermektedir.
- Endeksler aynı zamanda sermaye piyasası analizlerinde, özellikle beta katsayılarının hesaplanmasında önemli bir araç olarak kullanılmaktadır. Beta katsayıları, bir hisse senedinin piyasa genelindeki risk faktörlerine duyarlılığını ölçerken, endeksler bu hesaplamalar için temel referans olarak işlev görmektedir.
- Endekslere dayalı türev ürünler, opsiyonlar ve vadeli işlemler gibi yeni yatırım araçlarının geliştirilmesinde de endeksler kritik bir rol oynamaktadır. Bu tür türev ürünler, yatırımcılara piyasa beklentilerine göre stratejik pozisyonlar alma imkânı tanımaktadır.
- Son olarak, endeksler, alternatif yatırım araçlarının getirilerinin karşılaştırılmasında da yatırımcılara faydalı bilgiler sunmaktadır. Bu karşılaştırmalar, yatırımcıların portföylerini çeşitlendirme ve risklerini optimize etme süreçlerinde önemli bir rehber niteliği taşımaktadır.

Borsa endekslerinin hesaplanmasında kullanılan çeşitli yöntemler vardır. Bu yöntemler, endeksin bileşenlerinin ağırlıklandırılma şekline göre farklılık göstermektedir ve her bir yöntem, farklı bir yatırım stratejisini ya da piyasa bakış açısını yansıtabilmektedir. Başlıca hisse senedi endeksi hesaplama yöntemleri şunlardır(Karan, 2021, s. 67):

Aritmetik ortalama formülü ile;

- DJIA
- Nikkei

Geometrik ortalama formülü ile;

- Value Line Composite Index

Şirketlerin piyasa değerlerinin kullanıldığı formüller ile;

- S&P 500

- Topix
- Finansal Times Endeksi
- BIST Endeksleri

Endekslerin oluşturulmasında kullanılan hesaplama yöntemleri ve örnek seçim kriterleri, aynı piyasa için hesaplanan endekslerin farklı sonuçlar vermesine yol açabilmektedir. Bu farklılıklar, endeksin bileşenlerinin seçilme şekli, ağırlıklandırma yöntemleri ve veri toplama süreçlerinden kaynaklanabilir. Örneğin, fiyat ağırlıklı, piyasa değeri ağırlıklı veya serbest dolaşım ağırlıklı endeksler, aynı piyasa için farklı performans göstergeleri sunabilir. Bu nedenle, endeksin yapısı, hesaplama metodolojisi ve bileşenleri, yatırımcıların piyasanın gerçek durumunu doğru bir şekilde değerlendirmeleri açısından kritik öneme sahiptir. Endeksler, hisse senetlerinin işlem gördüğü borsalar tarafından hesaplanabileceği gibi, bağımsız finansal kuruluşlar tarafından da oluşturulabilir. Endekslerin seçimi ve oluşturulması sürecinde, piyasanın genel durumunu ne derece yansıttığı, yatırımcılar için belirleyici bir faktör olmaktadır. İyi bir endeks, piyasanın gerçek durumunu ne kadar doğru ve güvenilir bir şekilde yansıtabiliyorsa, o ölçüde tercih edilir ve yaygın olarak kullanılmaktadır. Endekslerin doğru bir şekilde yansıtılması, yatırım kararlarının sağlıklı bir temele oturtulması açısından büyük önem taşımaktadır (Dağlı, 2000).

Genel olarak borsa endekslerinin tanımı, hesaplama yöntemleri ve işlevleri üzerine yapılan değerlendirmelerin ardından, çalışmamızın odağını oluşturan E7 (Emerging 7) ve G7 (Group of Seven) ülkelerinin seçilmiş borsa endekslerine değinmek yerinde olacaktır. Bu kapsamda, E7 ve G7 ülkelerinin ekonomik büyüklükleri ve küresel finansal piyasalardaki rolleri dikkate alındığında, bu ülkelerin borsa endeksleri hem yerel hem de uluslararası yatırımcılar için büyük önem taşımaktadır. Şimdi, bu ülkelerdeki seçilmiş endekslerin özelliklerini detaylandırarak, bu endekslerin tahmin edilebilirliğine yönelik çalışmalarımıza temel oluşturacak bilgileri sunulacaktır.

1.4.5.1 G7 Ülkeleri ve Seçilmiş Borsa Endeksleri

G7, dünya ekonomisinin en gelişmiş ve sanayileşmiş yedi ekonomisini temsil eden bir gruptur. Bu ülkeler, ABD, Kanada, Almanya, Fransa, Birleşik Krallık, İtalya ve

Japonya'dan oluşmaktadır. G7, küresel ekonomi, ticaret, çevre, güvenlik ve kalkınma gibi çeşitli konularda uluslararası iş birliği sağlamak amacıyla düzenli olarak bir araya gelmektedir. Bu ülkeler, dünya Gayrisafi Yurtiçi Hasılanın (GSYİH) önemli bir bölümünü oluşturmakta ve finansal piyasaların düzenlenmesi ve uluslararası ekonomik politikaların şekillendirilmesinde lider roller üstlenmektedirler (Focuseconomic 2024).

1.4.5.1.1 Amerika (S&P500) Endeksi

ABD, dünyanın en büyük ve en etkili borsalarına ev sahipliği yapmaktadır. Bu borsaların başında New York Borsası (NYSE), Amerikan Borsası (AMEX), NASDAQ Borsası ve Chicago Borsası (CHX) gelmektedir. Amerikan borsaları kadar bu borsaların endeksleri de küresel finans dünyasında büyük öneme sahiptir ve geniş bir coğrafi alana yayılarak etkilerini hissettirmektedir. ABD'nin en büyük ve en bilinen borsa endeksi, Standard and Poor's (S&P) tarafından hesaplanan ve yönetilen S&P 500 endeksidir. Bu endeks, ABD'nin önde gelen 500 şirketini kapsayarak, piyasaların genel durumunu izlemek için en yaygın olarak kullanılan göstergelerden biri olmuştur. S&P 500 endeksi, 1923 yılında 233 şirket ile işlem görmeye başlamış, ancak 1957 yılında 500 şirketi kapsayacak şekilde genişletilerek günümüzdeki yapısına kavuşmuştur. Endeks, küresel çapta yatırımcılar tarafından yakından takip edilen bir gösterge olup, ABD piyasalarının genel eğilimlerini yansıtmada önemli bir referans noktası olarak kabul edilmektedir. S&P 500 endeksi, ABD'deki şirket hisselerinin yaklaşık %70'ini temsil etmekte ve sağlık, finans, enerji, sanayi, bilgi teknolojileri, perakende gibi çeşitli sektörlerde faaliyet gösteren şirketleri bünyesinde barındırmaktadır. Bu çeşitlilik, endeksin hem ABD ekonomisinin geniş bir yelpazesini kapsamasını sağlamakta hem de yatırımcılar için önemli bir analiz aracı olarak kullanılmasına imkân tanımaktadır (Çepni 2015).

1.4.5.1.2 Kanada (S&P/TSX) Endeksi

Dünyanın en büyük ve en önemli borsaları arasında yer alan Kanada Borsası, piyasa değeri açısından küresel sıralamada dokuzuncu sırada bulunan Toronto Menkul Kıymetler Borsası (TSX) ile öne çıkmaktadır. TSX, 2000'den fazla şirketin işlem gördüğü bir borsa olup, özellikle dünya çapında en fazla madencilik, petrol ve gaz şirketinin listelendiği borsa olarak dikkat çekmektedir. Kanada'nın pay senedi piyasasını temsil eden en önemli borsa endekslerinden biri olan S&P/TSX endeksi, TSX'de listelenen en

büyük şirketlerin piyasa değeri temel alınarak hesaplanmaktadır. S&P/TSX endeksi, Kanada borsasında işlem gören şirketlerin piyasa performansını izlemek amacıyla kullanılan bir bileşik endeks olup, aynı zamanda birden fazla alt endeksin ana endeksi olarak da işlev görmektedir (TradingView 2024b)

Bu çalışma kapsamında da analiz edilecek olan S&P/TSX Bileşik Endeksi, Standard and Poor's (S&P) tarafından hesaplanan ve Toronto Menkul Kıymetler Borsası'nda (TSX) listelenen şirketleri kapsayan en geniş endeks olarak kabul edilir. Bu endeks, TSX'te işlem gören yaklaşık 1.900 şirket arasından seçilen yaklaşık 225 Kanada şirketini içermektedir. Söz konusu şirketler, borsanın toplam piyasa değerinin yaklaşık %80'ini temsil etmektedir. Ocak 2024 itibarıyla, S&P/TSX Bileşik Endeksi'nin toplam piyasa değeri 3,32 trilyon Kanada doları sınırını aşmıştır. Endeks üyelerinin yaklaşık üçte biri, bankalar, yatırım şirketleri, finansal hizmet firmaları ve sigorta şirketlerinden oluşan finans sektörüne aittir. Endekste ayrıca yoğun olarak temsil edilen diğer sektörler arasında enerji, sanayi ve bilgi teknolojisi bulunmaktadır (S&P/TSX Composite Index).

1.4.5.1.3 Almanya (DAX) Endeksi

Frankfurt Menkul Kıymetler Borsası, Londra Borsası'nın ardından Avrupa'nın en büyük ikinci borsası olup, dünya çapında en büyük ve en eski borsalardan biri olarak kabul edilir. Almanya'nın ilk borsası olarak 1585 yılında, finans ve bankacılık merkezi olarak bilinen Frankfurt'ta kurulmuştur. Günümüzde de Avrupa Merkez Bankası'nın merkezi olan Frankfurt, bankacılık ve finans sektöründe stratejik bir öneme sahiptir. Almanya'daki sekiz menkul kıymet borsası arasında yaklaşık %90 işlem hacmi ile en büyük paya sahip olan Frankfurt Borsası, uluslararası piyasalarda "Alman Borsası" olarak anılmakta ve ülkenin en büyük borsası olarak öne çıkmaktadır (Güntürk 2023).

DAX hisse senedi endeksi, Frankfurt Borsası'nda işlem gören en büyük ve en likit hesaplamak için serbest dolaşım metodolojisini kullanarak, yalnızca piyasada aktif olarak işlem gören hisseleri dikkate almaktadır. İlk olarak 1988 yılında 1.163 puanlık bir başlangıç seviyesi ile oluşturulan DAX, o tarihten bu yana Almanya'nın en önemli ekonomik göstergelerinden biri haline gelmiştir. Günümüzde DAX endeksinde yer alan

şirketler, Frankfurt Borsası'nda işlem gören tüm hisselerin toplam piyasa değerinin yaklaşık %80'ini temsil etmektedir (Deutsche Börse Group - DAX).

2021 yılında yapılan bir revizyonla, endekste ki şirket sayısı 30'dan 40'a çıkarılmıştır, bu da endeksin daha geniş bir piyasa kesitini kapsamasını sağlamıştır. DAX, hem Almanya'nın ekonomik performansını yansıtan bir gösterge olarak hem de uluslararası yatırımcılar için önemli bir referans noktası olarak kabul edilmektedir (Deutsche Börse Group - DAX).

1.4.5.1.4 Fransa (CAC 40) Endeksi

Bu çalışmada analizi yapılacak bir diğer endeks olan CAC 40, eskiden Paris Borsası olarak bilinen Fransa'nın en büyük borsası olan Euronext Paris Borsasında işlem gören en büyük 40 şirketin piyasa değeri temel alınarak oluşturulan ve borsanın ana göstergesi olarak kabul edilen bir endekstir. Euronext, 2000 yılında Amsterdam, Brüksel ve Paris borsalarının birleşmesiyle kurulmuş olup, 2007 yılında New York Borsası (NYSE) Grubu ile birleşerek NYSE Euronext'in kurulmasını sağlamıştır. Ancak, 2014 yılında Euronext, yeniden bağımsız bir varlık haline gelerek bu birleşmeden ayrılmıştır. Euronext, altı farklı ülkede yer alan çeşitli borsaları yönetmektedir. Yaklaşık 4.000 halka açık şirketi bünyesinde barındıran Euronext, toplamda yaklaşık 30,5 trilyon dolarlık piyasa değerini temsil eden ve dünyanın en yüksek likiditeye sahip borsa grubunu işletmektedir. Bu kapsamda CAC 40, yapısı itibariyle çok uluslu şirketlerden oluşmakta olup, uluslararası yatırımcılar tarafından yakından takip edilen önemli bir küresel endeks olarak öne çıkmaktadır. Bu nedenle, siyasi ve ekonomik gelişmeler, doğal afetler, güvenlik sorunları gibi çeşitli etkenlerden görece daha fazla etkilenme potansiyeline sahiptir. CAC 40 endeksinde yer alan büyük şirketler arasında L'Oreal, Renault, Michelin Carrefour ve Total gibi önde gelen firmalar bulunmaktadır (investopedia 2022).

1.4.5.1.5 İngiltere (FTSE 100) Endeksi

Londra Menkul Kıymetler Borsası (LSE), dünyanın en eski borsalarından biri olarak New York Borsası (NYSE) ve Tokyo Borsası arasında yer almakta olup, Avrupa'nın en büyük ve Birleşik Krallık' ın birincil borsasıdır. Londra Borsası, NASDAQ

Borsası'na benzer bir işleyişe sahiptir. Bu sistemde, aracı kurumlar alım ve satım fiyatlarını borsanın elektronik işlem sistemine girer ve sistem, en yüksek alış fiyatlarını en düşük satış fiyatlarıyla eşleştirerek fiyat oluşumunu sağlamaktadır (Karan 2021).

Londra Menkul Kıymetler Borsası (LSE), birincil piyasaları aracılığıyla, dünya genelindeki en derin ve likit sermaye havuzlarına uygun maliyetli erişim imkânı sağlar. LSE, çeşitli sektörlerden gelen çok sayıda şirkete ev sahipliği yaparak, borsada kayıtlı şirketler için elektronik hisse senedi ticaretine olanak tanır. 60'tan fazla ülkeden binlerce şirketin işlem gördüğü LSE, tüm borsalar arasında en uluslararası nitelikte olanlardan biridir. Ana Pazar'ın performansı, şirketlerin başarısını izleyen çeşitli endekslerle ölçülmekte olup, FTSE 100 endeksi, Premium listesinde yer alan en büyük şirketlerin küresel ölçütü olarak kabul edilmektedir (An overview of London Stock Exchange markets - LSE 2020).

1984 yılında piyasa değerine göre en büyük 100 şirketin gerçek zamanlı bir endeksi olan FTSE 100 (Financial Times Stock Exchange 100 Index) Financial Times ile birlikte hesaplanarak piyasaya sürülmüş ve baz değeri 1000 olarak belirlenmiştir. FTSE 100 endeksi, Avrupa finansal piyasalarında yaygın kullanıma sahip bir gösterge niteliğindedir. Geçen süre zarfında endeks, 7.000 puanın üzerindeki seviyelere ulaşarak önemli bir gelişim kaydetmiştir. Çok sayıda piyasa analistinin, yatırımcının ve işlem yapan kişinin görüşüne göre FTSE 100, Amerikalı yatırımcıların Dow Jones ve S&P 500 endekslerini referans almasına benzer şekilde, Birleşik Krallık borsasının genel performansını yansıtan bir gösterge olarak kabul edilmektedir. FTSE 100 endeksinin en etkili bileşenleri arasında AstraZeneca, Shell ve HSBC Holding gibi şirketler yer almaktadır (Financial Times Stock Exchange Group (FTSE): Definition 2024).

FTSE 100 endeksinin kompozisyonunu oluşturan şirketlerin, diğer bir deyişle endeks bileşenlerinin yeniden değerlendirilmesi ve gerekli ayarlamaların yapılması, üç aylık periyotlarla gerçekleştirilmektedir. Bu süreç, genellikle Mart, Haziran, Eylül ve Aralık aylarının ilk Cuma gününü takip eden Çarşamba günü uygulanmaktadır. Endeksi oluşturan bileşenlerde ve bu bileşenlerin endeks içerisindeki ağırlıklarında meydana gelen herhangi bir değişiklik, yeniden değerlendirme sürecinden önceki iş gününün kapanışında tespit edilen şirket değerlerine dayanmaktadır (FTSE UK Index Series 2023).

1.4.5.1.6 İtalya (FTSE MIB) Endeksi

Gelişmiş bir ekonomi olan İtalya’da, borsa faaliyetleri 19. yüzyılın başlarına dayanmaktadır. 19. yüzyılın başlarında ülkenin hızla gelişen endüstriyel büyümesiyle birlikte, önceleri küçük ölçekleri sayesinde finansman ihtiyaçlarını kendi kaynakları ve banka kredileriyle karşılayabilen imalat şirketleri, daha geniş çaplı sermaye gereksinimlerini karşılamak amacıyla borsaya yönelmeye başlamıştır. Bu süreçte, Milano Borsası’nda işlem gören hisse senedi sayısı 1895 yılında 23 iken, bu rakam 1900 yılında 54’e, 1913 yılında ise 160’a yükselmiştir. 1913 yılında çıkarılan yasa ile borsanın yönetim, denetim ve kontrol yetkileri Bakanlık, Borsa Temsilcilikleri, Ticaret Odaları ve Aracı Kurumlar Sendikaları ve arasında paylaştırılmıştır. 1998 yılında borsanın özelleştirilmesiyle birlikte Borsa Italiana adıyla anonim şirkete dönüştürülmüş ve 2007 yılında Londra Menkul Kıymetler Borsası Grubu’nun bir parçası haline gelmiştir (The history of Borsa Italiana, the Italian Stock Exchange - Borsa Italiana 2024).

FTSE MIB Endeksi, İtalyan iç piyasa kapitalizasyonunun yaklaşık %80’ini oluşturan ve İtalya’nın en büyük 40 şirketini izleyen birincil hisse senedi endeksidir. Bu endeks, bankacılık, kamu hizmetleri, imalat gibi çeşitli sektörlerden şirketleri içermektedir. Endekste ki şirketlerin seçimi ve ağırlıklandırılması, bileşen hisse senetlerinin fiyatlarının ağırlıklı ortalaması kullanılarak gerçek zamanlı olarak hesaplanmaktadır. Bu hesaplama yöntemi, daha yüksek piyasa değerine sahip şirketlerin endeksin performansı üzerinde daha belirgin bir etki yaratmasına neden olmaktadır. Endeksin yönetimi ve hesaplanması, küresel finansal endeksleme ve kıyaslama hizmetleri alanında önde gelen kuruluşlardan biri olan FTSE Group tarafından gerçekleştirilmektedir. FTSE Group, London Stock Exchange Group’un tam mülkiyetindeki bir yan kuruluştur. Dow Jones Endüstri Ortalaması gibi, FTSE MIB de genellikle yerel borsa piyasasının ve İtalyan ekonomisinin genel sağlığını ve performansını ölçmek için bir gösterge olarak kabul edilmektedir. Endeks, çok uluslu elektrik ve gaz dağıtım şirketi Enel SpA, otomotiv üreticisi Stellantis NV, bankacılık grubu Intesa Sanpaolo SpA ve yarı iletken üreticisi STMicroelectronics NV gibi İtalya’nın önde gelen şirketlerini bünyesinde barındırmaktadır (FTSE MIB trading guide 2024).

1.4.5.1.7 Japonya (NIKKEI 225) Endeksi

Tokyo Borsası (TSE), Japonya'nın en büyük borsasıdır. Tokyo'da kurulmuş olan bu borsa, Asya kıtasındaki en büyük borsa olduğu gibi, dünyanın da en büyük ikinci borsasıdır. 15 Mayıs 1878 tarihinde kurulan borsada ağustos 2024 itibariyle 3956 halka açık şirket işlem görmektedir (Number of Listed Companies/Shares 2024)

TSE, Japan Exchange Group tarafından yönetilmekte olup, Toyota, Honda ve Mitsubishi gibi dünya çapında faaliyet gösteren önde gelen Japon şirketlerine ev sahipliği yapmaktadır. 1991-2001 yılları arasında Japonya'daki hisse senedi ve gayrimenkul balonlarının patlaması sonucu ülke ekonomisi önemli ölçüde daralmış ve TSE de bu süreçten olumsuz etkilenmiş ve küçülmüştür. TSE'de üç ana piyasa bulunmaktadır: Birinci Piyasa büyük şirketleri, İkinci Piyasa orta ölçekli şirketleri ve Anne Pazarı ise yüksek büyüme potansiyeline sahip şirketleri barındırmaktadır (Karan, 2021, s. 49-50).

Nikkei 225, dünya çapında birçok yatırımcının yakından takip ettiği Japonya'nın en önemli borsa endekslerinden biridir. Bu endeks, Tokyo Menkul Kıymetler Borsası'nda işlem gören ve 225 hisse senedinden oluşan, fiyat ağırlıklı Yen bazlı bir göstergedir. Endeks, adını önde gelen ekonomi gazetelerinden Nikkei' den almıştır. Fiyat ağırlıklı bir endeks olması, yüksek fiyatlı hisselerin endeks üzerindeki etkisini artırmaktadır. 1950'den bu yana hesaplanmakta olup, Toyota, Panasonic ve Bridgestone gibi büyük şirketleri kapsamaktadır. Endeks, Japonya'nın önde gelen medya kuruluşlarından biri olan Nihon Keizai Shimbun (Nikkei) gazetesi tarafından günlük olarak hesaplanmakta olup, her yıl yeniden değerlendirilmektedir. Japonya'nın Amerika ile olan ticari ilişkilerinden dolayı endeks Amerikan Dow Jones Endeksi'ndeki dalgalanmalardan etkilenmektedir. Nikkei 225'teki işlemler, Yen üzerinden gerçekleştirilir ve kar-zarar hesaplamaları da bu para birimiyle yapılmaktadır (NIKKEI 225 Canlı Fiyat Grafiği Yorumlar ve Teknik Analizler 2023).

1.4.5.2 E7 Ülkeleri ve Seçilmiş Borsa Endeksleri

Gelişme hızının yüksek olduğu E7 Ülkeleri Çin, Hindistan, Brezilya, Rusya, Meksika, Endonezya ve Türkiye'den oluşmaktadır. E7, 21. yüzyılın ekonomik dinamiklerinde giderek daha merkezi bir rol üstlenmektedir ve 2050 yılına kadar dünya

ekonomisinin büyük bir kısmını oluşturmaları beklenmektedir. Bu ülkeler, hızlı nüfus artışı, geniş iç pazarlar ve artan üretim kapasiteleri ile dikkat çekmektedir. E7 ülkeleri, 2050 yılına kadar küresel ekonomik büyümenin lokomotifi olma potansiyeline sahiptir ve G7 ülkelerinin ekonomik gücünü geride bırakmaları beklenmektedir. Bu ülkeler arasındaki büyüme oranları ve ekonomik gelişim hızları farklılık gösterse de, genel olarak hepsi güçlü bir ekonomik kalkınma süreci içerisinde (Ball, 2018; wealthbriefingasia).

1.4.5.2.1 Çin (SHANGHAI COMPOSITE) Endeksi

Çin ankarasının en büyük borsası olarak kabul edilen Şanghai Menkul Kıymetler Borsası (SSE), Çin Menkul Kıymetler Düzenleme Komisyonu (CSRC) tarafından yönetilen kar amacı gütmeyen bir organizasyondur. SSE'nin toplam piyasa değerinin büyük bir kısmı, geçmişte devlet kontrolünde olan ve günümüzde büyük ticari bankalar ve sigorta şirketleri gibi kuruluşlardan oluşmaktadır. SSE, hisse senedi borsaları arasında toplam piyasa değeri bakımından NYSE, Nasdaq ve Tokyo Borsası'nın ardından dördüncü sırada yer almaktadır. Şanghai Borsası'nda işlem gören halka açık her şirketin hisseleri, A hisseleri ve B hisseleri olmak üzere iki ana kategoriden meydana gelmektedir. B hisseleri ABD doları üzerinden fiyatlandırılır ve genellikle yabancı yatırımcılara açıktır. A hisseleri ise yuan cinsinden fiyatlandırılmakta olup, yalnızca yalnızca QFII olarak bilinen nitelikli bir program aracılığıyla yabancı yatırıma açıktır (Chen 2022).

SSE Composite tam adıyla Şanghai Borsası Composite Endeksi, Şanghai Borsası'nda (SSE) işlem gören tüm A-hisseleri ve B-hisselerinden oluşan bir borsa endeksidir. Endeks, 100 baz puanı kullanılarak hesaplanır. İlk raporlama günü 15 Temmuz 1991'dir (Methodology of SSE Composite Index t.y.). SSE Bileşik Endeksi, Şanghai Borsası'nda listelenen şirketlerin performansına genel bir bakış sağlamak için iyi bir göstergedir (Shanghai Stock Exchange, t.y.).

SSE Composite Endeksi'nin volatilité açısından oldukça değişken olduğu bilinmektedir. Bu dalgalanmaların temel nedenlerinden biri, Çin'in borsa yönetimi konusundaki sınırlı deneyimi olarak görülmektedir (Hodgkin 2015).

1.4.5.2.2 Hindistan (NIFTY 50) Endeksi

Hindistan Ulusal Menkul Kıymetler Borsası (National Stock Exchange of India-NSE), Hindistan'ın en büyük finans piyasası konumundadır. 1992 yılında kurulan NSE, 1994 yılında faaliyetlerini başlatmıştır. Elektronik piyasa altyapısına sahip olan NSE, gelişmiş bir borsa işlevi görmektedir (History & Milestones 2024).

NSE, Mumbai'de yer almakta olup Hindistan'ın önde gelen finans kuruluşlarının oluşturduğu bir grup tarafından yönetilmektedir. Hindistan sermaye piyasasına daha fazla şeffaflık kazandırmak amacıyla kurulmuştur. Tamamen otomatik elektronik ticaret olanağı sağlayan ilk borsa olmasının yanı sıra, türev araçlar ve borsa yatırım fonları (ETF'ler) için elektronik limit emir defteri sunan ilk borsa olarak da öne çıkmaktadır (Chen 2024).

Nifty 50 Endeksi, Hindistan'ın en tanınmış hisse senedi endekslerinden biridir. 1996 yılında Hindistan Ulusal Menkul Kıymetler Borsası (NSE) tarafından oluşturulan bu endeks, Hindistan ekonomisinin farklı sektörlerinde faaliyet gösteren en büyük ve en likit 50 şirketin performansını yansıtmaktadır. NIFTY 50 Endeksi, 1995 yılında başlangıç değeri 1.000 olacak şekilde oluşturulmuştur. Bu endeks, piyasada aktif olarak dolaşımda bulunan payların belirli bir zamandaki miktarını ifade eder ve serbest piyasa kapitalizasyon yöntemi kullanılarak ölçülür. Nifty 50 endeksi, merkezi Mumbai'de bulunan India Index Services and Products Limited (IISL) tarafından yönetilmektedir (Business News Today: Read Latest Business news, India Business News Live, Share Market & Economy News | The Economic Times t.y.).

1.4.5.2.3 Brezilya (BOVESPA) Endeksi

1817 yılında Sao Paulo kentinde kurulan Brezilya borsası, Brezilya'da zamanla ortaya çıkan çeşitli borsalarla birleşerek günümüze B3 (Brezilya Bolsa Balcão) olarak bilinen büyük bir borsanın oluşmasına zemin hazırlanmıştır. 2017'de BM & FBOVESPA ile menkul kıymetleri saklama ve mali uzlaştırma merkezi (CETIP) birleşerek, dünya standartlarında bir finansal piyasa altyapı şirketi meydana getirilmiştir (Nyasha ve Odhiambo 2020). B3 borsası, Maliye Bakanlığı bünyesinde faaliyet gösteren bir federal kurum olan Menkul Kıymetler ve Borsa Komisyonu (Securities and Exchange

Commission (CVM)) tarafından denetlenmekte ve düzenlenmektedir. B3 borsası Latin Amerika'nın en büyük borsalarından biri konumundadır (São Paulo Stock Exchange, 2023).

1968 yılında oluşturulan IBOVESPA, Brezilya borsasının performansını ölçmek amacıyla en çok işlem gören varlıkların toplam getiri endeksi olarak oluşturulmuştur. Bu endeks, Brezilya Borsası'nda işlem gören en likit varlıkların yaklaşık %80'ini kapsar ve bu varlıkların performansını ölçmek üzere tasarlanmış, geniş kapsamlı bir toplam getiri endeksidir. IBOVESPA, Brezilya borsasının genel durumu ve eğilimlerini yansıtan önemli bir gösterge olarak kabul edilir. Endeks, piyasa değeri ağırlıklı bir endekstir ve endeksin başlangıç değeri 100 baz puan olarak belirlenmiştir. Endeks bileşenleri her dört ayda bir (Ocak, Mayıs ve Eylül aylarında) gözden geçirilerek ve gerekli değişiklikler yapılmaktadır (Ibovespa B3 | B3 2024).

Ibovespa, Brezilya ekonomisinin döngülerine ve küresel ekonomik koşullara bağlı olarak yüksek volatilité gösterebilmektedir. Ibovespa, Brezilya ekonomisinin çeşitli sektörlerini temsil eden 84 hisse senedini içermektedir. Ancak, endeksin kompozisyonunda bazı sektörler daha ağırlıklı olabilmektedir. Örneğin, finans, enerji, madencilik ve tüketim malları sektörleri genellikle endekste önemli bir ağırlığa sahiptir (Bovespa Endeksi Bileşenler – BMFBOVESPA:IBOV Hisse Senetleri 2024).

1.4.5.2.4 Meksika (S&P/BMV IPC) Endeksi

1894 yılında, dönemin önde gelen brokerları tarafından Meksika'nın başkenti Mexico City'de Ulusal Borsa kurulmuştur. Daha sonra, diğer önemli brokerlarla birleşerek Meksika Borsası adını almış ve 1986 yılında 3 kamu ve 8 özel şirketin işlem görmesiyle faaliyetlerine başlamıştır (Grupo BMV, 2024a). Günümüzde, Meksika Borsası, Latin Amerika'nın ikinci büyük borsasıdır ve özel bir kuruluş olan BMV Grubu tarafından yönetilmektedir. Entegre bir borsa olarak hisse senetleri de dahil olmak üzere birçok varlık sınıfının alım satımına olanak tanımakta ve yerel ve uluslararası finans topluluğu için saklama, takas, ödeme hizmetleri ve veri ürünleri sunmaktadır. Meksika Borsası'nda işlem gören 144 halka açık hisse senedi bulunmakta olup, toplam piyasa değeri yaklaşık 530 milyar ABD dolarıdır (SSE 2024).

1978 yılında oluşturulan S&P/BMV IPC endeksi Meksika hisse senedi piyasasının başlıca göstergesi olup, Meksika Borsası'nda işlem gören en büyük ve likit hisse senetlerinin performansını takip eder. Meksika borsasında listelenen en büyük 33 şirketin hisse senetlerini içermektedir ancak bu sayı periyodik aralıklarla yapılan değerlendirmeler sonucu değişebilmektedir (S&P/BMV IPC, 2024). Bu endeks, 2017'de S&P Dow Jones Indices ile ortaklık kurarak uluslararası standartlara uyum sağlamış ve global tanınırlığını artırmıştır (S&P Dow Jones Indices, 2023). S&P/BMV IPC endeksi, piyasa değeri ağırlıklı bir metodoloji kullanmaktadır ve bileşenlerini piyasa kapitalizasyonu, likidite ve sektör temsili kriterlerine göre seçmektedir (SPG 2008) . Endeks, enerji, finans, sağlık, telekomünikasyon, tüketici malları gibi sektörlerden oluşmaktadır ve S&P/BMV IPC endeksi gelişmiş piyasa endekslerine göre daha yüksek volatiliteye sahip olabilmektedir (S&P/BMV IPC Endeksi Bileşenler 2024).

1.4.5.2.5 Endonezya (IDX COMPOSITE) Endeksi

Endonezya' nın başkenti Cakarta' nın eski adı Batavia'da 1912 yılında kurulan Cakarta borsası (JSX) ve Surabaya (SSX) borsasının 2017 yılında birleşmesiyle Endonezya borsası kurulmuştur. Cakarta borsası I. Ve II. Dünya savaşı esnasında kapalı olduğu zaman dilimleri bulunmaktadır. 1952 yılında sadece Endonezya hükümeti tahvili takas edilmektedir. 1956-1977 yıllarında pasif durumda iken 1977 yılında işlemlerine birkaç düzine şirketi listeleterek devam etmektedir. 1988-1992 yıllarında ticaret işlemlerini iyileştirmek için bir takım düzenleyici değişiklikler gerçekleştirmiş, 1995 yılında lanse ettiği otomatik ticaret sayesinde 2002 yılında uzaktan ticareti uygulamaya başladı (IDX 2024). 2020 yılında yayınlanan raporda Endonezya borsasını dünya standartlarına uygun hale getirmek için bir dizi düzenlemeler gerçekleştirilmiştir (Digital Capabilities 2020). Endonezya borsasında 2023 yılı itibarıyla 864 halka açık şirket işlem görmektedir. Endeks bileşenlerinin sayısı son yıllarda artış göstermiştir (IDX Composite 2024).

Jakarta Menkul Kıymetler Borsası Endeksi olarak da bilinen IDX Bileşik Endeksi, Endonezya Menkul Kıymetler Borsası'nda (IDX) işlem gören tüm hisse senetlerinin performansını izlemektedir. IDX Bileşik Endeksi'nin takibi, yatırımcılara Asya'nın en hızlı büyüyen piyasalarından birinin performansını değerlendirme imkânı sunmaktadır.

Diğer gelişmekte olan piyasa endeksleri gibi, IDX Bileşik Endeksi de yüksek volatilité gösterebilmektedir (TradingView 2024a).

1.4.5.2.6 Rusya (MOEX) Endeksi

2011 yılında Rus ticaret sistemi ve Moskova bankalar arası döviz borsasının birleşmesiyle kurulan Moskova borsası (MOEX), Rusya' nın en büyük borsası olma özelliğine sahiptir (MICEX-RTS 2011). MOEX, 2013 yılında halka arz edilmiş ve şirketin 2023 raporuna göre en büyük hissedarları, Rusya merkez bankası, Sberbank, Vnesheconombank ve Avrupa imar ve kalkınma bankasıdır. MOEX' in önemli bir hissesine ise ABD merkezli finans ve bankacılık kuruluşu olan State Street Bank & Trust Company sahiptir (MOEXAnnual 2023). Moskova merkezli borsa, çeşitli finansal varlıkların işlem gördüğü çok yönlü bir platform olarak ticareti kolaylaştırma özelliğine sahiptir. MOEX, menkul kıymetler saklama ve en büyük takas merkezini işletmekte olup, işlem gören hisse senetlerinin piyasa değeri bakımından dünyada ilk 20, türev piyasalar hacmi bakımından dünyada ilk 10 borsa arasında konumlanmaktadır (MOEX 2024). MOEX borsasında 832 halka açık şirket işlemde görmektedir (MOEXExchange 2024). Moskova borsasının bu çok yönlü yapısı, modern finans piyasalarının giderek artan karmaşıklığını ve entegrasyonunu yansıtmaktadır. Borsa, Rusya'nın finansal sisteminde merkezi bir rol oynamakta ve ülkenin ekonomik kalkınmasında önemli bir faktör olmaktadır.

MOEX endeksi Rusya' daki 10 sektörde faaliyet gösteren en büyük ve en likit 50 şirketin hisse senedi performansını izleyen piyasa değeri ağırlıklı ruble bazlı bir bileşik hisse senedi endeksidir (MOEX 2024). Endekste 2024 itibarıyla petrol, doğalgaz, bankacılık, havacılık firmalarını içeren 49 hisse senetleri yer almaktadır (MOEX Components 2024).

1.4.5.2.7 Türkiye (BIST 100) Endeksi

Türkiye tarihinde ilk borsacılık faaliyetleri 1854 Kırım savaşının neden olduğu borçlara istinaden çıkarılan tahviller İstanbul' da alınıp satılmaya başlanılmıştır. 1866 yılında kurulan borsa 1873 yılında Dersaadet Tahvilat Borsası" adını almıştır ancak 1929 Cumhuriyetin kurulmasıyla yapılan düzenlemelerle birlikte İstanbul menkul kıymetler borsası adı altında çalışmaya başlamıştır (IMKB 2024). Bankerlerin, pek çok tasarruf

sahibini büyük zarar uğratması sermaye piyasası kurulu kurularak tüm sermaye piyasasını denetleme yetkisi verilir. 120 yıllık bir dönem kapanarak 1985 de İstanbul menkul kıymetler borsası kurulur. Sembolik olarak satışa çıkarılan Boğaziçi köprüsüne ait gelir ortaklığı senedinin satışıyla ilk gong sesiyle başlayan işlemler 1989 yılında yabancı yatırımcılara her türlü menkul kıymete yatırım yapma ve kar transferi imkanı sağlanmıştır (BIST 2024). 2012 yılında İMKB vadeli işlem ve opsiyon piyasası (VİOP) kurulmasıyla 2013 yılında İMKB, Vadeli işlemler opsiyon borsası ve İstanbul altın borsası “Borsa İstanbul” markası olarak birleşti. Haziran 2024 itibariyle 540 hisse senedinden oluşan Borsa İstanbul’ un piyasa değeri yaklaşık 426 milyar \$ (BİSTİstatistik 2024).

BIST 100 Endeksi, İMKB 100 olarak adlandırılan Türkiye hisse senedi piyasası performansını gösteren endeks 2013 yılında Borsa İstanbul’ un kurulmasıyla XU100 olarak adlandırılmıştır. Piyasa değeri ağırlıklı olan endeks, halka açık en büyük 100 şirketin hisse senedini içermekte ve endeks bileşenleri yılda 4 kez gözden geçirilmektedir. Bankacılık, finans, perakendecilik, enerji ve havayolu gibi sektörleri içermekte olup sektörel ağırlıklar zamanla değişebilmektedir. BIST100 endeksi, yatırımcılar için piyasa performansının ana göstergesi olmaktadır ama gelişmekte olan bir piyasa endeksi olarak siyasi ve ekonomik gelişmelere oldukça duyarlı olması daha yüksek volatilité sahiplik gösterebilmektedir.

1.4.6. Borsa Endeks Tahmininde kullanılan Yöntemler

Finansal piyasaların dinamik yapısı, yatırımcıları ve araştırmacıları, gelecekteki fiyat hareketlerini öngörebilmek amacıyla çeşitli analiz yöntemlerine yönlendirmiştir. Borsa endeksleri, ekonomilerin genel sağlığını ve yatırımcı duyarlılığını yansıtan önemli göstergelerden biri olup, bu endekslerin doğru bir şekilde tahmin edilmesi, finansal karar alma süreçlerinde kritik bir rol oynamaktadır. Geçmiş veriler, makroekonomik göstergeler ve piyasa trendleri, endeks tahminlerinde kullanılan çok çeşitli yöntemlerin temelini oluşturmaktadır. Bu kapsamda hem geleneksel analiz yaklaşımları hem de modern makine öğrenmesi teknikleri, endekslerin gelecekteki performansını öngörmek için kullanılmaktadır. Aşağıdaki kısımda borsa endeks tahmininde yaygın olarak başvurulmuş yöntemler ve bu yöntemlerin öne çıkan özellikleri ele alınacaktır.

1.4.6.1 Temel Analiz

Temel analiz, bir firmanın halka açık finansal tabloları ve finansal performansına yansiyabilecek diğer önemli bilgiler ışığında, firmanın gerçek değerinin belirlenmesini amaçlar. Bu analizde, yatırımcıların en çok üzerinde durduğu hususlardan biri, firmanın piyasa değerine yansıyan menkul kıymet fiyatının, firmanın gerçek değeri ile ne ölçüde örtüştüğünü tespit etmektir. Gerçek değer, firmanın finansal varlıklarından beklenen dönemsel net nakit akışlarının, pazar riskleri ve firmaya özgü riskler dikkate alınarak belirlenen iskonto oranı ile bugünkü değere indirgenmesi sonucu elde edilen değerler toplamına eşit olacaktır (Canbaş & Doğukanlı, 1997, s.350).

Temel analiz, firmanın halka açık tüm bilgilerine, finansal tablolara ve ilgili değerlendirmelere dayanmaktadır. Firmanın durumunu değerlendirirken yalnızca firma ile ilgili özel bilgiler değil, aynı zamanda ekonomi, uluslararası, ulusal ve bölgesel olaylar gibi daha geniş kapsamlı faktörler de dikkate alınmaktadır. Firmanın gelecekteki performansına ilişkin beklentiler büyük ölçüde makroekonomik gelişmelerin etkisi altında şekillenmektedir. Dolayısıyla, firma ile ilgili bilgilerin önemli bir kısmı ekonomik ve sektörel gelişmelerle ilişkilidir ve bu nedenle temel analiz genellikle üç ana aşamada gerçekleştirilir. Bunlar;

- Ekonomik Analiz
- Sektör Analizi
- Firma Analizi.

Başarılı bir temel analiz süreci, öncelikle ekonominin, ardından sektörün ve en sonunda firmanın değerlendirilmesini içerir. Bu yaklaşım genellikle yukarıdan aşağıya doğru analiz (Top-Down Analysis) olarak adlandırılmaktadır. Bazı durumlarda ise analiz doğrudan firmadan başlatılabilir (Down-Top Analysis), ancak bu yöntem genellikle firmanın durumu diğer faktörlere göre çok daha kritik olduğunda tercih edilmektedir ve bu durum nadiren görülür. Ekonomik analiz, firmanın pazarla ilgili (sistemik) risklerini değerlendirirken, sektör ve firma analizleri daha çok firma ile ilgili (sistemik olmayan) riskleri ele almaktadır (Karan, 2021, s. 471).

Ülke ekonomileri, sürekli değişen dinamiklere sahiptir ve bu değişimler, ekonomik faaliyetler üzerinde önemli etkiler yaratmaktadır. Örneğin, enflasyon

oranlarındaki artış ya da düşüşler, faiz oranlarındaki değişimlerle birlikte hem şirketlerin değerlemeleri hem de şirketlerin gelecekteki stratejik kararlarını doğrudan etkileyebilmektedir. Bu kapsamda, bir firmanın gerçek değerine ulaşabilmek ve gelecekteki performansını doğru bir şekilde tahmin edebilmek için ekonomik faktörlerin analiz edilmesi büyük bir önem taşımaktadır. Bu nedenle, temel analizin ilk aşaması ekonomik analiz olup, ülkenin makroekonomik durumu, büyüme oranları, işsizlik, faiz ve enflasyon gibi değişkenlerin derinlemesine incelenmesini içerir. Bu analiz, firmanın faaliyet gösterdiği genel ekonomik ortamı anlamak ve gelecekte karşılaşacağı riskler ile fırsatları değerlendirmek açısından kritik bir rol oynamaktadır.

Ekonomik analizden sonra gelen ikinci aşama ise sektör analizidir. Her sektör, ekonomide farklı hızlarda büyüme ve gelişim gösterebilmektedir. Kimi sektörler inovasyon, talep artışı veya teknoloji gelişimi gibi faktörler nedeniyle hızlı bir büyüme kaydederken, bazı sektörler daha yavaş ve durağan bir büyüme sergileyebilmektedir. Sektörlerin büyüme potansiyeli, rekabet yapısı ve genel ekonomik koşullara duyarlılığı gibi unsurlar, yatırımcılar açısından önemli değerlendirme kriterleri olarak ifade edilebilmektedir. Ayrıca, her sektörün genel ekonomik konjonktürden farklı derecelerde etkilenmesi, sektör bazlı stratejik analizlerin yapılmasını gerekli kılmaktadır. Bu farklılıklar, yatırım kararları açısından kritik öneme sahiptir ve şirketin performansı üzerinde doğrudan etkili olabilmektedir. Dolayısıyla, sektörel dinamiklerin detaylı bir şekilde analiz edilmesi, doğru yatırım kararlarının alınabilmesinde önem arz etmektedir (Doğan, 2006).

İlk iki aşamada gerçekleştirilen ekonomik ve sektörel analizlerin ardından, temel analiz sürecinin üçüncü aşaması ise firma analizidir. Firma analizi, iki aşamalı olarak gerçekleştirilmektedir: Birinci aşamada, şirketin yönetim yapısı, ürün veya hizmet çeşitliliği gibi unsurlar ele alınmaktadır. Bu aşamada, yönetim stratejileri, rekabet avantajı ve operasyonel etkinlik gibi faktörler değerlendirilmektedir. İkinci aşama ise, finansal tablolara dayalı bir analizdir. Bu aşamada, gelir tablosu, bilanço gibi mali veriler incelenerek, şirketin gerçek değeri belirlenmeye çalışılmaktadır (Edward, Magee, Bassetti, 2018, s.3).

1.4.6.2 Teknik Analiz

Dow Teorisi temeline dayanan Teknik analiz ilk olarak Amerika Birleşik Devletleri'nde ortaya çıkmıştır. Teknik analiz, finansal piyasalarda geçmiş fiyat hareketleri, işlem hacimleri ve çeşitli türetilmiş göstergeleri kullanarak gelecekteki fiyat hareketlerini öngörmeye yönelik sistematik bir yaklaşımdır. Bu yöntem, piyasa davranışının belirli kalıplar ve trendler izlediği ve geçmiş piyasa verilerinin gelecekteki hareketleri tahmin etmede kullanılabileceği varsayımına dayanmaktadır. Temel ekonomik faktörler yerine piyasa verilerine odaklanan bu metodoloji, hisse senetlerinin değerlemesi ve gelecekteki fiyat hareketlerinin tahmini konusunda kendine özgü bir perspektif sunmaktadır. Şirketlerin mali tabloları ve finansal verileri, teknik analizde ikincil bir rol oynar. Bu yaklaşım, finansal raporların bilgi asimetrisine yol açabileceği ve piyasa etkinliğini tam olarak yansıtmayabileceği varsayımını temel almaktadır (Karşlı, 2004, s.493). Teknik analizin en temel unsuru grafiklerdir. Grafikler, piyasa fiyatlarındaki değişimlerin belirli bir zaman dilimi içinde ve işlem hacmiyle birlikte görselleştirilmesini sağlamaktadır. Fiyat hareketleri grafiklerde net bir şekilde gözlemlenebilir ve bu grafikler, matematiksel işlemler ve analizler yapılırken önemli bir referans olarak kullanılmaktadır (Edwards, Magee, Bassetti., 2018, s.4). Teknik analistler, bu nedenle, analizlerini piyasadan doğrudan elde edilebilen fiyat ve işlem hacmi gibi kantitatif ve objektif verilere dayandırır. Bu yöntem, piyasanın mikro yapısını ve anlık dinamiklerini yansıtan verilere odaklanarak, daha güncel ve potansiyel olarak daha az manipüle edilmiş bilgilerle çalışmayı amaçlar. Francis 'e göre teknik analiz, belirli temel varsayımlara dayanır:

1. Piyasa değeri, yalnızca arz ve talebin etkileşimi sonucunda belirlenir.
2. Arz ve talep, irrasyonel faktörlerin etkisi altında kalabilir.
3. Hisse senedi fiyatları, küçük dalgalanmalar haricinde belirli trendler doğrultusunda hareket eder.
4. Arz ve talepteki değişimler, trendlerin yön değiştirmesine neden olur ve bu değişimler grafiklerde gözlemlenebilir.

5. Belirli grafikler tekrar eden eğilimler sergiler ve bu eğilimler, fiyat tahminlerinde kullanılabilir (Francis, 1988, s.581).

Teknik analizde, esas olarak iki ana araç grubu kullanılır: destek ve direnç seviyeleri, işlem hacmi, baş ve omuz formasyonu, çubuk grafik, mum grafik, nokta ve şekil grafikler gibi teknik formasyonlar ve hareketli ortalamalar, nispi güç analizi, fiyatı artan ve azalanlar, güven endeksi, açığa satış oranı ve lot altı işlemleri teorisi gibi teknik göstergeler. Bu araçlar, piyasa davranışlarını analiz ederek gelecekteki fiyat hareketlerini öngörmeye yardımcı olmaktadır. (Dağlı, 2009, s.259-282).

1.4.6.3 Matematiksel ve İstatistiksel Yöntemler

Son yıllarda hızla gelişen zaman serileri analizi, özellikle gelecekteki olayları öngörmeye yönelik olarak giderek daha fazla kullanılmaktadır. Bu teknikler sayesinde, bir serinin tahmin dönemi dışındaki gelecekteki davranışları belirlenmeye çalışılır. Geleneksel zaman serisi analizi, geçmiş verileri inceleyerek, bu verilerin doğrusal kombinasyonları aracılığıyla gelecekteki olası değerleri tahmin etmeye odaklanmaktadır. Esas olarak temelde , bir değişkenin doğrusal olmayan değerlerinin sürekli olarak geçmiş değerleriyle ilişkilendirilerek bir model oluşturulması hedeflenmektedir (Bozkurt, 2007, s.7).

Zaman serilerinin analizinde kullanılan matematiksel ve istatistiksel yöntemler, finansal verilerin incelenmesi ve modellenmesinde gelecekteki değerlerin tahmin edilmesinde kullanılan temel araçlardır. Bu yöntemler, karmaşık finansal piyasa verilerindeki gizli örüntüleri ve ilişkileri ortaya çıkarmada, gelecekteki olası sonuçları öngörmede ve risk-getiri dinamiklerini anlamada kritik öneme sahiptir. Bu süreçte, veri setinin merkezi eğilimleri (ortalama, medyan), dağılım ölçüleri (standart sapma, varyans), korelasyon, regresyon, otoregresyon hareketli ortalama (ARMA) ve oto-regresyon entegreli hareketli ortalama (ARIMA), analizleri gibi yöntemler kullanılmaktadır (Sezer 2018).

1.4.6.4 Makine Öğrenme Yöntemleri

Makine öğrenmesi, bir makinenin belirli bir görev için önceden belirlenmiş talimatlar yerine, örüntü tanıma ve durumsal çıkarım yapma yeteneğine dayanarak

öğrenmesini sağlayan bir yapay zeka dalıdır (Coen, 2020, s.12). İnsanların karar verme süreçlerine benzer şekilde, makinelerde geçmiş deneyimlerden yola çıkarak gelecekteki sonuçları tahmin edebilmektedir.

Zaman serisi verilerinin analizinde, geleneksel yaklaşımların yanı sıra makine öğrenmesi yöntemleri de giderek daha fazla kullanılmaktadır. Makine öğrenme algoritmaları, geleneksel modellere bağımlı kalmaksızın yeni modellerin dinamik olarak oluşturulmasına olanak tanır. Bu yeni modeller sayesinde, veriler üzerinde ikili ya da çoklu sınıflandırmalar yapılabilir ve aynı zamanda gelecekteki veri değerleri tahmin edilebilir. Makine öğrenme türleri temel olarak üç ana kategoriye ayrılmaktadır: gözetimli öğrenme (supervised learning), gözetimsiz öğrenme (unsupervised learning) ve pekiştirmeli öğrenme (reinforcement learning). İlgili öğrenme türlerine ilişkin detaylı bilgiye ilerleyen bölümlerde yer verilecektir.

Zaman serileri analizinde, geleneksel istatistiksel modellerden farklı olarak, makine öğrenmesi, belirli bir süreç veya kural önerme gereksinimi olmaksızın verilerdeki desenleri tanımaya odaklanmaktadır (Nielsen, 2019, s.259-260). Geleneksel istatistiksel modeller, genellikle verilerin doğrusal bir yapıya sahip olduğunu varsayar ve bu nedenle doğrusal ilişkilerin modellenmesi üzerine kuruludur. Buna karşılık, makine öğrenmesi algoritmaları, daha esnek bir yapıya sahip olup doğrusal olmayan ilişkileri de etkin bir şekilde modelleme yeteneğine sahiptir (Sezer 2018). Bu esneklik, özellikle finansal piyasalarda makine öğrenme yöntemlerinin tercih edilmesinin temel nedenlerinden biridir. Finansal piyasalar, doğası gereği karmaşık ve dinamik yapılar sergilemekte olup, bu yapıların gelecekteki değerlerini tahmin etmek büyük bir ilgi konusu olmaktadır. Makine öğrenmesi, bu karmaşık yapıları anlamak ve gelecekteki eğilimleri tahmin etmek için güçlü bir araç olarak öne çıkmaktadır, bu da finansal analizlerde yaygın olarak kullanılmasını sağlamaktadır.

2. BÖLÜM:YAPAY ZEKA, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME

Finansal piyasalarda borsa endekslerinin tahmini, son yıllarda yapay zekâ ve veri bilimi alanlarında gerçekleşen yenilikçi gelişmelerle önemli bir yöntem değişikliği yaşamıştır. Geleneksel istatistiksel yöntemlerin, özellikle karmaşık ve doğrusal olmayan veri yapılarının tam anlamıyla modellenmesinde yetersiz kalması, yapay zekâ ve makine öğrenmesi gibi modern tekniklerin finansal analizlerde giderek daha fazla tercih edilmesine yol açmıştır. Bu yöntemler, büyük veri setlerinin işlenmesi ve veri örüntülerinin daha derinlemesine analiz edilmesi konusunda önemli avantajlar sunmaktadır. Özellikle derin öğrenme modelleri, zaman serisi verilerinde karmaşık kalıpları tanıma konusundaki üstün performansı ile öne çıkmakta ve daha yüksek doğrulukta tahminler üretebilme kapasitesine sahip bulunmaktadır.

Bu bölümde, borsa endeks tahmininde giderek artan bir şekilde uygulama bulan derin öğrenme teknikleri incelenirken, bu modellerin temel aldığı yapay zekâ ve makine öğrenmesi kavramlarına da geniş bir perspektiften yer verilecektir. Öncelikle, yapay zeka kavramı ve gelişimi ile çeşitli yaklaşımları üzerinde durulacak, ardından yapay zekanın finans alanındaki uygulamalarına yer verilecek daha sonra makine öğrenme sürecinin genel çerçevesi çizilecektir. Son olarak, derin öğrenme kavramı, algoritmalarının yapısı ve mimarileri, yapay zeka ve makine öğrenmesi çerçevesinde ele alınarak kapsamlı bir şekilde değerlendirilecektir.

2.1 YAPAY ZEKA KAVRAMI VE GELİŞİMİ

Yapay Zeka (YZ), akıllı makineler yaratmak amacıyla yapay teknolojiler aracılığıyla insan zekasını kopyalamayı ve geliştirmeyi hedefleyen bir çalışma alanıdır (Russell & Norvig, 2016; Zhongzhi, 2019, s.9). YZ alanında farklı görüşler bulunmaktadır; bazı araştırmacılar, YZ' nin rasyonel bir şekilde hareket edebilmesi ve düşünebilmesi gerektiğini savunurken, diğerleri bu yeteneklerin insan benzeri düşünme ve hareket etme kapasitesini vurgulamaktadır (Russell ve Norvig 2016).

Yapay zekanın temel amacı, insan benzeri düşünme yetisine sahip veya akıllı davranışlar sergileyebilen otonom sistemler ve robotlar geliştirmektir. Yapay zekânın temel hedefi, insan zekâsının bilişsel süreçlerini taklit ederek karmaşık sorunları

çözebilme, beklenmedik durumlara hızlı uyum sağlama, büyük ve karmaşık veri kümelerini anlamlandırma, mantıksal akıl yürütme ve geçmiş deneyimlerden öğrenme gibi yetkinlikleri otomatik hale getirebilen sistemler oluşturmaktır (Steels 1993). Bu kapsamda, yapay zeka çalışmaları, sadece hesaplamaya dayalı ya da mekanik süreçlerden ibaret olmayıp, öğrenen, gelişen ve adepte olabilen dinamik modeller geliştirme amacı taşımaktadır.

Yapay zekanın bir diğer amacı, insanların sahip olduğu üst düzey bilişsel işlevleri ve otonom davranışları taklit edebilen sistemler geliştirmek olarak öne çıkmaktadır. Bu kapsamda geliştirilen ya da tasarlanan bir yapay zeka sistemleri insan gibi düşünebilmeli, bu düşüncelere dayalı mantıklı tepkiler verebilmeli ve fiziksel çıktılar üretebilmelidir (Negnevitsky 2004)

Günümüzde yapay zekâ, yalnızca insan davranışlarını simüle eden bir teknoloji olmanın ötesine geçerek birçok sektörde karar destek mekanizmalarının temel bir unsuru hâline gelmiştir. Yapay zekânın sağlamış olduğu öğrenme ve adaptasyon yetenekleri, özellikle büyük veri analizi ve otomatik karar alma süreçlerinde önemli avantajlar sağlamaktadır.


YZ' nin kökenleri, son elli yıldır araştırılan bu genç alanın ötesinde, daha köklü bilimsel ve felsefi disiplinlere dayanmaktadır. Bu disiplinler arasında felsefe (akıl, mantık ve zihin fikirleri), matematik (mantık, tümdengelim ve tümevarım, olasılık, karar verme ve hesaplama teorileri), psikoloji, dilbilim ve bilgisayar bilimi yer almaktadır (Russel ve Norving 2010)

YZ' nin gelişiminde temel taşlardan biri, Alan Turing'in (1912-1954) 1937'de tanıttığı Turing Makinesi (ideal bir akıllı bilgisayar modeli) ve otomata teorisinin geliştirilmesidir. Yapay Zeka araştırmalarının ilk önemli adımlarından biri, Walter Pitts ve Warren McCulloch'un (1943) MP nöronunu geliştirdiği çalışmadır, bu çalışma yapay sinir ağları araştırmalarının başlangıcını oluşturmuştur (Russel ve Norving 2010; Zhongzhi 2019). O zamandan beri, araştırmacılar insan beyninin işleyişini taklit edebilecek bir “düşünme makinesi” yaratmayı amaçlamışlardır.

Alan Turing, makinelerin zekâ düzeyini değerlendirmek için 1950 yılında Turing Testi' ni önermiştir. Turing Testi, bir makinenin tüm bilişsel görevlerde insan seviyesinde

performans sergileyip sergilemediğini belirlemek için geliştirilmiştir. Eğer bir makine, bir insan ile yapılan bir iletişimde insan değil de makine olduğunu ayırt edemiyorsa, yani insan düşünme ve bilgi işleme kapasitesine sahip olduğunu gösteriyorsa, bu testi geçer (Russell ve Norvig, 2016, s.2-6). Bu test, makinenin bilgiyi saklama, bu bilgiyi sorulara yanıt vermek ve yeni sonuçlar çıkarmak için kullanma, yeni bağlamlara uyum sağlama, kalıpları belirleme ve tahmin yapma yeteneklerini değerlendirmektedir.

Yapay Zeka araştırmaları üç önemli döneme ayrılır. İlk dalga, bilgisayarların sınırlı işlem gücü nedeniyle duraklamıştır. İkinci dalga, 1980'lerde yapay sinir ağlarının ve makine öğrenme sistemlerinin gelişmesiyle başlamış, bu süreçte bilgisayarların hesaplama kapasitesi de artmıştır (Zhongzhi, 2019, s.299). Şu anda, derin öğrenme ile yönlendirilen üçüncü dalga yaşanmaktadır. Yapay zekânın geçirdiği evreler ve bu süreçlerle birlikte ortaya çıkan makine öğrenmesi ve derin öğrenme kavramlarının konumu, Şekil 2.1'de görselleştirilmiştir.



Şekil 2.1. Yapay Zeka Süreçleri ve Konumu

(Copeland 2016)

Yapay zekâ, makine öğrenmesi, yapay sinir ağları ve derin öğrenme, son yıllarda hem akademik hem de endüstriyel alanlarda sıkça kullanılan ve popüler hale gelen kavramlardır. Bu terimler çoğunlukla aynı doğrultuda kullanılsa da aralarında önemli

farklılıklar mevcuttur. Derin öğrenmenin önceki YZ yöntemlerinden en büyük farkı, sistemin insan müdahalesi olmadan kendi kendini eğitebilmesidir. Eski yapay zekâ sistemleri programcılar tarafından eğitilirken, derin öğrenme kendi kendine öğrenmektedir. Günümüzde yapay zeka en çok sinir ağları ve makine öğrenmesi aracılığıyla uygulanmakta olup, konuşma tanıma, doğal dil işleme, görüntü tanıma ve otonom sürüş gibi alanlarda yaygın olarak kullanılmaktadır (Pannu 2015). Çalışmanın ilerleyen bölümlerinde bu kavramlara ve bu kavramların birbiriyle olan ilişkisine detaylı olarak değinilecektir.

2.2 YAPAY ZEKA YAKLAŞIMLARI

YZ araştırmaları ilk olarak insan zihnini taklit eden ve “insan gibi düşünme” yaklaşımına göre çalışan programlar geliştirmeye odaklı iken ilerleyen yıllarda, mantık temelli yaklaşımlar ön plana çıkmış ve çalışmalar “rasyonel karar veren sistemler” oluşturmayı hedeflemişlerdir. Genel olarak yapay zekâ yaklaşımı olarak dört temel yaklaşım öne çıkmaktadır: İnsan gibi düşünme (Bilişsel Modelleme), İnsan gibi davranma (Turing Testi), Rasyonel düşünme (Düşünce Kanunları) ve Rasyonel davranma (Zeki Ajanlar) (Russel & ve Norving, 2010, s.2).

2.2.1. İnsan Gibi Düşünme (Bilişsel Modelleme) Yaklaşımı

Bir bilgisayar programının insan benzeri düşünme yeteneğine sahip olduğunu iddia edebilmek için, düşünme sürecinin nasıl gerçekleştiğinin bilinmesi gerekmektedir. İnsan zihninin işleyişi, psikolojik deneyler aracılığıyla incelenebilir ve bu deneylerden elde edilen bulgular teorik bir çerçeveye dönüştürülerek bilgisayar programlarına uyarlanabilir. Eğer geliştirilen programın girdi ve çıktılarına karşılık gelen tepkiler, insan davranışları ile örtüşüyorsa, bu durum programın belirli mekanizmalarının insan beynine benzer şekilde çalıştığının kanıtı olarak ifade edilebilir. İnsan gibi düşünen sistemler, bilişsel bilim alanındaki araştırmalar sonucunda ortaya konmuştur. Bilişsel bilim, insan zihninin kesin ve test edilebilir teorilerini oluşturmak amacıyla, yapay zekâ tabanlı bilgisayar modellerini ve psikolojik deney tekniklerini bir araya getiren bir yaklaşımdır (Russel ve Norving, 2010, s.4)

2.2.2. İnsan Gibi Davranma (Turing Testi) Yaklaşımı

Yapay zekâ araştırmalarında en temel sorulardan biri, bir makinenin gerçekten zeki olup olmadığının nasıl anlaşılacağıdır. Bu soruya yanıt arayan en önemli yaklaşımlardan biri İnsan Gibi Davranma Yaklaşımı, diğer adıyla Turing Testi Yaklaşımıdır. 1950 yılında Alan M. Turing tarafından geliştirilen ve ilk olarak "Computing Machinery and Intelligence" adlı makalesinde ortaya koyulan bu test, bir makinenin insan gibi düşünme yetisini değil, insan benzeri davranışlar sergileyerek karşısındaki insanı kandırabilme kapasitesini değerlendirmeye odaklanmaktadır. Turing Testi, kapalı bir odada bulunan bir insan değerlendiricinin, yalnızca metin tabanlı iletişim yoluyla karşısındaki varlığın insan mı yoksa makine mi olduğunu anlamaya çalıştığı bir düzene dayanmaktadır. Doğal dil işleme, makine öğrenmesi ve bilgi işleme gibi alanlarda yaşanan gelişmeler sayesinde makinelerin Turing Testi'ni geçme olasılığı artmış ve nihayetinde 2014 yılında gerçekleştirilen bir denemede, Eugene Goostman adlı yapay zekâ programı, testi geçen ilk sistem olmuştur (Berglas, 2015, s.42).

2.2.3. Rasyonel Düşünme (Düşünce Kanunları) Yaklaşımı

Rasyonel düşünme, mantıksal akıl yürütme yoluyla bilgiye ulaşmayı amaçlayan bir düşünce sistemidir. Bu yaklaşım, Antik Yunan'dan günümüze kadar felsefe ve bilim tarihinde önemli bir yer tutmaktadır. Antik Yunan düşünürü Aristoteles, "doğru düşünceyi" kodlamayı amaçlayan ilk kişilerden biriydi. Aristoteles'in felsefesinde düşünce, bir süreçten ibaret olarak ele alınmıştır. Bu süreç, akıl yürütme mantığına dayanmaktadır. Yapay zeka, rasyonel düşünme kapsamında, yapılan hesaplamaları analiz eden, akıl yürüten ve belirli bir amaca yönelik olarak harekete geçebilen bir model olarak ele alınmaktadır. Bu yaklaşım, yapay zekanın yalnızca verileri işleyip sonuç üretmekle kalmayıp, aynı zamanda akılcı çıkarımlar yaparak karar mekanizmalarını yönlendirebileceğini öne sürmektedir. Rasyonel düşünme temelli yapay zeka sistemleri, belirli bir hedef doğrultusunda en uygun kararları almak için bilgi işleme, mantıksal çıkarım yapma ve bu çıkarımlara dayalı olarak harekete geçme süreçlerini kullanır (Russel ve Norving, 2010, s.4).

2.2.4. Rasyonel Davranma (Zeki Ajan) Yaklaşımı

Zeki Ajan Yaklaşımı, yapay zekanın belirli bir hedef doğrultusunda en uygun eylemleri seçerek çevresiyle etkileşime giren otonom sistemler olarak ele alındığı bir yaklaşımdır. Her bilgisayar programı belirli görevleri yerine getirebilir, ancak zeki ajanlardan yalnızca işlem yapmaları değil, aynı zamanda çevresel değişkenleri algılayarak uyum sağlamaları ve karmaşık problemlere çözüm üretebilmeleri beklenir. Bu doğrultuda, bir zeki ajan, çevresini algılayan (sensörler veya veri girişleri aracılığıyla), bu algılara dayanarak rasyonel davranış sergileyen ve değişen koşullara adapte olarak en uygun eylemi gerçekleştiren bir sistem olarak tanımlanır (Steels 1993).

Rasyonel davranış yaklaşımı, diğer yaklaşımlara kıyasla iki önemli avantaja sahiptir. İlk olarak, "düşünce yasaları" yaklaşımına göre rasyonelliği sağlamak için daha genel ve esnek mekanizmalar sunmaktadır. Bu, yapay zeka sistemlerinin farklı problem alanlarında uyum sağlayabilmesini ve çeşitli durumlarda etkili kararlar alabilmesini kolaylaştırmaktadır. İkinci olarak ise, bu yaklaşım, insan davranışına veya insan düşüncesine dayalı modellerden daha çok bilimsel gelişime ve teknolojik ilerlemeye uygundur (Russel ve Norving, 2010, s.4).

2.3 FİNANS ALANINDA YAPAY ZEKA UYGULAMALARI

Son yıllarda, Yapay zekâ finans alanında birçok formda kullanılmaktadır. Yapay zekâ önemli ilerlemeler kaydederek insan sermayesini kısmen veya tamamen ikame etmekle kalmayıp, aynı zamanda performansı insanın sınırlarının ötesine taşıyabileceği gözlemlenmektedir. Aşağıda, YZ' nin bazı uygulamaları incelenecektir.

2.3.1. Metin Madenciliği ve Ses Tanıma

Yapay zeka metin ve insan konuşmalarını analiz etmek ve analize dayalı çıktı üretmek için kullanılmaktadır. Japon finans kuruluşları çağrı merkezlerinde IBM tarafından geliştirilen ileri düzeyde bir yapay zeka aracı olan Watson'ı kullanmaktadır (Kashiwagi 2015). Ülkemizde ise birçok banka çağrı merkezlerinde yapay zekâ araçlarını kullanarak iş gücü ve zamandan tasarruf etmektedir. Bunlara ek olarak finans kuruluşları kurumsal açıklamalar, haber ve sosyal medya içerikleri gibi metinsel bilgileri otomatik

olarak analiz etmek ve bunlar hakkında raporlar üretmek için yapay zekâ araçları kullanılmaktadır.

2.3.2. Anomali Tespiti

Anomali tespitinde YZ kullanılmaktadır; desen tanıma teknikleri, standart davranışlardan sapmaları belirlemek için uygulanır. Bu yetenek, kara para aklama, güvenlik açıkları, yasa dışı finansal planlar ve yasadışı işlemler gibi faaliyetlerin tespitinde kritik bir rol oynar ve anomali bulunduğu otomatik uyarılar vermektedir. (Kashiwagi 2015). Bu teknolojiyi kullanan önde gelen şirketlerden biri olan MasterCard, 2016 yılının sonunda "Decision Intelligence" hizmetini tanıtmıştır. Bu hizmet, sahtekarlık tespiti amacıyla yapay zekâyı kullanarak, müşterilerin alışveriş davranışlarını, alışverişlerin yapıldığı yerleri, zaman dilimlerini, alışverişlerin tipik fiyat aralıklarını ve diğer faktörleri analiz eden algoritmalarla normal ve anormal davranışları tespit etmektedir. Bu sayede, sistem olağandışı bir faaliyet tespit ettiğinde hızlıca hesap hareketlerini durdurup, daha fazla doğrulama yapılana kadar hesabı bloke edebilmektedir (MasterCard 2016).

2.3.3. Portföy Yönetimi ve Danışmanlık

Yapay zeka, optimal yatırım stratejilerinin geliştirilmesinde yaygın olarak kullanılmaktadır. Son yıllarda, bireysel yatırımcılara otomatik portföy yönetimi tavsiyeleri sunan robo-danışmanlık hizmetlerine yönelik artan bir ilgi gözlemlenmektedir (Kashiwagi 2015). YZ hizmetleri, genellikle daha düşük ücretler talep ederken, geleneksel insan danışmanlarıyla en az eşdeğer, hatta bazen daha üstün performans sağlayabilmektedir. Bazı şirketler, yapay zekâ kullanarak, otomatik optimal portföy seçimi, otomatik dengeleme ve varlık tahsisi gibi hizmetler sunan modeller ve analizler geliştirmektedir (Betterment 2024).

2.3.4. Piyasa Duygu ve Haber Analizi

Yapay zekâ uygulamaları, piyasa duyarlılığı analizinde de kullanılmaktadır ve bu, genellikle metin madenciliğinin bir alt kümesi olarak değerlendirilmektedir. Sosyal medya platformlarının hızla gelişmesi ve büyük veri

havuzlarının oluşması ile piyasa duyarlılığı analizine olan ilgi artmıştır. İnternet ve sosyal medya üzerindeki insan etkileşimlerinden kaynaklanan bu artan "büyük veri" yığını, piyasa katılımcılarının davranışlarını araştırmak için yeni fırsatlar sunmaktadır. Örneğin, sosyal medya içeriklerinin yapılan duygu analizleri, çeşitli seçimlerde sonuçların tahmin doğruluğunu artırdığını tespit etmişlerdir (Ceron, Curini, ve Iacus 2015). Belirli bir konuya yönelik çevrimiçi aramaların ekonomik faaliyetlerle ilişkisi olduğunu tespit edilmiştir (Moat vd. 2013; Preis, Moat, ve Stanley 2013).

2.3.5. Algoritmik Al-Sat

Algoritmik ticaret, piyasa koşullarındaki değişiklikler ve fiyat seviyeleri hakkındaki bilgileri birleştirerek çok hızlı otomatik işlemler gerçekleştiren özel algoritmalara dayanan sistemlerdir. Bu işlemler genellikle o kadar hızlı gerçekleştirilir ki, "yüksek frekanslı ticaret" terimi bu durumu tanımlamak için kullanılmaktadır. İnsanların bu kadar kısa bir sürede bilgiyi işleyememesi, bu alanda algoritmalara karşı dezavantajlı olmalarına yol açmaktadır.

Yapay zekâyı başarıyla uygulayan ve algoritmik ticaret gerçekleştiren şirketler arasında Renaissance Technologies ve Bank of America bulunmaktadır (Bank of America 2024; Renaissance Technologies 2024). Değişen piyasa koşullarına uyum sağlamak ve ticareti uygulamak için gelişmiş ticaret modellerinde yapay zekâ kullanılmaktadırlar.

Makine öğrenimi yöntemleri, derin öğrenme ve görüntü tanıma teknolojileri kullanılarak tahmin modelleri ve yatırım stratejileri için veri taraması yapılabilmektedir.

2.3.6. Kredi Değerlendirilmesinde YZ Kullanımı

Kredi değerlendirmesi YZ' nin başarılı olduğu alanlardan bir tanesi olarak gösterilmektedir. Kredi riski analizi, kredi derecelendirmesi ve puanlaması, tahvil derecelendirmesi gibi süreçleri kapsamaktadır. Yapay sinir ağlarının (YSA) kredi değerlendirmesi ve iflas tahmini konularında daha yüksek doğruluk oranları sağladığını gözlemlenmiştir (Bahrammirzaee 2010).

ZestFinance şirketi, geniş veri noktaları kullanarak kredi analizindeki önyargıları ortadan kaldıran ZAML (Zest Automated Machine Learning) adlı makine öğrenimi

sistemini geliřtirmiřtir. Bu sistem, geleneksel yntemlerin aksine daha doęru kredi deęerlendirmeleri yaparken, zellikle kredi gemiři olmayan ge borluların tespit edilmesine de yardımcı olmaktadır.

2.3.7. Zaman Serisi Tahmini ve Analizi

Makine ęrenmesi ve derin ęrenme teknikleri, finansal piyasalardaki zaman serisi verilerini analiz etmekte gl aralar sunmaktadır. Bu yapay zekâ yntemleri, karmařık tarihsel veri setlerini iřleyerek, gelecekteki fiyat hareketlerini tahmin etmek iin etkili modeller oluřturabilmektedir. Makine ęrenimi ve derin ęrenme algoritmaları, hisse senedi fiyatları, emtia fiyatları, dviz kurları, kripto para fiyatları, tahvil getirilerini tahmin edebilmekte yatırımcı iin davranıřlarına katkıda bulunmaktadır.

2.3.8. Hedge Fon Stratejileri

Hedge fonlar, yksek net deęere sahip bireysel yatırımcılar veya kurumsal yatırımcılar iin ynetilen zel yatırım araları olarak tanımlanmaktadır. Hedge fonlar, geleneksel yatırım fonlarından farklı olarak, daha agresif ve eřitlendirilmiř stratejiler kullanarak yksek getiri hedefler. Bu fonlar, basit alım-satım iřlemlerinin tesine geerek, arbitraj, trev rnler, alternatif yatırımlar ve kaldıra kullanımı gibi karmařık yntemleri bir arada uygulamaktadırlar (Korkmaz & Ceylan, 2006, s.166).

Makine ęrenmesi ve derin ęrenme, hedge fonlar iin byk veri yıęınlarını analiz ederek gelecekteki fiyat hareketlerini tahmin etmek, riskleri minimize etmek ve ticaret stratejilerini optimize etmek iin kullanılmaktadır. Makine ęrenmesi ve derin ęrenme algoritmaları, verilerdeki gizli iliřkileri ve kalıpları tespit ederek, fon yneticilerine daha bilinli yatırım kararları sunar.

2.4 MAKİNE ęRENMESİ

Derin ęrenme zel bir makine ęrenmesi trdr. Bu nedenle derin ęrenmeyi anlamak iin ncelikle makine ęrenmesinin ve bunun temel prensiplerinin doęru bir řekilde kavranması gerekmektedir. alıřma kapsamında derin ęrenmeye temel oluřturacak dzeyde makine ęrenmesi hakkında genel bilgi verilecektir.

Makine öğrenmesi, "örnek veriler veya geçmiş deneyimleri kullanarak bir performans kriterini optimize etmek üzere bilgisayarları programlama" olarak tanımlanmaktadır (Alpaydın, 2010, s.1-4). Makine öğrenimi, bilgisayar sistemlerinin açık talimatlar olmaksızın deneyimlerden öğrenme ve performanslarını iyileştirme yeteneği kazandıkları bir araştırma alanıdır (Samuel 1959). Bu alan, algoritmaların veri üzerinde çalışarak örüntüleri tespit etmesine, bu örüntülerden çıkarımlar yapmasına ve gelecekteki benzer durumlarda bu öğrenilmiş bilgiyi kullanmasına olanak tanımaktadır. Böylece, geleneksel programlamanın aksine, makine öğrenimi sistemleri, karşılaştıkları yeni durumlara adapte olabilme ve performanslarını zaman içinde artırabilme yeteneğine sahip olurlar. Makine öğrenmesi, istatistiksel modelleme, veri madenciliği ve algoritma geliştirme gibi süreçleri kapsar ve bu süreçler genellikle deneme yanılma yoluyla iyileştirilmektedir.

Makine öğrenmesi, yalnızca bilgisayar programlarının geliştirilmesiyle sınırlı kalmayıp, aynı zamanda insan öğrenme sürecini taklit edebilen ve belirli görevleri otonom olarak yerine getirebilen algoritmaların tasarımına ve uygulanmasına odaklanmaktadır. Bu alandaki temel hedef, makinelerin insan benzeri düşünme ve karar verme yetenekleri kazanmasını sağlamaktır. Makine öğrenmesi, örüntü tanıma, veri madenciliği ve yapay sinir ağları gibi çeşitli disiplinleri bünyesinde barındırmaktadır. Günümüzde bu alandaki gelişmeler, satranç oynayan bilgisayar sistemleri, hedef takibi yapabilen füzeler, otonom görev robotları ve insansız hava araçları gibi günlük yaşamda farklı alanlarda çeşitli teknolojik uygulamalarla kendini göstermektedir. Teknolojinin hızla gelişmesi ve dijitalleşmenin yaygınlaşması, dijital cihaz sayısında ve bu cihazlar tarafından üretilen veri miktarında çarpıcı bir artışa yol açmıştır. Büyük ölçekli veriler, ön işleme teknikleri ile bilgiye dönüştürülerek anlamlı hale getirilmektedir. Bu bilgi, sürekli güncellenebilen ve yeni verilerle optimize edilebilen modellerin oluşturulmasını sağlamaktadır. Makine öğrenmesi; arama motorları, doğal dil işleme (NLP), görüntü tanıma, tıbbi teşhis ve sağlık hizmetleri, otonom araçlar, finans ve borsa tahminleri, veri madenciliği, sosyal medya analizi, siber güvenlik, robotik, oyun stratejileri, öneri sistemleri, yüz tanıma teknolojileri, hizmet kalitesinin artırılması, çeviri ve dil hizmetleri, perakende ve tedarik zinciri optimizasyonu, hastalıkların patolojik belirtilerinin sınıflandırılması, kredi skorlama ve finansal risk analizi gibi geniş bir uygulama alanına sahiptir (Bugnion, Nicolas, ve Kozlov 2017).

2.4.1. Makine Öğrenmesi Fonksiyonları

Makine öğrenmesi fonksiyonları, gerçek hayatta karşılaşılan farklı problemlerin analiz edilmesi, modellenmesi ve çözülmesine yönelik olarak geliştirilmiş yöntemlerdir. Bu fonksiyonlar, farklı veri türleri ve problem yapılarına uygun olarak tasarlanarak büyük veri kümelerinden anlamlı çıkarımlar, tahminler yapmaya ve karar alma süreçlerini iyileştirmeye yardımcı olmaktadır. Makine öğrenmesinin en yaygın görevleri aşağıda sıralandığı gibidir.

2.4.1.1 Sınıflandırma

Sınıflandırma işlemi, bir girdi değişkeninin n ayrı kategoriden hangisine dahil olduğunu belirlenmesi ile gerçekleşmektedir. Başka bir ifadeyle giriş verilerinin daha önce tanımlanmış etiketlere atanmasını sağlamaktadır. Özellikle veri odaklı tahminleme ve karar alma süreçlerinde kritik bir rol oynayan sınıflandırma, makine öğrenmesinin en yaygın kullanılan fonksiyonlarından biri olarak öne çıkmaktadır ve birçok sınıflandırma türleri mevcuttur. Sınıflandırma görevine örnek olarak, nesne tanıma problemi gösterilebilir. Bu problemde sisteme girdi olarak verilen resimden nesne tanıma problemi çözülmektedir. Örneğin, Willow Garage PR2 robotu çeşitli içecekleri tanıyıp insanların istediği içecekleri servis edebilmektedir (Goodfellow, Bengio, ve Courville 2018, s.97). Aynı şekilde, yüz tanıma teknolojileri aracılığıyla insanlar sistemlere kendilerini tanıtabilmektedir. Sınıflandırma fonksiyonu, tıp alanında hastalık teşhisi ve tıbbi görüntü analizi, finans sektöründe kredi risk değerlendirmesi ve dolandırıcılık tespiti, e-ticarette müşteri segmentasyonu ve öneri sistemleri, siber güvenlikte kötü amaçlı yazılım tespiti ve spam filtreleme gibi geniş bir uygulama yelpazesine sahiptir.

2.4.1.2 Anomali Saptama

Bu fonksiyonda program, veri setinde normal örüntülere uymayan sapmaları tespit etmektedir. Bu yöntem bir kısmı olağan dışı ya da değişik olan bir dizi olayı veya belirli bir modele göre beklenmeyen gözlemleri tespit etmeyi amaçlamaktadır. Kredi kartı dolandırıcılığı saptama bu fonksiyonun bir örneği olarak gösterilebilir. Kişilerin alışveriş alışkanlıklarını modelleyen finansal kurum bu sayede kartın kötüye kullanıldığını tespit edebilmektedir. Kart ya da kart bilgilerinin çalınması durumunda,

hırsızın yapmış olduđu alışverişler sizin yapmış olduđunuz alışveriş dağılımından farklı bir olasılıkla gerçekleşeceđinden dolayı, farklılık şirket tarafından saptanarak kartın kullanımı kapatılıp dolandırıcılığın önene geçilebilecektir (Goodfellow vd. 2018, s.99). Bunun yanında bu fonksiyon, siber güvenlik, sağlık, endüstriyel süreç izleme (arızaların erken tespiti) gibi farklı alanlarda kullanılmaktadır.

2.4.1.3 Sayısal Tahmin (Bağlanım)

Bu fonksiyonda, modelin verilen girdilere dayanarak sayısal bir çıktı tahmin etmesi beklenmektedir. Bağlanım ile sınıflandırma fonksiyonları birbirine çok benzemektedir. Fakat bu iki fonksiyonun çıktı biçimleri birbirinden farklılık göstermektedir (Goodfellow vd. 2018, s.98). Bu yöntem finans piyasalarında hisse senedi tahmini, sağlık sektöründe hastalık risk skorlarının belirlenmesi, pazarlamada müşteri harcama tahminleri gibi geniş bir uygulama alanına sahiptir.

2.4.1.4 Kümeleme (Clustering)

Kümeleme fonksiyonu, veri setindeki benzer özelliklere sahip veri noktalarını gruplamayı hedeflemektedir. Fonksiyonun temel amacı, verilerdeki doğal yapıyı ortaya çıkarmak ve bu verileri birbirine benzeyen alt gruplara (kümeler) ayırmaktır (Likas, Vlassis, ve Verbeek 2003). Makine öğrenmesinin bu fonksiyonu birçok alanda kullanılmaktadır. Örneğin, pazarlama alanında müşteriler satın alma alışkanlıkları, demografik özellikleri veya tercihlerine göre gruplandırılmaktadır. Bir diğerkullanım alanı olarak ise, resimlerdeki pikseller veya nesneler kümeleme algoritmaları kullanılarak sınıflandırılabilir. Böylece insanları, hayvanları ve nesneleri tespit edilebilmektedir.

2.4.1.5 Birliktelik Kuralı (Association Rule)

Veri madenciliği ve makine öğrenmesi alanlarında büyük veri kümelerindeki değişkenler arasındaki ilişkiyi ortaya çıkarmak için kullanılan kurallara birliktelik kuralları (association rules) adı verilmektedir. Mevcut herhangi bir veri kümesinden çok sayıda olası birliktelik kuralı türetilir. Fakat bu kuralların büyük bir kısmı anlamlı bir ilişkiyi temsil etmez. Bu sebeple birliktelik kurallarının geçerliliğini veya güvenilirliğini istatistiksel ölçütler ile ortaya koymak gerekmektedir (Bramer, 2007, s.8). Örneğin,

elektronik ticaret sitelerinde, bir müşteri sepete belirli bir ürün eklediğinde, birliktelik kuralları kullanılarak bu ürünle sıkça birlikte satın alınan diğer ürünler önerilebilir. Bu, birliktelik kuralı (association rule) analizinin tipik bir uygulamasıdır. Örneğin, "Eğer bir müşteri dizüstü bilgisayar satın alırsa, %65 olasılıkla bir laptop çantası da satın alır" şeklinde bir kural, birliktelik analizi ile elde edilebilir.

2.4.1.6 Boyut İndirgeme (Dimensionality Reduction)

Veri kümesindeki özellik sayısının azaltılma süreci boyut indirgeme olarak ifade edilmektedir. Gözlem sayısının özellik sayısından daha az olduğu veri setlerinde çalışmak oldukça karmaşık ve zordur. . Yüksek boyutlu veri kümelerinde değişkenler arası bulunan yüksek korelasyon, gereksiz ve tekrarlana bilgilerin oluşmasına neden olmaktadır. Özellik sayısındaki artış, hesaplama maliyetlerini artırdığı gibi modelin yorumlanmasını da güçleştirmektedir. Boyut indirgeme teknikleri sayesinde veri seti, istatistiksel analizlere daha uygun hale gelmekte ve yorumlanabilirliği artmaktadır. Boyut indirgemede temel hedef esas veri kümesindeki bilgiyi mümkün olan en az kayıp ile koruyup daha düşük boyutlu bir temsil meydana getirmektir. Bu durum modelleme sürecini daha verimli hale getirebilmektedir (Murphy 2012).

2.4.2. Makine Öğrenme Türleri

Makine öğrenmesi, çok çeşitli alanlarda uygulanarak başarılı sonuçlar elde etmiştir. Bu geniş uygulama yelpazesi, makine öğrenmesinin farklı türlerinin gelişmesine yol açmıştır. Makine öğrenmesinin temel türleri denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç grupta incelenmektedir.

2.4.3. Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenmede, istenilen çıktıya ulaşmak amacıyla model, örnek bir veri seti üzerinde eğitilmektedir. Bu eğitim sürecinde, modele giriş verileri ve bu verilere karşılık gelen doğru etiketler sunulmaktadır. Model, bu etiketli veriler aracılığıyla öğrenme sürecini tamamladıktan sonra, daha önce karşılaşmadığı yeni veri noktaları üzerinde tahminlerde bulunma yeteneği kazanmaktadır (Coen, 2020, s.15) .

2.4.4. Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, modele yalnızca giriş verileri sunulmakta ve modelin bu verilerden anlamlı yapılar veya örüntüler tespit etmesi beklenmektedir. Bu öğrenme yaklaşımı, veri setindeki gizli yapıların keşfedilmesi amacıyla kullanılmakta olup, genellikle kümeleme veya boyut indirgeme gibi teknikleri içermektedir. (Coen, 2020, s.16).

2.4.5. Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, modelin bir çevre ile etkileşime girerek aldığı geri bildirimler doğrultusunda öğrenmesini sağlamaktadır. Model, belirli bir hedefe ulaşmak amacıyla optimal eylemleri seçme stratejisini geliştirmekte ve bu süreçte ödülleri veya cezalar ile yönlendirilmektedir. Bu öğrenme yaklaşımı, oyun teorisi ve robotik gibi alanlarda yaygın olarak uygulanmaktadır. (Coen, 2020, s.14).

2.5 DERİN ÖĞRENME

Derin öğrenme, insan beynindeki sinir ağlarının işleyişini taklit ederek çalışan bir makine öğrenmesi yöntemidir. Geleneksel makine öğrenmesi algoritmalarından farklı olarak, derin öğrenme modelleri çok katmanlı yapılar kullanarak büyük miktarda veriden otomatik olarak öğrenme kapasitesine sahiptir. Bu katmanlar, verideki özellikleri hiyerarşik olarak öğrenir ve veri içerisindeki karmaşık desenleri yakalayabilir. Derin öğrenme, yapay sinir ağlarının çok sayıda parametre ve katmana sahip gelişmiş bir versiyonu olarak tanımlanabilir. Modern teknolojilerin gelişmesiyle birlikte, özellikle grafik işlem birimlerinin (GPU) sağladığı büyük işlem gücü ve maliyetlerin azalması, derin öğrenmenin büyük veri analizlerinde ve karmaşık sorunların çözümünde etkili bir yöntem olarak öne çıkmasına olanak tanımıştır (Deng 2014). Otomatik özellik çıkarma yeteneği, derin öğrenmeyi diğer makine öğrenme algoritmalarına göre daha güçlü kılan unsurlardan biridir (Wang vd. 2015). Derin öğrenme, makinenin verileri analiz ederek sınıfları ayırt edebilmek için uygun özellikleri otomatik olarak keşfetmeye çalıştığı bir süreçtir. Bu süreçte, hangi özelliklerin sınıflandırıcı oluşturmak için kullanılacağını makine kendisi belirler ve öğrenir (Gad, Gad, ve John 2018)

Derin öğrenme, çok daha karmaşık sinir sistemlerinin oluşturulmasına ve gerçek dünyada daha verimli bir şekilde uygulanmasına olanak tanımaktadır. Derin öğrenme ile önceki yapay zeka türleri arasındaki en belirgin fark, derin öğrenme sistemlerine insan müdahalesinin olmamasıdır. Yapay sinir ağlarında (YSA), programcıların eğitim verilerini hazırlaması, sistemi eğitmesi, analitik mantığı oluşturması ve sonuçları değerlendirip doğruluğunu test etmesi gerekirken, derin öğrenme sistemlerinde bu adımlar programcılara ihtiyaç duymadan otomatik olarak gerçekleştirilmektedir (Kashiwagi 2015)

Derin öğrenme yöntemlerinin tercih edilmesi, çok katmanlı yapıları sayesinde büyük ve karmaşık veri setlerini işleme, bu verilerdeki gizli desenleri, kalıpları bulma, model oluşturma ve karmaşık ilişkiler çözmesi etkili olmaktadır (Manaswi vd., 2018, s.37). Böylece doğrusal olmayan işlemlerde bile yüksek başarı gücüne sahiptir. Derin öğrenme, yoğunlukla etiketlenmemiş verilerin kullanımında etkin bir şekilde kullanılmaktadır. Derin öğrenme teknikleri özellikle büyük veri setleriyle başarılı sonuçlar ortaya koymaktadır (Liu vd., 2017, s.22). Derin öğrenme algoritmaları büyük veri setlerinde başarılı oldukları kadar küçük veri setlerinde etkileyici sonuçlar vermektedir (Sönmez 2023).

Derin öğrenme mimarileri, farklı veri türlerini işlemek ve çeşitli görevlerde başarı elde etmek için geliştirilmiş çeşitli yapay sinir ağı yapılarıdır. Yapay sinir ağları, derin öğrenme mimarilerinin temelini oluşturan ve biyolojik sinir ağlarından esinlenerek geliştirilen yapılar olduğu için, bu mimarilerin nasıl çalıştığını anlamak adına yapay sinir ağlarının temel prensiplerini incelemek büyük önem taşımaktadır. Bu sebeple derin öğrenme mimarilerine değinmeden önce yapay sinir ağları hakkında genel bilgi verilecektir.


Yapay Sinir Ağları, beynin nöral yapısına dayanan elektronik modellerdir. Beyin temel olarak deneyimlerden öğrenir. YSA en temel sinir ağı modelidir. Bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Genellikle basit problemlerde kullanılır ve sınırlı sayıda katmana sahiptir.

Yapay Sinir Ağları (YSA), insan beynindeki nöronların işleyişini taklit eden elektronik modellerdir. Beyin, öğrenmeyi deneyimler yoluyla gerçekleştirir ve YSA'lar


da bu prensibe dayanır. YSA, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Genellikle daha basit problemleri çözmek için kullanılır ve sınırlı sayıda katman içerir. Bu yapı, temel sinir ağı modeli olarak kabul edilir ve öğrenme süreçlerinde temel görevlerde etkili sonuçlar verebilir.

Matematiksel bir perspektifle ele alındığında, Yapay Sinir Ağları (YSA), ağırlıklandırılmış bağlantılar vasıtasıyla birbirine bağlanmış birçok işlem biriminden (yapay nöron) meydana gelmektedir. Her bir işlem birimi, "aktivasyon fonksiyonu" veya "transfer fonksiyonu" adı verilen matematiksel bir denklem kullanarak diğer nöronlardan aldığı sinyalleri işler. Bu süreçte, gelen sinyaller toplanır, dönüştürülür ve sonuç olarak sayısal bir çıktı üretilir. İnsan beynindeki biyolojik sinir hücrelerinden esinlenilerek tasarlanan bu yapay nöronlar, bir ağ yapısı içinde birbirleriyle etkileşimde bulunarak Yapay Sinir Ağlarının temelini oluşturur (Yurtoğlu 2005).

Bir sinir hücresi, hücre gövdesi, dentrit ve aksonlardan oluşmaktadır (Harvey 1994). Sinir hücrelerinden gelen uyarılar dentritler aracılığı ile hücre gövdesine iletilir. Hücre gövdesinde meydana gelen bir aktivasyon süreci, hücrenin kararlı durumunu değiştirerek kimyasal bir reaksiyon zinciri başlatmaktadır. Bu süreç sonucunda üretilen sinyaller, aksonlar yoluyla başka sinir hücrelerine aktarılır. Uyarıların bir hücreden diğerine iletiminde, akson uçları ile dendritler arasında bulunan sinaptik boşluklar (sinaps) kritik bir rol oynar. Sinaptik boşlukta yer alan "sinaptik kesecikler", uyarıların diğer hücrelere geçişini sağlayan yapısal elemanlardır. Sinir hücrelerine ulaşan uyarılarla bağlantılı olarak, hücreler arasındaki mevcut sinaptik bağlantılar güçlenebilir, zayıflayabilir veya tamamen yeni bağlantılar kurulabilir. Bu dinamik değişimler, "öğrenme" olarak adlandırılan biyolojik süreci temsil etmektedir. Yapay sinir ağları, biyolojik nöronların işleyişinin matematiksel olarak basitleştirilmiş bir modeline dayanır (Kröse ve Van der Smagt 1996). Sırasıyla Şekil 2.2. ve Şekil 2.3. Biyolojik sinir hücresi ve Yapay sinir hücresini temsil etmektedir. Tablo 2.1.' de Biyolojik sinir sistemi ile yapay sinir sisteminin eşleştirilmesi verilmiştir.



Şekil 2.2. Biyolojik Sinir Hücresi



Şekil 2.3. Yapay Sinir Hücresi

Tablo 2.1. Biyolojik Sinir sistemi ve Yapay Sinir Sistemi

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi	
Nöron	İşlemci Elemanı	
Dentrit	Toplama Fonksiyonu	
Hücre Gövdesi	Transfer Fonksiyonu	
Aksonlar	Yapay Nöron Çıkışı	
Sinapslar	Ağırlıklar	

Yapay Sinir hücreleri, beş temel bileşenden oluşmaktadır: girdi değişkenleri, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktılar (Okutkan 2014).

- **Girdi Değişkenleri:** Bir yapay sinir hücresi, birçok bilgi alır ve bu bilgileri işler. Bu alınan bilgiler, ilgili sinir hücresi için girdi olarak kabul edilir. Girdiler ($x_1, \dots, x_n$), dış dünyadan gelmiş olabileceği gibi, aynı hücreden veya bir önceki katmandaki başka bir işlem elemanının çıktısı da olabilir (Elmas 2021). Girdi değişkenlerinin sayısı, yapay sinir ağının çevreyi nasıl algıladığına bağlı olarak değişebilir. Eğer çevre, yapay sinir ağının işleyeceği verilerden oluşuyorsa, girdilerin yapısı bu veri değişkenlerine uygun olmalıdır (Buscema 2002).

- **Ağırlıklar:** Ağırlıklar: ($w_1, w_2, \dots, w_n$), bir yapay sinir hücresine gelen bilginin önemini ve bu bilginin hücre üzerindeki etkisini belirleyen parametrelerdir. Her bir giriş değeri ($x_1, x_2, \dots, x_n$), kendine özgü bir ağırlık değeri ile çarpılarak hücreye iletilir. Bir ağırlık değerinin büyük veya küçük olması, bilginin değerini göstermez. Bunun yerine, ağırlık değerinin pozitif (+) veya negatif (-) olması, bilginin olumlu veya olumsuz etkisini ifade etmektedir. Ağırlık değerinin sıfır olması durumunda ise, ilgili girdinin hücre üzerinde herhangi bir etkisinin bulunmadığını göstermektedir. Ağırlıklar, sabit değerler olabileceği gibi, eğitim süreci boyunca güncellenen değişken parametreler de olabilir (Öztemel 2012).

- **Toplama Fonksiyonu:** Bu fonksiyon, bir hücreye ulaşan net girdiyi hesaplamak için kullanılır ve bu hesaplama sürecinde farklı yöntemler uygulanabilir. En yaygın kullanılan yöntem, ağırlıklı toplamı belirleme yaklaşımıdır. Bu yöntemde, her bir girdi değeri kendi ağırlığı ile çarpılır ve elde edilen sonuçlar toplanarak hücreye gelen net girdi olarak hesaplanmaktadır. Ağırlıklı toplam, çarpımsal, minimum, maksimum, ortalama, öklid norm, çoğunluk ve kümülatif toplam fonksiyonları toplama fonksiyonlarından bazılarıdır.

- **Aktivasyon Fonksiyonu:** Bir yapay sinir hücresinin çıktısını belirlemek için kullanılan fonksiyonlar, aktivasyon fonksiyonu olarak adlandırılır. Bu fonksiyonlar, bir girdi katmanı, bir çıktı katmanı ve bir veya daha fazla paralel gizli katmandan oluşan yapay sinir ağlarında, çıktı değerlerinin aralığını sınırlamak veya belirlemek amacıyla kullanılmaktadır (Öztemel 2012; Sönmez 2023). Sigmoid, hiperbolik tanjant, adım,

doğrusal, relu, elu, softmax, swish, gelu ve sinüsoidal başlıca aktivasyon fonksiyonlarıdır (Akay 2009; Korukçu 2022; Öztemel 2012).

- Çıktılar: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeri, bir yapay sinir hücresinin ürettiği sonuçtur. Bu çıktı değeri ya dış dünyaya ya da başka bir sinir hücresine girdi olarak iletilmektedir. Ayrıca, tekrarlayan sinir ağlarında, hücre ürettiği çıktıyı kendisine geri besleyerek girdi olarak da kullanabilmektedir. Bu geri besleme mekanizması, zaman serisi veya dizi modellerinde önemli bir rol oynamaktadır.

2.6 DERİN ÖĞRENME MİMARİLERİ

Derin öğrenme mimarileri, verileri çok katmanlı bir yapı ile işleyerek daha karmaşık desenleri tanıyabilir ve daha gelişmiş tahminler yapabilirler. Yaygın olarak kullanılan derin öğrenme mimarileri hakkında aşağıda bilgi verilmektedir.

2.6.1. Evrişimli Sinir Ağı (Convolutional Neural Network, CNN)

1989 yılında LeCun ve arkadaşları tarafından sunulan bir Sinir Ağı (NN) türü olan Evrişimsel Sinir Ağları (CNN), makine görüşü (MV) uygulamalarında büyük bir potansiyel sergilemiştir (LeCun vd. 1989). CNN'ler, görüntü içeriğini anlama konusunda en etkili öğrenme algoritmalarından biri olarak öne çıkmış ve görüntü segmentasyonu, sınıflandırma, tespit ve geri alma gibi görevlerde üstün performans göstermiştir (Ciresan vd. 2012). Günümüzde, görüntü işleme ve bilgisayarla görme (CV) yarışmalarının önde gelen katılımcıları derin CNN tabanlı modelleri kullanmaktadır.


CNN'lerin en dikkat çekici özelliklerinden biri, verideki mekânsal veya zamansal korelasyonları etkin bir şekilde kullanabilmesidir. CNN mimarisi genellikle bir dizi öğrenme aşamasına bölünmüş olup, bu aşamalar evrişim katmanları, doğrusal olmayan işlem birimleri ve alt örnekleme katmanlarının kombinasyonundan oluşur (Jarrett vd. 2009).

2.6.2. Tekrarlayan Sinir Ağı (Recurrent Neural Network, RNN)

Tekrarlayan Sinir Ağları (RNN'ler), sıralı ve zaman serisi verilerini öğrenmeye yönelik tasarlanmış bir sinir ağı türüdür (Salehinejad vd. 2018). RNN sıralı verilere ve


bağımlılıklara odaklanırken YSA daha basit görevlerde kullanılmaktadır. RNN, bir veya daha fazla geri besleme döngüsüne sahip yapay nöronlardan oluşan denetimli makine öğrenimi modelleri sınıfını temsil etmektedir (Haykin, 1998, s.754). Bu ağlar, zaman içerisinde bilgiyi koruyabilmelerini sağlayan geri beslemeli bağlantılar içerir ve böylece önceki adımlardan gelen bilgileri kullanarak gelecekteki tahminleri iyileştirirler. RNN'lerin eğitimi, girdi-hedef çiftlerinden oluşan bir veri seti ile gerçekleştirilmektedir. Eğitim sürecinde amaç, ağın ağırlıklarını optimize ederek modelin çıktısı ile hedef değerler arasındaki farkı, yani kayıp fonksiyonunu, en aza indirmektir (Salehinejad vd. 2018). Bu yapı, RNN'leri özellikle dil modeli, konuşma tanıma ve finansal zaman serisi gibi ardışık verilerin önemli olduğu problemler için ideal hale getirmektedir.

Tekrarlayan Sinir Ağları (RNN), sinir ağı mimarilerinde geçmiş bilginin işlenmesini sağlayan ve verinin zaman içerisindeki bağımlılıklarını modelleyebilen bir yapı sahiptir. Diğer sinir ağlarından farkı, ileri beslemeli ağlar gibi sadece mevcut zaman serisi ve sıralı bilgilere ilaveten önceki basamaklarda alınan bilgiyi hafızasında tutarak ilerleyen adımlarda kullanabilmesidir. Bu durum, özellikle zaman serisi, konuşma tanıma ve dil işleme gibi verinin ardışık olduğu problemler için oldukça elverişlidir. Geri besleme döngüsü RNN'lerin en belirgin özelliklerinin başında gelmektedir. Döngü sayesinde ağ sadece mevcut girdiyi kullanarak çıkarımda bulunmak yerine, zaman serisindeki her bir girdi önceki girdilerden etkilenmektedir. Geleneksel sinir ağlarının sahip olmadığı bir yeteneği, geçmişini hatırlayarak öğrenmeyi mümkün kılar. RNN sinir ağlarının çalışma yapısı insanların öğrenme sistematüğini benzemektedir. Başka bir ifadeyle, RNN yapıları, insanların önceki deneyimlerini ve bilgilerini bellekte saklayıp, bu birikimi sonraki adımlarda kullanarak yeni öğrenilen bilgileri üzerine inşa etme süreçlerine benzer şekilde çalışmaktadır (Asefisaray 2018). RNN'ler, geri besleme mekanizması sayesinde, giriş verilerinin önceki durumlarını dikkate alarak öğrenme sürecini optimize ederler. Her bir nöron, yalnızca mevcut girdiden değil, aynı zamanda önceki zaman adımlarındaki durumlarından da etkilenir. Bu yapı, özellikle ardışık ve zamansal bağımlılık gösteren veri setlerinde güçlü sonuçlar üretmelerine olanak tanımaktadır. Şekil 3.1' de basit bir RNN yapısı görülmektedir.



Şekil 2.4. RNN Yapısı

Şekil 2.4.’ de “ X_t ” değişkeni giriş değerini “ h_t ” değişkeni ise çıkış değişkenini vermektedir. Çıktı değişkeni bir sonraki adımı beslemektedir. Böylece RNN’ de bulunan döngüler sayesinde önceki adımın bilgileri sonraki adıma aktarılmasına imkan sağlamaktadır. RNN’ lerin asıl amacı olan, önceki bilgileri kullanma yeteneğini döngülerin aracılığıyla yerine getirilmiş olmaktadır. Geleneksel sinir ağlarının aksine RNN’ de sonuca üretilirken girdi ve çıktıya ek olarak önceki girdilere diğer bir ifadeyle geçmişe bağlı kalmaktadır. Şekil 3.2.’de RNN yapısının açık hali gösterilmektedir.



Şekil 2.5. RNN Yapısı (Açık Hali)

RNN modelinin matematiksel formülü Denklem 2.1.’ de gösterilmektedir. Bir aktivasyon fonksiyonu ile kullanımı ise Denklem 2.2.’ de gösterilmektedir.

$$h_t = f(h_{t-1}, x_t) \quad (2.1)$$

$$h_t = \tanh(W_{hh}h_{t-1} + W_{xh}x_t) \quad (2.2)$$

h_t = şu andaki h değeri

h_{t-1} = bir önceki h değeri

x_t = şu anki girdi vektörü


W = Ağırlık

h = gizli katman

W_{hh} = bir önceki gizli katmanın ağırlığı

W_{xh} = şu anki gizli katman ağırlığı

$\tanh$ = aktivasyon fonksiyonu



Şekil 2.6. Tek Katmanlı RNN yapısı

2.6.3. Uzun Kısa Süreli Bellek Ağı (Long Short-Term Memory Network, LSTM)

LSTM (Uzun Kısa Süreli Bellek) mimarisi, uzun vadeli bağımlılıkları etkili bir şekilde modelleyebilen bir tekrarlayan sinir ağı (RNN) türüdür. Bu model, konvansiyonel RNN'lerde sıkça karşılaşılan ve özellikle uzun sekans işlemede belirginleşen gradyan


patlama ve gradyan kaybı problemlerinin üstesinden gelmesi için tasarlanmıştır (Hochreiter 1997). LSTM'in ayırt edici özelliği, içerdiği kapı mekanizmaları (input, forget ve output kapıları) sayesinde, zamansal gecikmeler çok uzun olduğunda bile bilgiyi seçici olarak hatırlama, unutma ve güncelleme yeteneğidir. Bu yapı, gradyan akışını kontrol ederek, ağıın uzun vadeli bağımlılıkları öğrenmesini ve korumasını sağlar, böylece geleneksel RNN'lerin karşılaştığı optimizasyon zorluklarını aşmaktadır (Van Houdt, Mosquera, ve Nápoles 2020) .

LSTM ağları bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşmaktadır. Girdi katmanındaki nöron sayısı açıklayıcı değişkenlerin sayısına (özellik uzayı) eşittir (Fischer ve Krauss 2018). LSTM ağlarının temel özelliği, bellek hücreleri olarak adlandırılan gizli katman veya katmanlarda bulunmaktadır. Hafıza hücrelerinin her biri, hücre durumunu koruyan ve ayarlayan üç kapıya sahiptir: bir unutma kapısı (ft), bir giriş kapısı (it) ve bir çıkış kapısı (ot). Unutma kapısı, hücre durumundan hangi bilgilerin çıkarılacağını belirlerken, giriş kapısı, hücre durumuna hangi yeni bilgilerin ekleneceğini tanımlamaktadır. Çıkış kapısı ise hücre durumundaki hangi bilgilerin çıkış olarak kullanılacağını belirler (Fischer ve Krauss 2018).

Çalışmanın uygulama bölümünde ilgili modele daha detaylı değinilmiştir.

2.6.4. Çift Yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory Network, Bi-LSTM)

Girdi değişkenlerinin iki yönlü işlendiği LSTM modelidir. Bu çift yönlü işleme sayesinde, zaman serisi verilerindeki önceki ve sonraki adımlar arasındaki ilişkiler daha etkin şekilde öğrenilir. LSTM' in bu iki yönlü uygulaması uzun vadeli bağımlılıkları öğrenmede daha başarılı sonuçlar vermekte ve model doğruluğunu artırmaktadır (Siami-Namini ve Namin 2018). Uzun serilerdeki ilişkileri öğrenme konusunda başarılı olan Bi-LSTM bu alanda sıkça kullanılmaktadır. Şekil 2.7.' de Çift yönlü LSTM' in (Bi-LSTM) işleyişi gösterilmektedir



Şekil 2.7. Çift Yönlü LSTM Yapısı (Bi-LSTM)

RNN ağlarında, eğitim setinin ağ üzerinden geçirilmesi ve ağırlık parametrelerinin güncellenmesi epok olarak nitelendirilmektedir. Bir epok veri setinin ileri yönlü beslemesi ve geri yayılım algoritması ile ağırlıkların optimize edilmesini kapsamaktadır. LSTM modellerinde her bir epokta, ağırlık parametrelerinin güncellenmesi dolayısıyla performansın artırılması amaçlanmaktadır. Literatür incelendiğinde standart bir epok değerinin bulunmaması veri setinin yapısal özellikleri ve model karmaşıklığından kaynaklandığı ifade edilebilir.

Finansal zaman serileri, uzun vadeli ilişkiler barındıran karmaşık bir yapıya sahiptir. LSTM modelinde bulunan hücre durumu (cell state) borsa verilerindeki trendi ve volatilité değişimlerini yakalamak için iyi bir performans sağlamaktadır. LSTM, doğrusal olmayan ilişkileri yakalayabilme ve birden fazla değişkeni senkron olarak işleyebilmektedir.

2.6.5. Gated Recurrent Unit (GRU)

Bir RNN türü olan GRU uzun dönem bağımlılıkları öğrenirken ortaya çıkan kaybolan ve patlayan gradyanlar problemlerini çözmek için önerilmektedir. Kaybolan gradyanlar, geri yayılım esnasında gradyanların üssel olarak küçülmesi ve sıfıra yaklaşmasını ifade eder. Patlayan gradyanlar ise gradyanların geri yayılım esnasında üssel olarak çok büyümesi çok büyük değerler almasını ifade eder (Cho vd. 2014). LSTM

hücresinden daha basit bir yapıya sahip olan GRU, unutma ve giriş kapıları birleştirilerek güncelleme kapısı oluşturulur buna ilaveten sıfırlama kapısına sahiptir (Rana 2016).

2.6.6. Generatif Çekişmeli Ağlar (Generative Adversarial Networks, GAN)

Derin öğrenme alanında önemli bir yere sahip olan GAN iki nöral ağı birbirine karşı yarıştığı, üretici ağı gerçek veriye benzer sentetik veri üretmeye, ayırıcı ağı ise verinin gerçek mi sentetik mi olduğunu tahmin etmeye çalışmaktadır. Denetimli ve denetimsiz öğrenme türlerinde yetersiz veri seti kullanımında benzersiz sentetik örnekler üreten algoritmalar (Goodfellow vd. 2020). Çözünürlüğü düşük resimlerden yüksek çözünürlüklü resimler elde edilebilmektedir (Bulat, Yang, ve Tzimiropoulos 2018). Görüntü üretimi ve manipülasyonu, ses sentezi, video oluşturma, veri artırma, çeviri sistemleri gibi birçok alanda kullanılmaktadır.

2.6.7. Derin İnanç Ağı (Deep Belief Network, DBN)

Derin İnanç Ağları (Deep Belief Network-DBN), olasılıksal üretici grafik modeller olup, birçok gizli birim katmanına sahiptir. Derin inanç ağları, geleneksel derin sinir ağlarında görülen derin katmanlı yapılarıdaki aşırı uyum ve yavaş öğrenme gibi problemlere çözüm getirmesi için öne sürülmüştür (Hua, Guo, ve Zhao 2015). Ses ve görüntü sınıflandırmada başarılı sonuçlar elde edilen derin inanç ağları (DİA), denetimsiz öğrenme yöntemiyle etiketlenmemiş büyük miktardaki veriyi eğiterek özelliklerini öğrenmektedir (Spencer, Eickholt, ve Cheng 2014).

2.6.8. Otoenkoder (Autoencoder)

Otokodlayıcılar, 1986'da ortaya çıkan ve gözetimsiz öğrenme için tasarlanmış ileri düzey derin sinir ağı mimarileridir (Rumelhart, Hinton, ve Williams 1986). Kodlayıcı ve kod çözücü olmak üzere iki ana bileşenden oluşan bu yapılar, özellikle bilgisayarla görme alanında geniş uygulama alanına sahiptir. Otokodlayıcılar, veriyi sıkıştırma ve yeniden oluşturma prensibiyle çalışarak, görüntü gürültüsü azaltma, sıkıştırma, siyah-beyaz görüntüleri renklendirme ve nesne sınıflandırma gibi karmaşık işlemlerde kullanılmaktadır (Goodfellow vd., 2020, s. 502).

2.6.9. Hibrit Mimariler

Kapsamlı ve etkili çözümler bulmak için derin öğrenme yöntemleri biraya getirilerek esnek ve güçlü yapılara meydana getirilebilir. Hibrit mimariler, derin öğrenme alanında farklı model türlerin ve yöntemlerin bir araya gelmesiyle oluşmaktadır.



3. BÖLÜM: UYGULAMADA KULLANILAN TAHMİN YÖNTEMLERİ, TEKNİK GÖSTERGELER VE İLGİLİ LİTERATÜR TARAMASI

3.1 OTOREGRESİF ENTEGRE HAREKETLİ ORTALAMA MODELİ (ARIMA)

Zamana bağımlılık içeren ve belirli aralıklarla veya sürekli toplanan veri kümesi zaman serilerini ifade etmek için kullanılmaktadır (Ramola vd. 2008). Zaman serilerinin modellenmesi, geçmişteki verilerden öğrenerek gelecekteki değerlerin tahmin edilmesi üzerine kurulmaktadır. Zaman serisi analizinde yaygın olarak kullanılan istatistiksel tahmin yöntemleri arasında en kapsamlı ve sistematik yaklaşımlardan biri Box-Jenkins metodolojisidir. Bu yöntem çerçevesinde geliştirilen modeller arasında Otoregresif (AutoRegressive-AR), Hareketli Ortalama (Moving Average-MA), Otoregresif Hareketli Ortalama (Autoregressive Moving Average-ARMA) ve Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) modelleri yer almaktadır. Box-Jenkins yöntemleri, zaman serisinin yapısal özelliklerine göre uygun modelin belirlenmesini, parametre tahminini ve modelin doğrulanmasını içeren aşamalı bir sürece dayanır. Bu kapsamda, ARIMA modeli, bir zaman serisinin gelecekteki değerlerinin, geçmiş gözlemleri ve rassal hata terimlerinin doğrusal bir kombinasyonu aracılığıyla tahmin edilebileceği varsayımına dayanır. Durağan zaman serileri için $AR(p)$, $MA(q)$ ve bunların birleşimi olan $ARMA(p,q)$ modelleri tercih edilirken; durağan olmayan serilerde, serinin fark alma yöntemiyle durağanlaştırılması sonrasında uygulanan $ARIMA(p,d,q)$ modelleri kullanılmaktadır (Hamzaçebi ve Kutay 2004).

$ARIMA(p, d, q)$ modeli ilk olarak 1976 yılında Box ve Jenkins tarafından ortaya atılmıştır (Box vd. 2015). Zaman serilerinin tahmin ve analizinde kullanılan istatistiksel bir yöntem olan ARIMA modeli, geleceği tahmin etmek için geçmişteki değerleri kullanmaktadır. Otoregresif (AR), entegrasyon (I) ve hareketli ortalama (MA) bileşenlerinden meydana gelmektedir. Zaman serilerinde istatistiksel yöntemlerden olan ARIMA kullanılırken durağan olmayan serinin bir başka ifadeyle, zaman serisinin ortalama, varyans, otokorelasyon gibi istatistiksel özelliklerinin zaman içinde sabit

kalmaması durumu göz önünde bulundurulmaktadır. Durağan olan zaman serilerinde ARMA modeli kullanılmaktadır. Doğrusal bir yapıya sahip zaman serisi modelin uygulanabilmesi için en temel unsurlardan biridir. Durağan olmayan serilerde, uygun derecede fark alma işlemiyle seri durağan hale getirilebilmektedir (Çevik 1999). Fark alma yöntemiyle mevsimsellik ve trend ortadan kaldırılmaktadır (Fanoodi, Malmir, ve Jahantigh 2019). Denklem $y'_t = y_t - y_{t-1}$

(3.1.' te durağan olmayan zaman serisi verilerini birinci dereceden farkı alınarak durağan hale getirilebilmektedir. Birinci dereceden fark alınarak durağan hale gelmeyen zaman serilerine ikinci derece fark alma işlemin uygulanarak durağan hale getirilebilmektedir. Denklem $y''_t = y_t - 2y_{t-1} + y_{t-2}$

(3.2.' de ikinci dereceden fark alma işlemi gösterilmektedir. Fark alma katsayısı d ile belirtilir ve fark alma derecesini ifade etmektedir. ARIMA (p, d, q) şeklinde yazılmaktadır.

$$y'_t = y_t - y_{t-1} \quad (3.1)$$

$$y''_t = y_t - 2y_{t-1} + y_{t-2} \quad (3.2)$$

Analizde kullanılan zaman serisi durağan bir yapıya sahipse (d=0) model AR ve MA sürecinden oluşan ARMA (p, q)' ya dönüşmektedir. ARIMA modeli değişkenlik gösterebilmektedir (Çevik 1999).

ARIMA modeli, ARIMA (p, d, q) olarak tanımlanmaktadır (Newbold 1983).

p: Otoregresif modelin derecesi (AR)

d: Fark alma derecesi

q: Hareketli ortalama modelinin derecesi (MA)

Modelin AR bileşeni, serideki bir değer, önceki zaman noktalarındaki değerlerle olan ilişkisine dayandığını varsayar ve bu ilişkileri modellemeye çalışmaktadır (Hyndman 2018). Model zaman serisinde “p” adım önceki değerini kullanarak mevcut değeri tahmin etmektedir. Bir zaman serisi modeli oluşturulurken, serinin otoregresif bir yapıya sahip olduğu bilinse dahi, modelde yer alacak gecikme derecesinin doğru bir şekilde belirlenmesi büyük önem taşımaktadır. Gecikme sayısının isabetli bir biçimde tespit edilmesi, modelin tahmin doğruluğunu ve genel başarımını artıran temel

unsurlardan biridir. Bununla birlikte, yetersiz sayıda gecikme kullanılması durumunda modelde önemli yapısal bilgilere erişilememesi nedeniyle bilgi kaybı yaşanabilirken, aşırı sayıda gecikmenin modele dâhil edilmesi ise çoklu doğrusal bağlantı (multicollinearity) sorununu artırarak modelin tahmin performansını olumsuz etkileyebilmekte ve ayrıca modelin serbestlik derecesini azaltarak istatistiksel anlamlılığı zayıflatabilmektedir. AR modelinin p dereceden genel denklem, denklem 3.3.' te gösterilmektedir

$$Y_t = C + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \epsilon_t \quad (3.3)$$

Modelin MA bileşeni, tahmin sürecini iyileştirmek için tahmin hatalarının q gecikmeli değerlerini kullanmaktadır. Bu modelde, önceki hataların lineer kombinasyonu ile gelecekteki değerler tahmin edilmektedir (ArunKumar vd. 2021). Modelinin derecesi "q" ile ifade edilir ve kaç önceki hata teriminin kullanılacağını belirtmektedir. Bir MA (q) modelinin q dereceden denklemi denklem 3.4.' te gösterilmektedir.

$$Y_t = C + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (3.4)$$

Hareketli Ortalama (MA) süreci, zaman serilerinde gözlemlenen yavaş etkilerin modellenmesinde ve serideki kısa vadeli düzensizliklerin giderilerek trend eğiliminin ortadan kaldırılmasında sıklıkla tercih edilen bir yöntemdir. Bu model, geçmiş dönemlere ait hata terimlerinin doğrusal kombinasyonlarını kullanarak serideki geçici dalgalanmaları açıklamayı hedefler ve özellikle durağanlığı sağlama sürecinde önemli bir rol oynamaktadır (Gujarati 2004, s.839).

Otoregresif Hareketli Ortalama (ARMA) modeli, bağımlı değişkenin mevcut değerini yalnızca kendi geçmiş değerleri ile değil, aynı zamanda geçmiş ve mevcut hata terimlerinin bir fonksiyonu aracılığıyla açıklayan bir model yapısı sunmaktadır. Durağan zaman serilerinin modellenmesinde yalnızca AR ya da yalnızca MA modellerinin kullanılması, bazı durumlarda yeterli esnekliği sağlayamamakta ve modelin veri yapısını tam olarak yansıtmasını engelleyebilmektedir. Özellikle yüksek dereceli AR veya MA modelleri, çok sayıda parametre tahminini gerektirdiğinden, modelin yalınlığını ve uygulanabilirliğini azaltabilmektedir. Ayrıca, aynı veri yapısını açıklayabilecek birden fazla alternatif modelin bulunabileceği de literatürde bilinmektedir. Bu çerçevede, cimrilik ilkesi, zaman serisinin yapısal özelliklerini en az sayıda parametre ile temsil

edebilen optimal modelin tercih edilmesini öngörmektedir (Enders 1995). Bu çerçevede, AR ve MA süreçlerinin birleşiminden oluşan doğrusal ve tek değişkenli ARMA modeli, parametre sayısını azaltma imkânı sunarken, serinin yapısal özelliklerine daha uygun ve daha etkili bir modelleme çerçevesi sağlamaktadır. Yukarıda da ifade edildiği gibi durağan olmayan zaman serilerinin analizinde ARMA modeli kullanılırken durağanlık özelliği göstermeyen serilerde ARIMA modeli kullanılmaktadır. ARIMA modelini çok değişkenli bir şekilde kullanmakta mümkündür. Ancak bu durumda model artık ARIMAX olarak ifade edilmektedir (Fan vd. 2009; Jalalkamali, Moradi, ve Moradi 2015). ARIMAX modeli kurulurken ilk adım dışsal değişkenlerin yer aldığı uygun ARIMA modelinin belirlenmesidir.

ARIMA modelinin genel tahmin denklemi denklem 3.5.' te gösterilmektedir.

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \theta_q \epsilon_{t-q} + \epsilon_t \quad (3.5)$$

Y_t : Zaman serisini t zamandaki değeri (d dereceden farkı alınmış)

C : Sabit terim


ϕ_p : Otoregresif model parametreleri (d dereceden farkı alınmış)

ϵ_t : Zaman serisinin t zamandaki hata terimi

θ_q : Hareketli ortalama parametreleri

ARIMA model seçiminde ve tanımlamasında sıklıkla kullanılan Akaike Bilgi Kriteri (AIC) ve Bayesian Bilgi Kriteri (BIC), modelin istatistiksel uygunluğunu değerlendirirken önemli kriterlerdir. AIC ve BIC, modelde kullanılan parametrelerin sayısı ile modelin hata oranını göz önünde bulundurarak en uygun modeli seçmeye olanak sağlamaktadır. AIC, modelin veri setine en iyi uyumu sağlayıp sağlamadığını ölçmek için kullanılmaktadır. Daha düşük AIC değerleri, modelin daha iyi bir uyum gösterdiği anlamına gelmektedir. BIC ise modelin doğruluğu kadar, gerçek modele olan yakınlığını da dikkate almaktadır. En düşük BIC değerine sahip model en iyi model olarak kabul edilmektedir (Çınar ve Sevüktekin 2017). Denklem 3.6. ve 3.7. 'de AIC ve BIC denklemleri gösterilmektedir. Buradaki k değişkeni modeldeki parametre sayısını ifade ederken L maksimum olasılık değerini ve n değişkeni gözlem sayısını belirtmektedir.

olarak göze çarpmaktadır. LSTM modelindeki hafıza kapısı sayesinde bir önceki adımdan gelen bilgi bir sonraki adıma iletilmektedir. Unutma kapısı sayesinde ise hangi bilginin aktarılıp aktarılmayacağına karar vermektedir. Şekil 3.2.' te LSTM mimarisi gösterilmektedir.



Şekil 3.2. Uzun Kısa Süreli Bellek (LSTM) Ağı Mimari Yapısı

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.8)$$

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

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.10)$$


$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.11)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.12)$$

$$h_t = o_t * \tanh(C_t) \quad (3.13)$$

Şekil 3.2.' te gösterilen unutma kapısı, hangi bilginin unutulacağına veya saklanacağına karar vermektedir. Bu kapıda h_{t-1} ve x_t değerleri *sigmoid* fonksiyonundan geçip 0-1 aralığına indirgenerek C_{t-1} hücre durumundaki sayı için bu aralıkta değer üretilmektedir. Değer 1 çıkarsa bu değeri korur aksi takdirde yani 0 durumunda ise bu değerden kurtul anlamına gelmektedir. Unutma kapısı bir önceki LSTM hücresinin çıktı ve durumuna bağlıdır. Giriş kapısı, hücre durumunda saklanacak yeni bilgilerin

seçiminden sorumludur. Önceki LSTM biriminin hafıza durumu ve gizli durum vektörlerine bağlı olarak çalışmaktadır. Süreç iki aşamada gerçekleşmektedir: İlk olarak *sigmoid* fonksiyonu güncellenecek değerleri belirlemekte, ardından *tanh* fonksiyonu yeni aday değerler vektörünü ($\tilde{C}_t$) oluşturmaktadır. Hücrenin mevcut durumu (C_{t-1}) ile yeni durum (C_t) arasındaki geçiş, unutma kapısından gelen f_t değeri ile kontrol edilmektedir. Bu değer 1'e yaklaştıkça mevcut bilgi korunur, 0'a yaklaştıkça ise saklanan değer denkleme katılmamaktadır. *Tanh* fonksiyonu, giriş katmanında belirlenen güncellemeleri takiben yeni saklanacak değeri hesaplar. Nihai hücre durumu, giriş kapısının çıktısı olan *sigmoid* aktivasyon fonksiyonundan elde edilen i_t ile *tanh* fonksiyonundan gelen $\tilde{C}_t$ değerlerinin çarpımının, önceki adımda hesaplanan $f_t * C_{t-1}$ ile toplanması sonucu elde edilmektedir. LSTM' in çıktı aşamasında, hücre durumundan hangi bilgilerin aktarılacağı belirlenir. Bu süreçte öncelikle *sigmoid* fonksiyonu ile çıkarılacak bileşenler seçilmektedir. Ardından, hücre durumu -1 ile 1 arasında değerler üreten tanjant fonksiyonundan geçirilmektedir. *Sigmoid* fonksiyonu (0-1 aralığında) yeni bilginin kullanım kararını verirken, tanjant fonksiyonu saklanan bilginin kullanım oranını belirler. Çıkış katmanı, bu iki katmandan gelen değerlerin çarpımı oluşturulurken aynı zamanda elde edilen değer bir sonraki katmana da giriş parametresi sağlamaktadır (Olah 2024). Denklemlerde f_t unutma kapısını, i_t giriş kapısını o_t ise çıkış kapısını temsil ederken w terimi ağırlık matrislerini b terimi ise bias (yanlılık) vektörünü ifade etmektedir.



Şekil 3.3. İleri Beslemeli LSTM Yapısı

3.3 MODELLERİN DEĞERLENDİRME KRİTERLERİ

Literatürde, Finansal zaman serileriyle yapılan çalışmalarda modellerin performansını değerlendirmek ve karşılaştırmak için farklı istatistiksel ölçütler kullanılmaktadır. Bu istatistiksel ölçütler modellerin tahmin doğruluğunu, genel performansını ve güvenilirliğini değerlendirmemize imkan sağlamaktadır. Finansal zaman serilerinden borsa endeks tahmininde modelin başarısını değerlendirmede kullanılan bu kriterler araştırmacılar ve yatırımcılar için önem arz etmektedir.

Çalışmada ARIMA ve LSTM modellerinin performansını değerlendirmek için Ortalama Kare Hata (MSE), Ortalama Karekök Hata (RMSE), Mutlak Hata Değeri (MAE) ve Ortalama Mutlak Yüzdesel Hata (MAPE) başarı kriterleri kullanılmıştır. Her bir metrik modelin farklı yönünü ele almakta ve birlikte kullanıldıklarında modellerin genel başarısı hakkında kapsamlı bir değerlendirme imkanı vermektedir. Kullanılan bu başarı kriterleri farklı veri setleri ve farklı zaman dilimlerinde modellerin tutarlılığını değerlendirmemize imkan sağlamaktadır. Başarı kriterlerinin matematiksel formülü Tablo 3.1’de verilmektedir.

Tablo 3.1. Başarı Metrikleri

Başarı Metriği	Formüller
Ortalama Kare Hatası (Mean Square Error)	$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$
Kök Ortalama Kare Hatası Root Mean Square Error	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$
Ortalama Mutlak Hata (Mean Absolute Error)	$MAE = \left(\sum_{t=1}^n \left \frac{y_t - \hat{y}_t}{n} \right \right)$
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error)	$MAPE = \left(\sum_{t=1}^n \left \frac{y_t - \hat{y}_t}{n} \right \right) \frac{100}{n}$

3.4 ENDEKS TAHMİNİNDE GİRDİ DEĞİŞKENİ OLARAK

KULLANILAN TEKNİK GÖSTERGELER

Finansal piyasalarda yatırım kararlarının şekillenmesinde önemli rol oynayan teknik analiz, piyasa dinamiklerini matematiksel ve istatistiksel yöntemlerle yorumlama sürecidir. Bu analiz yöntemi, fiyat hareketlerinin geçmiş dönemlerdeki davranışlarını inceleyerek gelecekteki olası hareketleri öngörmeyi amaçlar. Teknik analizin temelinde, piyasa verilerinin sistematik bir şekilde işlenmesi ve bu verilerin çeşitli matematiksel formülasyonlarla anlamlı göstergelere dönüştürülmesi yatmaktadır (Fang vd., 2014).

Teknik analiz, yalnızca piyasalarda oluşan gerçek fiyat ve hacim verilerinin kullanıldığı bir analiz tekniğidir. Günümüzde bilgisayarların artan bilgi işleme kapasiteleri sayesinde çok sayıda teknik analiz verilerinin hızlı ve kapsamlı bir şekilde hesaplanması da mümkün olabilmektedir (Wilder, 1987, s.6). Teknik analiz, fiyat ve hacim verilerini temel alarak, gün içindeki en yüksek, en düşük ve kapanış değerlerini kullanmaktadır. Bu verilerden elde edilen farklı oranlarla oluşturulan teknik göstergeler, kısa, orta ve uzun vadeli periyotlar için yatırımcılara piyasalarda alım-satım kararlarında rehberlik eden bir yöntem sunmaktadır. Bu yaklaşım, piyasa eğilimlerini anlamada ve yatırım stratejilerinin belirlenmesinde etkili bir araç olarak öne çıkmaktadır.

Teknik göstergeler finansal varlıkların verilerini analiz etmek amacıyla kullanılan matematiksel hesaplama yöntemleridir. Bu göstergelerin çoğu, fiyat hareketlerinin gelecekteki yönünü tahmin etmeye yönelik öngörüler sunmayı amaçlarken, bazıları ise mevcut trendin sürekliliğini değerlendirmeye odaklanmaktadır. Her bir gösterge, belirli bir zaman periyodu için kendine özgü matematiksel formüllerle hesaplanmaktadır. Göstergelerin matematiksel temelli yapısı, yatırım kararlarında subjektif yorumların etkisini minimize ederek, daha objektif bir analiz çerçevesi sunmaktadır. (Colby ve Meyers, 1988).

Günümüzde yapay zeka ve makine öğrenimi teknolojilerinin gelişimiyle birlikte, teknik göstergeler daha da önem kazanmıştır. Özellikle LSTM ve ARIMA gibi zaman serisi analiz modelleri, teknik göstergelerin ürettiği verileri kullanarak daha sofistike tahmin modelleri oluşturabilmektedir. Bu göstergeler, modeller için önemli giriş

değişkenleri olarak kullanılarak, piyasa hareketlerinin daha doğru tahmin edilmesine olanak sağlamaktadır.

Teknik göstergelerin en önemli özelliklerinden biri, piyasadaki tüm bilginin fiyatlara yansıdığı varsayımına dayanmasıdır (Orçun, 2010, s.31). Bu yaklaşım, temel analizden farklı olarak, şirket veya ekonomi ile ilgili diğer faktörleri doğrudan değerlendirmeye almaz. Bunun yerine, fiyat ve hacim verilerinin matematiksel analizi üzerine yoğunlaşmaktadır. Bu özellik, özellikle makine öğrenimi modellerinde kullanım için uygun bir yapı oluşturmakta, çünkü verilerin sayısallaştırılmış ve standartlaştırılmış olması, modellerin eğitimi için ideal bir temel sağlamaktadır.

Teknik göstergelerin bir diğer önemli yönü, farklı zaman dilimlerinde analiz yapabilme esnekliği sunmasıdır. Göstergeler, gün içi verilerden aylık verilere kadar çeşitli periyotlarda hesaplanabilir, bu da farklı yatırım stratejileri için uygun analiz imkânı sağlamaktadır. Bu esneklik, yapay zeka modellerinin farklı zaman ölçeklerinde tahmin yapabilmesine olanak tanımakta ve modellerin adaptif öğrenme kabiliyetini artırmaktadır.

Bu tez çalışmasında girdi değişkeni olarak kullanılan ve literatürde de genel kabul görmüş on teknik gösterge aşağıda detaylı bir şekilde anlatılacaktır.

3.4.1. Hareketli Ortalama (Moving Average, MA)

Hareketli ortalama teknik analizde sıklıkla kullanılan en önemli göstergelerden biridir. İlgili varlığın belli bir zaman aralığındaki fiyat değişimlerinin ortalamasını ifade eder. Hareketli ortalama finansal varlığın fiyat trendinin yönünü belirlemekte ve yatırımcının alım satım kararlarına rehberlik ederek stratejik karar kalma süreçlerini desteklemektedir (Ali vd. 2015).

Hareketli ortalamalar, piyasa trendinin yönünü belirlemenin yanı sıra, fiyat değişkenliğini (volatilitiyi) daha düzgün bir çizgiye indirgemek, böylece ana trendleri daha net bir şekilde ortaya koymak ve fiyatın tepe ve dip noktalarını tespit etmek gibi işlevler de üstlenmektedir (Pring, 2002, s.154).

Hareketli ortalamalarda kullanılacak zaman aralığı kısa veya uzun vadeli olarak yapılan yatırımlara göre değişmektedir Hareketli ortalamalar için 10 günlük periyot çok

kısa vadeyi, 200 günlük periyot ise uzun vadeyi ifade etmektedir. Hareketli ortalamaların hesaplanmasında genel olarak kullanılan üç temel hesaplama yöntemi bulunmaktadır. Basit hareketli ortalama, ağırlıklı hareketli ortalama ve üstel hareketli ortalama daha çok kullanılan hesaplama yöntemleri arasında yer almaktadır (Marple Jr, 2019, s.288-289).

Basit hareketli ortalama yöntemi, seçilen zaman dilimindeki tüm değerlerin eşit ağırlığa sahip olduğu bir hesaplama yaklaşımıdır. Yöntemin güvenilir ve basit olması ayrıca geçmiş fiyatların mevcut fiyatlardan ne kadar farklılaştığını ya da saptığını hesaplaması popülerliğinin başlıca nedenlerindendir. C_t kapanış fiyatını ifade ederken, hareketli ortalama aşağıdaki $MA = \frac{C_t + C_{t-1} + \dots + C_{t-n}}{n}$

(3.14 ile hesaplanmaktadır (Kristoufek 2014).

$$MA = \frac{C_t + C_{t-1} + \dots + C_{t-n}}{n} \quad (3.14)$$

Örneğin, 10 günlük bir basit hareketli ortalama hesaplanırken, geriye dönük olarak 10 günün kapanış fiyatları toplanır ve elde edilen toplam 10'a bölünerek ortalama değer bulunur.

Hareketli ortalama, özellikle trend gösteren piyasalarda etkili bir analiz yöntemi olarak değerlendirilmektedir. Hareketli ortalamaların en yaygın kullanım şekli, fiyatın ortalamayı aşağı yönde kırması durumunda satış, yukarı yönde kırması durumunda ise alış sinyali olarak yorumlanmasıdır. Ayrıca, fiyatın hareketli ortalamasının altında bulunması ayı piyasasına, hareketli ortalamasının üzerinde seyretmesi ise boğa piyasasına işaret eden bir teyit göstergesi olarak kullanılabilir (https://forex.com.tr)

3.4.2. Ağırlıklı Hareketli Ortalama (Weighted Moving Average, WMA)

Ağırlıklı hareketli ortalama teknik analizde sıkça tercih edilen, hareketli ortalamalar başlığı altında en yaygın kullanılan üç yöntemden biridir. Bu yöntem; istenilen periyotlarda son günlerdeki kapanış fiyatlarına fazla ağırlık verilerek hesaplanan hareketli ortalama türü olarak tanımlanabilir (Lucas ve Saccucci, 1990, s.1). Ağırlıklı hareketli ortalama, basit hareketli ortalamasının yetersiz kaldığı düşüncesiyle geliştirilmiştir. Basit hareketli ortalamalarda geçmiş günlere ait kapanış fiyatları eşit olarak dikkate alınırken ağırlıklı hareketli ortalamalarda son günlere ait fiyatlara ağırlık

verilerek değerlendirme yapılmaktadır. Ağırlıklı hareketli ortalama aşağıdaki denklem 3.16. ile hesaplanır (Lowry vd., 1992, s.47).

$$WMA = \frac{((n) * Ct + (n - 1) * Ct-1 + \dots + Ct-n)}{(n + (n - 1) + \dots + 1)} \quad (3.15)$$

Örneğin beş günlük ağırlıklı hareketli ortalamayı hesaplamak için, seçilen beş günün kapanış fiyatlarına ağırlık katsayıları uygulanır. İlk günün kapanış fiyatı 1 ile, ikinci günün kapanış fiyatı 2 ile, üçüncü gün 3 ile, dördüncü gün 4 ile ve beşinci gün 5 ile çarpılarak ağırlıklandırılır. Elde edilen bu beş değer toplanarak ağırlıklı bir toplam oluşturulur. Ardından, bu ağırlıklı toplam, kullanılan katsayıların toplamı olan 15'e bölünerek beş günlük ağırlıklı hareketli ortalama değeri hesaplanır.

3.4.3. Hareketli Ortalamalar Yakınlaşma-Uzaklaşma Göstergesi (Moving Average Convergence Divergence, MACD)

Trendleri takip etmek için 1979 yılında Gerald Appel tarafından geliştirilen ve teknik analizde en çok tercih edilen ve en etkili göstergelerden biri olan MACD, fiyatların iki farklı hareketli ortalaması arasındaki ilişkiyi ifade eden bir momentum göstergesidir. 26 günlük üssel hareketli ortalamasının 12 günlük üssel hareketli ortalamadan çıkartılması MACD olarak ifade edilir (Appel 2003). Bunun yanı sıra bu göstergeyle birlikte, "signal" veya "trigger" çizgisi olarak ifade edilen 9 günlük üssel hareketli ortalama da grafik üzerinde gösterilir. MACD eğrisinin bu hareketli ortalamayı yukarı yönde kestiği noktalar alım, aşağı yönde kestiği noktalar ise satım sinyali olarak değerlendirilir (Günak, 2007, s.135).

MACD göstergesi sıfır seviyesinde dengededir ve hareket yönü sıfır seviyesinin altına veya üzerine doğru gerçekleşir. MACD, genellikle 12 ve 26 günlük üssel hareketli ortalamalar kullanılarak hesaplanır. Eğer 12 günlük ortalama değer, 26 günlük ortalamasının üstüne çıkarsa MACD sıfır seviyesinin üzerine yükselir bu ise kısa vadeli işlemlerin uzun vadeli işlemlere kıyasla daha güçlü hale geldiğini gösterir. Öte yandan 12 günlük ortalamasının 26 günlük ortalamasının altında olması durumunda, MACD sıfır seviyesinin altına iner ve bu durumda uzun vadede satışların artacağını ifade eder (Chong ve Ng, 2008, s.1112).

Son olarak MACD göstergesi ile fiyat hareketleri arasındaki uyumsuzluk durumundan bahsedilebilir. Bu uyumsuzluk mevcut trendin sona ereceğini işaret eden bir durum olarak değerlendirilir. Eğer MACD yeni düşük seviyelere ulaşırken fiyatlar bu düşük seviyeleri test edemezse, düşüş trendinin sona ermesi beklenir. Benzer şekilde, MACD yeni yüksek seviyelere ulaşırken fiyatların yeni yüksek seviyelere erişememesi, yükseliş trendinin sonlanabileceğini gösterir. MACD denklem $MACD = EMA_{12} - EMA_{26}$ (3.167. ile hesaplanmaktadır (Fernández-Blanco vd. 2008).

$$MACD = EMA_{12} - EMA_{26} \quad (3.16)$$

EMA: Üssel Hareketli Ortalama

3.4.4. Mal Kanalı Endeksi (Commodity Channel Index, CCI)

CCI, 1980 yılında Donald Lambert tarafından geliştirilen, geçmiş döneme ait fiyat hareketleri ortalamasının, güncel olan fiyat ile farkının hangi uzaklıkta olduğunu ortaya koymaktadır. Lambert CCI için 5 ile 25 günlük periyotların kullanılmasını önermektedir (Erdoğan 2023, s.267). İlgili gösterge için sıfır çizgisi merkez olarak ve -100 ile +100 referans değerler olarak kabul edilir. 100' ün altı aşırı satım, +100'ün üstü aşırı alım bölgesi olarak ifade edilmektedir (Lambert, 1983, s.2). Fakat, CCI'nın hızlı değişim göstermesi nedeniyle, küçük dalgalanmalarda bile referans noktalarını geçmesi mümkündür. Bu özelliğinden dolayı, genellikle kısa vadeli trend değişimlerini belirlemek için kullanılmaktadır (Hsu 2011).

CCI, piyasalarda geçmiş fiyatlardan yararlanırken, güncel fiyatların örüntüsünü koruma amacıyla üssel hareketli ortalamalar yerine basit hareketli ortalamaları kullanmaktadır. Aşağıdaki dört temel adımda hesaplanmaktadır (Lambert, 1983, s.120-124).

1. Her gün için ortalama fiyat hesaplanır.

$$M_t = \frac{H_t + L_t + C_t}{3} \quad (3.17)$$

L_t : En Düşük Fiyat, H_t : En Yüksek Fiyat

2. Seçilen periyot için ortalama fiyat hesaplanır.

$$SM_t = \frac{\sum_{i=1}^n M_{t-i+1}}{n} \quad (3.18)$$

3. Ortalama sapma hesaplanır.

$$D_t = \frac{\sum_{i=1}^n |M_{t-i+1} - SM_t|}{n} \quad (3.19)$$

4. M_t son günün ortalama değeri olmak üzere

$$CCI = \frac{M_t - SM_t}{0.015 D_t} \quad (3.20)$$

3.4.5. Göreceli Güç Endeksi (Relative Strength Index, RSI)

Göreceli Güç Endeksi, 1978 yılında J. Welles Wilder Jr. tarafından New Concepts in Technical Trading Systems adlı kitabında tanımlanmıştır. RSI, n-periyotluk yukarı yönlü kapanışların hareketli ortalamasının, n-periyotluk aşağı yönlü kapanışların hareketli ortalamasına oranı ile hesaplanmaktadır ve aşağıdaki denklem 3.22. ile ifade edilmektedir (Siegel vd., 2014, s.180).

$$RSI = 100 - \frac{100}{(\sum_{i=0}^{n-1} Up_{t-i}/n) / (\sum_{i=0}^{n-1} Dw_{t-i}/n)} \quad (3.21)$$

Up_t : Yukarı Doğru Fiyat Değişim Ortalaması

Dw_t : Aşağı Doğru Fiyat Değişim Ortalaması

Aşırı alış ve aşırı satışı ortaya koyan en etkili momentum osilatörlerinin başında gelen RSI, oldukça basit ve anlaşılır bir yapıda olmasına rağmen en yaygın kullanılan ve geçerliliği yüksek göstergelerden biridir. İlgili gösterge için önerilen kullanım periyodu 14 günlük periyottur (Günak, 2007, s. 166).

RSI, yatırım araçlarını belirli bir dönemin geçmiş değerleriyle karşılaştırma yaparak değerlendirir. Hesaplanarak oluşturulan bu gösterge 0-100 aralığında bir değer alır. İlgili gösterge için 30 ve 70 değer aralığı referans olarak ifade edilir. RSI değeri 30 seviyesinin altında kalıyorsa aşırı satım, 70 seviyesinin üzerine çıkıyorsa aşırı alım

olduğunun göstergesidir ve bu durumda fiyat hareketlerinin farklılık göstereceği sinyali verilmiş olur (Klassen, 2005, s.77).

RSI çizgisinin 30 referans seviyesini yukarı doğru kırması, alış sinyali, 70 referans seviyesinin aşağı yönlü kırılması ise satış sinyali olarak kabul edilir (Günak, 2007, s.166). RSI hesaplanırken ilgili periyottaki günlerin azalış ve yükselişleri farklı farklı toplanarak ortalamaları alınır ve eldeki mevcut fiyat düzeyi ile karşılaştırılır. Bu sayede ilgili enstrümanın kendi gücüyle talebi karşılayıp karşılayamayacağını görülür. Göstergenin esas amacı önceki günlerin fiyat ortalamalarıyla yatırım aracının fiyat dalgalanmalarını anlayabilmek ve bugünkü taleplerin oluşturacağı etkiyi belirlemektir (Ṫaran-Morořan 2011).

3.4.6. Stokastik %K (Stochastic %K)

Stokastik George Lane tarafından geliştirilmiş olan Stokastik %K, gelecekteki fiyatların geçmişteki kapanış fiyatlarına yakın seviyelerde gerçekleşeceği varsayımıyla teknik analiz yapılmasına olanak tanıyan bir göstergedir (Lane 1985).Stokastik, mevcut fiyatı belirli bir periyot boyunca kaydedilen fiyat düzeyleriyle karşılařtıran bir göstergedir. Olası dönüş noktalarını tespit etmek amacıyla destek ve direnç noktaları, stokastik analizinin temel bileřenleri arasında yer almaktadır (Thomsett 2012).

Kısa vadede alım-satım yapan yatırımcıların karşılařtıkları kayıpları minimize etmek amacıyla geliştirilmiş araçlardan biri stokastik göstergedir. Bu gösterge, bir salınım göstergesi türü olup, fiyatların aşırı alım ve aşırı satım bölgelerini tespit etmek için kullanılmaktadır (Tomakin 2007).

Stokastik göstergesi, hisse senedi fiyatının belirli bir dönemde ulařtığı fiyat düzeylerine yakın bir noktada kapanacağı varsayımına dayanan bir analiz aracıdır. Bu durumda fiyatlar yükseliř eğilimindeyse kapanış fiyatının seçilen dönem içinde kaydedilen en yüksek seviyeye yakın gerçekleşmesi, fiyatlar düşüş eğilimindeyse kapanış fiyatının aynı dönem içerisindeki en düşük seviyeye yakın olması beklenir. Alım-satım kararları da bu temel varsayıma göre şekillendirilir (Erdiñç, 1996, s.178).

Stokastik göstergesi grafik üzerinde kullanıldığında, birbirine bağılı şekilde ve 0 ile 100 arasında salınım yapan iki ayrı çizgi ortaya çıkar. Bu çizgilerden biri, kesiksiz düz

bir çizgiyle gösterilen ve %K eğrisi olarak isimlendirilen hattır. Diğer ise kesikli çizgiyle temsil edilen ve %D çizgisi olarak isimlendirilen hattır. %K çizgisi yavaşlatılmış değişim değerlerini ifade ederken, %D çizgisi daha dinamik ve duyarlı bir yapı sergiler (Sihabuddin, Rosadi ve Wibowo, 2009).

İlgili gösterge için alt sınır 20 iken 80 ise üst sınırı ifade etmektedir. 0-20 aralığı aşırı satım, 80-100 aralığı ise aşırı alım olduğunun göstergesidir. Stokastik K denklem 3.23. ile hesaplanmaktadır (Hsu 2011).

$$\%K = \frac{C_t - LL_{t-n}}{HH_{t-n} - LL_{t-n}} * 100 \quad (3.22)$$

HH_t : Son t gün için maksimumların maksimum değeri

LL_t : Son t gün için minimumların minimum değeri

3.4.7. Stokastik % D (Stochastic % D)

Yavaşlatılmış %K eğrisi, belirli bir dönem için hesaplanan %K eğrisinin ortalamasını ifade eder. Aynı şekilde, bu döneme ait hareketli ortalama ise %D eğrisi olarak adlandırılır. Lane, stokastik (%K)'nın 3-periyotluk basit hareketli ortalaması ile stokastik (%D)'nin hesaplandığını belirtmektedir (Lane 1985). %D çizgisi kesikli çizgiyle temsil edilir ve sinyal çizgisi olarak adlandırılır. Fiyatlar yükselirken gösterge ters yönde hareket ediyorsa, bu durum fiyatların düşüş eğilimine girebileceği anlamını taşımaktadır (Sihabuddin vd. 2009).

Alım-satım sinyalleri, Stokastik %D'nin yukarı yönlü kesilmesi durumunda alım, aşağı yönlü kesilmesi durumunda ise satım yapılabileceğini göstermektedir ve Stokastik % D denklem 3.24. ile hesaplanmaktadır (Kim 2003).

$$\%D = \frac{\sum_{i=0}^{n-1} K_{t-i}}{n} \% \quad (3.23)$$

3.4.8. Williams'ın %R Göstergesi (Williams' %R)

Williams'ın %R göstergesi, aşırı alım ve aşırı satım bölgelerini belirlemeye yönelik bir momentum göstergesidir. Larry Williams tarafından geliştirilen gösterge

hesaplanma yöntemi ve yorumlanma şekliyle stokastik osilatöre büyük ölçüde benzerlik göstermektedir (Murphy 1999). Gösterge -100 ile 0 arasında değerler alır. Eğer değer -80 referans değerinin altına inerse piyasanın aşırı satım, -20'nin üstüne çıkarsa aşırı alım bölgesinde olduğunu gösterir. Bu göstergenin bir değer özelliği de fiyatlardaki olası dönüşleri tahmin edebilmesidir. Genellikle, piyasa fiyatlarının tepe yapmasından ve yön değiştirmesinden birkaç gün önce, Williams'ın %R göstergesi de bir tepe noktası ve dönüş oluşturur (Siegel vd.,2014, s.342). Bu nedenle, göstergenin fiyat hareketlerinden önce dalgalanma ve dönüşler gerçekleştirmesi, yatırımcılar için önemli bir öngörü aracı sunmaktadır.

Williams'ın %R, periyot ve değerlerine ek olarak değerler arasındaki uyumsuzlukları da analiz etmektedir. Bu kapsamda fiyatların en yüksek ve en düşük seviyeleri dikkate alınarak Williams %R açısından yükseliş trendindeki en yüksek ve en düşük fiyatlarla düşüş trendindeki en yüksek ve en düşük fiyatların karşılaştırılması ve değerlendirmesi yapılmalıdır (Achelis 2001).

Ayrıca Williams'ın %R göstergesine göre girilecek pozisyonun sinyali alınabilmektedir. Gösterge hareketli ortalamasını yukarı yönde keserek üzerine çıkarsa uzun, aşağı yönde kestiğinde ise kısa pozisyona girme sinyalini almış oluruz. Williams %R denklem 3.25 ile hesaplanmaktadır (Steele ve Esmahi, 2015).

$$\%R = \frac{H_n - C_t}{H_n - L_n} * (-100) \quad (3.24)$$

H_n = Periyottaki en yüksek fiyat

L_n = Periyottaki en düşük fiyat

3.4.9. Momentum Göstergesi (Momentum Indicator - MOM)

Momentum Göstergesi, teknik analizde belirlenen zaman dilimi boyunca fiyatların hareket yönünü, hızını ve kuvvetini ölçmek amacıyla kullanılmaktadır. Gösterge, hem trend yönlü piyasalarda hem de fiyatların dar bir bantta hareket ettiği yatay piyasalarda etkin bir şekilde kullanılabilen bir göstergedir (Perşembe, 2013, s.149).

Momentum göstergesi, bugünkü kapanış fiyatını belirli bir periyot önceki kapanış fiyatıyla karşılaştırarak, mevcut fiyat seviyesinin geçmiş fiyat seviyesine göre konumunu değerlendirir (Özekşi, 2005, s. 289).

Momentum göstergesi, belirli bir referans değeri veya orta seviyeyi baz alır ve bu değer %100 olarak kabul edilir. Gösterge, bu referans seviyesinden uzaklaştıkça piyasa koşullarında zıt yönde hareketlerin meydana gelebileceğini işaret eder. Orta seviyeden uzak yerde tepe noktası oluşturan ve sonrasında geri dönen fiyatlar hareketleri, yatırımcılar için al- sat sinyali oluşturmaktadır (Inghelbrecht vd. 2012). Momentum göstergesinin referans değerini yukarı yönlü kesmesi, alım sinyali; aşağı yönlü kesmesi ise satım sinyali olarak yorumlanmaktadır (Tomakin 2007).

Momentum göstergesindeki negatif uyumsuzluk, RSI göstergesinde olduğu gibi fiyat hareketlerinin gelecekteki yön değişimlerini öngörmek amacıyla kullanılabilir. Fiyat ile momentum göstergesi arasında bir uyumsuzluk oluştuğunda, mevcut fiyat trendinin yön değiştirme olasılığı düşünülebilir, bu gösterge denklem 3.26. ile hesaplanmaktadır (Hsu 2011).

$$MOM = C_t - C_{t-n} \quad (3.25)$$

3.4.10. Birikim /Dağıtım Göstergesi (Accumulation/Distribution, A/D Line)

A/D Göstergesi, fiyatlarda meydana gelen değişimlerin yüksek işlem hacmiyle desteklenmesi durumunda, trendin gücünün arttığını ve bu trendin devamlılığını değerlendirmeye yönelik bir göstergedir (Achelis 2001). Diğer bir ifadeyle işlem hacmi ne kadar yüksekse, fiyat hareketlerinin o kadar güçlü bir trendi yansıttığı ve bu trendin devam etme ihtimalinin yüksek olduğu varsayılır.

A/D göstergesinin hesaplanması, kapanış fiyatı ile gün içindeki en düşük fiyat arasındaki farktan, günün en yüksek fiyatı ile kapanış fiyatı arasındaki farkın çıkarılmasıyla başlar. Bu fark, günün en yüksek fiyatı ile en düşük fiyatı arasındaki farka bölünür ve para akış çarpanı elde edilir. Daha sonra bu çarpan işlem hacmi ile çarpılarak para akış hacmi bulunur. Elde edilen değerler toplanarak A/D göstergesi bulunur. Gösterge, her gün bir önceki güne eklenerek kümülatif bir şekilde hesaplanır. (Achelis 2001).

Bu hesaplama yöntemi çerçevesinde, kapanış fiyatı gün içerisindeki en yüksek fiyata yaklaştıkça A/D göstergesinin değeri artış gösterecektir. Bu durum, yatırımcıların alım (toplama) eğiliminin güçlü olduğunu ve piyasadaki talebin baskın hale geldiğini göstermektedir. Kapanış fiyatı gün içerisindeki en düşük fiyata yaklaştıkça ise A/D göstergesinin değeri düşecektir. Bu azalma, piyasada satış (dağıtım) baskısının ağırlık kazandığını ve yatırımcıların varlıklarını elden çıkardığını işaret etmektedir. Bunların yanı sıra kapanış fiyatı gün içerisindeki en yüksek ve en düşük fiyatlara eşit mesafede olması durumunda A/D göstergesi aynı kalacaktır. Bu durum, fiyat hareketlerinin ve işlem hacminin denge durumunda olduğunu, piyasada belirgin bir toplama veya dağıtım baskısının oluşmadığını ifade etmektedir. A/D göstergesi denklem 3.27. ile hesaplanmaktadır (Steele ve Esmahi, 2015).

$$A/D = \sum \frac{(C_t - L_t) - (H_t - C_t)}{H_t - L_t} * Hacim \quad (3.26)$$

3.5 BORSA ENDEKS TAHMİNİNE İLİŞKİN LİTERATÜR TARAMASI

Finansal piyasalarda tahminleme yatırımcıların karar alma süreçlerini iyileştirmek ve risk yönetimini optimize etmek amacıyla uzun yıllardır önemli bir araştırma alanı olmuştur. Günümüzde geleneksel yöntemlerin yanı sıra makine öğrenme yöntemlerinin de bu alanda yoğun bir şekilde kullanılması piyasa dinamiklerinin daha hassas ve doğru bir şekilde modellenmesini sağlamaktadır. Bu kapsamda literatürde yer alan çalışmaların incelenmesi, kullanılan yöntemlerin etkinliğini değerlendirmek ve mevcut araştırmalara katkı sağlaması açısından önem arz etmektedir. Çalışmanın bu kısmında yurt dışında ve Türkiye'de borsa endeks ve hisse senedi tahminini geleneksel modellerden ARIMA derin öğrenme yöntemlerinden ise LSTM modelini kullanan çalışmalara yer verilmiştir.

3.5.1. Borsa Endeks Tahminine İlişkin Türkiye' de Yapılan Çalışmalar

Yayar ve Karaca (2011) çalışmalarında, İMKB Sınaî Endeksinin hareket yönünü Box-Jenkins modeli kullanarak tahmin etmişlerdir. Çalışmada veri seti olarak ilgili endeksin Ocak 1997-Aralık 2009 dönemine ait aylık kapanış verileri kullanılmıştır. Bu kapsamda İMKB Sınaî Endeksi'nin enflasyondan arındırılmış 156 aylık verileri ve uygulanan model yardımıyla 2010 yılı ilk altı aylık sınai endeks değerleri tahmin

edilmiştir. Elde edilen bulgulara göre tahmin edilen değerlerin gerçekleşen değerlere yakın olduğu ifade edilmiş ve modelin kısa vadeli tahmin performanslarında daha başarılı sonuçlar sergilediği vurgulanmıştır.

Altıntop (2016) çalışmasında, teknik göstergeler, yurtdışı borsa endeksleri, makroekonomik göstergeler ve haftanın günleri gibi değişkenleri girdi verisi olarak kullanıp BIST 100 endeksinin yönünü tahmin etmiştir. Endeks yönü tahminini dalgacık dönüşümü ve destek vektör makineleri yöntemlerini birlikte kullanarak gerçekleştirmiştir. Çalışma sonucuna göre dalgacık dönüşümünün destek vektör makinelerinin tahmin düzeyini önemli ölçüde artırdığı ortaya konulmuştur.

Özkan ve Güngör (2017) çalışmalarında, 2005-2015 yıllarına ait endeks kapanış değerlerini kullanarak BIST-30, BIST 100 ve S&P 500 endekslerini tahmin etmişlerdir. İlgili endeks tahminleri için Geometrik Brownian Hareketi yaklaşımına dayalı bir model kullanılmıştır. Elde edilen tahmin sonuçları geleneksel ARIMA yaklaşımı kullanılarak karşılaştırma sağlanmıştır. Çalışma sonucuna göre Geometrik Brownian Hareketi Modelinin ilgili endeks değerlerinin tahmini için daha uygun olduğu tespit edilmiştir.

Gunduz, Cataltepe, ve Yaslan (2017) çalışmalarında, BİST’de sık işlem gören GARAN, THYAO ve ISCTR olmak üzere üç hisse senedinin günlük hareket yönlerini derin sinir ağları yöntemlerini kullanarak tahmin etmişlerdir. 2011-2015 dönemini içeren çalışmada bireysel hisse senedi fiyatlarından ve dolar – altın fiyatlarından oluşan teknik göstergeler girdi olarak kullanılmıştır. Yapılan sınıflandırma doğruluk ve F-measure metrikleri kullanılarak değerlendirilmiştir. Değerlendirme neticesinde hisse senetlerinden GARAN 0,61, THYAO 0,578 ve ISCTR 0,574 doğruluk oranları ile tahmin edilmiştir.

Değirmenci ve Akay (2017) çalışmalarında, BİST 100, altın, döviz ve petrol fiyatları geleneksel zaman serisi yöntemlerinden Box-Jenkins modelleri ve ARCH modeli ile öngörmeye çalışmışlardır. Çalışmada bu değişkenlere ait 01.02.2009-11.25.2016 tarihleri arasını kapsayan haftalık veri seti kullanılmıştır. Yapılan analiz neticesinde altın fiyatları dışında kalan diğer tüm değişkenlerde asimetric etkinin varlığı tespit edilmiştir. Çalışmada ayrıca ARCH modellerinden elde edilen öngörülerine ilişkin Theil istatistiklerinin sıfıra oldukça yakın olduğu belirlenmiştir.

Kara (2019) çalışmasında, Borsa İstanbul 100 Endeksi hareket yönünü çeşitli teknik göstergeleri girdi verisi olarak kullanarak tahmin etmiştir. Endeks yönü tahmininde makine öğrenme yöntemlerinden yapay sinir ağları, destek vektör makineleri, karar ağaçları, naive bayes, k-en yakın komşuluk yöntemleri kullanılırken lojistik regresyon ve doğrusal diskriminant analizi gibi istatistiksel yöntemler kullanılmıştır ve ilgili sınıflandırma yöntemlerinin performansı karşılaştırılmıştır. Modellerin karşılaştırılmasında doğruluk ve hata oranlarının ölçüt olarak kullanıldığı çalışmanın sonucuna göre yapay sinir ağları endeks hareket yönü tahmininde en iyi yöntem olarak tespit edilmiştir.

Sakarya ve Yılmaz (2019) çalışmalarında, 02.01.2001 ile 31.12.2018 aralığına ait verilerle derin öğrenme mimarisini kullanarak BİST 30 Endeksinin günlük hareket tahminini çeşitli girdi verileri kullanarak gerçekleştirmeye çalışmışlardır. Çalışma da önerilen bütünleşmiş sistemin %80 doğruluk oranıyla tatmin edici düzeyde olduğu tespit edilmiştir.

Gündüz (2019) çalışmasında, BİST 100’de yer alan hisse senetlerinin günlük ve saatlik yön tahminleri yapay ve derin öğrenme modelleriyle gerçekleştirilmiştir. Çalışmada, borsa tahmininde derin öğrenme modellerinin, yapay öğrenme modellerine güçlü bir alternatif olarak belirtilmiş ve sunulan farklı derin öğrenme yöntemlerinin performans düzeyi, destek vektör makineleri ve lojistik regresyon yöntemlerine üstünlük sağlamıştır. Ayrıca yöntemlerde heterojen veri kaynaklarının (Fiyat-Haber) kullanılması performans düzeyini artırmamıştır.

Şişmanoğlu vd. (2020) yapmış oldukları çalışmada, LSTM, GRU, BLSTM olmak üzere 3 ayrı derin öğrenme modelini kullanarak 2 Ocak 1968-9 Nisan 2018 dönemine ait verilerle New York Borsasında yer alan IBM hisse senedinin fiyat tahminini gerçekleştirmişlerdir. Ayrıca modellerin karşılaştırmalı analizi yapılmıştır. Yapılan analizler neticesinde 5 günlük girdilerle eğitilen BLSTM modelinden %63,54’lük bir yönsel doğruluk değeri ve 0,001’lik RMSE değeri ile tatmin edici sonuçlar elde edilmiştir.

Hasan (2020) BIST 100 endeksinin yönünü tahmin etmek amacıyla yapmış olduğu çalışmada, makine öğrenme ve derin öğrenme yöntemlerini karşılaştırmalı olarak incelemiştir. Çalışmada girdi değişkeni olarak teknik göstergelerden oluşan bir veri seti kullanılmıştır. Sınıflandırma işlemleri için destek vektör makinesi, lojistik regresyon,

rastgele orman ve derin sinir ağıları yöntemleri uygulanmıştır. Modellerin performans değerlendirmesi karışıklık matrisi, bileşik getiri ve maksimum düşüm metrikleri kullanılarak değerlendirilmiş olup önerilen derin sinir ağıları modelinin daha düşük eşik değerleri ile kısa vadeli tahminlerde diğer modellere kıyasla daha başarılı olduğu ortaya konulmuştur.

Güteryüz, Özden ve Gülhan (2021) çalışmalarında, BIST30 Endeksini tahmin etmek üzere klasik istatistiki tahmin yöntemlerinden ARIMA modeli ile yapay zekâ tabanlı LSTM modelini kullanarak sonuçların karşılaştırmasını yapmışlardır. Çalışmanın veri seti, 4 Ocak 2000-22 Mayıs 2020 dönemine ilişkin 20 yıllık günlük verilerden oluşmaktadır. İlgili verilerin %80 i eğitim, %20 si test seti olarak kullanılmıştır. Gerçekleştirilen analizlerde, LSTM tabanlı algoritmanın geleneksel yöntemle göre %26.34 oranında daha iyi sonuç verdiği tespit edilmiştir.

Taş, Gülüm ve Tulum (2021) yapmış oldukları çalışmada S&P 500 endeksine ait verileri kullanarak geleceğe yönelik fiyat tahmini gerçekleştirmişlerdir. Bu amaca yönelik olarak 12.08.2000 ve 13.08.2020 tarihleri arasındaki endeks verileri ile LSTM ve çok katmanlı algılayıcılar (MLP) modelleri kullanılmış ve modellerden elde edilen sonuçlar karşılaştırılmıştır. Elde edilen tahmin sonuçları RMSE ve MSE değerlerine göre değerlendirilmiştir. Buna göre LSTM modelinin tahmin performansı MLP modeline kıyasla daha başarılı bulunmuştur.

Çetin ve Metlek (2021) yapmış oldukları çalışmada, İslami hisse senedi piyasasını temsil eden Katılım endeksini tahmin etmek için LSTM modelini kullanmışlardır. Modelde girdi değişkeni olarak endeks tabanlı öznitelikler kullanılmıştır. Endeks tabanlı girdi değişkenleri doğrultusunda birçok parametre tek bir endeks değeriyle modele dâhil edilmiştir. İlgili modelde değerlendirme kriterleri olarak kullanılan MAE, RMSE, MAPE ve R^2 değerleri sırasıyla 0,06, 0,08, 0,02 ve 0,994 olarak tahmin edilmiştir.

Arslankaya ve Toprak (2021) çalışmalarında, makine öğrenme yöntemlerinden Polinom Regresyon ve Random Forest regresyon derin öğrenme yöntemlerinden LSTM ve RNN yöntemlerini kullanarak hisse senedi fiyat tahmini gerçekleştirmişlerdir. İlgili tarih aralığındaki hisse senedine ait kapanış değerleri ve günler veri seti olarak kullanılarak tahmin işlemi gerçekleştirilmiştir. Tahmin sonuçları başarıları değerlendirilirken MSE, MAE ve RMSE ölçütleri kullanılmıştır. Tahmin sonuçlarına

göre RF regresyon modeli en iyi sonucu veren yöntem olarak belirlenirken PR modeli en kötü sonuç veren model olmuştur.

Sarıkoç ve Çelik (2022) yapmış oldukları çalışmada, Borsa İstanbul 100 endeksini derin öğrenme ağı ile tahmin etmeye çalışmışlardır. Veri ön işleme aşamasında bir takım istatistiksel boyut indirgeme yöntemlerini kullanarak derin öğrenme ağı performansına olan etkisi tespit edilmeye çalışılmıştır. İlgili endekse ait günlük veriler ve teknik analiz bilgileri çalışmanın veri setini oluştururken söz konusu veriler ile 5 gün sonraki fiyat tahmini gerçekleştirilmeye çalışılmıştır. Modelin performansı değerlendirilirken R^2 ve RMSE ölçütleri kullanılmış ve elde edilen sonuçlara göre Temel Bileşen Analizi (PCA)+ LSTM hibrit modeli diğer boyut indirgeme yöntemleriyle oluşturulan modellere kıyasla daha yüksek performans göstermiştir. Ayrıca PCA+LSTM modeli, LSTM modelinin elde ettiği sonuçlardan daha yüksek oranda tahmin düzeyi göstermiştir.

Aker (2022) çalışmasında, LSTM ve Fbprophet yöntemlerini kullanarak BİST 100 endeks verilerini tahmin etmeye çalışmıştır. Araştırma 01-01-2021 ile 31-12-2021 dönemini kapsayan endeks verileri üzerinden yapılmış olup, modelin başarı metrikleri MAE, MSE, RMSE olarak ele alınmıştır. Çalışmanın deneysel sonuçlarına göre daha düşük hata oranları ile LSTM modelinin Fbprophet modelinden daha yüksek tahmin performansı gösterdiği ortaya konulmuştur.

Dalkiran ve Ozan (2022) yapmış oldukları çalışmada, Borsa İstanbul'da işlem gören İş Bankası A.Ş (ISCTR) hisse senedinin günlük fiyat tahminini hisseye ait uzun dönem verileri ile gerçekleştirmişlerdir. Bu verilere ek olarak tahmin başarısını artırmak için VAKBN, AKBNK, GARAN, QNBFB hisse senetleri ile USD/TRY, BIST30, Borsa İstanbul Bankacılık Endeksi (BANKX) endekslerine ait geçmiş verileri de kullanılmıştır. İlgili çalışmada LSTM Modeli Adam ve RMSProp optimize edicileri ile birlikte kullanılarak analiz işlemi gerçekleştirilmiştir. Elde edilen analizler neticesinde tahmin başarısının tatmin edici düzeyde olduğu ortaya konulmuştur.

Akbulut ve Kemal (2023) yapmış oldukları çalışmada, Ocak 2017 ve Ekim 2021 tarihleri arasındaki döviz ve emtia piyasaları ile gelişmekte olan ülkelerin borsa endekslerinin verilerinden yararlanarak makine öğrenmesi ve derin öğrenme yöntemleriyle BIST 100 piyasa hareketlerini tahmin etmişlerdir. Makine öğrenme yöntemlerinin tahmin değeri ile LSTM yönteminin tahmin değeri karşılaştırıldığında

LSTM modelinin daha etkili olduđu sonucuna varılmıştır. LSTM modelinin performans metrikleri MAE, RMSE, RAE değeri için sırasıyla 10.27, 14.15 ve 6.06 olarak saptanmıştır.

Özden (2023) çalışmasında, Tarımsal Girdi Fiyat Endeksini tahmin etmek üzere istatistik yöntemlerden ARIMA, SARIMA modellerini, derin öğrenme yöntemlerinden ise CNN ve LSTM modellerini kullanmıştır. Çalışmada değerlendirme ölçütü olarak RMSE, MSE, metrikleri kullanılmış olup, ARIMA modeli için ilgili değeri sırasıyla 0.16409 ve 0.0269247, CNN modeli için ise 0.16994 ve 0.288791 bulunmuştur. En iyi sonuçlar bu iki modelden elde edilmiş ve bunları LSTM modeli izlemektedir.

Albayrak ve Saran (2023), çalışmalarında 28 tane finansal indikatör kullanarak BİST verileri üzerinde gün içi tahminler gerçekleştirmişlerdir. Veriler 100 farklı hisse senedinin saatlik verilerini içermekte olup 2001-2020 dönemini kapsamaktadır. Çalışmada ARIMA modeli üç farklı derin öğrenme modeli olan LSTM, GRU ve dikkat katmalı LSTM ile karşılaştırılmıştır. Arıma modeli ile gerçekleştirilen tahmin sonuçlarında ortalama hata oranı diğer üç derin öğrenme modeline göre daha yüksek olarak hesaplanmıştır. Derin öğrenme modellerinden dikkat katmanlı LSTM modeli en iyi sonuç veren model olmuştur. LSTM modelinden elde edilen sonuçlar GRU modeline yakın sonuçlar olsa da GRU modeli daha yüksek tahmin performansı göstermiştir.

Erden (2023) çalışmasında, BİST-30 endeksine dâhil olan EREGL hissesine ait zaman serisi verilerini tahmin etmek için geleneksel yöntemlerden ARIMA, derin öğrenme yöntemlerinden ise LSTM, GRU ve RNN modellerini kullanmıştır. Çalışmanın veri setini 01.01.2020-09.09.2022 tarih aralığındaki günlük veriler oluşturmaktadır. Analizler sonucu ARIMA modelinin diğer modellere kıyasla daha düşük tahmin performansına sahip olduğu tespit edilmiştir. Derin öğrenme modellerinden elde edilen tahmin sonuçlarına göre en iyi tahmin performansını %93,24 doğruluk oranı ile 5 zaman gecikmeli RNN modelinin sağladığı ortaya koyulmuştur.

Aydın vd. (2024) çalışmalarında, BIST30' da dahil olan THYAO, AKBNK, KCHOL ve KRDMD hisse senetlerinin tahminini ARIMA ve LSTM modellerini kullanarak gerçekleştirmişlerdir. Tahminlemede 20.04.2020 – 24.04.2024 tarihleri arasındaki günlük kapanış fiyatlarını kullanmışlardır. Çalışmanın sonuçlarına göre LSTM modeli ARIMA modeline göre daha yüksek performans göstermiştir. ARIMA modeli

kısa vadeli analizler için uygun bulunurken uzun vadeli analizlerde kritik hatalar ürettiği gözlemlenmiştir. LSTM modelinin ise uzun vadeli bağımlılıkları tahmin etmede gerçeğe yakın değerler ürettiği ortaya konulmuştur.

3.5.2. Borsa Endeks Tahminine İlişkin Yurt Dışında Yapılan Çalışmalar

Adebayo, Sivasamy ve Shangodoyin (2014) hisse senedi piyasası tahmininde en iyi ARIMA modelinin seçimi için yapmış oldukları çalışmalarında, 2002 ile 2012 yılları arasında Botsvana ve Nijerya'dan toplanan üç aylık borsa verileri kullanılmıştır. Modelin tahmin performansının değerlendirmesinde AIC, BIC, HQC, RMSE ve MAE kriterleri kullanılmıştır. Botsvana hisse senedi piyasası için en iyi tahmin modeli ARIMA (3,1,1) ve Nijerya için ise ARIMA (1,1,4) olarak bulunmuştur. En iyi ARIMA modeline ilişkin AIC, BIC, HQC, RMSE ve MAE değerleri Botsvana hisse senedi piyasasında sırasıyla 1.565, 1.864, 1.616, 0.754, 0.618 olarak Nijerya hisse senedi piyasası için ise 2.178, 2.475, 2.219, 0.635, 0.487 olarak tespit edilmiştir.

Banerjee (2014) çalışmasında, Hindistan borsasına ait Sensex endeksinin aylık kapanış verilerini kullanarak endeksin gelecekteki gözlemlenmemiş değerlerini tahmin etmeye çalışmıştır. 2007-2012 yıllarına ait verileri kullanarak ARIMA modeli yardımıyla analiz gerçekleştirilmiş olup analiz için en uygun model ARIMA (1, 0,1) olarak belirlenmiştir. Modeli kurmak için 2013 yılı sensex verileri ile doğrulama tekniği oluşturulmuştur.

Rathnayaka vd. (2015) çalışmalarında, Sri Lanka Colombo Menkul Kıymetler Borsası'nda (CSE) yer alan ASPI ve SL20 fiyat endekslerini tahmin etmek için ARIMA-ANN tabanlı hibrit bir yaklaşım sunmuşlardır. Çalışma Eylül 2010 ile Aralık 2013 dönemini kapsamakta olup, ASPI ve SL20 endekslerin tahmini için belirlenen model seçim kriteri sonuçları, Akaike bilgi kriteri ve Schwarz kriteri doğrultusunda sırasıyla ARIMA (4, 1, 3) ve ARIMA (1, 1, 1) olarak belirlenmiştir. Çalışmada borsa tahminleri ilk olarak ARIMA ve YSA yaklaşımları ile ayrı ayrı ele alınmış sonrasında ise önerilen ARIMA-ANN hibrit yaklaşımı ile gerçekleştirilmiştir. Uygulanan hibrit model tahmin sonuçlarına göre ASPI fiyat endeksi için MAPE, MAE ve RMSE değerleri sırasıyla 0.3424, 21.2208, 30.2510, SL20 endeksi için ise 0.4254, 14.1000, 15.8930 olarak tespit

edilmiş ve önerilen modelin geleneksel tahmin yaklaşımlarına göre daha anlamlı olduğu sonucuna ulaşılmıştır.

Roondiwala, Patel ve Varma (2017) çalışmalarında, NIFTY 50 endeksinin getirilerini tahmin etmek üzere RNN ve LSTM yaklaşımlarını kullanmışlardır. Çalışmada ilgili endeksin beş yıllık tarihi verileri modelin eğitimi ve doğrulaması için kullanılmıştır. Değerlendirme kriteri olarak kullanılan RMSE değeri eğitim verilerinde 0.00983, test verilerinde ise 0.00859 olarak hesaplanmış ve böylelikle LSTM modelinin hisse senedi piyasaları tahmininde yüksek performans sağlayan bir yöntem olduğu ortaya konulmuştur.

Hiransha M vd. (2018) çalışmalarında, Çok Katmanlı Algılayıcılar (Multilayer Perceptron-MLP), Tekrarlanan Sinir Ağları (RNN), Uzun-Kısa Süreli Bellek (LSTM) ve Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN) olmak üzere dört tür derin öğrenme mimarisini kullanmışlardır. Hindistan Ulusal Borsası (NSE) ve New York Borsasına (NYSE) ait hisse senedi fiyatlarının tahminini gerçekleştirmek üzere yapılan çalışmada kullanılan dört ağ NSE'den TATA MOTORS'un fiyatıyla eğitilmiştir. Tahmin sonuçları CNN'in diğer yöntemlere göre daha iyi bir sonuç verdiği yönündedir. Elde edilen sonuçlar ARIMA modeliyle karşılaştırıldığında ise sinir ağlarının mevcut doğrusal modelden daha iyi performans gösterdiği tespit edilmiştir.

Namin ve Namin (2018) çalışmalarında, zaman serileri verilenini tahmin etmek için özellikle LSTM modeli gibi yeni derin öğrenme tabanlı algoritmaların geleneksel algoritmalara göre üstün olup olmadığını ortaya koymaya çalışmışlardır. Çalışmada elde edilen bulgular LSTM modelinin ARIMA modelinden daha üstün tahmin performansına sahip olduğunu yönündedir. İlgili çalışmada, LSTM modeli ile yapılan tahminlerin ARIMA yöntemine göre RMSE hata oranlarında %84- %87 arasında azalma sağladığı ortaya konulmuştur. Ayrıca derin öğrenmede eğitim sürelerinin sayısının eğitilmiş ağı tahmin performansı üzerinde bir etkisinin olmadığı ve tamamen rastgele bir davranış gösterdiği çalışmaya ileri sürülmüştür.

Manurung, Budiharto ve Prabowo (2018) çalışmalarında, Endonezya borsasına ait piyasa tahmini için LSTM tabanlı bir model önermekte ve bunu geleneksel tahmin yöntemlerinden ARIMA modeli ile karşılaştırmaktadırlar. Veriler Bank Central Asia (BCA)'nın 2013-2018 yılları arasındaki dönemi kapsamaktadır ve Yahoo Finance' tan

temin edilmiştir. Uygulamada girdi değişkeni olarak Açılış, En Yüksek, En Düşük ve Kapanış (OHLC) değerleri kullanılmış olup analiz sonucunda, LSTM modeliyle en doğru tahmin 1 yıldan daha kısa vadeli veriler kullanılarak yüksek epoch ile gerçekleştirilen eğitim aşamasından elde edilmiştir. Bir yıllık verilerle elde edilen sonuçlar 3 ve 5 yıllık verilerden elde edilenlere göre daha yüksek çıkmıştır. Ayrıca önerilen modelin, geleneksel ARIMA modeline kıyasla kısa vadeli verilerde daha yüksek performans gösterdiği ortaya konulmuştur.

Shah, Campbell, ve Zulkernine (2018) çalışmalarında, Hindistan BSE Sensex endeksinin günlük ve haftalık hareket tahminini karşılaştırmalı olarak gerçekleştirmek amacıyla LSTM, RNN ve DNN modellerini kullanmışlardır. Çalışmadan elde edilen sonuçlara göre LSTM RNN, haftalık tahminlerde DNN' e göre daha başarılı sonuçlar sunarken uzun vadeli tahminlerde daha umut verici bir model olabileceği ortaya konulmuştur.

Yan ve Ouyang (2018) çalışmalarında, Şangay Bileşik Endeksi'nin günlük kapanış fiyatının tahmini için dalgacık analizi ile LSTM sinir ağını birleştirerek bir zaman serisi modeli önermişlerdir. Veriler, 4 Ocak 2012 ile 31 Haziran 2017 tarihleri arasındaki dönemi kapsamakta olup, Wind Information'dan elde edilmiştir. Önerilen LSTM modeli daha sonra çok katmanlı algılayıcı, destek vektör makinesi ve K-en yakın komşular gibi makine öğrenme modelleri ile karşılaştırılmıştır. Deneysel sonuçlar, LSTM modelinin diğer sık makine öğrenme yöntemlerine göre 0.0030 MAE değeriyle daha iyi tahmin performans gösterdiğini ve finansal zaman serilerinin statik ve dinamik trend tahmininde mükemmel sonuçlar sağladığını göstermektedir. Bu ise LSTM modelinin finansal zaman serisi tahminindeki etkinliğini ve uygunluğunu ortaya koymaktadır.

Fischer ve Krauss (2018) çalışmalarında, sıralı verilerle çalışmada ileri düzey bir yöntem olan LSTM ağları ile 1992-2015 yılları arasında S&P 500 hisselerinin verilerini kullanarak yön tahmini gerçekleştirmişlerdir. Oluşturulan LSTM modelinin tahmin sonuçları ilgili modelin, Random Forest, Deep Neural Network ve Lojistik Regresyon gibi hafızasız modellere kıyasla daha iyi performans gösterdiğini ortaya koymaktadır.

Li vd. (2019) minimum risk taşıyan bir sinir ağı ile orta vadeli hisse senedi fiyatlarını tahmin etmeyi amaçladıkları çalışmalarında, birden fazla modeli birleştiren bir hisse senedi fiyat modeli önerilmiştir. İlk adımda, otoregresif hareketli ortalama (ARMA)

modeli kullanılarak hisse senedi orta vadeli tahmin problemi oluşturulmuştur. Daha sonra, fiyat değişikliklerinin habercisi olabilecek hacim gibi hisse senedi fiyatıyla yüksek oranda ilişkili birkaç değişken orta vadeli ARMA tabanlı tahmin modeline (Mid-ARMA) dahil edilmiştir. Ayrıca, Sermaye Varlık Fiyatlama Modeli'nden (CAPM) ilham alınarak, piyasa fiyatı ve hisse senedi ile piyasa arasındaki korelasyon katsayısı, Mid-ARMA modeline dahil edilerek tahmin doğruluğu artırılmıştır. Mid-ARMA modeline dayalı olarak, hisse senedi fiyatlarını tahmin etmek için bir orta vadeli LSTM tabanlı derin sinir ağı (Mid-LSTM) önerilmiştir. Son olarak, Mid-LSTM ağı, S&P 500 verilerine dayalı olarak birçok geleneksel makine öğrenimi yöntemiyle karşılaştırılmıştır. Gerçekleştirilen deneylerden elde edilen sonuçlar ile önerilen Mid-LSTM' in tahmin doğruluğunda %2-4 oranında bir iyileşme sağladığı ortaya konulmuştur.

Siame-Namini, Tavakoli, ve Namin (2019) çalışmalarında, finansal zaman serilerinin tahmininde LSTM, Bi-LSTM ve ARIMA modellerinin performansını karşılaştırmışlardır. Çalışmada kullanılan veriler Ocak 1985-Ağustos 2018 dönemine ait bazı hisse senedi endekslerinin günlük, haftalık ve aylık verilerini ayrıca Temmuz 2009-Temmuz 2019 dönemine ait IBM hisse senedinin günlük verilerini içermektedir. Yapılan analizlerde değerlendirme ölçütü olarak RMSE değeri kullanılmıştır ve elde edilen sonuçlara göre ek bir eğitim katmanının tahmin doğruluğunu yaklaşık %37,78 oranında artırdığı ve modelleme süreci için fayda sağladığı belirtilmiştir. Bunun yanı sıra BiLSTM tabanlı modellerin daha yavaş eğitildiği ve dengeye ulaşabilmek için ek veri yığınlarının gerekli olduğu ifade edilmiştir.

Kim ve Kang (2019) çalışmalarında, çeşitli makine öğrenme tekniklerini kullanarak KOSPI 200 endeksinin eğilimlerini tahmin etmeye çalışmışlardır. Bu kapsamda ilgili çalışmada çok katmanlı algılayıcı (MLP), tek boyutlu evrimsel sinir ağları (1D CNN), istiflenmiş uzun kısa süreli bellek (stacked LSTM), dikkat ağları ve ağırlıklı dikkat ağları gibi çeşitli derin öğrenme modelleri karşılaştırılmıştır. Geçmişe dönük 60 işlem gününü kullanarak yapılan çalışmada, LSTM içeren modellerin tahmin gücünün diğerlerinden daha iyi olduğu tespit edilmiştir.

Idrees, Alam ve Agarwal (2019) çalışmalarında, Sensex ve Nifty verilerini kullanarak borsa endeks tahminini ARIMA modeli kullanarak tahmin etmeye çalışmışlardır. Tarihi borsa verilerinin girdi değişkeni olarak kullanıldığı çalışma Ocak

2012- Aralık 2016 dönemini kapsamaktadır. Yapılan deneysel çalışma sonucunda, tahmin edilen zaman serisi ile gerçekleşen zaman serisi arasında hem Nifty hem de Sensex için ortalama yüzde %5’lik bir sapma tespit edilmiştir.

Dhyani vd. (2020) çalışmalarında, Nifty50 endeksinin gelecekteki değerini tespit etmek amacıyla ARIMA Modelini kullanmışlardır. 2014 ile 2018 dönemini kapsayan analizde NIFTY kapanış endeksinin aylık verileri kullanılmıştır. Analizden elde edilen sonuçlarda tahmin edilen fiyatın, belirtilen tarihteki gerçek fiyata oldukça yakın olduğu tespit edilmiştir.

Abdulrahman ve Hayfron-Acquah (2020) çalışmalarında Ayırık Fourier dönüşümünün düşük geçiren filtresi ile veri ayrıştırmasına dayalı olarak ARIMA ve LSTM modellerini birleştiren bir hibrit model önermişlerdir. Gana Menkul kıymetler borsasından elde edilen verilerle gerçekleştirilen deneyler sonucu önerilen hibrit modelin bireysel ARIMA ve LSTM modellerine kıyasla daha iyi performans gösterdiği RMSE değerleri ile ortaya konulmuştur.

Girsang, Lioexander ve Tanjung (2020) çalışmalarında Endonezya’nın en bilinen finansal kurumlardan birinin hisse senedi fiyatları tahmin etmek için LSTM ve ARIMA modellerini kullanmışlardır. LSTM modeli hem optimize edilmiş haliyle hem de optimize edilmeden değerlendirmeye alınmış ve elde edilen sonuçlar ARIMA modeli ile karşılaştırılmıştır. Optimize edilen LSTM modeli için Search Economics algoritması kullanılmıştır. Çalışmada ilgili finansal kurumun hisse senedi fiyatlarını içeren bir veri seti kullanılmış olup 2006-2019 yılları arasındaki günlük kapanış, açılış, en yüksek, en düşük ve hacim bilgileri değişken olarak kullanılmıştır. Elde edilen deneysel sonuçlar RMSE metriği kullanılarak karşılaştırıldığında en iyi sonucu veren model optimize edilmiş LSTM modeli en kötü sonuç ise ARIMA modeline ait olduğu tespit edilmiştir.

Dadhich vd. (2021) çalışmalarında, zaman serisi tahmini için Hindistan’ın iki büyük endeksi olan BSE ve NSE endekslerinin günlük kapanış verilerini kullanmışlardır. Çalışmada ekonometrik tahmin modeli olarak ARIMA modeli kullanılmış ve NSE endeksi için en uygun ARIMA modeli DLOG_NSE (0, 1, 4), BSE endeksi için ise DLOG_BSE (3, 1, 2) modeli seçilmiştir. 1 Mart 2018-28 Mart 2018 tarihleri arasındaki toplam 474 gözlem baz alınarak belirlenen en iyi model yardımıyla ilgili endekslerin tahminleri ve gerçek performansları arasında tatmin edici düzeyde başarılı sonuçlar elde

edilmiş ve modelin kısa vadeli değer tahmini için kullanılabilecek en iyi tahmin modeli olduğu vurgulanmıştır.

Ho, Darman ve Musa (2021) çalışmalarında Bursa Malezya borsasının kapanış fiyatlarını tahmin etmek için ARIMA ve NN ve LSTM modellerini kullanmışlardır. Çalışmada Bursa Malezya borsasının kapanış fiyatlarını tahmin etmek için 2 Ocak 2022 ile 19 Ocak 2021 tarihleri arasındaki tarihsel verilerden yararlanılmıştır. Veri setinin %70'i eğitim %30' u ise test seti olarak kullanılmıştır. En iyi tahmin modelinin seçimlerinde MAPE ve RMSE değerleri kullanılmış olup LSTM modeli en düşük değerlendirme ölçütlerine sahip model olmuştur. Model %90 üzerinde bir doğruluk oranı elde etmekle kalmamış pandemi döneminde hisse senedi fiyatlarındaki öngörülemeyen hareketleri açıklayabilmiştir.

Ashok ve Prathibhamol (2021) çalışmalarında geçmiş verilere dayalı olarak hisse senedi fiyat hareketlerini tahmin etmeyi amaçlamışlardır. Çalışmada lineer regresyon, hareketli ortalama, ARIMA ve LSTM yöntemleri RMSE değerleri baz alınarak karşılaştırılmıştır. Çalışmada LSTM modelinin %77'lik bir doğruluk oranı ile en iyi performans gösterdiği ortaya konmuştur. Ayrıca TATA Global Beverages' den elde edilen veriler üzerinde yapılan deneysel çalışmalar sonucunda ARIMA modelinin kısa dönemli tahminlerde güçlü bir potansiyele sahip olduğu sonucuna varılmıştır.

Mahadik, Vaghela ve Mhaisgawali (2021) yatırımcılara piyasanın genel eğilimini özetleyen modeller tasarlamak amacıyla yapmış oldukları çalışmalarında modellerin oluşturulması ve test edilmesi için NSE-TATA ve ADANI PORTS olmak üzere 2 veri seti kullanmışlardır. Kullanılan veri seti açılış, kapanış, yüksek ve düşük değerlerini içeren şirketlerin geçmiş ve hisse senetleri fiyatlarından oluşmaktadır. İlgili veri setleri ile ARIMA ve LSTM modelleri sunulmuş elde edilen analiz sonuçlarına göre sağlanan veriler modele uyduğunda ve uygun parametre değerleri ayarlandığında bireysel modellerin iyi çalıştığı ortaya konulmuştur. Her bir öznitelik için modellerin doğruluğu %90 üzerinde tespit edilmiştir

Vuong vd. (2022) çalışmalarında, hisse senedi fiyat tahmin performansını artırmak için gelişmiş makine öğrenimi ve derin öğrenme yaklaşımlarına dayanan bir yöntem önermektedirler. Bu kapsamda ilk olarak zaman serisi verilerinden önemli özellikleri seçmek ve gereksiz özellikleri elemek için aşırı gradyan artırma (XgBoost)

uygulamışlardır. Daha sonra seçilen bu özellikleri derin öğrenme ağlarından LSTM ağına girdi olarak aktarmışlardır. Derin LSTM ağı, girdinin zamansal yapısını yansıtmak ve gelecekteki fiyatları daha iyi performansla tahmin için kullanılmıştır. Önerilen model , 2008-2018 tarihlerini kapsayan bir Forex veri setine uygulanıp elde edilen deneysel sonuçlar geleneksel ARIMA modeli ile karşılaştırılmıştır. Değerlendirme kriteri olarak MAE, MSE, RMSE değerleri ele alınmış olup önerilen modelin ARIMA modelinden daha iyi performans gösterdiği ortaya konulmuştur.

Dong (2022) çalışmasında, 2016-2022 yılları arasındaki Google'ın geçmiş verilerini kullanarak gelecekteki hisse senedi fiyatlarını tahmin etmek için ARIMA ve LSTM modelini uygulamıştır. Modelleme sürecinde her iki modelin de yüksek uyum doğruluğuna sahip olduğu tespit edilmiş ancak yapılan karşılaştırmalar sonucunda LSTM modeli ARIMA modeline kıyasla daha yüksek uyum doğruluğu sağladığı görülmüştür.

Abdulhafidh Derhem Dael (2022) çalışmasında, borsanın gelecekteki eğilimini tahmin etmek için İstatistiksel, makine öğrenimi, doğal dil işleme ve duygu analizi kullanarak gerçekleştirmiştir. Çalışmada nicel ve nitel verileri birleştiren hibrit bir model önerilmiştir. Üretken düşman ağları yöntemiyle önerilen model işletilmiştir. Çalışmada nicel veri olarak 35 parametre kullanılırken nitel veri olarak tweetler ve haberler kullanılmıştır. Çalışmada modelin yürütülmesi için Python programlama dili kullanılmıştır. Elde edilen sonuçlara göre üretken düşman ağları temel modelleri daha iyi performans göstermektedir.

Lv vd. (2022) çalışmalarında, zaman serisi ayrıştırması ve hibrit bir model temelinde yeni bir hisse senedi endeksi tahmin modeli geliştirmişlerdir. Araştırmada Uyarlamalı Gürültü ile Tam Ansambl Önemli Mod Ayrıştırması (CEEMDAN) yöntemi hisse senedi endeksini farklı özellik ölçeklerine ve trend bileşenlerine sahip bir dizi Doğal Mod Fonksiyonuna (IMFs) ayrıştırmaktadır. ADF testi ile bileşenlerin durağanlık durumu analiz edilmiştir. Test sonucunda durağan olan zaman serileri için ARMA modeli, durağan olmayan zaman serilerini modellemek için ise LSTM ağı kullanılmıştır. Sonraki aşamada zaman serileri için elde edilen tahmin sonuçları birleştirilerek nihai tahmin değeri tespit edilmiştir. Dört farklı hisse senedi endeksi için gerçekleştirilen analizde önerilen model diğer referans modellerden daha iyi tahmin sonucu sunmuştur.

Mashadihasanli (2022) çalışmasında, 2009-2021 dönem aralığında yer alan aylık bazda 147 gözlemden meydana gelen BIST endeks verilerini ARIMA modeli ile tahmin etmiştir. Araştırmada tahmin için en uygun ARIMA modeli (3,1,5) olarak belirtilmiş ve sonuçlar tahmin edilen değerlerin gerçekleşen değerlere yakın olduğunu ve seçilen ilgili modelin tahmin hatalarını azalttığını ortaya koymuştur.

Xiao vd. (2022) Çalışmalarında 50 farklı halka açık şirketin fiyat tahminini ARIMA ve LSTM modeli kullanarak gerçekleştirmişlerdir. Çalışmada kullanılan veri seti 1 Ocak 2010 ile 31 Ocak 2018 dönemine ilişkin işlem günlerindeki en yüksek fiyatlardan oluşmaktadır. Finans.yahoo.com adresinden elde edilen veriler kullanılarak her iki modelde bir sonraki günün hisse fiyatını tahmin etmek için 60 günlük geçmiş verilerini kullanmıştır. Modellerin performansları MAE, MSE ve RMSE göstergelerine göre değerlendirilmiştir. Analiz sonuçlarına göre hem ARIMA hem LSTM hisse senedi fiyatlarını tahmin edebilen modeller olarak kabul edilmiş ve tahmin sonuçları ile gerçek sonuçlar genel olarak tutarlı bulunmuştur. LSTM modeli özellikle hisse senedi fiyatlarındaki değişimleri yakalama da daha iyi performans gösterdiği tespit edilmiştir. Çalışmada genel olarak her iki yaklaşımında güçlü yönleri vurgulanmıştır.

Zhu ve He (2022) çalışmalarında Amazon hisse senedi fiyatını tahmin etmek için en uygun modeli belirlemek amacıyla ARIMA, XGBoost ve LSTM modelini kullanmışlardır. Birçok açıdan modellerin değerlendirmesi yapılırken değerlendirme ölçütü olarak MSE kullanılmış ve LSTM modelinin en iyi uyum etkisine sahip olduğu tespit edilmiştir.

Bhandari vd. (2022) S&P 500 endeksinin bir sonraki gün kapanış fiyatını tahmin etmek için yapmış oldukları çalışmalarında, özel bir sinir ağı mimarisi olarak kabul edile LSTM modelini kullanmışlardır. Model de girdi değişkeni olarak temel piyasa verileri, makroekonomik veriler ve teknik göstergelerden oluşturulmuş dokuz öngörücüden oluşan bir birleşim kullanılmıştır. İlgili girdi değişkenleri ile tek katmanlı ve çok katmanlı LSTM modelleri geliştirilmiştir. Çalışmada performans değerlendirme kriteri olarak RMSE, MAPE ve R (Korelasyon Katsayısı) kullanılarak karşılaştırma yapılmıştır. Elde edilen deneysel sonuçlara göre tek katmanlı LSTM modelinin çok katmanlı LSTM modellerine göre üstün bir uyum ve yüksek tahmin doğruluğu sağladığı tespit edilmiştir.

Bathla, Rani, ve Aggarwal (2023) çalışmalarında derin öğrenmenin 2020 yılında hisse senetleri fiyatlarındaki yaşanan yüksek dalgalanmaları tahmin etmek için bir sinir ağı modeli inşa etmişlerdir. Önerilen LSTM modelinde borsa endeks verilerine ait veri seti Ocak 2010- Mart 2020 dönemini kapsamakta olup modelde sigmoid aktivasyon fonksiyonu ve adam optimizasyonu kullanılmıştır. Yapılan deneysel çalışma ile kullanılan LSTM modelinin geleneksel modellere kıyasla hisse senetleri fiyatını tahminde daha başarılı performans gösterdiği ortaya konulmuştur. Önerilen model kullanılarak hesaplanan MAPE değerleri, NSE, BSE, NASDAQ, NYSE, Dow Jones ve Nikkei 225 için sırasıyla 3.89, 1.21, 3.01, 1.19, 2.03 ve 0.86 olarak tespit edilmiştir.

Li vd. (2023) çalışmalarında, dört büyük teknoloji şirketi olan Apple (AAPL), Google (GOOG), Microsoft (MSFT) ve Amazon (AMZN)'un hisse senedi kapanış fiyatlarını tahmin etmek için LSTM tabanlı tahmin modeli geliştirmeyi ve değerlendirmeyi amaçlamışlardır. 2012-2023 dönemini kapsayan veri setinde tahmin için hisse senetlerinin tarihi fiyat verileri kullanılmıştır. Veri seti, %95 eğitim ve %5 test olarak ikiye ayrılmış olup, LSTM modeli ilk kısımda eğitilmiş ve ikinci kısımda değerlendirilmiştir. Adam optimizasyonu ve ortalama kare hata kayıp fonksiyonu ile eğitilen model, RMSE metriği ile değerlendirilmiştir. İlgili değer ise 18,89 olarak tespit edilmiştir.

Nikou, Mansourfar ve Bagherzadeh (2023) yapmış oldukları çalışmalarında İShares MSCI Birleşik Kırallık'ın kapanış fiyatını derin öğrenme yöntemiyle tahmin etmişlerdir. Ayrıca derin öğrenme yöntemiyle elde edilen tahmin sonuçlarını diğer makine öğrenme yöntemleriyle karşılaştırmışlardır. Çalışmada, Yapay Sinir Ağları, Destek Vektör Regresyon, Random Forest ve LSTM olmak üzere dört ayrı veri madenciliği tekniği kullanılmıştır. Ocak 2015 ile Haziran 2018 tarihleri arasındaki günlük veriler üzerinden yapılan analizde, tahmin başarısını değerlendirmek için MAE (Ortalama Mutlak Hata), MSE (Ortalama Kare Hata) ve RMSE (Kök Ortalama Kare Hata) gibi hata ölçütleri kullanılmıştır. Analiz sonuçlarına göre İShares MSCI Birleşik Kırallık'ın kapanış fiyatının tahmininde derin öğrenme yöntemi, diğer makine öğrenme yöntemlerine göre daha iyi sonuç vermiştir.

Jarrah ve Derbali (2023) Suudi Arabistan Krallığı'nın hisse senedi piyasası endekslerini tahmin etmeyi amaçladığı çalışmalarında, tek değişkenli (kapanış fiyatı) ve

çok değişkenli (açılış, kapanış, en yüksek, en düşük) girdi değişkenleri kullanarak LSTM modeli uygulamışlardır. 1 Ocak 2017-21 Kasım 2022 dönemini kapsayan veri seti ile gelecek yedi gün için kapanış fiyatı tahmini gerçekleştirilmiştir. Önerilen çok değişkenli LSTM modeli ve tek değişkenli model için sırasıyla %97,49 ve %92,19 tahmin oranları tespit edilmiştir.

Wu, Chen ve Ding (2023) çalışmalarında Apple hisse senedinin kapanış fiyatını tahmin etmek için ARIMA ve LSTM modellerini kullanmışlardır. 04.01.2016 ile 21.09.2020 dönemine ait tarihi verileri kullanarak yapılan analizde son 60 gözlem test verisi olarak ayrılmıştır. En iyi model RMSE metriği ile değerlendirilmiştir. Her iki model arasında LSTM modeli daha düşük RMSE değerine sahip olduğu tespit edilmiştir.

Furizal vd. (2024) çalışmalarında Endonezya'nın önde gelen bankalarından biri olan Bank Central Asia'nın hisse senedi verilerini tahmin etmek için bir LSTM sinir ağı modeli kullanmışlardır. Uygulanan model, 200 birimden oluşan tek bir gizli LSTM katmanından oluşmaktadır. İlgili hisse senedi verileri 8 Haziran 2004 -19 Nisan 2024 tarihleri arasını kapsamaktadır ve veri kümesi işlem tarihi, açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı, düzeltilmiş kapanış fiyatı ve işlem hacminden oluşmaktadır. Model, MAE ve MSE ölçümleri kullanılarak değerlendirilmiş olup, sonuçlar modelin test verilerinde 0,0142'lik bir MAE ile yüksek doğruluk elde ettiğini ortaya koymaktadır.

Beniwal, Singh ve Kumar (2024) çalışmalarında derin öğrenme modellerini kullanarak, beş küresel hisse senedi endekslerinin, (Nifty, DJIA, DAX, Nikkei 225, SSE) günlük fiyatlarını bir yıla kadar uzun vadede tahmin etmeye çalışmışlardır. Çalışmaya ait veriler, Ocak 2013- 28 Şubat 2023 dönemini kapsamaktadır. Çalışmada kullanılan altı farklı model (DNN, RNN, LSTM, Bi-LSTM, GRU, CNN)'in performansı RMSE ve MAPE ölçütleri ile karşılaştırılmıştır. Elde edilen sonuçlar, LSTM modelinin uzun vadeli günlük fiyat tahminindeki üstünlüğünü doğrular niteliktedir.

Ahammad vd. (2024) çalışmalarında ARIMA ve LSTM modellerini kullanarak Apex Food hisse senedine ait kapanış fiyatı tahminini karşılaştırmalı bir analizle ele almışlardır. Tahmin analizinde veri seti olarak 10 yıllık tarihi veriler kullanılmış olup modellerin tahmin doğruluğunu ve verimliliğini değerlendirmek için MAE ve RMSE metrikleri kullanılmıştır. Araştırma bulguları beklentilerin aksine ARIMA modelinin

LSTM modeline kıyasla daha iyi performans gösterdiği ortaya koymuşlardır. ARIMA modeli için 4.336 RMSE ve 3.45 MAE değerleriyle daha küçük hata oranları elde ederek daha yüksek tahmin doğruluğu sergilemiştir.

Panchal, Ferdouse ve Sultana (2024) çalışmalarında ARIMA ve LSTM Ağlarını kullanarak hisse senedi fiyat tahmini gerçekleştirmişlerdir. Çalışmada Apple, Google ve Tesla hisse senetlerinin tarihsel fiyat verilerinden yararlanılarak ilgili hisselerin kapanış fiyatını tahmin etmek için geliştirilen modellerde RMSE ve MAPE değerlendirme ölçütü olarak kullanılmıştır. Elde edilen bulgulara göre LSTM modeli ARIMA modeline kıyasla daha iyi bir tahmin gücü göstermiştir. LSTM modelleri daha düşük RMSE değerleri (Ho, Darman, ve Musa 2021) üretmiştir. ARIMA modelleri karmaşık desenleri yakalamada sınıfta kalmıştır.

Mochurad ve Dereviannyi (2024) çalışmalarında finansal piyasalarda, destek vektör regresyonu, ARIMA, LSTM ve XGBoost gibi yöntemleri kullanarak tahmin analizi gerçekleştirmişlerdir. 3 ayrı veri seti üzerinde gerçekleştirilen bu analizler doğrultusunda LSTM ve ARIMA kullanılarak hibrit bir model önerilmiştir. Bu hibrit model sayesinde RMSE metriği açısından %15' lik bir iyileşme tespit edilmiştir.

Finansal zaman serilerinin tahmininde yaygın olarak kullanılan ARIMA ve LSTM modellerinin performanslarına yönelik mevcut literatür incelendiğinde, bu modellerin hisse senedi ve endeks öngörülerinde sıklıkla tercih edildiği görülmektedir. Bununla birlikte, mevcut çalışmaların büyük çoğunluğunun bu iki modelin tahmin başarımını ayrı ayrı ya da sınırlı piyasa koşulları altında ele aldığı; ancak gelişmiş (G7) ve gelişmekte olan (E7) ekonomiler gibi farklı yapısal ve dinamik özelliklere sahip piyasalarda modellerin karşılaştırmalı analizine yeterince yer verilmediği dikkat çekmektedir.

Bu sınırlılık, yalnızca algoritma temelli doğruluk ölçütlerinin değerlendirilmesi ile sınırlı kalınmasına neden olmakta, modellerin tahmin başarımlarının ülkelerin piyasa yapısı ve finansal gelişmişlik düzeyleri gibi faktörlerden nasıl etkilendiğine dair bütüncül bir perspektifin geliştirilememesine neden olmaktadır. Bu doğrultuda, söz konusu boşluğu doldurmak amacıyla, G7 ve E7 ülkelerine ait seçilmiş borsa endeksleri için hem ARIMA hem de LSTM modelleri uygulanarak kapsamlı bir karşılaştırmalı tahmin analizi gerçekleştirilmiş ve böylece hem model bazlı hem de piyasa yapısı temelli çıkarımlar yapılması hedeflenmiştir.

4. BÖLÜM: BORSA ENDEKS TAHMİN UYGULAMASI

Bu bölümde, gelişmiş ülkeleri temsilen G7 ve gelişmekte olan ülkeleri temsilen E7 ülkelerine ait seçilmiş borsa endekslerinin tahmini, geleneksel zaman serisi yöntemlerinden ARIMA derin öğrenme yöntemlerinden LSTM modelleri kullanılarak gerçekleştirilmiştir. Araştırma kapsamında, 01/09/2006 – 15/02/2022 tarihleri arasındaki döneme ait borsa endeks verileri kullanılmıştır. Veri seti, literatürde genel kabul görmüş ve finansal tahmin modellerinde sıklıkla kullanılan 10 teknik gösterge üzerinden hesaplanmıştır. Bu göstergeler arasında Basit Hareketli Ortalama, Ağırlıklı Hareketli Ortalama, MACD, CCI, RSI, Stokastik K, Stokastik D, Williams' %R, Momentum, A/D gibi yaygın olarak tercih edilen teknik analiz araçları yer almaktadır. Ayrıca, modelin tahmin gücünü artırmak amacıyla makroekonomik göstergelerden altının ONS fiyatı, Brent petrol fiyatı ve Dolar Endeksi (DXY) de veri setine dahil edilmiştir. Bu yaklaşım, teknik ve makroekonomik faktörlerin borsa endeksleri üzerindeki etkisini bütüncül bir şekilde incelemeyi mümkün kılmıştır. Çalışmada, ARIMA ve LSTM modellerinin tahmin performansları, G7 ve E7 ülkelerinin borsa endeksleri üzerinde ayrı ayrı test edilmiş ve bu sayede, bu iki modelin tahmin gücü farklı ülke dinamiklerine sahip borsa endekslerinde ortaya konulmuştur ve bu yöntemlerin avantajları ile sınırlılıkları tartışılmıştır.

4.1 UYGULAMANIN AMACI

Bu tezin amacı, borsa endeksini, endeksi etkilediği düşünülen teknik ve makroekonomik göstergeleri girdi verisi olarak kullanarak geleneksel (ARIMA) ve derin öğrenme (LSTM) yöntemleriyle tahmin etmeye çalışmaktır. Ayrıca çalışma, gelişmiş ekonomileri temsil eden G7 ülkeleri ile gelişmekte olan ekonomileri temsil eden E7 ülkelerine ait seçilmiş borsa endekslerini ayrı ayrı inceleyerek, farklı ekonomik yapılara sahip ülkelerdeki tahmin modellerinin performansını karşılaştırmayı amaçlamaktadır. Bu doğrultuda, hem geleneksel yöntemlerin hem de derin öğrenme modellerinin farklı ülke dinamiklerindeki etkinliği ortaya konulacak ve literatüre bu alanda özgün bir katkı sunulacaktır. Bu sayede hisse senedi piyasasındaki bireysel ve kurumsal yatırımcılar, fon

yöneticileri, finansal analistler gibi birçok karar alıcı için etkin bir tahmin modeli ortaya konulmaya çalışılacaktır.

4.2 VERİ SETİ

Bu çalışmada, G7 ve E7 ülkelerine ait seçilmiş borsa endekslerinin tahmini için teknik ve makroekonomik göstergeler kullanılmıştır. Çalışmanın bağımlı değişkeni olarak, 1 Eylül 2006 ile 15 Ocak 2022 tarihleri arasındaki döneme ait borsa endekslerinin günlük kapanış fiyatları kullanılmıştır. Bağımsız değişkenler ise, literatürde yaygın olarak kabul gören ve finansal tahmin modellerinde sıklıkla tercih edilen 10 teknik gösterge ile 3 makroekonomik göstergeden (altın fiyatları, petrol fiyatları ve dolar endeksi) oluşmaktadır.

2006-2022 döneminin seçilmesinin temel nedeni, bu zaman aralığının küresel ekonomi açısından önemli dönüm noktalarını kapsamasıdır. Bu dönem, 2008 küresel finansal krizi, 2010-2012 Avrupa borç krizi ve 2020 COVID-19 pandemisi gibi borsa endeksleri üzerinde derin etkiler yaratan olayları içermektedir. Bu tür ekonomik şoklar, modellerin farklı ekonomik koşullar altındaki performansını analiz etmek ve modellerin dayanıklılığını değerlendirmek açısından ideal bir ortam sunmaktadır. Ayrıca, bu dönem, güvenilir ve tutarlı veri kaynaklarının yaygın olarak erişilebilir olduğu bir zaman dilimidir. Bu durum, elde edilen sonuçların literatürdeki diğer çalışmalarla karşılaştırılabilir olmasını sağlamaktadır.

Çalışmada kullanılan tüm veri seti, finansal piyasa verilerine yönelik güvenilir kaynaklar olan Investing.com ve finance.yahoo.com platformlarından temin edilmiştir.

4.2.1. Analizde Kullanılan Ülkeler ve Borsa Endeksleri

Bu tez çalışması kapsamında, dünyanın en gelişmiş ekonomilerini temsil eden G7 ülkeleri (ABD, Japonya, Almanya, İngiltere (Birleşik Krallık), Fransa, İtalya ve Kanada) ile gelişme hızının en yüksek olduğu E7 ülkeleri (Çin, Hindistan, Brezilya, Rusya, Endonezya, Meksika ve Türkiye) ele alınmıştır.

G7 ülkeleri, küresel ekonominin büyük bir bölümünü temsil eden ve finansal piyasaları istikrarlı olan ekonomilerdir. Bu ülkelerin borsa endeksleri, küresel ekonomik


dinamiklerden önemli ölçüde etkilenmekte ve finansal tahmin modelleri için önemli bir referans noktası oluşturmaktadır. Öte yandan, E7 ülkeleri, yüksek büyüme potansiyeline sahip olmakla birlikte, ekonomik ve politik belirsizliklerin daha yoğun olduğu piyasalara sahiptir. Bu nedenle, E7 ülkelerinin borsa endeksleri, modellerin farklı ekonomik koşullar altındaki performansını analiz etmek açısından önemli bir fırsat sunmaktadır.

Çalışmada, her iki ülke grubuna ait borsa endeksleri için aşağıdaki endeksler dikkate alınmıştır:

Tablo 4.1. Analizde Kullanılan Ülkeler ve Borsa Endeksleri

G7 Ülkeleri	Seçilen Endeksler
ABD	S&P 500
KANADA	S&P/TSX COMPOSITE
ALMANYA	DAX
FRANSA	CAC40
İNGİLTERE	FTSE100
İTALYA	FTSE MIB
JAPONYA	NIKKEI 225
E7 Ülkeleri	Seçilen Endeksler
ÇİN	SHANGHAI COMPOSITE
HİNDİSTAN	NIFTY 50
BREZİLYA	BOVESPA
MEKSİKA	S&P/BMV IPC
ENDONEZYA	IDX COMPOSITE
RUSYA	MOEX
TÜRKİYE	BİST100

Tablo 4.1.' de bulunan endeksler, ilgili ülkelerin ekonomik performanslarını ve finansal piyasa dinamiklerini yansıtan temel göstergeler olup, çalışmanın analizlerinde bağımlı değişken olarak kullanılmıştır. İlgili bağımlı değişkenlerin kapanış verileri Şekil 4.1.' de gösterilmiştir.



Şekil 4.1. G7 ve E7 Ülkelerinin Endeks Kapanış Verileri

Bu veriler analizde kullanılan tüm ülkeler kapsamında ayrı ayrı 3414 iş gününü kapsamaktadır.

4.2.2. Girdi Değişkenleri ve Veri Hazırlama Süreci

Çalışmada, ilgili ülkelerin seçilmiş borsa endekslerinin tahmini için hem teknik hem de makroekonomik göstergeler bağımsız değişken olarak kullanılmıştır. Teknik göstergeler, literatürde yaygın olarak kabul gören ve finansal tahmin modellerinde sıklıkla tercih edilen göstergeler arasından seçilmiştir. Bu göstergeler, literatürdeki (Kim 2003; Diler 2003; Yu, Wang, ve Lai 2005; Lu 2010; Kara, Boyacioglu, ve Baykan 2011; Hsieh, Hsiao, ve Yeh 2011; Şenol 2013; Dunis vd. 2013; Wang vd. 2015; Anbalagan ve Maheswari 2015; Jabbarzadeh vd. 2016; Anish ve Majhi 2016; Lee ve Soo 2017; Dingli ve Fournier 2017; Bao, Yue, ve Rao 2017; Li ve Tam 2017; Rout vd. 2017; Widegren 2017; Chen, Wu, ve Bu 2018; Pabuçcu 2019; Dash vd. 2019; Gündüz 2019; Sakarya ve Yılmaz 2019; Lalithendra Nadh ve Syam Prasad 2019; Kara 2019) çalışmalarda kullanılan teknik göstergeler incelenerek belirlenmiştir.

Makroekonomik göstergeler ise, küresel ekonomik dinamiklerin borsa endeksleri üzerindeki etkisini yansıtan değişkenler arasından seçilmiştir. Bu değişkenlerin belirlenmesinde, literatürdeki (Tektaş ve Karataş 2004; Toraman 2008; Kutlu ve Badur 2009; Akcan ve Kartal 2011; Karymshakov ve Abdykaparov 2012; Aygören, Sarıtaş, ve Morali 2012; De Oliveira, Nobre, ve Zárata 2013; Yakut, Yakut, ve Yavuz 2014; ÇALIŞKAN ve Deniz 2015; Siddiqui ve Abdullah 2015; Telli ve Coşkun 2016; Kim ve Won 2018; Dayı 2018; Kantar 2020; Çınaroğlu ve Avcı 2020; Bhandari vd. 2022) çalışmalar referans alınmıştır. Bu doğrultuda çalışmada bağımsız değişken olarak kullanılan teknik ve makroekonomik göstergeler Tablo 4.2.' de gösterilen şekliyle belirlenmiştir.

Tablo 4.2. Analizde Kullanılan Girdi Değişkenleri

Sıra	Girdi Değişkenleri
1	Hareketli Ortalamalar (MA)
2	Ağırlıklı Hareketli Ortalama (WMA)
3	Hareketli Ortalamalar Yakınlaşma-Uzaklaşma Göstergesi (MACD)
4	Emtia Kanal Endeksi (CCI)
5	Göreceli Güç Endeksi (RSI)
6	Stokastik K% (K%)
7	Stokastik D% (D%)
8	Larry William's R% (WILLR %)
9	Momentum (MOM)
10	Birikim/Dağıtım Göstergesi (A/D)
11	Altın (ONS)
12	Petrol (BRENT)
13	Dolar Endeksi (DXY)

Tablo 4.2’de sunulan girdi değişkenleri, ilk 10’u teknik göstergeler, son üçü ise makroekonomik göstergeler olmak üzere sınıflandırılmıştır. Çalışma kapsamında, teknik göstergelerin analize uygun hale getirilmesi için öncelikle matematiksel formüller yardımıyla hesaplanması gerekmektedir. Bu doğrultuda, kullanılan formüller Tablo 4.3’te sunulmuştur.

Tablo 4.3. Belirlenen Teknik Göstergeler ve Formülleri

MA	$\frac{C_t + C_{t-1} + \dots C_{t-n}}{n}$
WMA	$\frac{((n) * C_t + (n - 1) * C_{t-1} + \dots + C_{t-n})}{(n + (n - 1) + \dots + 1)}$
MACD	$MACD = EMA_{12} - EMA_{26}$
CCI	$\frac{M_t - SM_t}{0.015D_t}$
RSI	$100 - \frac{100}{(\sum_{i=0}^{n-1} Up_{t-i}/n) / (\sum_{i=0}^{n-1} Dw_{t-i}/n)}$
K%	$\frac{C_t - LL_t - n}{HH_{t-n} - LL_{t-n}} * 100$
D%	$\frac{\sum_{i=0}^{n-1} K_{t-i}}{n} \%$
WILLR%	$\frac{H_n - C_t}{H_n - L_n} * (-100)$
MOM	$MO = C_t - C_{t-n}$
A/D	$\sum \frac{(C_t - L_t) - (H_t - C_t)}{H_t - L_t} * Hacim$

* Tablo 4.3.' te yer alan C_t kapanış fiyatı, L_t en düşük fiyat ve H_t en yüksek fiyat.

EMA Üstel hareketli ortalama, LL_t son t gün için minimumların minimumu, HH_t son t gün için maksimumların maksimum değeri.

$$M_t = (H_t + L_t + C_t)/3 \quad (4.1)$$

$$SM_t = (\sum_{i=0}^n M_{t-i+1}/n) \quad (4.2)$$

$$D_t = (\sum_{i=1}^n |M_{t-i+1} - SM_t|/n) \quad (4.3)$$

Up_t ve Dw_t sırasıyla t zamanındaki yukarı ve aşağı yönlü fiyat değişimlerini ifade etmektedir.

Finansal veri setleri üzerinde derin öğrenme ve istatistiksel analizlerin etkin bir şekilde gerçekleştirilebilmesi amacıyla kapsamlı bir veri ön işleme süreci uygulanmıştır. Bu süreç, veri setinin analize hazır hale getirilmesi için gerekli olan temel adımları içermektedir. İlk olarak, veri seti üzerinde temizleme işlemleri gerçekleştirilerek tutarsızlıklar, gereksiz bilgiler uygun yöntemlerle giderilmiştir. Eksik veriler, istatistiksel yöntemler doğrultusunda tamamlanarak veri bütünlüğü sağlanmıştır. Sonrasında, her bir ülke için teknik göstergeler Excel ortamında hesaplanmış ve bu hesaplamaların doğruluğu, Investing ve TradingView gibi güvenilir finansal platformlar üzerinden teyit edilmiştir. Bu adım, veri setinin analitik modellere entegre edilmeden önce güvenilirliğini artırmak amacıyla gerçekleştirilmiştir. Bir diğer ön işleme adımı olarak, durağanlık testleri (istatistiksel yöntem için) uygulanarak veri setinin durağan olup olmadığı kontrol edilmiştir. Durağan olmayan veri setleri, istatistiksel analizlerin geçerliliğini sağlamak amacıyla durağan hale getirilmiştir. Ayrıca, veri setinin ölçeklendirilmesi ve model performansının iyileştirilmesi amacıyla normalizasyon işlemleri uygulanmıştır. Bu ön işleme adımları, ARIMA ve LSTM modelinin uygulanabilmesi için veri setini hazır hale getirmiştir. Çalışmanın analiz bölümünde, ülke bazında gerçekleştirilen veri hazırlama ve ön işleme süreçleri detaylı bir şekilde ele alınacak ve bu süreçlerin model performansı üzerindeki etkileri tartışılacaktır. Bu kapsamda öncelikle geleneksel istatistiksel yöntemlerden ARIMA modeli kullanılarak G7 ve E7 ülkelerine ait seçilmiş borsa endekslerinin tahmini ardından, derin öğrenme yöntemlerinden LSTM modeli ile söz konusu endekslerin tahmini gerçekleştirilecektir.

4.3 ARIMA (BOX-JENKINS) YÖNTEMİ İLE ENDEKS TAHMİNİ

Bu bölümde, G7 ve E7 ülkelerine ait seçilmiş borsa endeksleri, ARIMA modeli kullanılarak tahmin edilecektir. Çalışma kapsamında, 01.09.2006 ile 02.02.2022 tarihleri arasındaki günlük veriler analiz edilmiştir. Bağımlı değişken olarak belirlenen borsa endeksleri, teknik göstergeler ve makroekonomik değişkenler yardımıyla modellenmiştir. Araştırmanın ilk aşamasında, G7 ülkelerine ait borsa endeksleri üzerinde tahminleme çalışmaları gerçekleştirilmiş olup, sonraki aşamada ise E7 ülkelerinin borsa endeksleri için benzer analizler yapılmıştır.

ARIMA modeli uygulanırken, modelleme sürecinin ilk aşamasında serilerin durağanlık düzeyleri Augmented Dickey-Fuller (ADF) testi kullanılarak değerlendirilmiştir. Test sonuçlarına göre durağan olmayan serilere birinci dereceden fark alma yöntemi uygulanmış ve bu şekilde seriler durağan hale getirilmiştir. Serilerin durağanlaştırılmasının ardından, otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafiklerinden faydalanılarak modelde kullanılacak gecikme değerleri (p ve q parametreleri) belirlenmiştir.

Model parametrelerinin belirlenmesinin ardından, ARIMA modelinin farklı varyasyonları uygulanmış ve Akaike Bilgi Kriteri (AIC) dikkate alınarak en uygun model seçilmiştir. Modelleme sonucunda elde edilen bulgular, öngörü performansını değerlendirmek amacıyla MSE, RMSE, MAE ve MAPE gibi performans kriterleriyle analiz edilmiştir. Son olarak, model çıktıları grafiksel analizlerle desteklenmiş, tahmin edilen değerler ile gerçek değerler karşılaştırılmış ve modelin uygunluğu değerlendirilmiştir.


Çalışmada, ARIMA modelinin uygulanması ve sonuçların değerlendirilmesi aşamalarında Python programlama dili kullanılmıştır. Python'un sağladığı esneklik ve geniş kütüphane desteği sayesinde, modelleme süreçleri etkin bir şekilde gerçekleştirilmiştir. Elde edilen bulgular, G7 ve E7 ülkelerinin borsa endekslerinin davranışlarının anlaşılmasına ve geleceğe yönelik tahminlerin yapılmasına önemli katkılar sunacağı düşünülmektedir. Bu çalışma, hem gelişmiş ekonomileri temsil eden G7 ülkeleri hem de gelişmekte olan ekonomileri temsil eden E7 ülkeleri için borsa endekslerinin tahmin edilmesine yönelik karşılaştırmalı bir perspektif sunmayı hedeflemektedir. Analizlerin detayları ve sonuçları, çalışmanın ilerleyen bölümlerinde ayrıntılı bir şekilde ele alınacaktır.

4.3.1. G7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin Arıma Modeli İle Tahmini

Çalışmanın bu kısmında, G7 ülkelerinin borsa endekslerinin tahmin edilmesine yönelik metodolojik yaklaşım ve analiz süreci genel hatlarıyla ele alınacak olup, her bir ülke için elde edilen bulgular ayrıntılı bir şekilde sunulacaktır.

4.3.1.1 Amerika (S&P 500) Endeksi Tahmin Analizi

S&P 500 borsa endeks tahmininde bağımlı değişken olan ilgili endeksin kapanış fiyatlarına ait endeks grafiği Şekil 4.2.' de gösterilmiştir.




Şekil 4.2. S&P 500 Endeksi Kapanış Verileri

Ekonometrik modellerde kullanılan değişkenler arasında anlamlı ilişkiler elde edilebilmesi için serilerin durağanlık koşulunu sağlaması gerekmektedir. Bir serinin durağan olmaması, ortalamasının ve varyansının zamana bağlı olarak değişkenlik gösterdiği anlamına gelmektedir. Bu durum, seriye dayalı olarak oluşturulan modellerin yanlış tanımlanmasına yol açabilmektedir. Çalışmada kullanılan bağımlı ve bağımsız değişkenlerin sahte regresyon sorununa neden olmaması için serilerin durağan hale getirilmesi gerekmektedir. Öncelikle incelenen serinin varyansını sabitleştirmek için seriye uygun bir dönüşüm uygulanması gerekmektedir. Logaritması alınan değişkenlerin durağanlık durumu, ADF testi sonuçları ile analiz edilmiştir. Değişkenlerin durağanlık durumunu gösteren bilgiler Tablo 4.4. ADF Birim Kök Test Sonuçları' te verilmiştir.

Tablo 4.4. ADF Birim Kök Test Sonuçları

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-11.9291	I(1)
D LOG MA14	-11.5881	I(1)
LOG RSI	-12.0525	I(0)
D LOG WMA	-13.7765	I(1)
Momentum	-11.7106	I(0)
LOG StokastikK	-19.2973	I(0)
LOG StokastikD	-12.1201	I(0)
MACD	-12.0960	I(0)
R	-19.2470	I(0)
LOG ACC	-4.0336	I(0)
CCI	-16.2872	I(0)
D LOG DXY	-12.1339	I(1)
D LOG PETROL	-58.6842	I(1)
D LOG ALTIN	-19.6861	I(1)

Değişkenlerden Momentum, MACD, Williams' R ve CCI dışındaki değişkenlerin logaritmik dönüşümü alınarak modele dahil edilmiştir. Bu dört değişken ise negatif değer içerdiğinden seviye değerinde model kapsamına alınmıştır. Yapılan test sonuçlarına göre, RSI, Stokastik K, Stokastik D ve ACC değişkenlerinin seviyede durağan olduğu ve birim kök taşımadığı belirlenmiştir. Diğer değişkenlerin ise birinci dereceden farkları alınarak %1, %5 ve %10 anlamlılık düzeylerinde kritik değerleri karşıladığı ve durağan oldukları tespit edilmiştir. Durağan hale getirilen değişkenlerin grafikleri Şekil 4.3.' te gösterilmiştir.




Şekil 4.3. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ilişkin tamamlayıcı istatistikler Tablo 4.5.' te sunulmuştur. Ayrıca, değişkenler arasındaki korelasyon ilişkilerini gösteren ısı haritası Şekil 4.4.' te yer almaktadır.

Tablo 4.5. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.5402	0.0547	0.5415	-0.2513	11.1309
MA14	0.6864	0.0338	0.6901	-2.5308	49.8402
RSI	0.7247	0.1354	0.7522	-0.8847	0.7523
WMA	0.6784	0.0286	0.6806	-1.3676	24.5421
Momentum	0.6338	0.0648	0.6373	-1.307	12.6441
Stokastik K	0.9254	0.1048	0.9658	-2.839	10.9307
Stokastik D	0.8715	0.1423	0.9322	-1.6666	3.0997
MACD	0.5022	0.0638	0.5019	-0.0864	13.1178
R	0.6413	0.3035	0.7252	-0.579	-0.9737
ACC	0.7792	0.2053	0.8598	-1.1271	0.4296
CCI	0.6287	0.1541	0.6708	-0.6593	-0.2352
DXY	0.4837	0.0616	0.483	0.1339	4.062
PETROL	0.5917	0.0537	0.5932	-0.1739	8.0304
ALTIN	0.469	0.059	0.4697	0.1076	8.3378



Şekil 4.4. Değişkenler Arası Korelasyon


Şekil 4.4. verilere göre, endeks değeri ile DXY arasında negatif yönlü bir ilişki olduğu tespit edilmiştir. Diğer değişkenler olan Stokastik K, R, RSI, WMA, CCI, ve MA ile endeks arasındaki korelasyon katsayıları ise zayıf düzeyde kalmıştır. Momentum,

Stokastik D, MACD, ACC ve Altın göstergeleri ile endeks arasında neredeyse ihmal edilebilir düzeyde çok zayıf bir ilişki saptanmıştır.

Bu sonuçlar, söz konusu değişkenlerin model girdisi olarak kullanılabilirliğini desteklemektedir. Zayıf korelasyonel bağlantıların varlığı, değişkenler arasında çoklu doğrusal bağlantı riskini azaltarak tahmin modelinin parametrik stabilitesini ve istatistiksel güvenilirliğini artırmaktadır. Ayrıca, bu durum değişkenlerin birbirinden bağımsız bilgi içeriği taşıdığını göstermekte ve modelin açıklayıcı gücünü (R^2) artırma potansiyeline katkı sağlamaktadır. Böylece, modelin daha tutarlı ve genelleştirilebilir tahminler yapması mümkün hale gelmektedir.


4.3.1.1.1 S&P 500 Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Logaritmik dönüşüm ve birinci dereceden fark alma işlemleri sonrasında tüm seriler durağan hale getirilmiş ve uygun model seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en iyi açıklayıcı modelin belirlenmesinde şu kriterler dikkate alınmıştır: modelin en düşük Akaike Bilgi Kriteri (AIC) değerine sahip olması, F istatistiğinin istatistiksel olarak anlamlı çıkması, modelin kalıntılarının hata kareleri toplamının düşük olması ve modelin açıklayıcılığını temsil eden en yüksek R^2 değerine ulaşması. Bu değerlendirme ölçütleri, en uygun modelin seçilmesinde temel referans noktaları olarak kullanılmaktadır. Buna göre S&P 500 endeksinin tahmini için, en düşük AIC değeri (-12123.855) göz önünde bulundurularak, ARIMA (2,1,2) modeli seçilmiştir. ARIMA (2,1,2) model sonucuna göre elde edilen artık değer (kalıntılar) grafiği Şekil 4.5.' te gösterilmiştir.



Şekil 4.5. ARIMA (2,1,2) S&P 500 Artıkların Histogram Grafiği

Şekil 4.5.' te görüldüğü üzere artıkların çoğunlukla sıfır etrafında toplanması modelin genel eğilimi doğru yakaladığını göstermektedir. Bu bulgular, ARIMA (2,1,2) modelinin veriye uyumunun istatistiksel olarak anlamlı olduğunu ve tercih edilebilir bir model olduğunu teyit etmektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.6.' da, yine ilgili modele ait başarı metrikleri Tablo 4.6.' da sunulmuştur.



Şekil 4.6. ARIMA (2,1,2) S&P 500 Tahmin Grafiği

Şekil 4.6. İncelendiğinde, gerçek değerler ile tahminlerin genel trend ve dalgalanmaları tutarlı bir şekilde yakaladığını göstermekte olup, sapmaların istatistiksel olarak aşırı düzeyde olmadığı gözlemlenmiştir.

Tablo 4.6. S&P 500 Endeks Tahmini Başarı Metrikleri


Model	MSE	RMSE	MAE	MAPE
ARIMA (2,1,2)	26083.92	161.51	100.53	4.8129

Modelin performansı Tablo 4.6.' da yer alan başarı metrikleriyle değerlendirildiğinde, RMSE değerinin 161.5 olması modelin tahminlerinin gerçek değerden ortalama olarak ± 161.5 puan sapma gösterdiğini ifade etmektedir. Daha küçük hatalara karşı duyarlı olan MAE değeri ise 100.5 olarak hesaplanmıştır. Bu durum, modelin tahminlerinin gerçek değerden ortalama olarak ± 100.5 puanlık mutlak sapma gösterdiğini göstermektedir. MAPE değerinin %4.81 olması, modelin tahminlerinin

gerçek değerden ortalama olarak %4.81 oranında sapma gösterdiğini ifade etmektedir. Bu metrikler birlikte değerlendirildiğinde, modelin tahmin performansının genel olarak başarılı olduğu ve modelin orta vadeli stratejik planlamalar ve risk yönetimi süreçlerinde kullanılabileceği sonucuna varılmıştır.

4.3.1.2 Kanada (S&P/TSX) Endeksi Tahmin Analizi

S&P/TSX borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.7.' de sunulmuştur.




Şekil 4.7. S&P/TSX Endeksi Kapanış Verileri

Çalışmada kullanılan bağımlı ve bağımsız değişkenlerin durağanlık testi uygulanmadan önce, serilerin varyansını stabilize etmek amacıyla uygun dönüşümlerin gerçekleştirilmesi gerekmektedir. Bu kapsamda, logaritmik dönüşüm uygulanarak serilerin varyansındaki olası dalgalanmalar minimize edilmiştir. Dönüşüm işleminin ardından, verilerin durağanlık durumu ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.7.' de sunulmuştur.

Tablo 4.7. ADF Birik Kök Test Sonuçları

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-10.8786	I(1)
D LOG MA14	-12.4280	I(1)
LOG RSI	-11.1468	I(0)
D LOG WMA	-13.7792	I(1)
Momentum	-9.2908	I(0)
LOG Stokastik K	-12.9480	I(0)
LOG Stokastik D	-15.1655	I(0)
MACD	-12.0209	I(0)
R	-18.6021	I(0)
LOG ACC	-6.0289	I(0)
CCI	-16.0072	I(0)
D LOG DXY	-20.5483	I(1)
D LOG PETROL	-9.4482	I(1)
D LOG ALTIN	-19.3826	I(1)

Tablo 4.7.' de sunulan verilere göre, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle bu değişkenlere logaritmik dönüşüm uygulanamamış ve düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanmıştır. Logaritmik dönüşüm sonrasında durağanlık göstermeyen değişkenler, birinci dereceden farkı alınarak %1, %5, %10 anlamlılık düzeylerindeki kritik değerler için durağan olduğu belirlenmiştir. Durağan hale getirilen değişkenlerin grafikleri Şekil 4.8. Durağan Hale Getirilmiş Değişkenler.' de gösterilmiştir.




Şekil 4.8. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ilişkin tamamlayıcı istatistikler Tablo 4.8.' de ayrıntılı bir biçimde sunulmuştur. Ayrıca, değişkenler arasındaki korelasyon ilişkilerini gösteren ısı haritası Şekil 4.9.' da yer almaktadır.

Tablo 4.8. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.5398	0.0462	0.5418	0.1089	12.1774
MA14	0.7959	0.0265	0.7977	-1.4195	16.7515
RSI	0.7432	0.1311	0.7662	-1.0511	1.8312
WMA	0.8057	0.0275	0.8071	-1.561	16.0579
Momentum	0.7425	0.0612	0.7481	-1.9588	13.8605
Stokastik K	0.9249	0.089	0.9576	-2.1157	5.4558
Stokastik D	0.8426	0.1586	0.8987	-1.4499	1.8791
MACD	0.5776	0.0616	0.5772	-0.4571	11.8732
R	0.6014	0.297	0.6541	-0.4022	-1.1026
ACC	0.878	0.123	0.9263	-2.089	5.2279
CCI	0.5754	0.1473	0.6003	-0.4872	-0.2992
DXY	0.5265	0.0677	0.5258	-0.035	3.3283
PETROL	0.5917	0.0528	0.5933	-0.015	7.308
ALTIN	0.4842	0.0556	0.4843	0.0708	10.2866




Şekil 4.9. Değişkenler Arası Korelasyon

Şekil 4.9.'daki verilere göre, endeks değeri ile DXY arasında negatif yönlü bir ilişki tespit edilmiştir. Buna karşın, Stokastik K, R, RSI, WMA, CCI, Momentum ve Petrol değişkenleri ile endeks arasındaki korelasyon katsayılarının zayıf düzeyde olduğu görülmektedir. MA, Stokastik D, ACC, MACD ve Altın göstergeleri ise endeks ile çok zayıf bir ilişki sergilemektedir.

Bu bulgular, ilgili değişkenlerin model girdisi olarak kullanılabilirliğini göstermektedir. Özellikle zayıf korelasyonlar, değişkenler arasındaki çoklu doğrusal bağlantı riskini azaltarak tahmin modelinin parametrik stabilitesini ve istatistiksel güvenilirliğini artırmaktadır. Ayrıca, değişkenlerin birbirinden bağımsız bilgi içeriğine sahip olması, modelin açıklayıcı gücünü yükselterek tahmin performansına olumlu katkı sağlamaktadır. Değişkenler arasındaki korelasyon analizinde, çoklu doğrusal bağlantı sorununa yol açabilecek düzeyde yüksek bir ilişki tespit edilmemiştir. Bu nedenle, tüm değişkenlerin tahmin modellerine dâhil edilmesinde herhangi bir sakınca bulunmamaktadır.


4.3.1.2.1 S&P /TSX Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Seriler durağan hale getirildikten sonra, farklı ARIMA modelleri üzerinden karşılaştırmalı bir değerlendirme yapılmış ve bu modeller arasından seriyi en iyi açıklayan model belirlenmiştir. Yapılan deneysel süreçlerin ardından, en düşük AIC değerini gösteren ARIMA (2,1,0) modelinin diğer modellere göre en uygun model olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri -13232.785 olarak tespit edilmiştir. ARIMA (2,1,0) model sonucuna göre elde edilen artık değer grafiği Şekil 4.10.' Şekil 4.10. Artıkların Histogram Grafiği'de gösterilmiştir.



Şekil 4.10. Artıkların Histogram Grafiği

Şekil 4.10. İncelendiğinde histogram grafiğinin normallik varsayımını karşıladığını göstermektedir. Bu bulgular, ARIMA (2,1,0) modelinin veriye uyumunun istatistiksel olarak anlamlı olduğunu ve tercih edilebilir bir model olduğunu teyit etmektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.11’ de, yine ilgili modele ait başarı metrikleri Tablo 4.9.’ da sunulmuştur.



Şekil 4.11. ARIMA (2,1,0) S&P/TSX Tahmin Grafiği

Şekil 4.11. İncelendiğinde, gerçek endeks değeri ile ARIMA (2,1,0) model tahminlerinin grafiksel karşılaştırması, modelin genel trendi yakalama yeteneğini açıkça ortaya koymaktadır. Tahmin eğrisinin gerçek değerlerle yakın bir seyir izlemesi, sapmaların istatistiksel olarak aşırı düzeyde olmadığını göstermektedir.

Tablo 4.9. S&P/TSX Endeks Tahmini Başarı Metrikleri


Model	MSE	RMSE	MAE	MAPE
ARIMA (2,1,0)	229603.16	479.17	297.67	3.9267

Modelin performansı başarı metrikleri ile değerlendirildiğinde, RMSE değerinin 479.17 olduğu tespit edilmiştir. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 479.17 puanlık bir sapma gösterebileceğine işaret etmektedir. Daha küçük hatalara duyarlı bir metrik olan MAE değeri ise 297.67 olarak belirlenmiştir. Bu durum, modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 297.67 puanlık bir sapma gösterdiğini ifade etmektedir. Ayrıca, MAPE değerinin %3.926 olarak

hesaplanması, modelin tahminlerinin gerçek değerlere göre ortalama olarak %3.926 oranında bir sapma gösterdiğini ortaya koymaktadır. Elde edilen bu bulgular, düşük yüzdesel hata modelin genel doğruluğunu ve tahmin başarısını istatistiksel olarak desteklemektedir.

4.3.1.3 Almanya (DAX) Endeksi Tahmin Analizi

DAX Borsa endeks tahmininde bağımlı değişken olan ilgili endeksin kapanış fiyatlarına ait endeks grafiği Şekil 4.12.' de gösterilmiştir.




Şekil 4.12. Almanya DAX Endeksi Kapanış Verileri

Çalışmada kullanılan bağımlı ve bağımsız değişkenlere durağanlık testi uygulanmadan önce, serilerin varyansını stabilize etmek amacıyla gerekli dönüşüm işlemleri gerçekleştirilmiştir. Bu doğrultuda, varyanstaki olası dalgalanmaların azaltılması için logaritmik dönüşüm uygulanmıştır. Dönüşüm sonrasında, serilerin durağanlık durumları ADF testi ile değerlendirilmiş ve test sonuçları Tablo 4.10' da detaylı olarak sunulmuştur.

Tablo 4.10. ADF Birik Kök Test Sonuçları

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-26.8174	I(1)
D LOG MA14	-11.5997	I(1)
LOG RSI	-12.7343	I(0)
D LOG WMA	-13.5234	I(1)
Momentum	-9.5121	I(0)
LOG Stokastik K	-15.4080	I(0)
LOG Stokastik D	-15.1030	I(0)
MACD	-14.5356	I(0)
R	-15.2229	I(0)
LOG ACC	-4.8769	I(0)
CCI	-14.3578	I(0)
D LOG DXY	-56.9479	I(1)
D LOG PETROL	-57.6183	I(1)
D LOG ALTIN	-13.6684	I(1)

Tablo 4.10.' da sunulan sonuçlar incelendiğinde, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle bu değişkenlere logaritmik dönüşüm uygulanamadığı ve bu sebeple düzey değerleriyle modele dahil edildiği görülmüştür. Buna karşılık, negatif değer içermeyen diğer değişkenlere logaritmik dönüşüm uygulanarak varyans stabilizasyonu sağlanmıştır. Logaritmik dönüşümün ardından durağanlık göstermeyen değişkenler, birinci dereceden farkları alınarak analiz edilmiştir. Yapılan ADF testi sonucunda, tüm değişkenlerin %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerlere göre durağan olduğu tespit edilmiştir. Durağan hale getirilen değişkenlerin grafiksel gösterimleri, Şekil 4.13.' te sunulmaktadır.




Şekil 4.13. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ilişkin tanımlayıcı istatistikler Tablo 4.11.' de ayrıntılı bir biçimde sunulmuştur. Ayrıca, değişkenler arasındaki korelasyon ilişkilerini gösteren ısı haritası Şekil 4.14.' te yer almaktadır.

Tablo 4.11. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.5491	0.0603	0.551	0.0057	6.5788
MA14	0.4253	0.0301	0.4283	-0.9152	17.2425
RSI	0.7697	0.1174	0.7904	-1.2456	3.1281
WMA	0.4483	0.0363	0.4513	-1.2129	13.9135
Momentum	0.6694	0.0677	0.6753	-1.1693	8.0877
Stokastik K	0.914	0.105	0.9548	-2.117	5.7383
Stokastik D	0.8445	0.162	0.9069	-1.4384	1.8031
MACD	0.5748	0.0686	0.5757	-0.2325	7.3843
R	0.6032	0.3074	0.6667	-0.4121	-1.18
ACC	0.7582	0.2088	0.8448	-0.9815	0.5241
CCI	0.5206	0.1582	0.5521	-0.4594	-0.3644
DXY	0.5857	0.0537	0.5851	-0.1812	6.5042
PETROL	0.4536	0.0403	0.4548	0.0391	8.1801
ALTIN	0.4986	0.058	0.4986	0.2476	11.8668




Şekil 4.14. Değişkenler Arası Korelasyon

Şekil 4.14. Analiz sonuçlarına göre, endeks değeri ile DXY arasında negatif yönlü bir ilişki olduğu belirlenmiştir. Diğer taraftan, Stokastik K, R, RSI, WMA, CCI, Momentum ve Petrol gibi değişkenlerin endeks ile olan korelasyon katsayılarının zayıf düzeyde kaldığı gözlemlenmiştir. MA, Stokastik D, MACD, ACC ve Altın göstergeleri ise endeks ile çok zayıf bir ilişki göstermektedir.

Bu sonuçlar, söz konusu değişkenlerin modelde girdi olarak kullanılabilirliğine işaret etmektedir. Zayıf korelasyonlar, değişkenler arasında çoklu doğrusal bağlantı riskini minimize ederek, modelin parametrik stabilitesini ve istatistiksel güvenilirliğini artırmaktadır. Ayrıca, değişkenlerin birbirinden bağımsız bilgi içeriği sunması, modelin açıklayıcı gücünü artırarak tahmin performansına önemli bir katkı sağlamaktadır. Bu durum, modelin daha sağlam ve güvenilir sonuçlar üretmesine olanak tanımaktadır.

4.3.1.3.1 DAX Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi


Seriler durağan hale getirildikten sonra, farklı ARIMA modelleri arasında karşılaştırmalı bir değerlendirme yapılmış ve seriyi en iyi açıklayan model belirlenmiştir. Deneysel analizler sonucunda, en düşük AIC değerine sahip olan ARIMA (1,1,5) modelinin, diğer modellere kıyasla en uygun model olduğu tespit edilmiştir. Söz konusu modelin AIC değeri- 11336.467 olarak hesaplanmıştır. ARIMA (1,1,5) modeline ilişkin artık değerlerin grafiği ise Şekil 4.15.' te sunulmuştur.



Şekil 4.15. Artıkların Histogram Grafiği

Artıkların histogram grafiği incelendiğinde, artık değerlerin genel olarak sıfır etrafında yoğunlaştığı ve simetrik bir dağılım sergilediği görülmektedir. Bu durum, artıkların yaklaşık olarak normal dağılıma uygunluk gösterdiğini işaret etmektedir. Kırmızı çizgiyle gösterilen teorik normal dağılım eğrisi ile histogramın büyük ölçüde

uyumlu olması, modelin tahmin hatalarının rastgele ve sistematik bir yapıya sahip olmadığını ortaya koymaktadır. Ayrıca, uç değerlerin sınırlı sayıda olması, modelin aşırı sapmalar üretmediğini göstermektedir. ARIMA (1,1,5) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.16.' da yine ilgili modele ait başarı metrikleri Tablo 4.12.' de sunulmuştur.



Şekil 4.16. ARIMA (1,1,5) DAX Endeks Tahmin Grafiği

Şekil 4.16.' da Almanya Borsası DAX endeksinin gerçek değerleri ile ARIMA (1,1,5) modelinin test verisi üzerindeki tahmin sonuçları karşılaştırılmıştır. Buna göre; ARIMA (1,1,5) modelinin genel trendi ve önemli dalgalanmaları yakalayabildiği ve modelin gerçek değerlerle paralel bir performansı sergilediği gözlenmektedir.

Tablo 4.12. DAX Endeks Tahmini Başarı Metrikleri


Model	MSE	RMSE	MAE	MAPE
ARIMA (1,1,5)	316447.86	562.54	369.99	5.5998

Modelin performansı başarı metrikleri ile değerlendirildiğinde; RMSE değeri 562.54 olarak hesaplanmıştır. RMSE değeri, genel hata büyüklüğünün nispeten düşük olduğunu göstermektedir. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 562.54 puanlık bir sapma gösterebileceğine işaret etmektedir. Daha küçük hatalara duyarlı bir metrik olan MAE değeri ise 369.99 olarak belirlenmiştir. Bu durum, modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 369.99 puanlık bir

sapma gösterdiğini ifade etmektedir ve MAE değeri, tahminlerdeki ortalama sapmanın makul seviyede olduğunu ortaya koymaktadır. Ayrıca, MAPE değerinin %5.59 olarak hesaplanması, modelin tahminlerinin gerçek değerlere göre ortalama olarak %5.59 oranında bir sapma gösterdiğini ortaya koymaktadır. Elde edilen bulgular modelin güvenilir tahminler ürettiğini desteklemektedir.

4.3.1.4 Fransa (CAC40) Endeksi Tahmin Analizi

CAC40 borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.17.' de sunulmuştur




Şekil 4.17. Fransa CAC40 Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerin varyansında gözlenebilecek olası dalgalanmaları stabilize etmek amacıyla uygun dönüşümler gerçekleştirilmiştir. Bu doğrultuda, serilere logaritmik dönüşüm uygulanmış ve varyanstaki potansiyel dalgalanmalar en aza indirgenmiştir. Dönüşüm işlemlerinin ardından serilerin durağanlık özellikleri, ADF testi kullanılarak değerlendirilmiş ve elde edilen bulgular Tablo 4.13.' te özetlenmiştir.

Tablo 4.13. ADF Birik Kök Test Sonuçları

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-18.5172	I(1)
D LOG MA14	-11.8667	I(1)
LOG RSI	-13.5776	I(0)
D LOG WMA	-13.2608	I(1)
Momentum	-11.2577	I(0)
LOG Stokastik K	-15.0052	I(0)
LOG Stokastik D	-15.1535	I(0)
MACD	-14.2388	I(0)
R	-12.1127	I(0)
LOG ACC	-3.6790	I(0)
CCI	-15.7009	I(0)
D LOG DXY	-55.9998	I(1)
D LOG PETROL	-56.9950	I(1)
D LOG ALTIN	-16.1499	I(1)

Tablo 4.13.' te sunulan verilere göre, Momentum, MACD, Williams %R ve CCI değişkenleri negatif değerlere sahip oldukları için bu değişkenlere logaritmik dönüşüm uygulanamamış ve düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanmıştır. Logaritmik dönüşümün ardından durağanlık göstermeyen değişkenlerin birinci dereceden farkı alınmış ve bu işlem sonucunda %1, %5 ve %10 anlamlılık düzeylerine ait kritik değerler açısından durağan oldukları tespit edilmiştir. Durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.18.' de sunulmuştur.




Şekil 4.18. Durağan Hale Getirilmiş Değişkenler

İlgili endeks için durağanlaştırılmış bağımlı ve bağımsız değişkenlere ilişkin detaylı istatistiksel bilgiler Tablo 4.14.' te kapsamlı bir şekilde sunulmuştur. Bunun yanı sıra, değişkenler arasındaki korelasyon ilişkilerini görselleştiren ısı haritası Şekil 4.19.' da gösterilmektedir.

Tablo 4.14. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.5537	0.063	0.5554	-0.0284	6.7594
MA14	0.7586	0.028	0.7607	-0.0337	11.9487
RSI	0.7771	0.1136	0.7966	-0.8993	1.3057
WMA	0.7102	0.0248	0.7121	-0.2864	14.6588
Momentum	0.6494	0.0673	0.6563	-1.0104	6.6461
StokastikK	0.9097	0.1068	0.9486	-2.127	6.0149
StokastikD	0.8433	0.1595	0.9018	-1.4137	1.9428
MACD	0.6341	0.0776	0.6343	-0.2825	4.9952
R	0.585	0.3058	0.6302	-0.3366	-1.2228
ACC	0.7135	0.2274	0.7705	-0.6389	-0.4436
CCI	0.5751	0.1304	0.5963	-0.4418	-0.3543
DXY	0.4827	0.0622	0.4822	0.0888	4.6611
PETROL	0.5661	0.0507	0.5677	0.2958	9.9851
ALTIN	0.5029	0.0591	0.5032	-0.089	13.6472




Şekil 4.19. Değişkenler Arası Korelasyon

Şekil 4.19.' da yer alan analiz sonuçlarına göre, endeks değeri ile Altın ve DXY arasında negatif yönlü bir ilişki tespit edilmiştir. Diğer değişkenlerden olan, MA, Stokastik K, R, RSI, WMA, CCI, Momentum ve Petrol'un endeks ile olan korelasyonlarının zayıf düzeyde kaldığı görülmüştür. Stokastik D ve MACD ve ACC göstergelerinin ise endeks ile çok zayıf bir ilişki gösterdiği belirlenmiştir.

Bu bulgular, söz konusu değişkenlerin modelde girdi olarak kullanılabilirliğini desteklemektedir. Zayıf korelasyon değerleri, değişkenler arasında çoklu doğrusal bağlantı riskini azaltarak modelin parametrik istikrarını ve istatistiksel güvenilirliğini artırmaktadır. Ayrıca, değişkenlerin birbirinden bağımsız bilgi içermesi, modelin açıklayıcı gücünü güçlendirmekte ve tahmin performansının iyileştirilmesine katkı sağlamaktadır. Bu durum, modelin daha tutarlı, genelleştirilebilir ve güvenilir sonuçlar üretmesini mümkün kılmaktadır.


4.3.1.4.1 CAC40 Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntıların hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, CAC40 endeksinin tahmini için en uygun modelin ARIMA (0,1,1) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri-10927.205 olarak hesaplanmıştır. ARIMA (0,1,1) model sonucuna göre elde edilen artık değer grafiği Şekil 4.20.' de gösterilmiştir



Şekil 4.20. Artıkların Histogram Grafiği

Şekil 4.20.' de yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler (aşırı sapmalar) sınırlı sayıdadır ve bu da ARIMA (0,1,1) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.21.' de, yine ilgili modele ait başarı metrikleri Tablo 4.15.' te sunulmuştur.



Şekil 4.21. ARIMA (0,1,1) CAC40 Endeks Tahmin Grafiği

Şekil 4.21 incelendiğinde, gerçek endeks değeri ile ARIMA (0,1,1) model tahminlerinin grafiksel karşılaştırılması yapılmıştır. Tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve birbirine paralel bir yapı sergilediği görülmektedir. Bu durum, modelin test seti üzerindeki performansının iyi olduğunu işaret etmektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin genelde doğru tahminlerde bulunduğunu ve genel trendi iyi yakaladığını göstermektedir.


Tablo 4.15. CAC40 Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (0,1,1)	48502.89	220.23	146.82	5.792

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; hesaplanan RMSE değeri 220.23 olarak bulunmuştur. Bu değer, modelin tahminlerinin genel hata büyüklüğünün nispeten düşük seviyede olduğunu ve tahminlerin ortalama endeks değeri etrafında ± 220.23 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan, daha küçük hatalara duyarlı bir metrik olan MAE değeri 146.82 olarak hesaplanmıştır. Bu sonuç, modelin tahminlerinin gerçek endeks değerlerinden ortalama olarak ± 146.82 birimlik bir sapma gösterdiğine işaret etmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir bir düzeyde olduğunu göstermektedir. Ayrıca, MAPE değerinin %5.79 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %5.79 oranında bir sapma içerdiğini ortaya koymaktadır. Elde edilen bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.1.5 İngiltere (FTSE100) Endeksi Tahmin Analizi

FTS100 borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.22.' de sunulmuştur



Şekil 4.22. İngiltere FTSE100 Endeksi Kapanış Verileri


İstatistiksel analiz öncesinde, değişkenlere ait serilerin varyans stabilizasyonunu sağlamak amacıyla logaritmik dönüşüm uygulanmıştır ve varyanstaki potansiyel

dalgalanmalar en aza indirgenmiştir. Dönüşüm işlemlerinin ardından serilerin durağanlık özellikleri, ADF testi kullanılarak değerlendirilmiş ve elde edilen bulgular Tablo 4.16.'da özetlenmiştir.

Tablo 4.16. ADF Birim Kök Test Sonuçları

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-16.5029	I(1)
D LOG MA14	-10.0431	I(1)
LOG RSI	-14.3413	I(0)
D LOG WMA	-14.3196	I(1)
Momentum	-12.1099	I(0)
LOG StokastikK	-15.6021	I(0)
LOG StokastikD	-15.2693	I(0)
MACD	-12.9118	I(0)
R	-14.0244	I(0)
LOG ACC	-4.9129	I(0)
CCI	-16.4733	I(0)
D LOG DXY	-33.4068	I(1)
D LOG PETROL	-10.0275	I(1)
D LOG ALTIN	-35.5292	I(1)

Tablo 4.16.'da gösterildiği üzere, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerler içermesi sebebiyle, bu değişkenler dönüşüm uygulanmaksızın düzey değerleriyle modele dâhil edilmiştir. Diğer değişkenlere uygulanan logaritmik dönüşümün ardından, durağanlık şartını sağlamayan serilerin birinci dereceden farkları alınmıştır. Gerçekleştirilen durağanlaştırma işlemleri sonucunda tüm değişkenlerin %1, %5 ve %10 anlamlılık seviyelerine ait kritik değerler açısından durağan oldukları tespit edilmiştir. Durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.22.'de sunulmuştur.




Şekil 4.23. Durağan Hale Getirilmiş Değişkenler

İlgili endeks için durağanlaştırılmış bağımlı ve bağımsız değişkenlere ilişkin detaylı istatistiksel bilgiler Tablo 4.17.' de kapsamlı bir şekilde sunulmuştur. Bunun yanı sıra, değişkenler arasındaki korelasyon ilişkilerini görselleştiren ısı haritası Şekil 4.24.' te gösterilmektedir.

Tablo 4.17. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.4558	0.0613	0.457	0.1035	8.6429
MA14	0.5585	0.0452	0.5617	-0.9337	12.4606
RSI	0.7066	0.1276	0.7266	-0.8991	1.3398
WMA	0.6575	0.0552	0.6606	-1.0514	9.0716
Momentum	0.6732	0.0759	0.6792	-0.9522	4.9814
StokastikK	0.8931	0.1219	0.9346	-2.0546	5.4866
StokastikD	0.8265	0.1699	0.8835	-1.3802	1.7168
MACD	0.6058	0.0815	0.6032	-0.1313	2.996
R	0.5755	0.3002	0.6063	-0.294	-1.1976
ACC	0.7857	0.1757	0.8538	-1.3783	2.1767
CCI	0.5768	0.1365	0.5996	-0.3953	-0.4426
DXY	0.4836	0.0625	0.483	0.0256	4.4017
PETROL	0.5664	0.0507	0.5675	0.0651	8.3941
ALTIN	0.4987	0.058	0.4987	0.1449	10.0597




Şekil 4.24. Endeksle Değişkenler Arası Korelasyon

Şekil 4.24.' te sunulan analiz sonuçlarına göre, endeks değeri ile DXY arasında negatif yönlü anlamlı bir ilişki tespit edilmiştir. Bununla birlikte, MA, Stokastik K, R, RSI, WMA, CCI, Momentum ve Petrol değişkenlerinin endeks ile olan korelasyon katsayılarının zayıf düzeyde kaldığı gözlemlenmiştir. Stokastik D, MACD, ACC ve Petrol göstergeleri ise endeks ile istatistiksel olarak çok zayıf bir ilişki göstermiştir.

Bu bulgular, bahsedilen değişkenlerin modelde girdi olarak kullanılabilirliğini desteklemektedir. Zayıf korelasyon değerleri, değişkenler arasında çoklu doğrusal bağlantı riskini minimize ederek modelin parametrik istikrarını ve istatistiksel güvenilirliğini artırmaktadır. Ayrıca, değişkenlerin birbirinden bağımsız bilgi içeriği sunması, modelin açıklayıcı gücünü artırmakta ve tahmin performansının iyileştirilmesine önemli bir katkı sağlamaktadır. Bu durum, modelin daha tutarlı, genelleştirilebilir ve güvenilir sonuçlar üretmesine olanak tanımaktadır. Dolayısıyla, söz konusu değişkenlerin modelde kullanımı, tahmin performansının artırılması ve istatistiksel geçerliliğin sağlanması açısından uygun olduğunu göstermektedir.


4.3.1.5.1 FTSE100 Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Seriler durağan hale getirildikten sonra, farklı ARIMA modelleri arasında karşılaştırmalı bir değerlendirme yapılmış ve seriyi en iyi açıklayan model belirlenmiştir. Deneysel analizler sonucunda, en düşük AIC değerine sahip olan ARIMA (3,1,5) modelinin, diğer modellere kıyasla en uygun model olduğu tespit edilmiştir. Söz konusu modelin AIC değeri -10967.272 olarak hesaplanmıştır. ARIMA (3,1,5) modeline ilişkin artık değerlerin grafiği ise Şekil 4.25.' te sunulmuştur.



Şekil 4.25. Artıkların Histogram Grafiği

Artıkların histogram grafiği incelendiğinde, artık değerlerin genel olarak sıfır etrafında yoğunlaştığı ve simetrik bir dağılım sergilediği görülmektedir. Bu durum, artıkların yaklaşık olarak normal dağılıma uygunluk gösterdiğini işaret etmektedir. Kırmızı çizgiyle gösterilen teorik normal dağılım eğrisi ile histogramın büyük ölçüde uyumlu olması, modelin tahmin hatalarının rastgele ve sistematik bir yapıya sahip olmadığını ortaya koymaktadır. Ayrıca, uç değerlerin sınırlı sayıda olması, modelin aşırı sapmalar üretmediğini göstermektedir. ARIMA (3,1,5) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.26.' da, yine ilgili modele ait başarı metrikleri Tablo 4.18.' de sunulmuştur.



Şekil 4.26 ARIMA (3,1,5) FTSE100 Endeks Tahmin Grafiği

Şekil 4.26.' da İngiltere Borsası FTSE100 endeksinin gerçek değerleri ile ARIMA (3,1,5) modelinin test verisi üzerindeki tahmin sonuçları karşılaştırılmıştır. Buna göre; ARIMA (3,1,5) modelinin genel trendi ve önemli dalgalanmaları doğru bir şekilde yakalayabildiği görülmektedir. Özellikle sabit trende yapısına sahip dönemlerde güçlü bir performans sergilediği gözlemlenmiştir.

Tablo 4.18. FTSE100 Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (3,1,5)	39106.1	197.75	128.78	7.251


Modelin performansı başarı metrikleri ile değerlendirildiğinde; RMSE değeri 197.75 olarak hesaplanmıştır. RMSE, modelin tahminlerinin gerçek değerlerden ortalama olarak ± 197.75 birim sapma gösterdiğini ifade etmektedir. Bu değer, modelin tahminlerinde genel hata büyüklüğünün nispeten düşük olduğunu göstermektedir.

MAE değeri ise 128.78 olarak belirlenmiştir. Bu durum, modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 128.78 puanlık bir sapma gösterdiğini ifade etmektedir. MAE, RMSE'ye kıyasla daha küçük hatalara duyarlıdır ve bu değer, modelin tahminlerindeki ortalama sapmanın makul seviyede olduğunu göstermektedir.

MAPE değeri %7.251 olarak hesaplanmıştır. Bu, modelin tahminlerinin gerçek değerlere göre ortalama %7.251 oranında bir sapma gösterdiğini ifade etmektedir. Bu sapma, modelin genel olarak kabul edilebilir bir doğrulukla tahminler ürettiğini göstermektedir.

4.3.1.6 İtalya (FTSE MIB) Endeksi Tahmin Analizi

FTS100 borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.27' de sunulmuştur



Şekil 4.27. İtalya FTSE MIB Endeksi Kapanış Verileri


İstatistiksel analiz öncesinde, değişkenlere ait serilerin varyans stabilizasyonunu sağlamak amacıyla logaritmik dönüşüm uygulanmıştır ve varyanstaki potansiyel dalgalanmalar en aza indirgenmiştir. Dönüşüm işlemlerinin ardından serilerin durağanlık

özellikleri, ADF testi kullanılarak değerlendirilmiş ve elde edilen bulgular Tablo 4.19.'da özetlenmiştir.

Tablo 4.19. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-59.0605	I(1)
D LOG MA14	-11.2945	I(1)
LOG RSI	-12.0381	I(0)
D LOG WMA	-13.2116	I(1)
Momentum	-10.7179	I(0)
LOG Stokastik K	-16.5017	I(0)
LOG Stokastik D	-14.3452	I(0)
MACD	-12.8010	I(0)
R	-14.7428	I(0)
D LOG ACC	-10.4287	I(1)
CCI	-15.5225	I(0)
D LOG DXY	-56.0979	I(1)
D LOG PETROL	-8.6813	I(1)
D LOG ALTIN	-12.4389	I(1)

Tablo 4.19.'da sunulan sonuçlar incelendiğinde, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle bu değişkenlere logaritmik dönüşüm uygulanamadığı ve bu sebeple düzey değerleriyle modele dahil edildiği görülmüştür. Buna karşılık, negatif değer içermeyen diğer değişkenlere logaritmik dönüşüm uygulanarak varyans stabilizasyonu sağlanmıştır. Logaritmik dönüşümün ardından durağanlık göstermeyen değişkenler, birinci dereceden farkları alınarak analiz edilmiştir. Yapılan ADF testi sonucunda, tüm değişkenlerin %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerlere göre durağan olduğu tespit edilmiştir. Durağan hale getirilen değişkenlerin grafiksel gösterimleri, Şekil 4.28.'de sunulmaktadır.




Şekil 4.28. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ilişkin tanımlayıcı istatistikler Tablo 4.20.' de ayrıntılı bir biçimde sunulmuştur. Ayrıca, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon Şekil 4.29.' da gösterilmiştir.

Tablo 4.20. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.6148	0.0601	0.6168	-0.1551	5.3367
MA14	0.6353	0.0454	0.6383	-0.5521	8.6729
RSI	0.7197	0.1493	0.7392	-0.7817	0.6733
WMA	0.5727	0.0513	0.5768	-1.1844	14.2456
Momentum	0.6614	0.0931	0.6697	-0.9746	3.9538
Stokastik K	0.8542	0.1627	0.9121	-1.7869	3.5843
Stokastik D	0.8319	0.161	0.885	-1.1622	0.7755
MACD	0.6253	0.089	0.6249	-0.1826	2.4219
R	0.5631	0.3106	0.5933	-0.2238	-1.3007
ACC	0.4589	0.0718	0.4566	0.3844	4.2079
CCI	0.5709	0.1575	0.5865	-0.3021	-0.5727
DXY	0.4896	0.0627	0.4892	0.0523	4.8094
PETROL	0.5799	0.0465	0.5813	-0.4387	13.2917
ALTIN	0.4477	0.0517	0.4479	-0.0708	12.2598




Şekil 4.29. Endeksle Değişkenler Arası Korelasyon

Şekil 4.29. verilerine göre, endeks değeri ile Altın ve DXY arasında negatif yönlü ilişki tespit edilmiştir. Diğer taraftan MA, Stokastik K, R, RSI, WMA, CCI Momentum ve Petrol gibi değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde kalmaktadır. Stokastik D ve MACD göstergeleri ile endeks arasında çok zayıf ilişki gözlemlenmektedir. ACC değişkeni ile ise orta düzeyde ilişki tespit edilmiştir. Bu bulgular söz konusu değişkenlerin model girdisi olarak kullanılabilirliğine işaret etmektedir. Zayıf korelasyonel bağlantılar, değişkenler arası çoklu doğrusal bağlantı riskini minimize ederek tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini artırmaktadır. Ayrıca, bu durum, değişkenlerin birbirinden bağımsız bilgi içeriği taşıdığını ifade etmekte ve modelin açıklayıcı gücünün (R^2) artırılmasına katkı sağlayabilmektedir.


4.3.1.6.1 FTSE MIB Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntıların hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, FTSE MIB endeksinin tahmini için en uygun modelin ARIMA (0,1,1) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri -12177.817 olarak hesaplanmıştır. ARIMA (0,1,1) model sonucuna göre elde edilen artık değer grafiği Şekil 4.30.' da gösterilmiştir



Şekil 4.30. Artıkların Histogram Grafiği

Şekil 4.30.' da yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (0,1,1) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.31.' de, yine ilgili modele ait başarı metrikleri Tablo 4.21.' de sunulmuştur.



Şekil 4.31. ARIMA (0,1,1) FTSE MIB Endeks Tahmin Grafiği

Şekil 4.31.' de gerçek endeks değerleri ile ARIMA (0,1,1) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks

değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır. Bu durum, ARIMA (0,1,1) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir. Grafikte gözlemlenen küçük sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir.


Tablo 4.21. FTSE MIB Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (0,1,1)	1470975	2323.84	828.83	4.3541

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; hesaplanan RMSE değeri 1212.84 olarak bulunmuştur. Bu değer, modelin tahminlerinin genel hata büyüklüğünün nispeten düşük seviyede olduğunu ve tahminlerin ortalama endeks değeri etrafında ± 1212.84 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha fazla duyarlıdır, bu nedenle bu değer düşük olması modelin genel performansının iyi olduğunu gösterir. Öte yandan, daha küçük hatalara duyarlı bir metrik olan MAE değeri 828.83 olarak hesaplanmıştır. Bu sonuç, modelin tahminlerinin gerçek endeks değerlerinden ortalama olarak ± 828.83 birimlik bir sapma gösterdiğine işaret etmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir bir düzeyde olduğunu göstermektedir. Ayrıca, MAPE değerinin %4.3541 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %4.3541 oranında bir sapma içerdiğini ortaya koymaktadır. Elde edilen bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.1.7 Japonya (NIKKEI 225) Endeksi Tahmin Analizi

NIKKEI 225 borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.32.' de sunulmuştur




Şekil 4.32. Japonya (NIKKEI 225) Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerin varyansında gözlenebilecek olası dalgalanmaları stabilize etmek amacıyla uygun dönüşümler gerçekleştirilmiştir. Bu doğrultuda, serilere logaritmik dönüşüm uygulanmış ve varyanstaki potansiyel dalgalanmalar en aza indirgenmiştir. Dönüşüm işlemlerinin ardından serilerin durağanlık özellikleri, ADF testi kullanılarak değerlendirilmiş ve elde edilen bulgular Tablo 4.22.' de özetlenmiştir.

Tablo 4.22. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-16.9448	I(1)
D LOG MA14	-11.0209	I(1)
LOG RSI	-12.5712	I(0)
D LOG WMA	-10.2052	I(1)
Momentum	-12.7375	I(0)
LOG Stokastik K	-15.3386	I(0)
LOG Stokastik D	-15.5744	I(0)
MACD	-15.5413	I(0)
R	-17.1413	I(0)
D LOG ACC	-19.5173	I(1)
CCI	-16.9419	I(0)
D LOG DXY	-57.8213	I(1)
D LOG PETROL	-8.7942	I(1)
D LOG ALTIN	-30.9487	I(1)

Tablo 4.22.' de sunulan verilere göre, Momentum, MACD, Williams %R ve CCI değişkenleri negatif değerlere sahip oldukları için bu değişkenlere logaritmik dönüşüm uygulanamamış ve düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanmıştır. Logaritmik dönüşümün ardından durağanlık göstermeyen değişkenlerin birinci dereceden farkı alınmış ve bu işlem sonucunda %1, %5 ve %10 anlamlılık düzeylerine ait kritik değerler açısından durağan oldukları tespit edilmiştir. Durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.33.' te sunulmuştur.




Şekil 4.33. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ilişkin tanımlayıcı istatistikler Tablo 4.23.' te ayrıntılı bir biçimde sunulmuştur. Ayrıca, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon Şekil 4.34.' te gösterilmiştir.

Tablo 4.23. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.418	0.0526	0.4191	0.2839	9.4029
MA14	0.5922	0.0644	0.5955	-0.4548	4.7644
RSI	0.7086	0.1184	0.7228	-0.7629	1.2619
WMA	0.502	0.0741	0.5053	-0.2634	4.6688
Momentum	0.6063	0.0881	0.6103	-0.4564	3.0496
StokastikK	0.903	0.1166	0.947	-2.1752	6.5876
StokastikD	0.8508	0.1508	0.9067	-1.2954	1.1183
MACD	0.5431	0.0932	0.5448	-0.2147	2.8043
R	0.5709	0.3144	0.6198	-0.3037	-1.2871
ACC	0.5363	0.0611	0.5352	0.474	5.2986
CCI	0.5239	0.1315	0.5429	-0.2506	-0.4724
DXY	0.431	0.0552	0.4306	-0.1039	3.861
PETROL	0.567	0.0513	0.5682	0.0881	9.715
ALTIN	0.503	0.0579	0.5029	-0.0135	11.5448




Şekil 4.34. Endeksle Değişkenler Arası Korelasyon

Şekil 4.34. verilerine göre, endeks değeri ile Altın ve DXY arasında negatif yönlü ilişki tespit edilmiştir. Diğer taraftan MA, Stokastik K, R, RSI, WMA, CCI ve Momentum gibi değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde kalmaktadır. Petrol, Stokastik D ve MACD göstergeleri ile endeks arasında çok zayıf ilişki gözlemlenmektedir. ACC değişkeni ile ise orta düzeyde ilişki tespit edilmiştir. Bu bulgular söz konusu değişkenlerin model girdisi olarak kullanılabilirliğine işaret etmektedir. Zayıf korelasyonel bağlantılar, değişkenler arası çoklu doğrusal bağlantı riskini minimize ederek tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini artırmaktadır. Ayrıca, bu durum, değişkenlerin birbirinden bağımsız bilgi içeriği taşıdığını ifade etmekte ve modelin açıklayıcı gücünün artırılmasına katkı sağlayabilmektedir.


4.3.1.7.1 NIKKEI 225 Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntıların hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, NIKKEI 225 endeksinin tahmini için en uygun modelin ARIMA (3,1,4) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 12859.300 olarak hesaplanmıştır. ARIMA (3,1,4) model sonucuna göre elde edilen artık değer grafiği Şekil 4.35.’ te gösterilmiştir



Şekil 4.35. Artıkların Histogram Grafiği

Şekil 4.35.' te yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (3,1,4) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.36.' da, yine ilgili modele ait başarı metrikleri Tablo 4.24.' te sunulmuştur.



Şekil 4.36. ARIMA (3,1,4) NIKKEI 225 Endeks Tahmin Grafiği

Şekil 4.36.' da gerçek endeks değerleri ile ARIMA (3,1,4) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks

değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır. Bu durum, ARIMA (3,1,4) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir. Grafikte gözlemlenen küçük sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir.

Tablo 4.24. NIKKEI 225 Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (3,1,4)	671489.56	819.44	566.76	6.0755

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 819.44 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 819.44 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 566.76 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 566.76 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin %6.07 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %6.07 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2. E7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin Arıma Modeli İle Tahmini

Çalışmanın bu kısmında, E7 ülkelerinin borsa endekslerinin tahmin edilmesine yönelik metodolojik yaklaşım ve analiz süreci genel hatlarıyla ele alınacak olup, her bir ülke için elde edilen bulgular ayrıntılı bir şekilde sunulacaktır.

4.3.2.1 Çin (SHANGHAI COMPOSITE) Endeksi Tahmin Analizi

SHANGHAI COMPOSITE borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.37.'de sunulmuştur.




Şekil 4.37. SHANGHAI Composite Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.25.’te sunulmuştur.

Tablo 4.25. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
LOG Endeks	-3.0392	I(0)
LOG MA14	-3.1229	I(0)
LOG RSI	-9.5888	I(0)
LOG WMA	-3.1836	I(0)
R	-15.6877	I(0)
Momentum	-7.7063	I(0)
LOG Stokastik K	-14.9830	I(0)
LOG Stokastik D	-14.8343	I(0)
MACD	-14.2634	I(0)
LOG ACC	-3.5195	I(0)
CCI	-13.1683	I(0)
D LOG DXY	-12.0089	I(1)
D LOG PETROL	-9.8333	I(1)
D LOG ALTIN	-43.4566	I(1)

Tablo 4.25.' te sunulan bulgular doğrultusunda, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle logaritmik dönüşüm uygulanamamış, bu değişkenler doğrudan düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir. Son olarak, durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.38.' de görselleştirilmiştir.




Şekil 4.38. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ilişkin tanımlayıcı istatistikler, ayrıntılı olarak

Tablo 4.26.' da sunulmuştur. Bunun yanı sıra, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon ilişkisi Şekil 4.39.' da görselleştirilmiştir.

Tablo 4.26. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.4377	0.1743	0.453	0.1872	0.1194
MA14	0.4482	0.1751	0.4635	0.1707	0.1179
RSI	0.6516	0.1521	0.665	-0.4418	0.0418
WMA	0.4483	0.1768	0.4647	0.1747	0.1146
R	0.5641	0.3228	0.6039	-0.2228	-1.363
Momentum	0.6382	0.0983	0.6432	-0.9953	5.9412
StokastikK	0.8831	0.1373	0.9351	-1.9021	4.2754
StokastikD	0.8144	0.183	0.8848	-1.1263	0.5473
MACD	0.3167	0.1568	0.2785	1.2075	1.4129
ACC	0.7235	0.2136	0.6892	-0.7697	0.3158
CCI	0.5099	0.144	0.5234	-0.1526	-0.6692
DXY	0.402	0.052	0.4015	0.3516	7.6309
PETROL	0.546	0.05	0.5473	0.0953	11.141
ALTIN	0.5028	0.058	0.5028	0.0744	12.6319




Şekil 4.39. Değişkenler Arası Korelasyon

Şekil 4.38.' de verilerine göre, endeks değeri ile MACD ve DXY arasında negatif yönlü korelasyon tespit edilmiştir. Bununla birlikte, Endeks ile WMA ve MA14 arasında

orta düzeyde, ACC ile zayıf düzeyde, Stokastik K, Stokastik D R, RSI, WMA, CCI, Momentum, Altın ve Petrol gibi değişkenlerle çok zayıf düzeyde korelasyon ilişkisi tespit edilmiştir. Bu durum, söz konusu değişkenlerin modelde bağımsız değişken olarak kullanılmasının çoklu doğrusal bağlantı riskini düşürerek modelin parametrik stabilitesini artırabileceğini göstermektedir. Bu bulgular, modelde kullanılacak değişkenlerin birbirinden bağımsız bilgi içeriği taşıdığını ve modelin açıklayıcı gücünün artırılmasına katkı sağlayabileceğini göstermektedir.

4.3.2.1.1 SHANGHAI COMPOSITE Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasında en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntıların hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, SHANGHAI COMPOSITE endeksinin tahmini için en uygun modelin ARIMA (5,0,4) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 26091.127 olarak hesaplanmıştır. ARIMA (5,0,4) model sonucuna göre elde edilen artık değer grafiği Şekil 4.40.' ta gösterilmiştir



Şekil 4.40. Artıkların Histogram Grafiği

Şekil 4.40.' ta yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir.

Kırmızı çizgi ile gösterilen normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (5,0,4) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.41.' de, yine ilgili modele ait başarı metrikleri Tablo 4.27.' de sunulmuştur.



Şekil 4.41. ARIMA (5,0,4) SHANGHAI Composite Endeks Tahmin Grafiği

Şekil 4.41.' de gerçek endeks değerleri ile ARIMA (5,0,4) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır.

Bu durum, ARIMA (5,0,4) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir.


Tablo 4.27. ARIMA (5,0,4) SHANGHAI Composite Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (5,1,4)	484.98	22.02	15.98	1.0716

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 22.02 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 22.02 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 15.98 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 15.98 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin %1.07 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %1.07 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2.2 Hindistan (NIFTY50) Endeksi Tahmin Analizi

NIFTY50 borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.42.' de sunulmuştur.



Şekil 4.42. NIFTY50 Endeksi Kapanış Verileri


Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler

uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.28.’de sunulmuştur.

Tablo 4.28. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-17.4551	I(1)
D LOG MA14	-11.3874	I(1)
LOG RSI	-10.4362	I(0)
D LOG WMA	-12.8844	I(1)
Momentum	-8.9068	I(0)
LOG Stokastik K	-17.8382	I(0)
LOG Stokastik D	-14.0290	I(0)
MACD	-12.8615	I(0)
R	-17.3162	I(0)
D LOG ACC	-10.3492	I(1)
CCI	-14.6368	I(0)
D LOG DXY	-16.9813	I(1)
D LOG PETROL	-8.9639	I(1)
D LOG ALTIN	-26.2311	I(1)

Tablo 4.28. ADF Birim Kök Testi’ de yer alan birim kök testi sonuçlarına göre, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması sebebiyle logaritmik dönüşüm uygulanamamış ve bu değişkenler modelde düzey değerleriyle kullanılmıştır. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir ve ilgili serilere ait grafikler Şekil 4.43.’ te görselleştirilmiştir.




Şekil 4.43. Durağan Hale Getirilmiş Değişkenler

Durağanlık sağlanan bağımlı ve bağımsız değişkenlere ait tanımlayıcı istatistikler

Tablo 4.29.'da kapsamlı bir şekilde sunulmuştur. Ek olarak, Şekil 4.44.' te bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon analizi de gösterilmiştir.

Tablo 4.29. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.4845	0.0441	0.485	0.1743	11.1502
MA14	0.4062	0.0298	0.4074	2.348	58.674
RSI	0.7334	0.137	0.7583	-0.7621	0.4049
WMA	0.3951	0.0354	0.3968	1.1887	36.9725
Momentum	0.6695	0.0654	0.6733	-0.9657	8.7191
Stokastik K	0.8413	0.1867	0.9198	-1.5188	1.5638
Stokastik D	0.8137	0.1959	0.8947	-1.2448	0.6963
MACD	0.3286	0.1409	0.304	0.9887	1.3485
R	0.5987	0.32	0.67	-0.4129	-1.2296
ACC	0.4953	0.073	0.4936	0.0723	2.8579
CCI	0.5513	0.152	0.5822	-0.3377	-0.6305
DXY	0.5563	0.0629	0.5556	-0.0839	4.2169
PETROL	0.4624	0.0418	0.4636	0.3435	14.396
ALTIN	0.5078	0.0576	0.5083	0.0433	12.9308




Şekil 4.44. Değişkenler Arası Korelasyon

Şekil 4.44. Değişkenler Arası Korelasyon verilerine göre, endeks değeri ile MACD ve DXY arasında negatif yönlü korelasyon tespit edilmiştir. Bununla birlikte, MA14, Stokastik K, R, RSI, WMA, CCI ve Momentum gibi değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde kalmaktadır. Bu durum, söz konusu değişkenlerin modelde bağımsız değişken olarak kullanılmasının çoklu doğrusal bağlantı riskini düşürerek modelin parametrik stabilitesini artırabileceğini göstermektedir. Öte yandan, ACC değişkeni ile endeks arasındaki ilişki orta düzeyde olup Petrol ve Stokastik D göstergeleri ise çok zayıf bir ilişkiye sahip olduğu görülmektedir. Bu bulgular, modelde kullanılacak değişkenlerin birbirinden bağımsız bilgi içeriği taşıdığını ve modelin açıklayıcı gücünün artırılmasına katkı sağlayabileceğini göstermektedir.


4.3.2.2.1 NIFY50 Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntılarının hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, NIFTY50 endeksinin tahmini için en uygun modelin ARIMA (2,1,5) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri -14869.051 olarak hesaplanmıştır. ARIMA (2,1,5) model sonucuna göre elde edilen artık değer grafiği Şekil 4.45.' te gösterilmiştir.



Şekil 4.45. Artıkların Histogram Grafiği

Şekil 4.45.' te yer alan artıkların histogram grafiği incelendiğinde, artık değerlerin yaklaşık olarak sıfır merkezli olduğu ve simetrik bir dağılım gösterdiği gözlemlenmektedir. Bu durum, modelin sistematik bir sapma içermediğini ve ortalama hatanın sıfıra yakın olduğunu göstermektedir. Normal dağılım ile artıkların histogramı genel olarak uyumludur. Artıkların normal dağılıma yakın olması, modelin hatalarının rastgele dağıldığını ve tahminlerin istatistiksel olarak güvenilir olduğunu ifade etmektedir. Artıkların geniş bir alana yayılmaması ve uç değerlerin sınırlı olması ARIMA (2,1,5) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili model ile gerçekleştirilen tahmin sonuçları Şekil 4.46.' da gösterilmiştir.



Şekil 4.46. ARIMA (2,1,5) NIFTY50 Endeks Tahmin Grafiği

Şekil 4.46.' da gerçek endeks değerleri ile ARIMA (2,1,5) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks

değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır. Bu durum, ARIMA (2,1,5) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir. Grafikte bazı dönemlerde model tahminleri ile gerçek değerler arasında küçük farklar olduğu görülmektedir. Bu sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir. İlgili modele ait başarı metrikleri Tablo 4.30.' da sunulmuştur.


Tablo 4.30. NIFTY50 Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (2,1,5)	185525.71	430.73	275.98	3.7278

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 430.73 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 430.73 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değerın düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 275.98 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 275.98 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin %3.72 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %3.72 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2.3 Brezilya (BOVESPA) Endeksi Tahmin Analizi

BOVESPA borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.47.' de sunulmuştur.




Şekil 4.47. BOVESPA Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.31.’de sunulmuştur.

Tablo 4.31. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-14.0144	I(1)
D LOG MA14	-12.6662	I(1)
LOG RSI	-10.2227	I(0)
D LOG WMA	-9.0045	I(1)
Momentum	-8.5684	I(0)
LOG StokastikK	-15.5660	I(0)
LOG StokastikD	-14.4209	I(0)
MACD	-16.3348	I(0)
R	-16.1661	I(0)
LOG ACC	-7.6884	I(0)
CCI	-14.4633	I(0)
D LOG DXY	-32.1693	I(1)
D LOG PETROL	-8.4763	I(1)
D LOG ALTIN	-20.2500	I(1)

Tablo 4.31.' de sunulan bulgular doğrultusunda, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle logaritmik dönüşüm uygulanamamış, bu değişkenler doğrudan düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir. Son olarak, durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.48.' de görselleştirilmiştir.




Şekil 4.48. Durağan Hale Getirilmiş Değişkenler

Durağanlık sağlanan bağımlı ve bağımsız değişkenlere ait tanımlayıcı istatistikler Tablo 4.32.' de kapsamlı bir şekilde sunulmuştur. Ek olarak, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon analizi Şekil 4.49.' da gösterilmiştir.

Tablo 4.32. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.5408	0.0599	0.5414	0.0583	7.8749
MA14	0.3278	0.0354	0.3283	2.2838	62.5171
RSI	0.7299	0.1301	0.741	-0.6035	0.2414
WMA	0.379	0.0431	0.3802	1.4391	35.3708
Momentum	0.6996	0.0623	0.7021	-1.6336	14.4868
Stokastik K	0.8953	0.1212	0.9401	-2.2675	7.8116
Stokastik D	0.827	0.1643	0.8882	-1.1707	0.8499
MACD	0.3439	0.1371	0.3156	1.2091	2.0793
R	0.5571	0.3104	0.5988	-0.2269	-1.3148
ACC	0.886	0.1232	0.896	-4.7542	24.3061
CCI	0.5707	0.1505	0.5848	-0.1938	-0.9302
DXY	0.513	0.0612	0.5125	0.2223	4.691
PETROL	0.5463	0.0484	0.5474	0.2395	9.5297
ALTIN	0.3721	0.0448	0.3719	0.8454	21.4076




Şekil 4.49. Endeksle Değişkenler Arası Korelasyon

Şekil 4.49. verilerine göre, endeks değeri ile DXY, ACC ve MACD arasında negatif yönlü korelasyonel ilişki tespit edilmiştir. Diğer taraftan MA, Stokastik K, R, RSI, WMA, CCI, Momentum ve Petrol gibi değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde kalmaktadır. Stokastik D, Altın göstergeleri ile endeks arasında ise çok zayıf bir ilişki gözlemlenmektedir. Bu bulgular, söz konusu değişkenlerin model girdisi olarak değerlendirilebileceğini ortaya koymaktadır. Zayıf korelasyonel ilişkiler, değişkenler arasındaki çoklu doğrusal bağlantı riskini azaltarak, tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini güçlendirmektedir. Ayrıca, bu durum değişkenlerin bağımsız bilgi içeriğine sahip olduğunu göstererek modelin açıklayıcılığını artırmakta ve tahmin performansına olumlu yönde katkı sunmaktadır.


4.3.2.3.1 BOVESPA Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntıların hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, NIKKEI 225 endeksinin tahmini için en uygun modelin ARIMA (2,1,2) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 115234.738 olarak hesaplanmıştır. ARIMA 2,1,2) model sonucuna göre elde edilen artık değer grafiği Şekil 4.50.' de gösterilmiştir.



Şekil 4.50. Artıkların Histogram Grafiği

Şekil 4.50. ' de yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (2,1,2) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.51.' de, yine ilgili modele ait başarı metrikleri Tablo 4.33.' te sunulmuştur.



Şekil 4.51. ARIMA (2,1,2) BOVESPA Endeks Tahmin Grafiği

Şekil 4.51.' de gerçek endeks değerleri ile ARIMA (2,1,2) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır. Bu durum, ARIMA (2,1,2) modelinin zaman serisinin yapısına uygun olduğunu

desteklemektedir. Grafikte gözlemlenen küçük sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir.


Tablo 4.33. BOVESPA Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (2,1,2)	18376005.22	4286.72	2908.49	5.8388

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 4286.72 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 4286.72 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 2908.49 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 2908.49 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin %5.83 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %5.83 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2.4 Meksika (S&P/BMV IPC) Endeksi Tahmin Analizi

Meksika S&P/BMV IPC borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.52’ de sunulmuştur.




Şekil 4.52. S&P/BMV IPC Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.34.’te sunulmuştur.

Tablo 4.34. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-28.9840	I(1)
D LOG MA14	-10.8717	I(1)
LOG RSI	-12.1653	I(0)
D LOG WMA	-10.6593	I(1)
R	-17.9132	I(0)
Momentum	-9.5037	I(0)
LOG Stokastik K	-11.9895	I(0)
LOG Stokastik D	-11.9895	I(0)
MACD	-10.7460	I(0)
LOG ACC	-5.6670	I(0)
CCI	-15.8911	I(0)
D LOG DXY	-58.1194	I(1)
D LOG PETROL	-8.8478	I(1)
D LOG ALTIN	-36.1562	I(1)

Tablo 4.34.’te sunulan bulgular doğrultusunda, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle logaritmik dönüşüm uygulanamamış, bu değişkenler doğrudan düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir. Son olarak, durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.53.’te görselleştirilmiştir.



Şekil 4.53. Durağan Hale Getirilmiş Değişkenler

Durağanlık sağlanan bağımlı ve bağımsız değişkenlere ait tanımlayıcı istatistikler


Tablo 4.35.' te kapsamlı bir şekilde sunulmuştur. Ek olarak, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon analizi Şekil 4.54.' te gösterilmiştir.

Şekil 4.54. Endeksle Değişkenler Arası Korelasyon

Şekil 4.54. Verilerine göre, endeks değeri ile DXY, ACC ve MACD arasında negatif yönlü ilişki tespit edilmiştir. Diğer taraftan, MA, Stokastik K, D, R, RSI, WMA, CCI, Momentum ve Petrol gibi değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde kalmaktadır. Altın ile endeks arasında ise çok zayıf bir ilişki gözlemlenmektedir. Bu bulgular, söz konusu değişkenlerin model girdisi olarak değerlendirilebileceğini ortaya koymaktadır. Zayıf ilişkiler, değişkenler arasındaki çoklu doğrusal bağlantı riskini azaltarak, tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini güçlendirmektedir. Ayrıca, bu durum, değişkenlerin bağımsız bilgi içeriğine sahip olduğunu göstererek modelin açıklama gücünü artırmakta ve tahmin performansına olumlu yönde katkı sunmaktadır.


4.3.2.4.1 S&P/BMV IPC Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasında en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntılarının hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, S&P/BMV IPC endeksinin tahmini için en uygun modelin ARIMA (2,1,2) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 12614.501 olarak hesaplanmıştır. ARIMA (2,1,2) model sonucuna göre elde edilen artık değer grafiği Şekil 4.55.’te gösterilmiştir.



Şekil 4.55. Artıkların Histogram Grafiği

Şekil 4.55.' te yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (2,1,2) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.56.' da, yine ilgili modele ait başarı metrikleri Tablo 4.36.' da sunulmuştur.



Şekil 4.56. ARIMA (2,1,2) S&P/BMV IPC Endeks Tahmin Grafiği

Şekil 4.56.' da gerçek endeks değerleri ile ARIMA (2,1,2) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks

değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır. Bu durum, ARIMA (2,1,2) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir. Grafikte gözlemlenen küçük sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir.


Tablo 4.36. S&P/BMV IPC Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (2,1,2)	220114.18	1486.31	1041.21	4.3682

Tablo 4.36.' da modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 1486.31 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 1486.31 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 1041.21 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 1041.21 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin %4.36 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %4.36 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2.5 Endonezya (IDX COMPOSITE) Endeksi Tahmin Analizi

IDX COMPOSITE borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.57.' de sunulmuştur.




Şekil 4.57. Endonezya (IDX Composite) Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.37.’de sunulmuştur.

Tablo 4.37. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-32.7643	I(1)
D LOG MA14	-9.6758	I(1)
LOG RSI	-9.6510	I(0)
D LOG WMA	-12.1524	I(1)
R	-18.3853	I(0)
Momentum	-8.3081	I(0)
LOG Stokastik K	-16.1771	I(0)
LOG Stokastik D	-10.3591	I(0)
MACD	-14.6933	I(0)
LOG ACC	-7.6083	I(0)
CCI	-15.2963	I(0)
D LOG DXY	-56.9943	I(1)
D LOG ALTIN	-16.7964	I(1)
LOG PETROL	-2.9501	I(0)

Tablo 4.37.’ de sunulan bulgular doğrultusunda, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle logaritmik dönüşüm uygulanamamış, bu değişkenler doğrudan düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir. Son olarak, durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.58’ de görselleştirilmiştir.




Şekil 4.58. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ait tanımlayıcı istatistikler Tablo 4.38.' de kapsamlı bir şekilde sunulmuştur. Ek olarak, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon analizi Şekil 4.59.' da gösterilmiştir.

Tablo 4.38. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.4673	0.0591	0.4697	-0.1308	8.9348
MA14	0.3151	0.0261	0.3156	5.2118	151.964
RSI	0.7335	0.1284	0.7542	-1.1408	2.3168
WMA	0.3591	0.0268	0.3596	3.4469	107.731
R	0.6052	0.287	0.6609	-0.4451	-1.0016
Momentum	0.6281	0.0628	0.6339	-1.4148	10.1017
Stokastik K	0.8946	0.1216	0.9392	-2.1053	5.5143
Stokastik D	0.8423	0.1588	0.9004	-1.5741	2.6372
MACD	0.5366	0.0727	0.537	-0.2532	5.9627
ACC	0.736	0.2326	0.8455	-1.28	0.7073
CCI	0.582	0.1494	0.6079	-0.5069	-0.1311
DXY	0.4481	0.0531	0.4479	-0.4301	4.4968
ALTIN	0.4892	0.0578	0.4891	0.05	8.1432
PETROL	0.6581	0.1701	0.6539	-0.3449	-0.3104




Şekil 4.59. Endeksle Değişkenler Arası Korelasyon

Şekil 4.59. verilerine göre, endeks değeri ile DXY, ACC ve PETROL arasında negatif yönlü ilişki tespit edilmiştir. Diğer taraftan MA14, Stokastik K, R, RSI, WMA, CCI ve Momentum değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde kalmaktadır. Stokastik D, MACD ve Altın göstergeleri ile endeks arasında ise çok zayıf bir ilişki gözlemlenmektedir. Bu bulgular, söz konusu değişkenlerin model girdisi olarak değerlendirilebileceğini ortaya koymaktadır. Zayıf korelasyonel ilişkiler, değişkenler arasındaki çoklu doğrusal bağlantı riskini azaltarak, tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini güçlendirmektedir. Ayrıca, bu durum, değişkenlerin bağımsız bilgi içeriğine sahip olduğunu göstererek modelin açıklama gücünü artırmakta ve tahmin performansına olumlu yönde katkı sunmaktadır.

4.3.2.5.1 IDX COMPOSITE Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasında en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntıların hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, NIKKEI 225 endeksinin tahmini için en uygun modelin ARIMA (4,1,4) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 11648.413 olarak hesaplanmıştır. ARIMA (4,1,4) model sonucuna göre elde edilen artık değer grafiği Şekil 4.60.' ta gösterilmiştir.



Şekil 4.60. Artıkların Histogram Grafiği

Şekil 4.60.' da yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (4,1,4) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.61.' de, yine ilgili modele ait başarı metrikleri Tablo 4.39.' da sunulmuştur.



Şekil 4.61. IDX Composite Endeks Tahmin Grafiği

Şekil 4.61.' de gerçek endeks değerleri ile ARIMA (4,1,4) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru

tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır. Bu durum, ARIMA (4,1,4) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir. Grafikte gözlemlenen küçük sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir.


Tablo 4.39. IDX Composite Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (4,1,4)	64767.26	254.49	164.5	7.0929

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 254.49 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 254.49 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 164.5 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 164.5 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin %7.09 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %7.09 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2.6 Rusya (MOEX) Endeksi Tahmin Analizi

MOEX borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.62.' de sunulmuştur.




Şekil 4.62. Rusya (MOEX) Endeksi Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.40.'ta sunulmuştur.

Tablo 4.40. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-8.6445	I(1)
D LOG MA14	-8.8239	I(1)
LOG RSI	-12.2172	I(0)
D LOG WMA	-12.1975	I(1)
R	-12.0341	I(0)
Momentum	-8.2322	I(0)
LOG Stokastik K	-17.4286	I(0)
LOG Stokastik D	-14.5273	I(0)
MACD	-12.2832	I(0)
D LOG ACC	-27.5524	I(1)
CCI	-13.9453	I(0)
D LOG DXY	-33.7764	I(1)
LOG PETROL	-3.1388	I(0)
D LOG ALTIN	-30.8828	I(1)

Tablo 4.40.' ta sunulan bulgular doğrultusunda, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle logaritmik dönüşüm uygulanamamış, bu değişkenler doğrudan düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir. Son olarak, durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.63.' te görselleştirilmiştir.




Şekil 4.63. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ait tanımlayıcı istatistikler Tablo 4.41.' de kapsamlı bir şekilde sunulmuştur. Ek olarak, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon analizi Şekil 4.64.' te gösterilmiştir.

Tablo 4.41. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.6165	0.0297	0.6166	-0.4826	30.519
MA14	0.1798	0.0196	0.1812	-1.2685	15.9242
RSI	0.7399	0.1274	0.7573	-0.9973	1.7552
WMA	0.2146	0.0222	0.2161	-1.6992	15.3462
R	0.5648	0.2998	0.602	-0.2461	-1.2207
Momentum	0.8017	0.0464	0.8054	-3.3436	30.5791
StokastikK	0.9113	0.0987	0.9467	-1.9738	4.9269
StokastikD	0.8029	0.1849	0.8697	-1.1758	0.7301
MACD	0.6868	0.0559	0.689	-1.8251	20.2479
ACC	0.1174	0.0255	0.1168	0.2724	3.4876
CCI	0.5517	0.1397	0.5706	-0.2926	-0.376
DXY	0.5085	0.0417	0.508	-0.0114	14.1026
PETROL	0.6612	0.1731	0.6604	-0.4245	-0.2602
ALTIN	0.5029	0.0563	0.5013	0.3526	16.8004




Şekil 4.64. Endeksle Değişkenler Arası Korelasyon

Şekil 4.64. verilerine göre, endeks değeri ile DXY ve PETROL arasında negatif yönlü ilişki tespit edilmiştir. Diğer taraftan MA14, Stokastik K, R, RSI, WMA, CCI ve Momentum değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde ACC ile orta düzeyde ilişki gözlemlenmektedir. Stokastik D, MACD ve Altın göstergeleri ile endeks arasında ise çok zayıf bir ilişki gözlemlenmektedir. Bu bulgular, söz konusu değişkenlerin model girdisi olarak değerlendirilebileceğini ortaya koymaktadır. Zayıf korelasyonel ilişkiler, değişkenler arasındaki çoklu doğrusal bağlantı riskini azaltarak, tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini güçlendirmektedir. Ayrıca, bu durum, değişkenlerin bağımsız bilgi içeriğine sahip olduğunu göstererek modelin açıklama gücünü artırmakta ve tahmin performansına olumlu yönde katkı sunmaktadır.


4.3.2.6.1 MOEX Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntılarının hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, MOEX endeksinin tahmini için en uygun modelin ARIMA (1,1,3) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 16951.157 olarak hesaplanmıştır. ARIMA (1,1,3) model sonucuna göre elde edilen artık değer grafiği Şekil 4.65.' te gösterilmiştir.



Şekil 4.65. Artıkların Histogram Grafiği

Şekil 4.65.' te yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (1,1,3) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.66' da, yine ilgili modele ait başarı metrikleri Tablo 4.42.' de sunulmuştur.



Şekil 4.66. MOEX Endeks Tahmin Grafiği

Şekil 4.66.' da gerçek endeks değerleri ile ARIMA (1,1,3) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere oldukça yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır.

Bu durum, ARIMA (1,1,3) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir. Grafikte gözlemlenen küçük sapmalar, modelin ani piyasa şokları veya beklenmedik olaylara karşı duyarlılığını gösterebilmektedir.


Tablo 4.42. MOEX Endeks Tahmini Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (1,1,3)	5527.3	74.35	43.02	1.8979

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 74.35 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 74.35 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 43.02 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 43.02 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin % 1.89 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %1.89 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.2.7 Türkiye (BIST100) Endeksi Tahmin Analizi

BIST100 borsa endeksi üzerine gerçekleştirilen tahmin analizinde, bağımlı değişken olarak ele alınan ilgili endeksin kapanış fiyatları Şekil 4.67.' de sunulmuştur.




Şekil 4.67. Türkiye (BIST100) Endeks Kapanış Verileri

Analiz öncesinde, bağımlı ve bağımsız değişkenlere ait serilerde gözlenebilecek olası varyans dalgalanmalarını stabilize etmek amacıyla gerekli dönüşümler uygulanmıştır. Bu çerçevede, serilere logaritmik dönüşüm yapılmış ve varyanstaki potansiyel oynaklık minimize edilmiştir. Dönüşüm işlemlerinin ardından, serilerin durağanlık durumları ADF testi ile analiz edilmiş olup, elde edilen sonuçlar Tablo 4.43.'te sunulmuştur.

Tablo 4.43. ADF Birim Kök Testi

Değişken	ADF Değeri	Durağanlık Durumu
D LOG Endeks	-55.8727	I(1)
D LOG MA14	-14.3161	I(1)
LOG RSI	-11.5219	I(0)
D LOG WMA	-16.7159	I(1)
Momentum	-10.4715	I(0)
LOG Stokastik K	-17.7993	I(0)
LOG Stokastik D	-14.5562	I(0)
MACD	-13.0397	I(0)
R	-16.4745	I(0)
D LOG ACC	-9.3279	I(1)
CCI	-15.9127	I(0)
D LOG DXY	-57.6490	I(1)
D LOG PETROL	-8.7540	I(1)
D LOG ALTIN	-25.3270	I(1)

Tablo 4.43.' te sunulan bulgular doğrultusunda, Momentum, MACD, Williams %R ve CCI değişkenlerinin negatif değerlere sahip olması nedeniyle logaritmik dönüşüm uygulanamamış, bu değişkenler doğrudan düzey değerleriyle modele dâhil edilmiştir. Negatif değer içermeyen diğer değişkenlere ise logaritmik dönüşüm uygulanarak serilerin varyans yapısı stabilize edilmiştir. Logaritmik dönüşüm sonrasında durağanlık özelliği göstermeyen değişkenlere birinci dereceden fark alma işlemi uygulanmış ve elde edilen sonuçlar %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerler ışığında durağanlık koşullarını sağladıklarını göstermiştir. Son olarak, durağan hale getirilen değişkenlere ilişkin grafikler Şekil 4.68.' de görselleştirilmiştir.




Şekil 4.68. Durağan Hale Getirilmiş Değişkenler

Durağan hale getirilen bağımlı ve bağımsız değişkenlere ait tanımlayıcı istatistikler Tablo 4.44.' te kapsamlı bir şekilde sunulmuştur. Ek olarak, bağımlı değişken ile bağımsız değişkenler arasındaki korelasyon analizi Şekil 4.69.' da gösterilmiştir.

Tablo 4.44. Tanımlayıcı İstatistikler

Değişken	Ortalama	Standart Sapma	Medyan	Çarpıklık	Basıklık
Endeks	0.5133	0.0579	0.5144	0.0227	6.7448
MA14	0.4674	0.0295	0.4678	1.6922	86.7539
RSI	0.7024	0.1289	0.7127	-0.5389	0.4151
WMA	0.5372	0.028	0.5379	1.1914	68.5894
Momentum	0.5758	0.0648	0.5766	0.1067	7.8768
StokastikK	0.8983	0.1182	0.9429	-2.008	5.1224
StokastikD	0.8403	0.158	0.9025	-1.213	0.8082
MACD	0.6819	0.0784	0.6834	-1.1016	8.7104
R	0.584	0.3051	0.6355	-0.3398	-1.2171
ACC	0.4674	0.0652	0.4643	0.4411	8.1917
CCI	0.5462	0.1632	0.5673	-0.3257	-0.5848
DXY	0.4846	0.0618	0.4837	0.2608	5.29
PETROL	0.5952	0.0525	0.5968	-0.6486	10.9718
ALTIN	0.4384	0.0513	0.4389	0.3028	14.0324




Şekil 4.69. Endeksle Değişkenler Arası Korelasyon

Şekil 4.69. verilerine göre, endeks değeri ile DXY arasında negatif yönlü ilişki tespit edilmiştir. Diğer taraftan MA14, Stokastik K, R, RSI, WMA, CCI ve Momentum değişkenlerle endeks arasındaki korelasyon katsayıları zayıf düzeyde ACC ile orta düzeyde ilişki gözlemlenmektedir. Stokastik D, MACD, Petrol ve Altın göstergeleri ile endeks arasında ise çok zayıf bir ilişki gözlemlenmektedir. Bu bulgular, söz konusu değişkenlerin model girdisi olarak değerlendirilebileceğini ortaya koymaktadır. Zayıf korelasyonel ilişkiler, değişkenler arasındaki çoklu doğrusal bağlantı riskini azaltarak, tahmin modelinin parametrik stabilitesini ve istatistiki güvenilirliğini güçlendirmektedir. Ayrıca, bu durum, değişkenlerin bağımsız bilgi içeriğine sahip olduğunu göstererek modelin açıklama gücünü artırmakta ve tahmin performansına olumlu yönde katkı sunmaktadır.


4.3.2.7.1 BIST100 Endeksi için ARIMA (p,d,q) Modelinin Belirlenmesi

Durağanlık şartının sağlanmasının ardından, tahmin modellerinin belirlenmesi ve seçimi aşamasına geçilmiştir. Bu süreçte, denenen ARIMA modelleri arasından en uygun modelin belirlenmesi amacıyla bir dizi istatistiksel kriter dikkate alınmıştır. Model seçiminde temel ölçütler arasında, en düşük AIC değerine sahip olma, F istatistiğinin istatistiksel anlamlılık göstermesi, modelin kalıntılarının hata kareleri toplamının düşük olması yer almaktadır. Bu kriterler, en iyi açıklayıcı modelin seçilmesinde başlıca referans noktaları olarak benimsenmiştir. Yapılan değerlendirmeler sonucunda, MOEX endeksinin tahmini için en uygun modelin ARIMA (1,1,3) olduğu tespit edilmiştir. Belirlenen modele ilişkin AIC değeri – 12345.072 olarak hesaplanmıştır. ARIMA (1,1,3) model sonucuna göre elde edilen artık değer grafiği Şekil 4.70.' te gösterilmiştir.



Şekil 4.70. Artıkların Histogram Grafiği

Şekil 4.70.' te yer alan artıkların histogram grafiği incelendiğinde, değerlerin çoğunlukla sıfır etrafında yoğunlaştığı ve simetrik bir dağılım gösterdiği görülmektedir. Kırmızı çizgi ile gösterilen teorik normal dağılım eğrisi, artıkların dağılımıyla büyük ölçüde uyumludur. Bu durum, model artıklarının normal dağıldığını ve modelin iyi bir şekilde kalibre edildiğini göstermektedir. Bununla birlikte, uç değerler sınırlı sayıdadır ve bu da ARIMA (1,1,3) modelinin, veri setini istatistiksel olarak yeterli düzeyde temsil ettiğini göstermektedir. İlgili Model ile gerçekleştirilen tahmin sonuçları Şekil 4.71.' de, yine ilgili modele ait başarı metrikleri Tablo 4.45.' te sunulmuştur.



Şekil 4.71. ARIMA (1,1,3) BIST100 Endeks Tahmin Grafiği

Şekil 4.71.' de gerçek endeks değerleri ile ARIMA (1,1,3) modelinin tahminleri arasındaki grafiksel karşılaştırma sunulmaktadır. Grafik incelendiğinde, tahminlerin genel olarak gerçek değerlere yakın olduğu ve paralel bir yapı sergilediği gözlemlenmektedir. Bu durum, modelin test seti üzerindeki performansının başarılı olduğunu ve genel trendi iyi yakaladığını göstermektedir. Tahmin edilen değerler ile gerçek değerler arasında gözle görülür büyük sapmaların olmaması, modelin doğru tahminler ürettiğini ve veri setinin dinamiklerini iyi öğrendiğini işaret etmektedir. Özellikle eğitim-test ayrımı sonrası test setinde benzer performansın sergilenmesi, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. Model, endeks değerlerindeki uzun vadeli trendleri ve dalgalanmaları başarılı bir şekilde yakalamıştır.

Bu durum, ARIMA (1,1,3) modelinin zaman serisinin yapısına uygun olduğunu desteklemektedir.

Tablo 4.45. BIST100 Endeks Tahmin Başarı Metrikleri

Model	MSE	RMSE	MAE	MAPE
ARIMA (1,1,3)	7525.15	86.75	59.32	5.1984

Modelin performansı, başarı metrikleri kullanılarak değerlendirildiğinde; RMSE değeri 86.75 olarak hesaplanmıştır. Bu değer, modelin tahminlerinin ortalama endeks değeri etrafında ± 86.75 birimlik bir sapma gösterebileceğini ifade etmektedir. RMSE, büyük hatalara daha duyarlı olduğundan, bu değer düşük olması modelin genel performansının iyi olduğunu göstermektedir. Küçük hatalara duyarlı olan MAE değeri ise 59.32 olarak bulunmuştur. Bu, modelin tahminlerinin gerçek değerlerden ortalama 59.32 birim sapma gösterdiğini belirtmekte olup, tahminlerdeki ortalama sapmanın kabul edilebilir düzeyde olduğunu ortaya koymaktadır. MAPE değerinin % 5.19 olarak hesaplanması, modelin tahminlerinin gerçek değerlere kıyasla ortalama %5.19 oranında bir sapma içerdiğini göstermektedir. Bu bulgular, modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.

4.3.3. Arıma Modeli İle Gerçekleştirilen Tahminlerin Genel Değerlendirilmesi

Çalışmanın bu kısmında geleneksel zaman serisi metotlarından ARIMA modeliyle yapılan G7-E7 ülkelerine ait seçilmiş borsa endeksleri tahminlerine ilişkin genel değerlendirilmeye yer verilecektir. Genel değerlendirme yapılırken, ülkeler arası ölçek farklılığının olması ve hataları yüzdesel olarak değerlendirdiği için MAPE değeri üzerinden karşılaştırma yapılacaktır. Literatürde, tahmin hatalarını yüzde cinsinden ifade etmesi nedeniyle MAPE istatistiği, tek başına anlam taşıyan bir metrik olarak değerlendirilmektedir ve bu özelliği, uygulamalarda daha fazla kabul görmesine neden olmaktadır. (Akgül, 2003).

Tablo 4.46. MAPE Kriterinin Sınıflandırılması

MAPE Değeri	Sınıflandırma
<%10	Çok iyi
%10-%20	İyi
%20-%50	Kabul Edilebilir
>%50	Yanlış ve Hatalı

(Lewis,1982)

Lewis, (1982) çalışmasında, tahmin hatalarının sınıflandırmasını Tablo 4.46.’ da olduğu gibi gerçekleştirmiştir:

MAPE değeri %10’un altında olan modeller, tahmin performansı açısından “çok iyi” olarak değerlendirilirken, %10 ile %20 arasındaki modeller “iyi” olarak kabul edilmektedir. %20 ile %50 arasındaki modellerin tahmin doğruluğu “kabul edilebilir” seviyede olup, %50’nin üzerindeki MAPE değerleri ise modelin öngörü gücünün yetersiz olduğunu ve tahminlerin yanlış veya hatalı olduğunu göstermektedir. Düşük MAPE değeri tahminlerin gerçek değerlere daha yakın olduğunu belirtmektedir.

Çalışma kapsamında, her bir ülke için seçilen endeksler bazında hesaplanan MAPE değerleri Tablo 4.47.’ de sunulmuştur.

Tablo 4.47. ARIMA Modeli Seçilmiş Borsa Endeksleri ve MAPE Değerleri

G7 Ülkeleri (Endeksler)	MAPE	E7 Ülkeleri (Endeksler)	MAPE
S&P 500 ARIMA (2,1,2)	4.812	SHANGHAI COMPOSITE (5,0,4)	1.071
S&P/TSX COMPOSITE ARIMA (2,1,0)	3.926	NIFTY 50 ARIMA (2,1,5)	3.727
DAX ARIMA (1,1,5)	5.599	BOVESPA ARIMA (2,1,2)	5.838
CAC40 ARIMA (0,1,1)	5.792	S&P/BMV IPC ARIMA (2,1,2)	4.368
FTSE100 ARIMA (3,1,5)	7.251	IDX COMPOSITE ARIMA (4,1,4)	7.092
FTSE MIB ARIMA (0,1,1)	4.354	MOEX ARIMA (1,1,3)	1.897
NIKKEI 225 ARIMA (3,1,4)	6.075	BIST100 ARIMA (1,1,3)	5.198

Tablo 4.47. incelendiğinde, G7 ülkelerinin borsa endeksleri için hesaplanan MAPE değerlerinin genel olarak düşük olduğu ve %10'un altında kaldığı görülmektedir. Özellikle S&P 500 (4.812), S&P/TSX Composite (3.926) ve FTSE MIB (4.354) endeksleri için elde edilen hata oranları, modelin yüksek doğrulukla tahmin yapabildiğini göstermektedir. Bununla birlikte, DAX (5.599), CAC40 (5.792), FTSE100 (7.251) ve NIKKEI 225 (6.075) endeksleri için hesaplanan MAPE değerleri, nispeten yüksek olmakla birlikte tahmin gücünün başarılı sınırlar içerisinde olduğu görülmektedir.

E7 ülkeleri açısından değerlendirildiğinde, MAPE değerlerinin G7 ülkelerine kıyasla daha geniş bir aralıkta dağıldığı görülmektedir. Özellikle SHANGHAI COMPOSITE (1.07) ve MOEX (1.89) gibi endeksler için hata oranları oldukça düşük olup, modelin bu piyasaları başarılı bir şekilde tahmin edebildiği söylenebilir. Öte yandan, BOVESPA (5.838), BIST100 (5.19) ve IDX Composite (7.09) gibi endeksler için hata oranlarının görece daha yüksek olduğu, ancak tahmin edilebilirlik açısından başarılı olduğu görülmektedir.


Bu sonuçlar, ARIMA modelinin genel olarak hem G7 hem de E7 ülke borsa endeksler için çok iyi düzeyde tahmin performansı sergilediğini göstermektedir. Bununla birlikte, gelişmekte olan ülkelerin endeksleri için tahmin hatalarının daha değişken olduğu ve bazı piyasalarda hata oranlarının nispeten daha yüksek seyrettiği dikkat çekmektedir. Bu durum, gelişmekte olan ülkelerin finansal piyasalarındaki dalgalanmaların ve yapısal farklılıkların, tahmin doğruluğunu etkileyen önemli faktörler arasında yer aldığını göstermektedir.

Sonuç olarak, elde edilen MAPE değerleri, gelişmiş ülkelerin borsa endekslerinin daha öngörülebilir ve düşük hata oranlarıyla tahmin edilebilir olduğunu, buna karşın gelişmekte olan ülkelerin endeksleri için tahmin doğruluğunun piyasa koşullarına bağlı olarak değişkenlik gösterdiğini ortaya koymaktadır.

4.4 LSTM MODELİ YÖNTEMİ İLE ENDEKS TAHMİNİ

Çalışmanın bu kısmında G7 ve E7 ülkelerine ait seçilmiş borsa endeksleri Derin Öğrenme Yöntemlerinden LSTM modeli ile tahmin edilecektir. ARIMA modelinde olduğu gibi 01.09.2006-02.02.2022 tarihleri arasındaki günlük veriler analize tabi tutulmuştur. Bağımlı değişken olarak belirlenen ülkelerin seçilmiş borsa endeksleri,

teknik ve makroekonomik değişkenler girdi verisi olarak kullanılmasıyla modellenmiştir. Çalışma kapsamında kullanılan modelin yapısı Şekil 4.72.' de verilmiştir.



Şekil 4.72. LSTM Akış Diyagramı

Çalışmada LSTM modelinin uygulanması ve sonuçların değerlendirilmesi aşamasında Python Programlama dili versiyon 3.12.1 kullanılmıştır. Python'da derin öğrenme modellerini geliştirmek için PyTorch, Scikit-learn kütüphaneleri kullanılmıştır.

Derin öğrenme modelleri, özellikle LSTM gibi zaman serisi modelleri, ölçeklendirilmiş verilere karşı oldukça duyarlıdır. Bu nedenle, veri setindeki değişkenler, min-max normalizasyonu yöntemi kullanılarak 0-1 aralığında ölçeklendirilmiştir. Veri seti, K-Kat Çapraz Doğrulama (K-Fold Cross Validation) yöntemi kullanılarak %80'i eğitim, %20'si ise test verisi olacak şekilde bölünmüştür. Bu yöntemin tercih edilmesinin temel nedeni, modelin ezberleme eğilimini azaltarak genelleme yeteneğini artırmaktır. Çapraz doğrulama, her bir katmanda farklı bir alt küme test seti olarak kullanılarak modelin tüm veri üzerinde test edilmesini ve daha tutarlı bir performans değerlendirmesi yapılmasını sağlamaktadır (Clarke, Fokoue, ve Zhang 2009, s.27).

Modelin optimum performansa ulaşabilmesi için çeşitli hiperparametre varyasyonları denenmiştir. Bu süreçte yapılan iyileştirme ve denemeler şunları içermektedir:

Giriş parametrelerinin düzenlenmesi, analizde kullanılan özellik sayısının azaltılması veya artırılması, model yapısının optimize edilmesi gizli katman (hidden layer) sayısının artırılıp azaltılması ve nöron sayılarının ayarlanması. Eğitim sürecinde

kullanılan epoch sayısının artırılıp azaltılması ve öğrenme oranının (learning rate) optimize edilmesi.

Çalışma kapsamında, her bir ülke için en iyi tahmin performansını sağlayan model parametrelerinin belirlenmesi amacıyla kapsamlı bir model seçimi ve hiperparametre optimizasyon süreci yürütülmüştür. Bu süreçte farklı parametre kombinasyonları değerlendirilmiş ve en düşük hata oranlarını veren optimal parametreler tespit edilmiştir. Yapılan analizler sonucunda, en iyi tahmin performansını sağlayan parametreler Tablo 4.48.' de gösterildiği şekliyle belirlenmiştir.

Tablo 4.48. LSTM Model Parametreleri

Ağ Mimarisi	LSTM
Nöron Sayısı	96
Katman Yapısı	1
Sıralı Veri Uzunluğu	15
Epoch Sayısı	600
K- Fold Çapraz Doğrulama	5
Öğrenme Oranı	0.005
Optimizer	Adam

Eğitim sürecinden geçirilen model, test veri seti üzerinde tahminler üreterek performansı değerlendirilmiştir. Bu değerlendirme sürecinde MAE, RMSE, MAPE, MSE gibi başarı metrikleri kullanılarak modelin tahmin gücü ve doğruluğu analiz edilmiştir. Bu kapsamda ilk aşamasında, ARIMA modelinde olduğu gibi G7 ülkelerine ait borsa endeksleri üzerinde tahminleme çalışmaları gerçekleştirilmiş olup, sonraki aşamada ise E7 ülkelerinin borsa endeksleri için benzer analizler yapılmıştır.

4.4.1. G7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin LSTM Modeli İle Tahmini


Çalışmanın bu kısmında, G7 ülkelerinin borsa endekslerinin LSTM modeli ile tahmin edilmesine yönelik metodolojik yaklaşım ve analiz süreci genel hatlarıyla ele alınacak olup, her bir ülke için elde edilen bulgular ayrıntılı bir şekilde sunulacaktır.

4.4.1.1 Amerika (S&P 500) Endeksi Tahmin Analizi

Çalışmanın bu kısmında, ABD'ye ait S&P 500 endeksinin tahmini Derin Öğrenme yöntemlerinden LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.

Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen bulgular grafikler eşliğinde yorumlanacaktır.


Şekil 4.73.' te LSTM modeliyle S&P 500 endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.73. LSTM S&P 500 Tahmin Grafiği

Şekil 4.73. incelendiğinde, modelin tahminleri (kırmızı çizgi) ile gerçek değerler (mavi çizgi) arasında yüksek düzeyde bir uyum olduğu görülmektedir. Özellikle 2006 ile 2022 yılları arasındaki uzun vadeli dönemde, S&P 500 endeksinde meydana gelen büyük ölçekli trend değişimleri ve dönemsel dalgalanmalar model tarafından başarılı bir şekilde öngörülmüştür. Modelin, genel eğilimleri başarılı bir şekilde yakaladığı ve test veri


setinde düşük hata oranıyla çalıştığı gözlemlenmiştir. Tahmin hatalarının analizi Şekil 4.74.' te gösterilmiştir.



Şekil 4.74. Artıkların Histogram Grafiği

Şekil 4.74.' te yer alan hataların histogram grafiği incelendiğinde, tahmin hataları normal dağılım göstermekte ve değerlerin çoğunlukla 0 etrafında yoğunlaştığı görülmektedir.

Modelin eğitim sürecinde hatasının nasıl değiştiğini görselleştiren Loss Fonksiyon grafiği Şekil 4.75.' te gösterilmiştir.



Şekil 4.75. Loss Fonksiyon Grafiği

Şekil 4.75. incelendiğinde, loss fonksiyon grafiği, eğitim (mavi) ve doğrulama (turuncu) MAE kayıplarının hızla azalarak durağan hale geldiğini göstermektedir. Eğitim

ve doğrulama eğrilerinin birbirine yakın olması, modelin iyi genelleme yaptığını ve ezberleme (overfitting) riskinin düşük olduğunu gösterir. Kayıp değerinin 0'a yakın seyretmesi, modelin tahmin hatasının oldukça düşük olduğunu işaret etmektedir. Model, veri setini başarılı bir şekilde öğrenmiş ve stabil hale gelmiştir. Modelin performansı başarı metrikleri ile birlikte değerlendirildiğinde Tablo 4.49.' da yer alan ölçütler elde edilmiştir.


Tablo 4.49. S&P 500 Endeks Tahmin Başarı Metrikleri

MSE	RMSE	MAE	MAPE
1288.4536	35.8286	22.9259	1.2033

Tablo 4.49. incelendiğinde hesaplanan RMSE değeri yaklaşık 35.82 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 35.82 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 22.92 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 22.92 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.20 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.20 oranında sapma içerdiğini ortaya koymaktadır. Elde edilen bu bulgular modelin tutarlı ve güvenilir tahminler ürettiğini desteklemektedir.


4.4.1.2 Kanada (S&P/TSX) Endeksi Tahmin Analizi

Çalışmanın bu kısmında, Kanada Borsasına ait S&P/TSI endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır. Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen bulgular grafikler eşliğinde yorumlanacaktır. Şekil 4.76.' da LSTM modeliyle S&P/TSI endeksine ait tahmin grafiği yer almaktadır.




Şekil 4.76. LSTM S&P/TSX Endeksi Tahmin Grafiği

Şekil 4.76. incelendiğinde, modelin tahminleri ile gerçek değerler arasında yüksek düzeyde bir uyum olduğu görülmektedir. S&P/TSX endeksinde meydana gelen büyük ölçekli trend değişimleri ve dönemsel dalgalanmalar model tarafından başarılı bir şekilde tahmin edilmiştir. Modelin, genel eğilimleri başarılı bir şekilde yakaladığı ve test dönemlerinde düşük hata oranıyla çalıştığı gözlemlenmiştir. Tahmin hatalarının analizi Şekil 4.77.' de gösterilmiştir.



Şekil 4.77. Artıkların Histogram Grafiği

Şekil 4.77.' de yer alan hataların histogram grafiği incelendiğinde, artık değerlerin çoğunlukla 0 etrafında yoğunlaştığı görülmektedir. Artıkların normal dağılıma yakın olması modelin hatalarının rastgele dağıldığını ve tahminlerin istatistiksel olarak güvenilir olduğunu göstermektedir. Modelin eğitim sürecinde hatasının nasıl değiştiğini görselleştiren Loss Fonksiyon grafiği Şekil 4.78.' de gösterilmiştir.



Şekil 4.78. Loss Fonksiyon Grafiği

Şekil 4.78. S&P/TSX Endeksinin LSTM modeli ile tahmini sırasında hata değerlerinin (MAE) nasıl değiştiğini göstermektedir. Eğitim ve doğrulama hatalarının birbirine yakın olması modelin veriyi iyi öğrendiği ve (overfitting) yapmadığını göstermektedir. Kayıp değerinin 0'a yakın seyretmesi, modelin tahmin hatasının oldukça düşük olduğunu işaret etmektedir. Modelin performansı başarı metrikleri ile birlikte değerlendirildiğinde Tablo 4.50.' de yer alan ölçütler elde edilmiştir.

Tablo 4.50. S&P/TSX Endeks Tahmini Başarı Metrikleri


MSE	RMSE	MAE	MAPE
63477.1922	241.669	179.105	1.3033

Tablo 4.50. incelendiğinde hesaplanan RMSE değeri 241.66 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 241.66 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 179.10 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 179.10 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.30 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.30 oranında sapma içerdiğini ortaya koymaktadır. Bu bulgular, modelin başarılı tahmin yeteneğini ve güvenilirliğini desteklemektedir.

4.4.1.3 Almanya (DAX) Endeksi Tahmin Analizi


Çalışmanın bu aşamasında, Almanya Borsasına ait DAX endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.

Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen bulgular grafikler eşliğinde yorumlanacaktır. Şekil 4.79.' da LSTM modeliyle DAX endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.79. LSTM DAX Endeksi Tahmin Grafiği


Şekil 4.79. incelendiğinde, modelin tahminleri ile gerçek değerler arasında yüksek düzeyde bir uyum olduğu görülmektedir. DAX endeksinde meydana gelen büyük ölçekli trend değişimleri ve dönemsel dalgalanmalar model tarafından başarılı bir şekilde tahmin edilmiştir. Modelin, genel eğilimleri başarılı bir şekilde yakaladığı ve test veri setinde düşük hata oranıyla çalıştığı gözlemlenmiştir. Tahmin hatalarının analizi Şekil 4.80.' de gösterilmiştir.



Şekil 4.80. Artıkların Histogram Grafiği

Şekil 4.80.' de yer alan hataların histogram grafiği gerçek değer- tahmin değerleri arasındaki farkların dağılımını göstermektedir. Artık değerlerin çoğunlukla 0 etrafında yoğunlaştığı görülmektedir. Artıkların normal dağılıma yakın olması modelin tahmindeki hatalarının rastgele dağıldığını ve tahminlerin istatistiksel olarak güvenilir olduğunu göstermektedir.

Modelin eğitim sürecinde hatasının nasıl değiştiğini görselleştiren Loss Fonksiyon grafiği Şekil 4.81.' de gösterilmiştir.



Şekil 4.81. Loss Fonksiyon Grafiği

Şekil 4.81. DAX Endeksinin LSTM modeli ile tahmini sırasında MAE değerlerinin epoch bazında nasıl değiştiğini göstermektedir. Eğitim ve doğrulama hatalarının birbirine yakın olması modelin veriyi iyi öğrendiği ve (overfitting)

yapmadığını göstermektedir. Kayıp değerinin 0'a yakın seyretmesi, modelin tahmin hatasının oldukça düşük olduğunu işaret etmektedir. Modelin performansı başarı metrikleri ile birlikte değerlendirildiğinde Tablo 4.51.' de yer alan ölçütler elde edilmiştir.

Tablo 4.51. DAX Endeks Tahmini Başarı Metrikleri


MSE	RMSE	MAE	MAPE
32409.5801	179.2719	124.8581	1.4273

Tablo 4.51. İncelendiğinde hesaplanan RMSE değeri 179.27 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 179.27 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 124.85 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 124.85 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.42 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.42 oranında sapma içerdiğini ortaya koymaktadır. Bu sonuçlar, modelin öngörülerinde tutarlılık gösterdiğini ve güvenilir tahminler sunduğunu ortaya koymaktadır.

4.4.1.4 Fransa (CAC40) Endeksi Tahmin Analizi


Çalışmanın bu aşamasında, Fransa Borsasına ait CAC40 endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.

Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen bulgular grafikler eşliğinde yorumlanacaktır. Şekil 4.82.' de LSTM modeliyle CAC40 endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.82. LSTM CAC40 Endeksi Tahmin Grafiği

Şekil 4.82. incelendiğinde, model tahminleri ile gerçek değerler arasında önemli bir uyum olduğu açıkça görülmektedir. CAC40 endeksinde gözlenen büyük çaplı trend değişimleri ve dönemsel dalgalanmalar, model tarafından oldukça başarılı bir şekilde tahmin edilmiştir. Modelin genel eğilimleri etkili bir biçimde yakaladığı ve test dönemlerinde düşük hata oranlarıyla performans sergilediği tespit edilmiştir. Tahmin hatalarının detaylı analizi ise Şekil 4.83.' te sunulmuştur.




Şekil 4.83. Artıkların Histogram Grafiği

Şekil 4.83.' te sunulan histogram, gerçek değerler ile tahmin edilen değerler arasındaki artıkların dağılımını göstermektedir. Artık değerlerin büyük bir kısmının 0 merkezli olduğu belirlenmiştir. Artıkların normal dağılıma yakın bir yapı sergilemesi, modelin tahmin hatalarının rastgele dağıldığını ve yapılan tahminlerin istatistiksel olarak

güvenilir olduğunu ortaya koymaktadır. Bu durum, modelin verideki sistemik örüntüleri başarıyla yakaladığını doğrular niteliktedir.

Modelin eğitim sürecinde hatanın değişimini gösteren Loss Fonksiyonu grafiği ise Şekil 4.84.' te verilmiştir. Bu grafik, modelin öğrenme performansını değerlendirmede önemli bir gösterge niteliği taşımaktadır.



Şekil 4.84. Loss Fonksiyon Grafiği

Şekil 4.84.' te CAC40 Endeksi için LSTM modeli kullanılarak gerçekleştirilen tahmin sürecinde MAE değerlerinin epochlara göre değişimini göstermektedir. Eğitim ve doğrulama hatalarının birbirine yakın seyretmesi, modelin veriyi etkili bir şekilde öğrendiğini ve overfitting sorununun yaşanmadığını ortaya koymaktadır. Kayıp değerinin (loss) 0'a yakın olması ise modelin tahminlerindeki hata oranının oldukça düşük olduğunu işaret etmektedir. Modelin performansı, başarı metrikleriyle birlikte değerlendirildiğinde, elde edilen sonuçlar Tablo 4.52.' de sunulan ölçütlerle özetlenmiştir.

Tablo 4.52. CAC40 Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
6424.5153	80.0637	57.066	1.3142

Tablo 4.52. incelendiğinde hesaplanan RMSE değeri 80.06 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 80.06 birimlik bir sapma

gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 57.06 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 57.06 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.31 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.31 oranında sapma içerdiğini ortaya koymaktadır. Elde edilen veriler, modelin tahmin performansının tutarlı ve başarılı olduğunu göstermektedir.

4.4.1.5 İngiltere (FTSE100) Endeksi Tahmin Analizi

Çalışmanın bu aşamasında, İngiltere Borsasına ait FTSE100 endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.


Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen bulgular grafikler eşliğinde yorumlanacaktır. Şekil 4.85.' te LSTM modeliyle FTSE100 endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.85. LSTM FTSE100 Endeks Tahmin Grafiği

Şekil 4.85. incelendiğinde, model tahminleri ile gerçek değerler arasında önemli bir uyum olduğu açıkça görülmektedir. FTSE100 endeksinde gözlenen değişimleri ve dönersel dalgalanmalar, model tarafından oldukça başarılı bir şekilde tahmin edildiği


görülmektedir. Modelin genel eğilimleri etkili bir biçimde yakaladığı ve test dönemlerinde düşük hata oranlarıyla performans sergilediği tespit edilmiştir. Tahmin hatalarının detaylı analizi ise Şekil 4.86.' da sunulmuştur.



Şekil 4.86. Artıkların Histogram Grafiği

Şekil 4.86.' da yer alan histogram, gerçek değerler ile model tahminleri arasındaki artıkların dağılımını göstermektedir. Artık değerlerin çoğunluğunun 0 merkezli yoğunlaştığı gözlenmiştir. Artıkların normal dağılıma yakın bir şekilde dağılması, modelin tahmin hatalarının rastgele bir yapıda olduğunu ve sonuçların istatistiksel olarak güvenilirliğini desteklemektedir.

Modelin eğitim sürecindeki performansını değerlendirmek için ise Şekil 4.87.' de kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur. Bu grafik, modelin öğrenme sürecindeki hatanın nasıl azaldığını ortaya koymakta olup, analizde önemli bir gösterge olarak değerlendirilmektedir.



Şekil 4.87. Loss Fonksiyon Grafiği

Şekil 4.87. FTSE100 Endeksi için LSTM modeli kullanılarak gerçekleştirilen tahmin sürecinde MAE değerlerinin epochlara göre değişimini göstermektedir. Eğitim ve doğrulama hatalarının birbirine yakın seyretmesi, modelin veriyi etkili bir şekilde öğrendiğini ve overfitting sorununun yaşanmadığını ortaya koymaktadır. Kayıp değerinin 0'a yakın olması ise modelin tahminlerindeki hata oranının oldukça düşük olduğunu işaret etmektedir. Modelin performansı, başarı metrikleriyle birlikte değerlendirildiğinde, elde edilen sonuçlar Tablo 4.53.' te sunulan ölçütlerle özetlenmiştir.

Tablo 4.53. FTSE100 Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
8715.1491	93.0105	66.7756	1.115

Tablo 4.53. incelendiğinde hesaplanan RMSE değeri 93.01 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 93.01 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 66.77 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 66.77 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.15 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.15 oranında sapma içerdiğini ortaya koymaktadır. Bu bulgular, modelin hem genel hem de detaylı performansının tatmin edici düzeyde olduğunu göstermektedir.

4.4.1.6 İtalya (FTSEMIB) Endeksi Tahmin Analizi

Çalışmanın bu aşamasında, İtalya Borsasına ait FTSEMIB endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.


Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen

bulgular grafikler eşliğinde yorumlanacaktır. Şekil 4.88.' de LSTM modeliyle FTSEMIB endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.88. LSTM FTSEMIB Endeks Tahmin Grafiği


Şekil 4.88 incelendiğinde, model tahminleri ile gerçek değerler arasında önemli bir uyum olduğu açıkça görülmektedir. FTSEMIB endeksinde gözlenen değişimleri ve dönemsel dalgalanmalar, model tarafından oldukça başarılı bir şekilde tahmin edildiği görülmektedir. Modelin genel eğilimleri etkili bir biçimde yakaladığı ve test dönemlerinde düşük hata oranlarıyla performans sergilediği tespit edilmiştir. Tahmin hatalarının detaylı analizi ise Şekil 4.89.' da sunulmuştur.



Şekil 4.89. Artıkların Histogram Grafiği

Şekil 4.89.' da yer alan histogram, gerçek değerler ile model tahminleri arasındaki artıkların dağılımını göstermektedir. Artık değerlerin normal dağılıma uygun ve çoğunluğunun 0 merkezli yoğunlaştığı gözlenmiştir. Bu dağılım, modelin tahmin

hatalarının rastgele bir yapıda olduğunu ve sonuçların istatistiksel olarak güvenilirliğini ifade etmektedir. Modelin eğitim sürecindeki performansını değerlendirmek için ise Şekil 4.90.' da kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur.



Şekil 4.90. Loss Fonksiyon Grafiği

Şekil 4.90. FTSEMIB Endeksi için LSTM modeli kullanılarak gerçekleştirilen tahmin sürecinde MAE değerlerinin epochlara göre değişimini göstermektedir. Eğitim ve doğrulama hatalarının birbirine yakın seyretmesi, modelin veriyi etkili bir şekilde öğrendiğini ve overfitting sorununun yaşanmadığını ortaya koymaktadır. Kayıp değerinin 0'a yakın olması ise modelin tahminlerindeki hata oranının oldukça düşük olduğunu işaret etmektedir. Modelin performansı, başarı metrikleriyle birlikte değerlendirildiğinde, elde edilen sonuçlar Tablo 4.54.' te sunulan ölçütlerle özetlenmiştir.

Tablo 4.54. FTSEMIB Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
198720.7844	444.7743	324.4827	1.5419


Tablo 4.54. incelendiğinde hesaplanan RMSE değeri 444.77 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 444.77 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 324.48 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 324.48 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.54 olarak hesaplanmıştır. Bu durum

modelin tahminlerinin gerçek değere kıyasla ortalama %1.54 oranında sapma içerdiğini ortaya koymaktadır. Bu bulgular, modelin hem genel hem de detaylı performansının tatmin edici düzeyde olduğunu göstermektedir.

4.4.1.7 Japonya (NIKKEI 225) Endeksi Tahmin Analizi

Çalışmanın bu aşamasında, gelişmiş ekonomilerden sonuncusu olan Japonya Borsasına ait NIKKEI225 endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.


Bu kapsamda, belirlenen modelin tahmin performansı, artık analizi, kayıp fonksiyonu ve başarı metrikleri üzerinden değerlendirilecek, nihayetinde elde edilen bulgular grafikler eşliğinde yorumlanacaktır. Şekil 4.91.' de LSTM modeliyle NIKKEI225 endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.91. LSTM NIKKEI 225 Endeks Tahmin Grafiği

Şekil 4.91. incelendiğinde, model tahminleri ile gerçek değerler arasında önemli bir uyum olduğu açıkça görülmektedir. NIKKEI225 endeksinde gözlenen değişimleri ve


kriz dönemlerindeki dalgalanmalar, model tarafından oldukça başarılı bir şekilde tahmin edildiği görülmektedir. Modelin genel eğilimleri etkili bir biçimde yakaladığı ve test dönemlerinde düşük hata oranlarıyla performans sergilediği tespit edilmiştir. Tahmin hatalarının detaylı analizi ise Şekil 4.92.' de sunulmuştur



Şekil 4.92. Artıkların Histogram Grafiği

Şekil 4.92.' de yer alan histogram, gerçek değerler ile model tahminleri arasındaki artıkların dağılımını göstermektedir. Artık değerlerin normal dağılıma uygun ve çoğunluğunun 0 etrafında toplandığı gözlenmiştir. Bu dağılım, modelin tahmin hatalarının rastgele bir yapıda olduğunu ve sonuçların gerçek endeks değerine yakın tahminler yapıldığını göstermektedir.

Modelin eğitim sürecindeki performansını değerlendirmek için ise Şekil 4.93.' te kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur.



Şekil 4.93. Loss Fonksiyon Grafiği

Şekil 4.93. NIKKEI225 Endeksi için LSTM modeli kullanılarak gerçekleştirilen tahmin sürecinde MAE değerlerinin epochlara göre değişimini göstermektedir. Eğitim ve doğrulama hatalarının birbirine yakın seyretmesi, modelin veriyi etkili bir şekilde öğrendiğini ve overfitting sorununun yaşanmadığını ortaya koymaktadır. Kayıp değerinin 0'a yakın olması ise modelin tahminlerindeki hata oranının oldukça düşük olduğunu işaret etmektedir. Modelin performansı, başarı metrikleriyle birlikte değerlendirildiğinde, elde edilen sonuçlar Tablo 4.55.' te sunulan ölçütlerle özetlenmiştir.

Tablo 4.55. LSTM NIKKEI Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
105520.2438	324.7947	230.3925	1.4894

Tablo 4.55. incelendiğinde, hesaplanan RMSE değeri 324.79 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 324.79 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 230.39 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 230.39 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.48 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.48 oranında sapma içerdiğini ortaya koymaktadır. Bu bulgular, modelin hem genel hem de detaylı performansının tatmin edici düzeyde olduğunu göstermektedir.

4.4.2. E7 Ülkelerine Ait Seçilmiş Borsa Endekslerinin LSTM Modeli İle Tahmini

Çalışmanın bu kısmında, E7 ülkelerinin borsa endekslerinin LSTM modeli ile tahmin edilmesine yönelik metodolojik yaklaşım ve analiz süreci genel hatlarıyla ele alınacak olup, her bir ülke için elde edilen bulgular ayrıntılı bir şekilde sunulacaktır.

4.4.2.1 Çin (SHANGHAI COMPOSITE) Endeksi Tahmin Analizi

Çalışmanın bu kısmında, Çin borsasına ait SHANGHAI COMPOSITE endeksinin tahmini Derin Öğrenme yöntemlerinden LSTM modeli kullanılarak gerçekleştirilmiştir.

Önceki kısımda detaylandırıldığı üzere, analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır.


Modelin eğitim sürecinde hiperparametre optimizasyonu gerçekleştirilmiş olup, farklı epoch sayıları, öğrenme oranları ve katman yapılarına göre modelin performansı karşılaştırılmıştır. Belirlenen nihai model ile yapılan tahminler sonucunda elde edilen veriler, hata oranları ve değerlendirme metrikleri çerçevesinde yorumlanmıştır. Şekil 4.94.' te LSTM modeliyle SHANGHAI COMPOSITE endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.94. LSTM SHANGHAI Composite Endeks Tahmin Grafiği


Şekil 4.94.' te görüldüğü üzere gerçek değerler ve model tahmini büyük ölçüde örtüşmektedir, bu da modelin endeks hareketlerini başarılı bir şekilde öğrendiğini ve tahmin ettiğini göstermektedir. Kırmızı kesikli çizgi, eğitim ve test veri kümelerinin ayrıldığı noktayı belirtmektedir. Bu noktadan sonra modelin hiç görmediği veriler üzerinde test edilmesi sağlanmıştır. Test veri setinde de model, genel trendleri başarılı bir şekilde takip etmektedir. Model, keskin düşüşleri büyük ölçüde yakalayabilmiş ve uzun vadeli trendleri başarılı bir şekilde tahmin edebilmiştir. Eğitim ve test sonuçlarının oldukça benzer olması, modelin overfitting yapmadığını göstermektedir. Modelin test setinde de güçlü performans sergilemesi, genelleme yeteneğinin yüksek olduğunu

göstermektedir. Hata bandının dar olması, modelin yüksek doğrulukla tahmin yaptığının bir diğer göstergesidir. Tahmin hatalarının detaylı analizi ise Şekil 4.95.' te sunulmuştur



Şekil 4.95. Artıkların Histogram Grafiği

Şekil 4.95.' te LSTM modelinin tahmin hatalarının dağılımını göstermektedir. Normal dağılım gösteren hata dağılımının, tepe noktası 0 civarındadır, bu da modelin sistematik bir hata üretmediğini, ortalama hatanın düşük seviyede olduğunu göstermektedir. Hatalar pozitif ve negatif yönde benzer şekilde yayılmıştır bu durum modelin tahminlerinde belirli bir tarafa eğilim göstermediğini ifade etmektedir. Modelin eğitim sürecindeki performansını değerlendirmek için ise Şekil 4.96.' da kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur.



Şekil 4.96. Loss Fonksiyon Grafiği

Şekil 4.96.' da, LSTM modelinin eğitim süreci incelendiğinde, loss fonksiyon grafiği modelin hızlı ve etkin bir öğrenme süreci geçirdiğini göstermektedir. İlk evrelerde keskin bir düşüş sergileyen loss değerleri, ardından kararlı bir şekilde minimize olarak

yaklaşık 0'a ulaşmış, eğitim ve validasyon loss'ları birbirine yakınsayarak modelin yüksek genelleme performansına işaret etmiştir. Modelin temel örüntüleri başarıyla yakaladığını ve overfitting riskinin düşük olduğunu ortaya koymaktadır. Modelin performansı, başarı metrikleriyle birlikte değerlendirildiğinde, elde edilen sonuçlar Tablo 4.56.' da sunulan ölçütlerle özetlenmiştir.


Tablo 4.56. LSTM SHANGHAI Composite Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
3897.6257	62.2652	41.4361	1.3783

Tablo 4.56. İncelendiğinde, hesaplanan RMSE değeri 62.26 puan olarak tespit edilmiştir. Bu değer modelin tahminlerinin genel hata büyüklüğünün düşük seviyede olduğunu ve tahminlerin ortalama endeks değer etrafında ± 62.26 birimlik bir sapma gösterebileceğini ifade etmektedir. Öte yandan daha küçük hatalara duyarlı olan MAE değeri 41.43 olarak hesaplanmıştır. Bu ise modelin tahminlerinin gerçek endeks değerinden ortalama olarak ± 41.43 birimlik bir sapma gösterdiğini ifade etmektedir. Hataların yüzdesel ifadesi olan MAPE değeri 1.37 olarak hesaplanmıştır. Bu durum modelin tahminlerinin gerçek değere kıyasla ortalama %1.37 oranında sapma içerdiğini ortaya koymaktadır. Bu bulgular, modelin yüksek tahmin gücünü ortaya koymaktadır.


4.4.2.2 Hindistan (NIFTY50) Endeksi Tahmin Analizi

Çalışmanın bu kısmında, Hindistan borsasına ait NIFTY50 endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır. Modelin eğitim sürecinde hiperparametre optimizasyonu gerçekleştirilmiş olup, farklı epoch sayıları, öğrenme oranları ve katman yapılarına göre modelin performansı karşılaştırılmıştır. Belirlenen nihai model ile yapılan tahminler sonucunda elde edilen veriler, hata oranları ve değerlendirme metrikleri çerçevesinde yorumlanmıştır. Şekil 4.97.' de LSTM modeliyle NIFTY50 endeksine ait tahmin grafiği yer almaktadır.




Şekil 4.97. LSTM NIFTY50 Endeks Tahmin Grafiği

Şekil 4.97.' de görüldüğü üzere gerçek değerler ve model tahmini büyük ölçüde örtüşmektedir, bu da modelin endeks hareketlerini başarılı bir şekilde öğrendiğini ve tahmin ettiğini göstermektedir. Kırmızı kesikli çizgi, eğitim ve test veri kümelerinin ayrıldığı noktayı belirtmektedir. Bu noktadan sonra modelin hiç görmediği veriler üzerinde test edilmesi sağlanmıştır. Test veri setinde de model, genel trendleri başarılı bir şekilde takip etmektedir. Model, yükseliş ve düşüşleri büyük ölçüde yakalayabilmiş ve uzun vadeli trendleri başarılı bir şekilde tahmin edebilmiştir. Eğitim ve test sonuçlarının oldukça benzer olması, modelin overfitting yapmadığını göstermektedir. Modelin test setinde de güçlü performans sergilemesi, genelleme yeteneğinin yüksek olduğunu göstermektedir. Hata bandının dar olması, modelin yüksek doğrulukla tahmin yaptığının bir diğer göstergesidir. Tahmin hatalarının detaylı analizi ise Şekil 4.98.' de sunulmuştur.



Şekil 4.98. Artıkların Histogram Grafiği

Şekil 4.98.' de sunulan grafik, LSTM modelinin tahmin hatalarının dağılımını göstermektedir. Hata değerlerinin normal dağılıma yakın bir yapıda olduğu ve dağılımın merkezinin 0 civarında yoğunlaştığı belirlenmiştir. Bu, modelin genel olarak düşük seviyede hata ürettiğini ve sistematik bir sapma içermediğini işaret etmektedir. Hataların pozitif ve negatif yönde benzer oranda yayılması, modelin tahminlerinde tarafsız davrandığını ve belirli bir yanlılığa sahip olmadığını doğrulamaktadır. Bu bulgular, modelin istikrarlı ve güvenilir bir performans sergilediğini göstermektedir. Modelin eğitim sürecindeki performansını değerlendirmek için ise Şekil 4.99.' da kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur.



Şekil 4.99. Loss Fonksiyon Grafiği

Şekil 4.99.' da yer alan loss fonksiyon grafiği, LSTM modelinin öğrenme dinamiklerini net bir şekilde ortaya koymaktadır. Başlangıç aşamasında kayıp değerlerinde önemli bir azalma gözlenirken, süreç ilerledikçe bu değerlerin kararlı bir şekilde düşerek yaklaşık olarak 0'a ulaştığı tespit edilmiştir. Eğitim ve doğrulama loss değerlerinin birbirine yakın seyretmesi, modelin hem eğitim verilerini iyi öğrendiğini hem de test verileri üzerinde etkili performans sergilediğini göstermektedir. Bu durum, modelin genelleme kapasitesinin yüksek olduğunu ve sistemik örüntüleri başarıyla yakaladığını doğrular niteliktedir. Elde edilen bulgular, modelin performansını

değerlendirmek amacıyla hesaplanan başarı metrikleriyle birlikte Tablo 4.57.' de sunulmuştur.

Tablo 4.57. LSTM NIFTY50 Endeks Tahmini Başarı Metrikleri


MSE	RMSE	MAE	MAPE
22330.416	149.1471	105.879	1.5093

Tablo 4.57.' de yer alan başarı metrikleri incelendiğinde, RMSE değeri 149.14 olarak belirlenmiştir. Bu sonuç, model tahminlerinin gerçek değerlerden ortalama olarak ± 149.14 birimlik bir sapma gösterebileceğini ve genel hata büyüklüğünün düşük seviyede kaldığını göstermektedir. Ayrıca, daha küçük hatalara duyarlı olan MAE değeri 105.87 olarak hesaplanmıştır. Bu durum, modelin tahminlerinin gerçek endeks değerlerinden ortalama olarak ± 105.87 birim uzaklıkta olduğunu ifade etmektedir.

Hataların yüzdesel olarak ifade edildiği MAPE değeri ise %1.50 olarak tespit edilmiştir. Bu oran, modelin tahminlerinin gerçek değerlerden ortalama olarak yalnızca %1.50' lik bir sapma içerdiğini ortaya koymaktadır. Bu bulgular, modelin hem mutlak hatalar açısından düşük performans sergilediğini hem de yüzde bazında oldukça hassas tahminler yapabildiğini göstermektedir. Sonuç olarak, elde edilen metrikler modelin yüksek tahmin gücüne sahip olduğunu ve verideki örüntüleri başarıyla yakaladığını doğrulamaktadır.

4.4.2.3 Brezilya (BOVESPA) Endeksi Tahmin Analizi


Çalışmanın bu kısmında, Brezilya borsasına ait BOVESPA endeksinin tahmini LSTM modeli kullanılarak gerçekleştirilmiştir. Analiz sürecine başlamadan önce veri setine çeşitli ön işleme adımları uygulanmış, eksik veriler giderilmiş ve ölçeklendirme işlemleri tamamlanmıştır. Modelin eğitim sürecinde hiperparametre optimizasyonu gerçekleştirilmiş olup, farklı epoch sayıları, öğrenme oranları ve katman yapılarına göre modelin performansı karşılaştırılmıştır. Belirlenen nihai model ile yapılan tahminler sonucunda elde edilen veriler, hata oranları ve değerlendirme metrikleri çerçevesinde yorumlanmıştır. Şekil 4.100.' de LSTM modeliyle BOVESPA endeksine ait tahmin grafiği yer almaktadır.



Şekil 4.100. LSTM BOVESPA Endeks Tahmin Grafiği


Şekil 4.100. incelendiğinde, gerçek değerler ile model tahminleri arasında yüksek düzeyde bir uyum olduğu görülmektedir. Bu durum, modelin endeks hareketlerini başarılı bir şekilde öğrendiğini ve gelecekteki değerleri hassas bir şekilde tahmin edebildiğini göstermektedir. Eğitim ve test veri kümelerinin ayrıldığı noktayı işaret etmekte olan kırmızı kesikli çizgiden sonra model, daha önce görmediği veriler üzerinde test edilmiştir. Test veri setinde de model, genel trendleri ve önemli dalgalanmaları başarıyla takip etmiştir. Özellikle yükseliş ve düşüş hareketlerini büyük ölçüde yakalayan model, uzun vadeli trendleri de etkili bir şekilde tahmin etmiştir.

Eğitim ve test sonuçlarının birbirine oldukça yakın olması, modelin aşırı öğrenme yapmadığını ve iyi bir genelleme yeteneğine sahip olduğunu ortaya koymaktadır. Hata bandının dar olması ise modelin tahminlerinin yüksek doğrulukta olduğunu gösteren ek bir göstergedir. Tahmin hatalarının daha detaylı analizi ise Şekil 4.101.' de sunulmuştur.



Şekil 4.101. Artıkların Histogram Grafiği

Şekil 4.101.' de LSTM modelinin tahmin hatalarının dağılımı incelenmiştir. Hata değerlerinin yaklaşık olarak normal dağılım gösterdiği ve dağılımın merkezinin 0 civarında yoğunlaştığı tespit edilmiştir. Bu durum, modelin ortalama hatasının düşük seviyelerde kaldığını ve sistematik bir eğilim veya sapma içermediğini ortaya koymaktadır. Ayrıca, hataların pozitif ve negatif yönde dengeli bir şekilde dağıldığı görülmüştür. Bu sonuç, modelin tahminlerinde belirli bir tarafa kaymadan tarafsız davrandığını ve rastgele hatalar ürettiğini doğrulamaktadır. Tüm bu bulgular, modelin tutarlı ve istikrarlı bir performans sergilediğini açıkça göstermektedir. Modelin eğitim sürecindeki performansını değerlendirmek için ise Şekil 4.102.' de kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur.



Şekil 4.102. Loss Fonksiyon Grafiği

Şekil 4.102.' de sunulan Loss fonksiyonu grafiği, LSTM modelinin öğrenme sürecine ilişkin önemli bulgular ortaya koymaktadır. Grafikte, başlangıç aşamasında kayıp değerlerinde belirgin bir düşüş gözlemlenmektedir. Bu düşüş, modelin veri setindeki örüntüleri hızlı bir şekilde öğrendiğini göstermektedir. Süreç ilerledikçe kayıp değerleri, yaklaşık olarak sıfıra yakınsayacak şekilde kararlı bir azalma eğilimi sergilemiştir. Eğitim ve doğrulama loss değerlerinin birbirine yakın bir seyir izlemesi, modelin hem eğitim verilerini başarıyla modellediğini hem de daha önce görmediği test verileri üzerinde etkin performans gösterdiğini işaret etmektedir. Bu durum, modelin yüksek genelleme yeteneğine sahip olduğunu ve verideki temel örüntüleri etkili bir şekilde yakaladığını doğrular niteliktedir. Modelin performansının niceliksel olarak

değerlendirilmesi amacıyla hesaplanan başarı metrikleri ise Tablo 4.58.' de detaylı olarak sunulmuştur.

Tablo 4.58. LSTM BOVESPA Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
2220353.075	1489.2616	1076.4294	1.6621

Tablo 4.58.' de verilen başarı metrikleri incelendiğinde, RMSE değeri 1489.26 olarak hesaplanmıştır. BOVESPA endeks değerinin son dönemlerde 120000 puanda olduğu göz önünde bulundurulduğunda RMSE değeri, model tahminlerinin gerçek değerlerden ortalama olarak ± 1489.26 birimlik bir sapma gösterdiğini ve genel hata büyüklüğünün kabul edilebilir düzeyde kaldığını ifade etmektedir. Benzer şekilde, daha küçük hatalara duyarlı olan MAE değeri 1076.42 olarak belirlenmiştir. Bu sonuç, modelin tahminlerinin gerçek endeks değerlerine ortalama olarak ± 1076.42 birim yaklaştığını göstermektedir. Hataların yüzdesel olarak değerlendirildiği MAPE değeri ise %1.66 olarak tespit edilmiştir. Bu oran, modelin tahminlerinin gerçek değerlerden ortalama olarak yalnızca %1.66 bir sapma içerdiğini ortaya koymaktadır. Elde edilen bulgular, modelin hem mutlak hata metriklerinde düşük değerler sergilediğini hem de yüzde bazında yüksek doğrulukta tahminler yapabildiğini doğrulamaktadır. Sonuç olarak, modelin güçlü bir tahmin yeteneğine sahip olduğu ve verideki desenleri etkili bir şekilde yakaladığı gözlemlenmektedir.


4.4.2.4 MEKSIKA (S&P/BMV IPC) Endeksi Tahmin Analizi

Çalışmanın bu aşamasında, Meksika borsasının S&P/BMV IPC endeksi için LSTM tabanlı bir tahmin modeli geliştirilmiştir. Analiz öncesinde veri seti üzerinde eksik verilerin doldurulması, gürültü minimizasyonu ve ölçeklendirme gibi ön işleme adımları gerçekleştirilmiştir. Modelin eğitim sürecinde, hiperparametre optimizasyonu kapsamında farklı epoch değerleri, öğrenme oranları ve katman yapıları denenmiş ve performansları detaylı olarak karşılaştırılmıştır. Nihai model ile elde edilen tahminler, hata metrikleri ve değerlendirme kriterleri üzerinden analiz edilmiş olup, bu süreçte modelin performansı niceliksel olarak değerlendirilmiştir. Şekil 4.103.' te, LSTM modelinin S&P/BMV IPC endeksi için oluşturduğu tahmin grafiği sunulmaktadır.



Şekil 4.103. LSTM S&P/BMV IPC Endeks Tahmin Grafiği


Şekil 4.103. İncelendiğinde, gerçek değerler ile model tahminleri arasında önemli düzeyde bir uyum olduğu belirlenmiştir. Bu durum, modelin endeks hareketlerini etkili bir şekilde yakaladığını ve gelecekteki değerleri hassasiyetle tahmin edebildiğini ortaya koymaktadır. Kırmızı kesikli çizgi, eğitim ve test veri kümelerinin ayrıldığı noktayı göstermektedir ve bu noktadan sonra model, daha önce karşılaşmadığı veriler üzerinde değerlendirilmiştir. Test veri setinde model, genel eğilimleri ve önemli dalgalanmaları başarıyla izlemiş, özellikle yükseliş ve düşüş hareketlerini büyük oranda doğru tahmin etmiştir. Ayrıca, uzun vadeli trendleri de etkili bir şekilde modellemiştir. Eğitim ve test sonuçlarının birbirine yakın olması, modelin aşırı öğrenme sorunu yaşamadığını ve güçlü bir genelleme kapasitesine sahip olduğunu doğrulamaktadır. Dar bir hata bandı ile sonuçlanan tahminler ise modelin yüksek doğrulukta performans sergilediğinin bir başka işaretidir. Tahmin hatalarının daha kapsamlı analizi ise Şekil 4.104.' te sunulmuştur.



Şekil 4.104. Artıkların Histogram Grafiği

Şekil 4.104.' te LSTM modelinin tahmin hatalarının dağılımı analiz edilmiştir. Hata değerlerinin yaklaşık olarak normal dağılım özelliği gösterdiği ve dağılımın

merkezinin 0 civarında yoğunlaştığı belirlenmiştir. Bu bulgu, modelin ortalama hatasının düşük düzeyde kaldığını ve sistematik bir yanlılık içermediğini işaret etmektedir. Ayrıca, hataların pozitif ve negatif yönde homojen bir şekilde dağıldığı tespit edilmiştir. Bu durum, modelin tahminlerinde belirli bir yöne eğilim göstermediğini ve rastgele hatalar ürettiğini doğrulamaktadır. Elde edilen sonuçlar, modelin istikrarlı bir performans sergilediğini ortaya koymaktadır. Modelin eğitim sürecindeki performansının değerlendirilmesi için ise Şekil 4.105.' te kayıp fonksiyonunun değişimini gösteren grafik sunulmuştur.



Şekil 4.105. Loss Fonksiyon Grafiği

Şekil 4.105.' te yer alan Loss fonksiyonu grafiği, LSTM modelinin öğrenme dinamiklerini ve performansını açık bir şekilde ortaya koymaktadır. Grafikte, eğitim sürecinin başlangıcında kayıp değerlerinde hızlı ve belirgin bir düşüş gözlenmektedir. Bu durum, modelin verideki örüntüleri kısa sürede öğrendiğini göstermektedir. Süreç ilerledikçe kayıp değerleri, yaklaşık olarak sıfıra yaklaşıp kararlı bir seyir izlemiş ve bu da modelin istikrarlı bir öğrenme süreci geçirdiğini doğrulamaktadır. Eğitim ve doğrulama loss değerlerinin birbirine yakın olması, modelin hem eğitim verilerini etkili bir şekilde yakaladığını hem de daha önce karşılaşmadığı test verileri üzerinde iyi bir performans sergilediğini göstermektedir. Bu bulgu, modelin aşırı öğrenme yapmadığını ve yüksek genelleme yeteneğine sahip olduğunu kanıtlamaktadır. Modelin performansının daha kapsamlı değerlendirilmesi için hesaplanan başarı metrikleri ise Tablo 4.59.' da detaylandırılmıştır.

Tablo 4.59. LSTM S&P/BMV IPC Endeks Tahmini Başarı Metrikleri


MSE	RMSE	MAE	MAPE
412725.7875	641.8509	477.2	1.3055

Tablo 4.59.’ da sunulan başarı metrikleri değerlendirildiğinde, RMSE değeri 641.85 olarak hesaplanmıştır. Model tahminlerinin gerçek değerlerden ortalama olarak ± 641.85 birimlik bir sapma gösterdiğini ifade etmektedir. Bu durum, genel hata büyüklüğünün nispeten düşük ve kabul edilebilir düzeyde kaldığını ortaya koymaktadır. Ayrıca, daha küçük hatalara duyarlı olan MAE değeri 477.2 olarak belirlenmiştir. Bu sonuç, modelin tahminlerinin gerçek endeks değerlerinden ortalama olarak ± 477.2 birim sapma gösterdiğini ve tutarlı bir performans sergilediğini göstermektedir.

Hataların yüzdesel olarak ifade edildiği MAPE değeri ise %1.30 olarak tespit edilmiştir. Bu oran, modelin tahminlerinin gerçek değerlerden ortalama olarak yalnızca %1.30’ lık bir sapma içerdiğini ve yüzde bazında oldukça hassas tahminler yapabildiğini doğrulamaktadır. Elde edilen bulgular, modelin hem mutlak hatalarda düşük değerler sergilediğini hem de yüzde bazında yüksek doğrulukta sonuçlar ürettiğini göstermektedir. Bu çerçevede, modelin güçlü bir tahmin yeteneğine sahip olduğu ve verideki temel desenleri başarıyla yakaladığını göstermektedir.


4.4.2.5 ENDONEZYA (IDX COMPOSITE) Endeksi Tahmin Analizi

Çalışmanın bu aşamasında, Endonezya borsasına ait IDX COMPOSITE endeksinin tahmini için bir LSTM modeli geliştirilmiştir. Analiz sürecine başlamadan önce veri seti üzerinde eksik verilerin tamamlanması, gürültünün azaltılması ve ölçeklendirme işlemleri gibi ön hazırlıklar yapılmıştır. Modelin eğitimi sırasında hiperparametre optimizasyonu gerçekleştirilerek farklı epoch sayıları, öğrenme oranları ve katman yapılarının performansları incelenmiş ve en uygun parametre kombinasyonu belirlenmiştir. Nihai model ile yapılan tahminler, çeşitli hata metrikleri ve değerlendirme kriterleri çerçevesinde detaylı bir şekilde analiz edilmiş, modelin genel performansı niceliksel olarak ortaya konmuştur. Şekil 4.106.’ da, LSTM modelinin IDX COMPOSITE endeksi için oluşturduğu tahmin sonuçları grafiksel olarak gösterilmiştir.



Şekil 4.106. LSTM IDX Composite Endeks Tahmin Grafiği


Şekil 4.106.' da gerçek değerler ile model tahminleri arasında yüksek düzeyde uyum tespit edilmiştir. Bu, modelin endeks hareketlerini etkili bir şekilde yakaladığını ve gelecekteki değerleri hassas bir şekilde tahmin edebildiğini göstermektedir. Kırmızı kesikli çizgi, eğitim-test ayrımını belirtmekte olup, test aşamasında model daha önce görmediği verilerde genel eğilimleri, önemli dalgalanmaları ve uzun vadeli trendleri doğru tahmin ettiği görülmektedir. Eğitim-test sonuçlarının yakın olması, modelin aşırı öğrenme yapmadığını ve iyi bir genelleme yeteneğine sahip olduğunu doğrulamaktadır. Dar hata bandı ise yüksek tahmin doğruluğunu işaret etmektedir. Tahmin hatalarının detaylı analizi Şekil 4.107.' de sunulmuştur.



Şekil 4.107. Artıkların Histogram Grafiği

Şekil 4.107.' de LSTM modelinin tahmin hatalarının dağılımı incelenmiştir. Analiz sonucunda, hata değerlerinin yaklaşık olarak normal dağılım gösterdiği ve

dağılımın merkezinin 0 civarında yoğunlaştığı görülmüştür. Bu durum, modelin ortalama hatasının düşük seviyelerde kaldığını ve sistematik bir sapma içermediğini ortaya koymaktadır. Hataların pozitif ve negatif yönde dengeli bir şekilde dağılması hataların rastgele olduğunu doğrulamaktadır. Bu bulgular, modelin tutarlı bir performans sergilediğini göstermektedir. Modelin eğitim sürecindeki performansı ise Şekil 4.108.’de yer alan kayıp fonksiyonu grafiği ile detaylı olarak değerlendirilmiştir.



Şekil 4.108. Loss Fonksiyon Grafiği

Şekil 4.108.’de sunulan loss fonksiyonu grafiği, LSTM modelinin öğrenme sürecini ve performans gelişimini yansıtmaktadır. Grafikte, eğitim sürecinin başlangıcında kayıp değerlerinde hızlı bir düşüş gözlemlenmiştir. Bu, modelin verideki temel örüntüleri kısa sürede öğrendiğini göstermektedir. Süreç ilerledikçe kayıp değerleri, sifıra yakın bir değere yaklaşarak kararlı bir eğilim sergilemiş ve bu durum modelin istikrarlı bir şekilde iyileştiğini ortaya koymaktadır. Eğitim ve validasyon loss değerlerinin birbirine yakın seyretmesi, modelin hem eğitim verilerinde etkili bir performans gösterdiğini hem de test verilerinde iyi bir genelleme yeteneğine sahip olduğunu kanıtlar niteliktedir. Bu sonuçlar, modelin aşırı öğrenme yapmadığını ve yeni verilere uyum gösterdiğini doğrulamaktadır. Modelin performansının daha detaylı analizi için hesaplanan başarı metrikleri ise Tablo 4.60.’da sunulmuştur.

Tablo 4.60. LSTM IDX Composite Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
6044.0531	77.5128	52.4182	1.3798

Tablo 4.60.' da sunulan başarı metriklerine göre, RMSE değeri 77.51 olarak hesaplanmıştır. Bu, model tahminlerinin gerçek değerlerden ortalama ± 77.51 birim sapma gösterdiğini ve genel hatanın düşük seviyelerde kaldığını ifade etmektedir. MAE değeri ise 52.41 olarak belirlenmiş olup, modelin gerçek değerlerle arasında ortalama ± 52.41 birimlik bir fark olduğunu göstermektedir. Ortalama yüzdesel hata değerini ifade eden MAPE ise %1.37 olarak tespit edilmiştir. Bu oran, modelin tahminlerinin gerçek değerlerden ortalama yalnızca %1.37 sapma içerdiğini ve yüksek doğrulukta sonuçlar ürettiğini ortaya koymaktadır. Bulgular, modelin hem mutlak hem de yüzde bazında iyi performans sergilediğini ve verideki örüntüleri etkili bir şekilde yakaladığını doğrulamaktadır.


4.4.2.6 RUSYA (MOEX) Endeksi Tahmin Analizi

Çalışmanın bu aşamasında, Rusya borsasına ait MOEX endeksinin tahmini için bir LSTM modeli geliştirilmiştir. Analiz sürecine başlamadan önce veri seti üzerinde eksik verilerin tamamlanması, gürültünün azaltılması ve ölçeklendirme işlemleri gibi ön hazırlıklar yapılmıştır. Modelin eğitimi sırasında hiperparametre optimizasyonu gerçekleştirilerek farklı epoch sayıları, öğrenme oranları ve katman yapılarının performansları incelenmiş ve en uygun parametre kombinasyonu belirlenmiştir. Nihai model ile yapılan tahminler, çeşitli hata metrikleri ve değerlendirme kriterleri çerçevesinde detaylı bir şekilde analiz edilmiş, modelin genel performansı niceliksel olarak ortaya konmuştur. Şekil 4.109.' da, LSTM modelinin MOEX endeksi için oluşturduğu tahmin sonuçları grafiksel olarak gösterilmiştir.



Şekil 4.109. LSTM MOEX Endeks Tahmin Grafiği


Şekil 4.109.' da gerçek değerler ile model tahminleri arasında güçlü bir uyum olduğu belirlenmiştir. Bu durum, modelin endeks hareketlerini başarıyla öğrenerek gelecekteki değerleri hassasiyetle tahmin edebildiğini göstermektedir. Test veri kümesinde model, daha önce karşılaşmadığı verilerde genel eğilimleri, önemli dalgalanmaları ve uzun vadeli trendleri etkili bir şekilde takip etmektedir. Eğitim ve test sonuçlarının birbirine yakın olması, modelin aşırı öğrenme sorunu yaşamadığını ve güçlü bir genelleme kapasitesine sahip olduğunu kanıtlamaktadır. Ayrıca, dar bir hata bandı ile sonuçlanan tahminler, modelin yüksek doğrulukta performans sergilediğini göstermektedir. Tahmin hatalarının detaylı Şekil 4.110.' da gösterilmektedir.



Şekil 4.110. Artıkların Histogram Grafiği

Şekil 4.110.' da LSTM modelinin tahmin hatalarının dağılımı analiz edilmiştir. İnceleme sonucunda, hata değerlerinin yaklaşık olarak normal dağılım özelliği gösterdiği

ve dağılımın merkezinin 0 civarında yoğunlaştığı tespit edilmiştir. Bu bulgu, modelin ortalama hatasının düşük düzeyde kaldığını ve herhangi bir sistematik yanlılık içermediğini işaret etmektedir. Hhataların pozitif ve negatif yönde homojen bir şekilde küçük bir aralıkta toplanması, LSTM modelinin MOEX endeksini genel olarak iyi tahmin ettiğini göstermektedir. Bu, modelin zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalayabildiğini ve öğrenebildiğini ifade etmektedir. Elde edilen sonuçlar, modelin istikrarlı ve güvenilir bir performans sergilediğini ortaya koymaktadır. Modelin eğitim sürecine ilişkin performans değerlendirmesi ise Şekil 4.111.’ de sunulan kayıp fonksiyonu grafiği üzerinden detaylandırılmıştır.



Şekil 4.111. Loss Fonksiyon Grafiği

Şekil 4.111.’ de yer alan loss fonksiyonu grafiği, LSTM modelinin öğrenme dinamiklerini ve performansını net bir şekilde ortaya koymaktadır. Grafikte, eğitim sürecinin başlangıcında kayıp değerlerinde belirgin bir düşüş tespit edilmiştir. Bu durum, modelin verideki temel örüntüleri hızlı bir şekilde yakaladığını göstermektedir. Süreç ilerledikçe kayıp değerleri, sıfıra yakın bir seviyeye yakınsayarak istikrarlı bir seyir izlemiş ve modelin sürekli olarak iyileştiği görülmektedir. Eğitim ile doğrulama loss değerlerinin birbirine yakın olması, modelin hem eğitim verilerini başarıyla öğrendiğini hem de daha önce görmediği test verilerinde etkili bir genelleme yapabildiğini işaret etmektedir. Bu bulgular, modelin overfitting sorunu yaşamadığını ve yeni verilere uyum

sağlama yeteneğine sahip olduğunu kanıtlamaktadır. Modelin performansının daha kapsamlı değerlendirilmesi için hesaplanan başarı metrikleri ise Tablo 4.61.’de gösterilmektedir.

Tablo 4.61. LSTM MOEX Endeks Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
2099.0023	44.6594	26.8021	1.6314

Tablo 4.61.’de yer alan başarı metrikleri incelendiğinde, RMSE değeri 44.65 olarak belirlenmiştir. Bu sonuç, model tahminlerinin gerçek değerlerden ortalama olarak ± 44.65 birimlik bir sapma gösterdiğini ve genel hata büyüklüğünün kabul edilebilir düzeyde kaldığını ortaya koymaktadır. Benzer şekilde, MAE değeri 26.80 olarak hesaplanmıştır. Bu, modelin tahminlerinin gerçek değerlerle arasında ortalama ± 26.80 birimlik bir fark olduğunu göstermektedir. Ortalama yüzdesel hata ölçütü olan MAPE ise %1.63 olarak tespit edilmiştir. Bu oran, modelin tahminlerinin gerçek değerlerden ortalama olarak yalnızca %1.63’lük bir sapma içerdiğini ve yüzde bazında oldukça hassas sonuçlar ürettiğini kanıtlamaktadır. Elde edilen bulgular, modelin hem mutlak hatalarda düşük değerler sergilediğini hem de yüzde bazında yüksek doğrulukta performans gösterdiğini doğrulayarak, verideki temel örüntüleri başarıyla yakaladığını işaret etmektedir.


4.4.2.7 TÜRKİYE (BIST100) Endeksi Tahmin Analizi

Çalışmanın bu kısmında, Türkiye borsasına ait BIST100 endeksinin tahmini için bir LSTM modeli oluşturulmuştur. Analiz öncesinde veri seti üzerinde eksik veriler doldurulmuş, gürültü minimize edilmiş ve ölçeklendirme işlemleri tamamlanmıştır. Model eğitimi sürecinde hiperparametre optimizasyonu yapılmış, farklı epoch değerleri, öğrenme oranları ve katman yapılarının performansları karşılaştırılarak en iyi parametre kombinasyonu seçilmiştir. Nihai model ile elde edilen tahminler, çeşitli hata metrikleri ve değerlendirme kriterleri kullanılarak detaylı biçimde incelenmiş ve modelin performansı niceliksel olarak değerlendirilmiştir. Şekil 4.112.’de, LSTM modelinin BIST100 endeksi için oluşturduğu tahmin sonuçları grafik olarak sunulmaktadır.



Şekil 4.112. LSTM BIST100 Endeks Tahmin Grafiği


Şekil 4.112. incelendiğinde gerçek değerler ile model tahminleri arasında önemli bir uyum olduğu görülmektedir. Bu durum, modelin endeks hareketlerini başarıyla öğrendiğini ve gelecekteki değerleri yüksek doğrulukta tahmin edebildiğini ortaya koymaktadır. Test aşamasında modelin, daha önce karşılaşmadığı verilerde genel eğilimleri, belirgin dalgalanmaları ve uzun vadeli trendleri etkili bir şekilde izlediği görülmüştür. Eğitim ve test sonuçlarının birbirine yakın olması, modelin overfitting sorunu yaşamadığını ve güçlü bir genelleme kapasitesine sahip olduğunu kanıtlamaktadır. Ayrıca, dar bir hata bandı ile sonuçlanan tahminler, modelin yüksek doğrulukta performans sergilediğini göstermektedir. Tahmin hatalarının daha detaylı incelenmesi için Şekil 4.113.' te yer almaktadır.



Şekil 4.113. Artıkların Histogram Grafiği

Şekil 4.113.' te LSTM modelinin tahmin hatalarının dağılımı analiz edilmiştir. İnceleme sonucunda, hata değerlerinin yaklaşık olarak normal dağılım özelliği gösterdiği ve dağılımın merkezinin 0 etrafında yoğunlaştığı tespit edilmiştir. Bu, modelin ortalama

hatasının düşük düzeyde kaldığını işaret etmektedir. Ayrıca, hataların pozitif ve negatif yönde homojen bir şekilde dağıldığı görülmüştür. Bu durum, modelin tahminlerinde belirli bir yöne kayma olmadığını ve hataların rastgele olduğunu doğrulamaktadır. Elde edilen sonuçlar, modelin istikrarlı bir performans sergilediğini ortaya koymaktadır. Modelin eğitim sürecine ilişkin performans değerlendirmesi ise Şekil 4.114.' te sunulan kayıp fonksiyonu grafiği üzerinden detaylandırılmıştır.



Şekil 4.114. Loss Fonksiyon Grafiği

Şekil 4.114.' te yer alan loss fonksiyonu grafiği, LSTM modelinin öğrenme dinamiklerini ve performansını ortaya koymaktadır. Grafikte, eğitim sürecinin başlangıcında kayıp değerlerinde belirgin bir düşüş tespit edilmiştir. Bu durum, modelin verideki temel örüntüleri hızlı bir şekilde yakaladığını göstermektedir. Süreç ilerledikçe kayıp değerleri, sifıra yakın bir seviyeye yakınsayarak istikrarlı bir seyir izlemiş ve modelin sürekli iyileştiğini doğrulamıştır. Eğitim ile doğrulama loss değerlerinin birbirine yakın olması, modelin hem eğitim verilerini başarıyla öğrendiğini hem de daha önce görmediği test verilerinde etkili bir genelleme yapabildiğini işaret etmektedir. Bu bulgular, modelin aşırı öğrenme sorunu yaşamadığını ve yeni verilere uyum sağlama yeteneğine sahip olduğunu göstermektedir. Modelin performansının daha kapsamlı değerlendirilmesi için hesaplanan başarı metrikleri ise Tablo 4.62.' de detaylandırılmıştır.

Tablo 4.62. LSTM BIST100 Tahmini Başarı Metrikleri

MSE	RMSE	MAE	MAPE
408.9376	20.1573	13.1175	1.701

Tablo 4.62.' de yer alan başarı metrikleri incelendiğinde, RMSE değeri 20.15 olarak belirlenmiştir. Bu sonuç, model tahminlerinin gerçek değerlerden ortalama olarak ± 20.5 birimlik bir sapma gösterdiğini ve genel hata büyüklüğünün kabul edilebilir düzeyde kaldığını ortaya koymaktadır. Benzer şekilde, MAE değeri 13.11 olarak hesaplanmıştır. Bu, modelin tahminlerinin gerçek değerlerle arasında ortalama ± 13.11 birimlik bir fark olduğunu göstermektedir. Ortalama yüzdesel hata ölçütü olan MAPE ise %1.70 olarak tespit edilmiştir. Bu oran, modelin tahminlerinin gerçek değerlerden ortalama olarak yalnızca %1.70' lik bir sapma içerdiğini ve yüzde bazında oldukça hassas sonuçlar ürettiğini kanıtlamaktadır. Elde edilen bulgular, modelin hem mutlak hatalarda düşük değerler sergilediğini hem de yüzde bazında yüksek doğrulukta performans gösterdiğini doğrulayarak, verideki temel örüntüleri başarıyla yakaladığını işaret etmektedir.

4.4.3. LSTM Modeli İle Gerçekleştirilen Tahminlerin Genel Değerlendirilmesi

Çalışmanın bu aşamasında, derin öğrenme yöntemlerinden LSTM modeli kullanılarak gerçekleştirilen G7 ve E7 ülkelerine ait seçilmiş borsa endekslerinin tahmin performansları üzerine genel bir değerlendirmeye yer verilmiştir. Değerlendirme sürecinde, ülkeler arası farklı ekonomik büyüklüklerden kaynaklanan ölçek farklılıkları, hata analizinde yanıltıcı sonuçlara yol açabilmektedir. Bu tür durumlarda, hataların mutlak değerler yerine yüzdesel olarak ifade edilmesi daha doğru bir yaklaşım sunacaktır. Bundan dolayı, modelin tahmin performansının daha tutarlı ve güvenilir bir şekilde karşılaştırılabilmesi için MAPE değerleri esas alınarak ülke borsa endeksleri bazında model performansları değerlendirilmiştir. MAPE değeri, tahminlerin gerçek değerlere ne kadar yakın olduğunu yüzde bazında ifade eden bir metrik olup, düşük MAPE değeri, tahminlerin gerçek değerlere daha yakın olduğunu göstermektedir. Bu kapsamda, her bir ülke endeksi için hesaplanan MAPE değerleri detaylı bir şekilde analiz edilmiş ve elde edilen sonuçlar Tablo 4.63.' te sunulmuştur.

Tablo 4.63. Seçilmiş Borsa Endeksleri ve MAPE Değerleri

G7 Ülke Borsa Endeksleri	MAPE	E7 Ülke Borsa Endeksleri	MAPE
S&P 500	1.20	SHANGHAI COMPOSITE	1.37
S&P/TSX	1.30	NIFTY50	1.50
DAX	1.42	BOVESPA	1.66
CAC40	1.31	S&P/BMV IPC	1.37
FTSE100	1.11	IDX COMPOSITE	1.37
FTSEMIB	1.54	MOEX	1.63
NIKKEI225	1.48	BIST100	1.70

Tablo 4.63. incelendiğinde tüm borsa endeksleri için hesaplanan MAPE değerlerinin düşük olduğu ve %10'nun altında kaldığı görülmektedir. Bu da modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ifade etmektedir. G7 ülkeleri için hesaplanan MAPE değerleri %1.11 ile %1.54 arasında değişmektedir. Genellikle G7 ülkelerine ait endekslerde ortalama MAPE değerleri daha düşük olup, modelin bu ülkelerde daha başarılı tahminler yaptığı söylenebilir. E7 ülkeleri için hesaplanan MAPE değerleri %1.37 ile %1.70 arasında değişmektedir. E7 ülkeleri için genel olarak G7 ülkelerine kıyasla görece daha yüksek MAPE değerleri gözlemlenmiştir. Bu da tahmin performansının az da olsa bu ülkelerde düştüğü gözlemlenmiştir. G7 ülkeleri için modelin tahmin doğruluğu daha yüksek, yani hata oranları görece daha düşük seviyelerde seyretmektedir. E7 ülkelerinde hata oranlarının biraz daha yüksek olması, bu ülkelerin finansal piyasalarındaki daha yüksek oynaklık, piyasa dinamiklerindeki farklılıklar veya veri setindeki özelliklerden kaynaklanıyor olabilir. Özellikle BIST100 ve BOVESPA gibi gelişmekte olan ülkelerin borsa endekslerinde tahmin hatalarının görece yüksek olması, bu piyasalardaki belirsizliklerin ve ani fiyat hareketlerinin model performansına olan etkisini göstermektedir. Bununla birlikte, genel hata oranları göz önünde bulundurulduğunda modelin tüm piyasalar için yüksek seviyede bir tahmin başarısı sunduğu söylenebilir.

4.5 ARIMA VE LSTM MODELİ İLE YAPILAN TAHMİNLERİNİN

KARŞILAŞTIRILMASI

Çalışmanın bu kısmında, Derin Öğrenme yöntemlerinden LSTM Modeli ile Geleneksel İstatistikî Yöntemlerden ARIMA modelinin G7 ve E7 ülkelerine ait seçilmiş borsa endeksleri için gerçekleştirdikleri tahmin performansları karşılaştırmalı olarak değerlendirilecektir. Her iki model için 01.09.2006-15.02.2022 dönemine ait günlük verilerden yararlanılmıştır. Yine her iki model için de aynı teknik göstergeler ile aynı makroekonomik göstergeler birlikte bağımsız değişken olarak kullanılmıştır. Bu modellerin tahmin performansları karşılaştırılırken ülkeler arası ölçek farklılıklarından dolayı değerlendirme ölçütü olarak ortalama mutlak yüzde hatayı temsil eden MAPE değeri esas alınmıştır. Bu istatistikî tahmin kriteri tahmin edilen değer ile gerçekleşen değer arasındaki farkın ölçülmesinde kullanılmaktadır. Bu kriterin mümkün olduğunca küçük olması tahmin modelinin performansını daha başarılı kılmaktadır. Daha önceki kısımlarda belirtilen G7 ve E7 ülkelerinin borsa endeksleri için ARIMA ve LSTM modelleri kullanılarak hesaplanan MAPE performansları Tablo 4.64.' te sunulmuştur.

Tablo 4.64. LSTM ve ARIMA Modellerinin MAPE Performansları

LSTM MODELİ		ARIMA MODELİ	
G7 Ülke Borsa Endeksleri	MAPE	G7 Ülke Borsa Endeksleri	MAPE
S&P 500	1.20	S&P 500 ARIMA (2,1,2)	4.812
S&P/TSX COMPOSITE	1.30	S&P/TSX COMPOSITE (2,1,0)	3.926
DAX	1.42	DAX ARIMA (1,1,5)	5.599
CAC40	1.31	CAC40 ARIMA (0,1,1)	5.792
FTSE100	1.11	FTSE100 ARIMA (3,1,5)	7.251
FTSEMIB	1.54	FTSE MIB ARIMA (0,1,1)	4.354
NIKKEI225	1.48	NIKKEI 225 ARIMA (3,1,4)	6.075
E7 Ülke Borsa Endeksleri	MAPE	E7 Ülke Borsa Endeksleri	MAPE
SHANGHAI COMPOSITE	1.37	SHANGHAI COMPOSITE (5,0,4)	1.071
NIFTY50	1.50	NIFTY 50 ARIMA (2,1,5)	3.727
BOVESPA	1.66	BOVESPA ARIMA (2,1,2)	5.838
S&P/BMV IPC	1.37	S&P/BMV IPC ARIMA (2,1,2)	4.368
IDX COMPOSITE	1.37	IDX COMPOSITE ARIMA (4,1,4)	7.092
MOEX	1.63	MOEX ARIMA (1,1,3)	1.897
BIST100	1.70	BIST100 ARIMA (1,1,3)	5.198

Buna göre ilgili tablolardaki MAPE deęerleri kıyaslandığında, LSTM modelinin hem G7 hem de E7 ülkelerinde ARIMA modeline kıyasla daha düşük hata oranları sunduęu ve özellikle %2'nin altında kaldığı görölmektedir. ARIMA modelinde ise bazı ülkeler için makul hata seviyeleri elde edilmiş olsa da, genel olarak tahmin hatalarının LSTM modeline kıyasla daha yüksek olduęu tespit edilmiştir.

Özellikle G7 ülkeleri için LSTM modelinin ARIMA modeline kıyasla daha düşük hata oranları ürettięi gözlemlenmektedir. Örneęin, S&P 500 endeksi için LSTM modeli için 1.20 MAPE deęeri hesaplanırken, ARIMA modeli için bu deęer 4.81 olarak belirlenmiştir. Benzer şekilde, CAC40 endeksi için LSTM modeli 1.31 MAPE deęeri üretirken, ARIMA modeli 5.79 MAPE deęeri hesaplamıştır. Bu durum, LSTM modelinin karmaşık örüntüleri daha iyi öğrenebildiğini ve zaman serisindeki doğrusal olmayan yapıları daha başarılı bir şekilde yakalayabildiğini göstermektedir.

E7 ülkeleri için de benzer bir durum gözlemlenmekle birlikte, Shanghai Composite endeksi tahmininde ARIMA modeli, 1.071 MAPE deęeri ile beklenenden daha düşük bir hata oranına sahip olduęu görölmektedir. Bu durum, ilgili veri setinde logaritmik dönüşüm sonrasında duraęanlığın saęlanması ARIMA modelinin performansını artırdığına işaret edebilir. Dięer bir ifadeyle verinin işleme yöntemi ve duraęanlık saęlama süreçlerinin model performansı üzerindeki etkisini göstermektedir. Ancak, dięer E7 ülke endeksleri için LSTM modelinin hata oranlarının daha düşük olduęu görölmektedir. Örneęin, BIST100 endeksi için LSTM modeli 1.70 MAPE deęeri üretirken, ARIMA modeli için bu deęer 5.19 olarak hesaplanmıştır. Yine benzer şekilde BOVESPA endeksi için LSTM modeli MAPE deęeri 1.66 iken ARIMA modeli için bu deęer 5.83 olarak hesaplanmıştır.

Tüm bu bulgular göz önüne alındığında LSTM modelinin G7 ve E7 ülkelerinin borsa endeksleri için daha iyi bir tahmin performansı sunduęu ve özellikle karmaşık finansal zaman serileri için daha uygun bir modelleme teknięi olduęu sonucuna varılabilir. Ayrıca her iki model için de elde edilen MAPE deęerleri, modellerin yüksek doğrulukla tahmin yaptığını göstermektedir.

SONUÇ VE ÖNERİLER

Finansal piyasaların karmaşıklığı ve dinamik yapısı yatırımcılar, finans kurumları ve politika yapıcılar için güvenilir tahmin modellerinin geliştirilmesini zorunlu kılmaktadır. Özellikle borsa endeksleri gibi geniş çapta takip edilen finansal göstergelerin doğru tahmin edilmesi yatırım stratejilerinin oluşturulması, risk yönetimi ve finansal istikrar açısından büyük bir önem taşımaktadır. Borsa endeksleri finansal piyasalardaki genel eğilimi ve yatırımcı duyarlılığını yansıtan temel göstergelerden biridir. Ancak borsa endeks tahmini, fiyat hareketleri, ekonomik veriler, jeopolitik gelişmeler, yatırımcı psikolojisi, küresel piyasa etkileşimleri gibi birçok faktörden etkilenmesi nedeniyle oldukça zordur. Geleneksel tahmin yöntemleri verilerin doğrusal yapılarını analiz ederken başarılı olsa da finansal piyasaların doğasındaki yüksek volatilité ve karmaşıklık daha gelişmiş yöntemlere duyulan ihtiyacı artırmıştır. Bu doğrultuda bu çalışmanın amacı gelişmiş ülke borsalarını temsil eden G7 ve gelişmekte olan ülke borsalarını temsil eden E7 ülkelerine ait seçilmiş borsa endeksinin tahminini geleneksel istatistik, yöntemlerden ARIMA, derin öğrenme yöntemlerinden ise LSTM modeli ile gerçekleştirmek ve ilgili modellerin tahmin performanslarını her bir ülke için ayrı karşılaştırmaktır. Bu kapsamda ilgili ülkelerin borsa endekslerine ait kapanış fiyatları bağımlı değişken olarak kullanılmış olup, her bir ülke için aynı teknik göstergeler (MA, WMA, Momentum, Stokastik K, Stokastik D, RSI, MACD, Williams' R, A/D ve CCI) ve aynı makro ekonomik göstergeler (altın ons fiyatı, Brent petrol fiyatı ve DXY) bağımsız değişken olarak kullanılmıştır. Yine her bir ülke bazında 01.09.2006 – 15.02.2022 dönemine ait günlük verilerden yararlanılmıştır. İlgili verilerin %80' i eğitim %20' si ise test verisi olarak kullanılmıştır. Çalışma kapsamında tüm veriler investing.com ve yahoo.finance.com sitesinden temin edilmiş olup analizler Python programlama dili versiyon 3.12.1. kullanılarak gerçekleştirilmiştir.

Çalışma kapsamında G7 ve E7 ülkelerinin alınmasındaki amaç hem gelişmiş hem de gelişmekte olan piyasalar arası farkları gözlemleme ve tahmin modellerinin bu farklı koşullar altında nasıl performans gösterdiğini ortaya koymaktır. Bu sayede hem akademik bir perspektif sunmak hem yatırımcılar, politika yapıcılar ve portföy yöneticileri içinde önemli çıkarım sağlamaktır. G7 ülkeleri üzerinde çalışmak, geleneksel ve derin öğrenme

tabanlı tahmin modellerinin istikrarlı ve yüksek hacimli piyasalardaki performansını test etmek açısından önem taşırken, E7 ülkeleri üzerinde çalışmak ise daha oynak yapıları, ekonomik büyüme dinamikleri, politik belirsizlikler ve dış etkenlere duyarlılıkları nedeniyle G7 ülkelerine kıyasla farklılık göstermektedir. Bu farklı dinamikler, model performansı üzerindeki etkileri gözlemlenmek açısından büyük önem taşımaktadır. Çalışmada hem teknik hem de makro ekonomik değişkenler kullanılırken, geliştirilen tahmin modellerinin hem piyasa içi hem de piyasa dışı faktörleri dikkate alarak modellerin tahmin gücünün değerlendirilmesi amaçlanmıştır. Bu doğrultuda literatür genel kabul görmüş 10 teknik gösterge ve modelin tahmin performansını etkileyen 3 makro ekonomik gösterge kullanılmıştır. Teknik göstergeler fiyat hareketleri ve işlem hacmi gibi piyasa verilerine dayalı analizler sunarak fiyat hareketlerini tahmin etmeye yardımcı olmaktadır. Makro ekonomik göstergeler ise küresel ekonomik koşulların piyasa üzerindeki etkilerini analiz etmeye katkı sağlamaktadır.

Ülke bazında gerçekleştirilen analizlerde ARIMA modelleri için (p,d,q) parametrelerinin belirlenmesi ve optimize edilmesi gerekmektedir, LSTM modellerinde katman sayısı, nöron sayısı, epoch sayısı ve öğrenme katsayısı gibi hiperparametrelerin seçimi ve ayarlanması sağlanmıştır. Her bir ülke için tahmin performansları, MSE, MAE, RMSE ve MAPE gibi hata metrikleri kullanılarak değerlendirilmiş ve modellerin doğruluk düzeyi ayrı ayrı analiz edilmiştir. Ülkeler genelinde gerçekleştirilen tahmin analizlerinin ardından, ölçek farklılıklarının neden olduğu hata oranlarındaki değişkenliği minimize etmek ve modellerin karşılaştırılabilirliğini artırmak amacıyla, performans değerlendirmesi MAPE değerleri üzerinden gerçekleştirilmiştir.

Genel olarak elde edilen bulgular, derin öğrenme tabanlı modellerin geleneksel zaman serisi yöntemlerine kıyasla daha başarılı tahmin sonuçları üretebildiğini göstermektedir. LSTM modeli, karmaşık veri yapılarını işleme ve uzun vadeli bağımlılıkları öğrenme kapasitesi sayesinde hem G7 hem de E7 ülke borsa endekslerinde daha düşük hata oranlarıyla tahmin yapabilmektedir. Modelin, farklı piyasalara uyum sağlayarak geniş bir veri setinde başarılı tahmin performansı sergilemesi, bu yöntemin finansal zaman serilerinde etkin bir araç olarak kullanılabileceğini ortaya koymaktadır. Özellikle volatilitenin yüksek olduğu piyasalarda da LSTM modelinin ARIMA modeline göre daha kararlı tahminler üretebildiği gözlemlenmiştir. Elde edilen sonuçlar

literatürdeki (Namin ve Namin 2018; Girsang vd. 2020; Güleriyüz vd. 2021; Zhu ve He 2022; Vuong vd. 2022; Albayrak ve Saran 2023; Bathla vd. 2023; Erden 2023b; Panchal vd. 2024; Wu vd. 2023; Aydın vd. 2024) çalışmaları destekler niteliktedir.

Buna karşılık, geleneksel ARIMA modeli, belirli piyasalarda rekabetçi bir tahmin performansı gösterse de özellikle volatilitenin yüksek olduğu endekslerde hata oranlarının görece daha yüksek olduğu, piyasa dalgalanmalarını ve doğrusal olmayan ilişkileri yakalama konusunda sınırlılıklar sergilediği gözlemlenmiştir. Ancak dikkat çekici bir şekilde Çin ve Rusya borsalarında istisnai bir performans göstermiştir. Bu sonucun söz konusu piyasaların kendine özgü yapısal özellikleri, düzenleyici yapısı ve merkezi otoritelerin piyasa istikrarını sağlamaya yönelik politika araçlarıyla ilişkili olduğu düşünülmektedir. ARIMA modelinin LSTM modeline rekabetçi tahminler ürettiği noktasında elde edilen sonuçlar literatürdeki (Ashok ve Prathibhamol 2021; Dadhich vd. 2021; Mahadik vd. 2021; Dong 2022; Mashadihasanli 2022; Xiao vd. 2022; Ahammad vd. 2024) çalışmaları destekler niteliktedir.

Bu çalışma, piyasa tahminlerinde tek bir yöntemle bağımlı kalınmaması gerektiğini ve model seçiminde piyasanın yapısal özelliklerinin dikkate alınmasının önemini vurgulamaktadır. Derin öğrenme yöntemlerinin piyasa tahmininde güçlü bir alternatif sunduğu görülse de geleneksel zaman serisi yöntemlerinin belirli koşullarda geçerliliğini koruduğu anlaşılmaktadır. Finansal tahmin modellerinin başarısı, kullanılan verinin niteliği ve modelin piyasa dinamiklerine ne kadar uyum sağladığı ile doğrudan ilişkilidir. Bu bulgular, yatırımcılar, piyasa analistleri ve politika yapımcılar için önemli çıkarımlar sunmaktadır. Özellikle piyasa tahminlerinde doğruluğun artırılması için farklı modelleme yaklaşımlarının bir arada kullanılması, değişken setinin genişletilmesi ve piyasa koşullarına uygun model seçimlerinin yapılması gerekliliği ortaya çıkmaktadır.

Çalışmanın sınırlılıkları;

Bu çalışma, 2006-2022 yılları arasında gelişmiş ve gelişmekte olan 14 farklı ülkenin seçilmiş borsa endekslerini tahmin etmeye odaklanmıştır. Ancak, bu dönemde yaşanan ekonomik krizler, pandemi, savaşlar ve olağanüstü durumlar model performansı üzerinde olumsuz etki yaratmaktadır.

Ülkeler arasında piyasa yapısı, düzenleyici çerçeve, likidite koşulları ve yatırımcı davranışları açısından farklılıklar bulunmaktadır. Bu durum, modelin her ülke için aynı başarı düzeyinde çalışmasını zorlaştırmaktadır.

Çalışmada kullanılan göstergeler belirli teknik ve makroekonomik değişkenlerle sınırlıdır. Bununla birlikte, politika değişiklikleri, küresel krizler ve jeopolitik riskler gibi dışsal faktörler, tahmin doğruluğu üzerinde etkili olabilmektedir. Bunun yanı sıra, kullanılan veri setinin büyüklüğü, özellikle derin öğrenme modellerinin işlem süresini artırarak hesaplama maliyetlerini yükseltmektedir.

Gelecekte yapılacak çalışmalar, farklı modelleme tekniklerini birleştiren hibrit yaklaşımlar veya alternatif veri kaynaklarını içeren genişletilmiş modellerle tahmin performansını daha da iyileştirebilir. Olağanüstü durumlardaki gürültülerin etkisini azaltmak için veri setine filtreler uygulanmak suretiyle modellerin performansı tekrar değerlendirilebilir.

KAYNAKÇA

- Abdulhafidh Derhem Dael, Fares. 2022. “Doğru Yatırım Kararları İçin Yapay Zeka Tekniklerini Kullanarak Borsa Tahmininin Kapsamlı Analizi”. Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü.
- Abdulrahman, U. F. I., ve B. Hayfron-Acquah. 2020. “A hybrid arima-LSTM model for stock price prediction.” *International Journal of Computer Engineering and Information Technology* 12(8):48-51.
- Achelis, Steven B. 2001. *Technical Analysis from A to Z*. McGraw Hill New York.
- Adebayo, Fatai Adewole, Ramysamy Sivasamy, ve Dahud Kehinde Shangodoyin. 2014. “Forecasting stock market series with ARIMA model”. *Journal of Statistical and Econometric Methods* 3(3):65-77.
- Ahammad, I., W. A. Sarkar, F. A. Meem, J. Ferdus, M. K. Ahmed, M. R. Rahman, Rabeya Sultana, ve M. S. Islam. 2024. “Advancing Stock Market Predictions with Time Series Analysis Including LSTM and ARIMA.” *Cloud Computing and Data Science* 226-41.
- Akay, Ali. 2009. “Yapay Sinir Ağları ile İMKB-100 Endeksi Gelecek Değer Öngörüsü”. Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, Trabzon.
- Akbulut, Serap, ve ADEM Kemal. 2023. “Derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak gelişmekte olan ülkelerin finansal enstrümanlarının etkileşimi ile Bist 100 tahmini”. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi* 12(1):1-1.
- Akcan, Ahmet, ve Cem Kartal. 2011. “İMKB Sigorta Endeksini Oluşturan Sirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini”. *Muhasebe ve Finansman Dergisi* (51):27-40.
- Aker, Yusuf. 2022. “Analysis of Price Volatility in BIST 100 Index With Time Series: Comparison of Fbprophet and LSTM Model”. *European Journal of Science and Technology*. doi:10.31590/ejosat.1066722.

- Albayrak, Emre, ve Nurdan Saran. 2023. "İstatistiksel ve Derin Öğrenme Modellerini Kullanarak Hisse Senedi Fiyat Tahmini". *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi* 16(2):161-69. doi:10.54525/tbbmd.1031017.
- Ali, Amjad, Yuxiang Wang, Wuhua Li, ve Xiangning He. 2015. "Implementation of simple moving voltage average technique with direct control incremental conductance method to optimize the efficiency of DC microgrid". Ss. 1-5 içinde *2015 international conference on emerging technologies (ICET)*. IEEE.
- Alpaydın, Ethem. 2010. *Introduction to Machine Learning*,. 2. bs. Londra: The MIT Press.
- Altıntop, Muhammet Yasir. 2016. "Dalgacık Dönüşümü Ve Destek Vektör Makineleri İle Tahmin: Bist Üzerine Bir Uygulama". Tez, Uşak Üniversitesi, Sosyal Bilimler Enstitüsü.
- Amenc, Noel, ve Veronique Le Sourd. 2005. *Portfolio theory and performance analysis*. John Wiley & Sons.
- An overview of London Stock Exchange markets - LSE. 2020. <https://www.londonstockexchange.com/personal-investing/>.
- Anbalagan, Thirunavukarasu, ve S. Uma Maheswari. 2015. "Classification and prediction of stock market index based on fuzzy metagraph". *Procedia Computer Science* 47:214-21.
- Anish, C. M., ve Babita Majhi. 2016. "Hybrid nonlinear adaptive scheme for stock market prediction using feedback FLANN and factor analysis". *Journal of the Korean Statistical Society* 45(1):64-76.
- Apak, Sudi. 1995. *Sermaye piyasaları ve borsa*. Bilim ve Teknik Yayınevi.
- Appel, Gerald. 2003. "Become your own technical analyst". *The Journal of Wealth Management* 6(1):27-36.
- Arsllankaya, Seher, ve Şevval Toprak. 2021. "Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini". *International Journal of Engineering Research and Development* 13(1):178-92.

- ArunKumar, K. E., Dinesh V. Kalaga, Ch Mohan Sai Kumar, Govinda Chilkoor, Masahiro Kawaji, ve Timothy M. Brenza. 2021. "Forecasting the dynamics of cumulative COVID-19 cases (confirmed, recovered and deaths) for top-16 countries using statistical machine learning models: Auto-Regressive Integrated Moving Average (ARIMA) and Seasonal Auto-Regressive Integrated Moving Average (SARIMA)". *Applied soft computing* 103:107161.
- Asefisaray, Benham. 2018. "Uçtan-Uca Konuşma Tanıma Modeli: Türkçe'deki Deneyler". Gazi Üniv.Fen Bilimleri Ens., Ankara.
- Ashok, A., ve C. P. Prathibhamol. 2021. "Improved analysis of stock market prediction:(ARIMA-LSTM-SMP)". Ss. 1-5.
- Aydın, Yıldız, Gizem Varol, Eyyüb Ensari Gökdeniz, ve Hakan Manus. 2024. "Hisse Senedi Fiyatlarının LSTM ve ARIMA Modelleri Kullanılarak Tahmin Edilmesi". *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 36(2):903-11.
- Aygören, Hakan, Hakan Sarıtaş, ve Tuncay Moralı. 2012. "İMKB 100 endeksinin yapay sinir ağları ve newton nümerik arama modelleri ile tahmini". *Uluslararası Alanya İşletme Fakültesi Dergisi* 4(1):73-88.
- Bahrammirzaee, Arash. 2010. "A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems". *Neural Computing and Applications* 19(8):1165-95.
- Bal, Miray. 2014. "Pay Piyasasında Kapanış Seansı ve Borsa İstanbul'da Fiyat Oluşumu Üzerine Etkilerinin Analizi". PhD Thesis, Yüksek Lisans Tezi, Marmara Üniversitesi, Bankacılık ve Sigortacılık
- Ball, Joshua. 2018."The Emerging Seven Countries Will Hold Increasing Levels of Global Economic Power by 2050". <https://globalsecurityreview.com/will-global-economic-order-2050-look-like/>.
- Banerjee, Debadrita. 2014. "Forecasting of Indian stock market using time-series ARIMA model". Ss. 131-35 içinde *2014 2nd international conference on business and information management (ICBIM)*. IEEE.
- Bank of America. 2024. <https://www.bankofamerica.com/>.

- Bao, Wei, Jun Yue, ve Yulei Rao. 2017. “A deep learning framework for financial time series using stacked autoencoders and long-short term memory”. *PloS one* 12(7):e0180944.
- Bathla, Gourav, Rinkle Rani, ve Himanshu Aggarwal. 2023. “Stocks of year 2020: prediction of high variations in stock prices using LSTM”. *Multimedia Tools and Applications* 82(7):9727-43.
- Beniwal, Mohit, Archana Singh, ve Nand Kumar. 2024. “Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices”. *Engineering Applications of Artificial Intelligence* 129:107617.
- Berglas, A. 2015. *When Computers Can Think: The Artificial Intelligence Singularity. Createspaces.*
- Berk, Niyazi. 2007. *Finansal Yönetim, Türkmen Kitabevi, İstanbul*. C. 21.
- Betterment. 2024. <https://www.betterment.com>.
- Bhandari, Hum Nath, Binod Rimal, Nawa Raj Pokhrel, Ramchandra Rimal, Keshab R. Dahal, ve Rajendra K. C. Khatri. 2022. “Predicting stock market index using LSTM”. *Machine Learning with Applications* 9:100320. doi:10.1016/j.mlwa.2022.100320.
- BIST. 2024. “Borsa İstanbul A.Ş.” <https://www.borsaistanbul.com/tr/sayfa/27/tarihsel-gelismeler>.
- BİSTİstatistik. 2024. “Market Statistics - Focus | The World Federation of Exchanges”. <https://focus.world-exchanges.org/issue/august-2024/market-statistics>.
- Bolak, Mehmet. 1994. *Sermaye piyasası: menkul kıymetler ve portföy analizi*. Beta basım yayım.
- Bovespa Endeksi Bileşenler – BMF BOVESPA: IBOV Hisse Senetleri. 2024. <https://tr.tradingview.com/symbols/BMF-BOVESPA-IBOV/components/>.
- Box, George EP, Gwilym M. Jenkins, Gregory C. Reinsel, ve Greta M. Ljung. 2015. *Time series analysis: forecasting and control*. John Wiley & Sons.
- Bozkurt, H. 2007. *Zaman Serileri Analizi*. 1. Ekin Kitabevi: Bursa.

- Bramer, M. 2007. *Principles of data mining*. 3. bs. England: Springer-Verlag London Ltd.
- Brazil Archives. 2023. <https://www.focus-economics.com/countries/brazil/>.
- Bugnion, P., P. R. Nicolas, ve A. Kozlov. 2017. *Scala: applied machine learning*. Packt Publishing Ltd.
- Bulat, Adrian, Jing Yang, ve Georgios Tzimiropoulos. 2018. “To learn image super-resolution, use a gan to learn how to do image degradation first”. Ss. 185-200 içinde *Proceedings of the European conference on computer vision (ECCV)*.
- Buscema, Massimo. 2002. “A Brief Overview And Introduction To Artificial Neural Networks”. *Substance Use & Misuse* 37(8-10):1093-1148.
- Business News Today: Read Latest Business news, India Business News Live, Share Market & Economy News | The Economic Times. t.y. <https://economictimes.indiatimes.com/>.
- Canbaş, Serpil, ve Hatice Doğukanlı. 1997. *Finansal Pazarlar: Finansal Kurumlar ve Sermaye Pazarı Analizleri*. İstanbul: Beta Yayınevi.
- Ceron, Andrea, Luigi Curini, ve Stefano M. Iacus. 2015. “Using Sentiment Analysis to Monitor Electoral Campaigns: Method Matters—Evidence From the United States and Italy”. *Social Science Computer Review* 33(1):3-20. doi:10.1177/0894439314521983.
- Ceylan, Ali, ve Turhan Korkmaz. 2017. *Sermaye Piyasası ve Menkul Değer Analizi*. İstanbul: Ekin Kitapevi.
- Chen, James. 2022. “Shanghai Stock Exchange: What It Is, How It Works”. <https://www.investopedia.com/terms/s/shanghai-stock-exchange.asp>.
- Chen, James. 2024. “What Is the National Stock Exchange of India Limited (NSE)?” https://www.investopedia.com/terms/n/national_stock_exchange.asp.
- Chen, Yuzhou, Junji Wu, ve Hui Bu. 2018. “Stock market embedding and prediction: A deep learning method”. Ss. 1-6 içinde *2018 15th International Conference on Service Systems and Service Management (ICSSSM)*. IEEE.
- Cho, Kyunghyun, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, ve Yoshua Bengio. 2014. “Learning Phrase Representations

Using RNN Encoder-Decoder for Statistical Machine Translation”. *arXiv:1406.1078*

Chong, Terence Tai-Leung, ve Wing-Kam Ng. 2008. “Technical Analysis and the London Stock Exchange: Testing the MACD and RSI Rules Using the FT30”. *Applied Economics Letters* 15(14):1111-14. doi:10.1080/13504850600993598.

Ciresan, Dan, Alessandro Giusti, Luca Gambardella, ve Jürgen Schmidhuber. 2012. “Deep neural networks segment neuronal membranes in electron microscopy images”. *Advances in neural information processing systems* 25:2843-51.

Clarke, B., E. Fokoue, ve H. H. Zhang. 2009. *Principles and Theory for Data Mining and Machine Learning*,. Springer.

Coen, Anderson. 2020. *Machine Learning for Beginners: The... Book by Anderson Coen*.

Colby, Robert W., ve Thomas A. Meyers. 1988. “The encyclopedia of technical market indicators”. (No Title).

Copeland, Michael. 2016. “What’s the Difference Between Artificial Intelligence, Machine Learning and Deep Learning?” <https://blogs.nvidia.com/blog/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>.

Çalışkan, Muhammed Mustafa Tuncer, ve Devran Deniz. 2015. “Yapay sinir ağlarıyla hisse senedi fiyatları ve yönlerinin tahmini”. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 31:177-94.

Çepni, Elif. 2015. “Ekonomik ve finansal göstergeler rehberi”. *Seçkin Yayıncılık, Ankara*.

Çetin, Dilşad Tülgen, ve Sedat Metlek. 2021. “Türkiye’deki İslami Hisse Senedi Endeksinin, Endeks Tabanlı Öznitelikler Kullanılarak Derin Öğrenme Yöntemi ile Tahmini”. *Acta Infologica* 5(2):287-98.

Çevik, Osman. 1999. “Zaman serileri analizinde Box-Jenkins yöntemi ve turizm verileri üzerine bir uygulama”. Yayımlanmamış Doktora Tezi, Kırıkkale Üniversitesi, SBE, Kırıkkale.

Çınar, Mehmet, ve Mustafa Sevüktekin. 2017. “Ekonometrik zaman serileri analizi: Eviews uygulamalı”. *Dora Basım Yayın Dağıtım Ltd. Şti., Gözden Geçirilmiş 5*.

- Çınaroğlu, Eda, ve Tunahan Avcı. 2020. “THY hisse senedi değerinin yapay sinir ağları ile tahmini”. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 34(1):1-19.
- Çulha, Emre. 2019. “Faiz oranları, bist-100 endeksi ve bist sektör endeksleri arasındaki ilişki”. Master’s Thesis, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü.
- Dadhich, Manish, Manvinder Singh Pahwa, Vipin Jain, ve Ruchi Doshi. 2021. “Predictive Models for Stock Market Index Using Stochastic Time Series ARIMA Modeling in Emerging Economy”. Ss. 281-90 içinde *Advances in Mechanical Engineering, Lecture Notes in Mechanical Engineering*, editör G. Manik, S. Kalia, S. K. Sahoo, T. K. Sharma, ve O. P. Verma. Singapore: Springer Singapore.
- Dağlı, Hüseyin. 2009. *Sermaye piyasası ve portföy analizi*. 1. bs. Trabzon: Derya Kitabevi.
- Dalkıran, İlker, ve Mehmet Ozan. 2022. “Predicting Of Stock Market Using Deep Learning Techniques”. *European Journal of Science and Technology*. doi:10.31590/ejosat.1145949.
- Dash, Rajashree, Sidharth Samal, Rasmita Rautray, ve Rasmita Dash. 2019. “A TOPSIS Approach of Ranking Classifiers for Stock Index Price Movement Prediction”. Ss. 665-74 içinde *Soft Computing in Data Analytics*. C. 758, *Advances in Intelligent Systems and Computing*, editör J. Nayak, A. Abraham, B. M. Krishna, G. T. Chandra Sekhar, ve A. K. Das. Singapore: Springer Singapore.
- Dayı, Faruk. 2018. “Hisse Senedi Getirilerinin Tahmininde Yapay Sinir Ağı Modeli Kullanımı: İmkb’de Bir Uygulama”. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)* 10(19):572-92.
- De Oliveira, Fagner A., Cristiane N. Nobre, ve Luis E. Zárate. 2013. “Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index—Case study of PETR4, Petrobras, Brazil”. *Expert systems with applications* 40(18):7596-7606.
- Değirmenci, Nurdan, ve Ali Akay. 2017. “Finansal verilerin ARIMA ve ARCH modelleriyle öngörüsü: Türkiye örneği”. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi* 12(3):15-36.

- Deng, Li. 2014. "A tutorial survey of architectures, algorithms, and applications for deep learning". *APSIPA transactions on Signal and Information Processing* 3:e2.
- Deutsche Börse Group - DAX. t.y. <https://deutsche-boerse.com/dbg-en/our-company/knowledge/glossary/glossary-article/DAX-242866>.
- Deutsche Börse Group - DAX welcomes ten new members. t.y. <https://deutsche-boerse.com/dbg-en/media/press-releases/DAX-welcomes-ten-new-members--2766886>.
- Dhyani, Bijesh, Manish Kumar, Poonam Verma, ve Abhishek Jain. 2020. "Stock market forecasting technique using arima model". *International Journal of Recent Technology and Engineering* 8(6):2694-97.
- Digital Capabilities. 2020. "Digital Capabilities To Advance Further". <https://www.idx.co.id/media/9969/2020.pdf>.
- Diler, Ali Ihsan. 2003. "Forecasting the direction of the ise national-100 index by neural networks backpropagation algorithm". *Istanbul Stock Exchange Review* 7(25-26):65-82.
- Dingli, Alexiei, ve Karl Sant Fournier. 2017. "Financial time series forecasting-a deep learning approach". *International Journal of Machine Learning and Computing* 7(5):118-22.
- Doğan, Bahar Burtan. 2011. "Ticaret Borsacılığının Dünyada Ve Türkiye'deki Gelişim Süreçlerine Genel Bir Bakış". *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 24(1):43-61.
- Doğan, V. 2006. "Forecasting Stock Marker Return Using Artificial Neural Networks". Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- DOĞUKANLI, Hatice, ve Serpil Canbaş. 1997. "Finansal Pazarlar: Finansal Kurumlar ve Sermaye Pazarı Analizleri". *Beta Yayınevi, İstanbul*.
- Dong, H. 2022. "Stock Price Prediction Using ARIMA and LSTM." Ss. 195-201 içinde *6th Annual International Conference on Data Science and Business Analytics*.

- Dunis, Christian L., Rafael Rosillo, David de la Fuente, ve Raúl Pino. 2013. "Forecasting IBEX-35 moves using support vector machines". *Neural Computing and Applications* 23:229-36.
- "E7" Countries To Overtake "G7" By 2050 If Trends Persist - PwC. t.y. <https://www.wealthbriefingasia.com/article.php?id=52503>.
- Edwards, Robert D., John Magee, ve WH Charles Bassetti. 2018. *Technical analysis of stock trends*. 11. bs. Boca Raton: CRC press.
- Elmas, Çetin. 2021. *Yapay Zekâ Uygulamaları*,. 5. bs. Ankara: Seçkin Yayıncılık.
- Enders, Walter. 1995. "Applied econometric time series". *John Wiles and Sons* (3):107-18.
- Erden, Caner. 2023a. "Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Kıyaslanması: Bir Borsa İstanbul Hissesi Örneği". *Yönetim ve Ekonomi Dergisi* 30(3):419-38.
- Erden, Caner. 2023b. "Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Kıyaslanması: Bir Borsa İstanbul Hissesi Örneği". *Yönetim ve Ekonomi Dergisi* 30(3):419-38.
- Erdinç, Yaşar. 2023. *Yatırımcı ve teknik analiz sorgulanıyor*. İstanbul: Siyasal Kitabevi.
- Fabozzi, Frank J. 2015. *Capital markets: institutions, instruments, and risk management*. MIT Press.
- Fan, J., R. Shan, X. Cao, ve P. Li. 2009. "The analysis to tertiary-industry with ARIMAX model." *Journal of mathematics research* 1(2)(156).
- Fanoodi, Bahareh, Behnam Malmir, ve Farzad Firouzi Jahantigh. 2019. "Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models". *Computers in Biology and Medicine* 113:103415. doi:10.1016/j.compbiomed.2019.103415.
- Fernández-Blanco, Pablo, Diego J. Bodas-Sagi, Francisco J. Soltero, ve J. Ignacio Hidalgo. 2008. "Technical Market Indicators Optimization Using Evolutionary Algorithms". Ss. 1851-58 içinde *Proceedings of the 10th annual conference companion on Genetic and evolutionary computation*. Atlanta GA USA: ACM.

- Financial Times Stock Exchange Group (FTSE): Definition. 2024. <https://www.investopedia.com/terms/f/ftse.asp>.
- Fischer, Thomas, ve Christopher Krauss. 2018. "Deep learning with long short-term memory networks for financial market predictions". *European journal of operational research* 270(2):654-69.
- Focuseconomic. 2024. <https://www.focus-economics.com/countries/turkey/>.
- Francis, C. 1986. *Investments: analysis and management*.
- Francis, Jack Clark. 1988. *Management of investments*.
- FTSE MIB trading guide. 2024. <https://capital.com/trade-ftsemib>.
- FTSE UK Index Series. 2023. https://www.lseg.com/content/dam/ftse-russell/en_us/documents/policy-documents/ftse-faq-document-uk-2023.pdf.
- Furizal, Furizal, Asdelina Ritonga, Alfian Ma'arif, ve Iswanto Suwarno. 2024. "Stock Price Forecasting with Multivariate Time Series Long Short-Term Memory: A Deep Learning Approach". *Journal of Robotics and Control (JRC)* 5(5):1322-35.
- Gad, Ahmed Fawzy, Ahmed Fawzy Gad, ve Suresh John. 2018. *Practical computer vision applications using deep learning with CNNs*. Springer.
- Gayrimenkul Sertifikaları. 2024. <https://www.borsaistanbul.com/files/gayrimenkul-sertifikalari-brosuru.pdf>.
- Girsang, A. S., F. Lioexander, ve D. Tanjung. 2020. "Stock price prediction using lstm and search economics optimization." *IAENG International Journal of Computer Science* 47(4):758-64.
- Goodfellow, Ian, Yoshua Bengio, ve Aaron Courville. 2018. *Derin Öğrenme*. 1. bs. Ankara: Ankamat Matbaacılık.
- Goodfellow, Ian, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, ve Yoshua Bengio. 2020. "Generative Adversarial Networks". *Communications of the ACM* 63(11):139-44. doi:10.1145/3422622.
- Greff, Klaus, Rupesh K. Srivastava, Jan Koutník, Bas R. Steunebrink, ve Jürgen Schmidhuber. 2016. "LSTM: A search space odyssey". *IEEE transactions on neural networks and learning systems* 28(10):2222-32.

- Grupo BMV.2024. “ Grupo BMV Hakkımızda”. <https://www.bmv.com.mx/en/bmv-group/about-us>.
- Gujarati, Damodar. 2004. *Basic econometrics*. 4. bs. New York: Magraw Hill Inc.
- Gunduz, Hakan, Zehra Cataltepe, ve Yusuf Yaslan. 2017. “Stock market direction prediction using deep neural networks”. Ss. 1-4 içinde *2017 25th Signal Processing and Communications Applications Conference (SIU)*. IEEE.
- Gülyüz, Didem, Erdemalp Özden, ve Ünal Gülhan. 2021. “Predicting BIST 30 Index with Arıma And Rnn-Lstm Models”. *24. Finans Sempozyumu Bildiri Kitabı* 152.
- Günak, Nadir. 2007. *İleri teknik analiz uygulamaları*. İstanbul: Literatür Yayıncılık.
- Günal, Mehmet. 2012. *Para banka ve finansal sistem*. Berikan Yayınevi.
- Gündüz, H. 2019. “Derin öğrenme yöntemleri ile zaman serisi tahmini”. PhD Thesis, Doktora Tezi, Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi
- Güntürk, Özlem. 2023. “Covid-19 Salgınının Borsa Endeksleri Üzerindeki Etkisinin Analizi: G7 Ülkeleri Ve Türkiye”. Yüksek Lisans Tezi, Bolu Abant İzzet Baysal Üniversitesi Lisansüstü Eğitim Enstitüsü İktisat Anabilim Dalı, Bolu.
- Hamzaçebi, Coşkun, ve Fevzi Kutay. 2004. “Yapay sinir ağları ile türkiye elektrik enerjisi tüketiminin 2010 yılına kadar Tahmini”. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 19(3).
- Harvey, R. L. 1994. *Neural Network Principles*. New Jersey: Prentice-Hall Inc.
- Hasan, Afan. 2020. “Derin öğrenme ve makine öğrenmesi yöntemleriyle borsa alım satım davranışlarının modellenmesi”. PhD Thesis.
- Haykin, Simon. 2001. *Neural networks: a comprehensive foundation*. 2. bs. Kanada: Prentice Hall PTR.
- Hiransha M, Gopalakrishnan E.A., Vijay Krishna Menon, ve Soman K.P. 2018. “NSE Stock Market Prediction Using Deep-Learning Models”. *Procedia Computer Science* 132:1351-62. doi:10.1016/j.procs.2018.05.050.
- History & Milestones. 2024. <http://www.nseindia.com/national-stock-exchange/history-milestones>.

- Ho, M. K., H. Darman, ve S. Musa. 2021. "Stock price prediction using ARIMA, neural network and LSTM models." içinde *In Journal of Physics: Conference Series*. C. 1988.
- Hochreiter, S. 1997. "Long Short-term Memory". *Neural Computation MIT-Press*.
- Hodgkin, Jay. 2015. "Boom and Bust: China's Stock Market Turmoil". <https://ideas.darden.virginia.edu/boom-and-bust-chinas-stock-market-turmoil>.
- Hsieh, Tsung-Jung, Hsiao-Fen Hsiao, ve Wei-Chang Yeh. 2011. "Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm". *Applied soft computing* 11(2):2510-25.
- Hsu, Chih-Ming. 2011. "A hybrid procedure for stock price prediction by integrating self-organizing map and genetic programming". *Expert Systems with Applications* 38(11):14026-36.
- <https://forex.com.tr>. t.y. "Hareketli Ortalamalar". <https://forex.com.tr/hareketli-ortalamalar/>.
- Hua, Yuming, Junhai Guo, ve Hua Zhao. 2015. "Deep belief networks and deep learning". Ss. 1-4 içinde *Proceedings of 2015 international conference on intelligent computing and internet of things*. IEEE.
- Hyndman, R. J. 2018. *Forecasting: principles and practice*. OTexts.
- Ibovespa B3 | B3. 2024. https://www.b3.com.br/pt_br/market-data-e-indices/indices/indices-amplos/ibovespa.htm.
- Idrees, Sheikh Mohammad, M. Afshar Alam, ve Parul Agarwal. 2019. "A prediction approach for stock market volatility based on time series data". *IEEE Access* 7:17287-98.
- IDX. 2024. "Overview and History of IDX". <https://www.idx.co.id/>.
- IDX Composite. 2024. "IDX Composite Endeksi Hisse Fiyatları - Investing.com". <https://tr.investing.com/indices/idx-composite-components>.
- IMKB. 2024. "25.YIL". <https://www.borsaistanbul.com/Dosyalar/25yil/index.html>.
- IMOEX.2024.MoscowExchange. <https://www.moex.com/en/index/IMOEX/constituents>

- Inghelbrecht, Koen, Dries Heyman, Stefaan Pauwels, ve Pieter Marius. 2012. "Technical trading rules in emerging stock markets". *World Academy of Science, Engineering and technology* 59:2241-64.
- investopedia. 2022. <https://www.investopedia.com/terms/c/cac40.asp>.
- Işık, Olcay. 2012. "Hukuki açıdan borsa ve borsa türleri". *Yalova Üniversitesi Hukuk Fakültesi Dergisi* 1(1).
- Jabbarzadeh, Armin, Saeed Shavvalpour, Hossein Khanjarpanah, ve Davood Dourvash. 2016. "A multiple-criteria approach for forecasting stock price direction: Nonlinear probability models with application in S&P 500 index". *International Journal of Applied Engineering Research* 11(6):3870-78.
- Jalalkamali, A., M. Moradi, ve N. Moradi. 2015. "Application of several artificial intelligence models and ARIMAX model for forecasting drought using the Standardized Precipitation Index". *International journal of environmental science and technology* (12):1201-10.
- Jarrah, Mutasem, ve Morched Derbali. 2023. "Predicting Saudi Stock Market Index by Using Multivariate Time Series Based on Deep Learning". *Applied Sciences* 13(14):8356.
- Jarrett, Kevin, Koray Kavukcuoglu, Marc'Aurelio Ranzato, ve Yann LeCun. 2009. "What is the best multi-stage architecture for object recognition?" Ss. 2146-53 içinde *2009 IEEE 12th international conference on computer vision*. IEEE.
- Kantar, Lokman. 2020. "Bist 100 Endeksinin Yapay Sinir Ağları Ve Arma Modeli İle Tahmini". *Muhasebe ve Finans İncelemeleri Dergisi* 3(2):121-31.
- Kara, İsmail. 2019. "*Borsa Endeksi Hareket Yönünün Tahmininde Sınıflandırma Yöntemlerinin Performanslarının Karşılaştırılması: Bist 100 Örneği*". doctoralThesis, Afyon Kocatepe Üniversitesi Sosyal Bilimler Enstitüsü.
- Kara, Yakup, Melek Acar Boyacioglu, ve Ömer Kaan Baykan. 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):5311-19.

- Karan, Mehmet. 2021. *Yatırım analizi ve portföy yönetimi*. 7. bs. Ankara: Gazi Kitabevi.
- Karaşin, A. Gültekin. 1987. *Sermaye piyasası analizleri*. Sermaye Piyasası Kurulu.
- Karlı, Muharrem. 1989. *Sermaye piyasası, borsa, menkul kıymetler*. C. 3. Baskı.
- Karlı, Muharrem. 2004. *Sermaye Piyasası Borsa Menkul Kıymetler*. İstanbul: Alfa Yayıncılık.
- Karymshakov, Kamalbek, ve Yzat Abdykaparov. 2012. "Forecasting stock index movement with artificial neural networks: The case of istanbul stock exchange". *Trakya University Journal of Social Science* 14(2):231-42.
- Kashiwagi, Ryoji. 2015. *Utilization of artificial intelligence in finance*. 227. Nomura Research Institute.
- Kim, Ha Young, ve Chang Hyun Won. 2018. "Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models". *Expert Systems with Applications* 103:25-37.
- Kim, Kyoung-jae. 2003. "Financial time series forecasting using support vector machines". *Neurocomputing* 55(1-2):307-19.
- Kim, Sangyeon, ve Myungjoo Kang. 2019. "Financial Series Prediction Using Attention LSTM". *arXiv preprint arXiv:1902.10877*.
- Klassen, Myungsook. 2005. "Investigation of Some Technical Indexes in Stock Forecasting Using Neural Networks." Ss. 75-79 içinde *WEC* (5). Citeseer.
- Konuralp, Gürel. 2005. *Sermaye Piyasaları Analizler (İkinci Baskı)*. 2. İstanbul: Kuramlar Ve Portföy Yönetimi, Alfa Yayınları.
- Korkmaz, Turhan, ve Ali Ceylan. 2006. *Sermaye Piyasası ve Menkul Değer Analizi*, (3. Baskı). 3. Bursa: Ekin Kitabevi.
- Korukçu, M. Ö. 2022. *Mühendislik Alanında Uluslararası Araştırmalar III*. EĞİTİM YAYINEVİ.
- Kristoufek, Ladislav. 2014. "Detrending moving-average cross-correlation coefficient: Measuring cross-correlations between non-stationary series". *Physica A: Statistical mechanics and its applications* 406:169-75.

- Kröse, B., ve P. Van der Smagt. 1996. *An Introduction to Neural Networks*. Amsterdam: The University of Amsterdam.
- Kutlu, Birgül, ve Bertan Badur. 2009. “Yapay Sinir Ağları İle Borsa Endeksi Tahmini”. *Yönetim-İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Dergisi* 20(63).
- Lalithendra Nadh, V., ve G. Syam Prasad. 2019. “Stock Market Prediction Based on Machine Learning Approaches”. Ss. 75-79 içinde *Computational Intelligence and Big Data Analytics, SpringerBriefs in Applied Sciences and Technology*. Singapore: Springer Singapore.
- Lambert, Donald R. 1983. “Commodity channel index: Tool for trading cyclic trends”. *Technical Analysis of Stocks & Commodities* 1:47.
- Lane, George C. 1985. “Lane’s stochastics: the ultimate oscillator”. *Journal of Technical Analysis* 21:37-42.
- LeCun, Y., B. Boser, JS Denker, D. Henderson, RE Howard, W. Hubbard, ve LD Jackel. 1989. “LeCun: Backpropagation applied to handwritten zip code recognition”. *Neural computation*, 1(4), 541-551..
- Lee, Che-Yu, ve Von-Wun Soo. 2017. “Predict stock price with financial news based on recurrent convolutional neural networks”. Ss. 160-65 içinde *2017 conference on technologies and applications of artificial intelligence (TAAI)*. IEEE.
- Lewis, Colin David. 1982. “Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting”.
- Li, Xinyi, Yinchuan Li, Xiao-Yang Liu, ve Christina Dan Wang. 2019. “Risk Management via Anomaly Circumvent: Mnemonic Deep Learning for Midterm Stock Prediction”. *arXiv preprint arXiv:1908.01112*.
- Li, Zhenglin, Hanyi Yu, Jinxin Xu, Jihang Liu, ve Yuhong Mo. 2023. “Stock market analysis and prediction using LSTM: A case study on technology stocks”. *Innovations in Applied Engineering and Technology* 1-6.

- Li, Zhixi, ve Vincent Tam. 2017. "Combining the real-time wavelet denoising and long-short-term-memory neural network for predicting stock indexes". Ss. 1-8 içinde *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE.
- Likas, A., N. Vlassis, ve J. J. Verbeek. 2003. "The Global k-Means Clustering Algorithm." *Pattern Recognition* 36(2):451-61.
- Liu, Weibo, Zidong Wang, Xiaohui Liu, Nianyin Zeng, Yurong Liu, ve Fuad E. Alsaadi. 2017. "A survey of deep neural network architectures and their applications". *Neurocomputing* 234:11-26.
- Lowry, Cynthia A., William H. Woodall, Charles W. Champ, ve Steven E. Rigdon. 1992. "A multivariate exponentially weighted moving average control chart". *Technometrics* 34(1):46-53.
- Lu, Chi-Jie. 2010. "Integrating independent component analysis-based denoising scheme with neural network for stock price prediction". *Expert Systems with Applications* 37(10):7056-64.
- Lucas, James M., ve Michael S. Saccucci. 1990. "Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements". *Technometrics* 32(1):1-12. doi:10.1080/00401706.1990.10484583.
- Lv, Pin, Qinjuan Wu, Jia Xu, ve Yating Shu. 2022. "Stock index prediction based on time series decomposition and hybrid model". *Entropy* 24(2):146.
- Mahadik, A., D. Vaghela, ve A. Mhaishgawali. 2021. "Stock price prediction using lstm and Arima." In 2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC) (pp. 1594-1601). IEEE.
- Manaswi, Navin Kumar, Navin Kumar Manaswi, ve Suresh John. 2018. *Deep learning with applications using python*. Springer.
- Manurung, Adler Haymans, Widodo Budiharto, ve Harjanto Prabowo. 2018. "Algorithm and modeling of stock prices forecasting based on long short-term memory (LSTM)." *ICIC Express Letters*, 12(12), 1277-1283.
- Mashadihasanli, Tamerlan. 2022. "Stock market price forecasting using the Arima model: an application to Istanbul, Türkiye". *Journal of Economic Policy Researches* 9(2):439-54.

MasterCard. 2016. “Mastercard Rolls out Artificial Intelligence across Its Global Network”.

<https://www.businesswire.com/news/home/20161130005546/en/Mastercard-Rolls-out-Artificial-Intelligence-across-Its-Global-Network%C2%A0%C2%A0>.

Methodology of SSE Composite Index. t.y.

MICEX-RTS. 2011. “MICEX and RTS Merger Creates Russian Exchange Powerhouse”.

<https://www.prnewswire.com/news-releases/micex-and-rts-merger-creates-russian-exchange-powerhouse-135844938.html>.

Mishkin, Frederic S. 2007. *The economics of money, banking, and financial markets*. Pearson education.

Moat, Helen Susannah, Chester Curme, Adam Avakian, Dror Y. Kenett, H. Eugene Stanley, ve Tobias Preis. 2013. “Quantifying Wikipedia usage patterns before stock market moves”. *Scientific reports* 3(1):1801.

Mochurad, L., ve A. Dereviannyi. 2024. “An ensemble approach integrating LSTM and ARIMA models for enhanced financial market predictions.” *Royal Society Open Science* 11(9).

MOEX. 2024. “Moscow Exchange”. <https://www.moex.com>.

MOEX Components. 2024. “MCX Endeksi Hisse Fiyatları - Investing.com”. <https://tr.investing.com/indices/mcx-components>.

MOEXAnnual. 2023. “Moscow Exchange - Annual Reports”. <https://www.moex.com/s1354>.

MOEXExchange. 2024. “| SSE Girişimi”. <https://sseinitiative.org/stock-exchange/moex>.

Murphy, John J. 1999. *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. Penguin.

Murphy, K. P. 2012. *Machine learning: a probabilistic perspective*. MIT Press.

Namin, Sima Siami, ve Akbar Siami Namin. 2018. “1. Graduate Research Assistant and Ph.D. Student, Department of Agricultural and Applied Economics”. *arXiv preprint arXiv:1803.06386*.

- Negnevitsky, M. 2004. *Artificial Intelligence: A Guide to Intelligent Systems*. Addison-Wesley.
- Newbold, Paul. 1983. "ARIMA Model Building and the Time Series Analysis Approach to Forecasting". *Journal of Forecasting* 2(1):23-35. doi:10.1002/for.3980020104.
- Nielsen, Aileen. 2019. *Practical Time Series Analysis: Prediction with Statistics and Machine Learning*. O'Reilly Media, Inc.
- NIKKEI 225 Canlı Fiyat Grafiği Yorumlar ve Teknik Analizler. 2023. <https://www.gcmyatirim.com.tr/forex/yatirim-araclari/yabanci-borsa-endeksleri/nikkei-225>.
- Nikou, Mahla, Gholamreza Mansourfar, ve Jamshid Bagherzadeh. 2023. "Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms". *Intelligent Systems in Accounting, Finance and Management* 26(4):164-74. doi:<https://doi.org/10.1002/isaf.1459>.
- Number of Listed Companies/Shares. 2024. <https://www.jpx.co.jp/english/listing/co/index.html>.
- Nyasha, Sheilla, ve Nicholas M. Odhiambo. 2020. "Determinants of the Brazilian stock market development". *The Journal of Developing Areas* 54(1).
- Okutkan, Caner. 2014. "*Borsa İstanbul Şirketlerinin Hisse Senedi Getirilerinin Yapay Sinir Ağları Ve Çoklu Regresyon Yöntemleri Kullanarak Analizi*". Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü.
- Olah, Christopher. 2024. "Understanding LSTM Networks". <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- Orçun, Çağatay. 2010. "*Finansal piyasalarda alım satım kararlarında teknik analiz ve İMKB uygulaması*". Master's Thesis, Dokuz Eylül Üniversitesi (Turkey).
- Orhan, Osman Z., ve Seyfettin Erdoğan. 2007. *Para Politikası (4. Baskı)*.
- Ökte, M. Kutluğhan Savaş. 1994. "*Gelişen Borsalar*". Yüksek Lisans Tezi, İstanbul Üniversitesi, İstanbul.
- Örten, Remzi, ve İpek Örten. 2001. *Türev finansal araçlar ve muhasebe uygulamaları*. Gazi Kitabevi.

- Özden, Cevher. 2023. "İstatistiksel ve Derin Öğrenme Yöntemlerini Kullanarak Tarımsal Girdi Fiyat Endeksi'nin Tahmin Edilmesi". *Turkish Journal of Agriculture-Food Science and Technology* 11(9):1751-55.
- Özekşi, Anıl. 2005. *Kazanma sanatı*. Alfa yayınları.
- Özkan, Tuba, ve Bener Güngör. 2017. "Geometrik Brownian Hareketi Modeli İle Endeks Dalgalanmalarını Değerlendirme: Bist-30, Bist-100 Ve S&p 500 Endeksleri Üzerine Bir Uygulama: Evaluate Index Fluctuations With Geometric Brownian Motion Model: An Application On Bist-30, Bist-100 And S&P 500 Indexes." *Ataturk University Journal of Economics & Administrative Sciences* 31(2):377-95.
- Öztemel, Ercan. 2012. *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- Pabuççu, Hakan. 2019. "Borsa Endeksi Hareketlerinin Makine Öğrenme Algoritmaları İle Tahmini". *Uluslararası İktisadi ve İdari İncelemeler Dergisi* (23):179-90.
- Panchal, S. A., L. Ferdouse, ve A. Sultana. 2024. "Comparative Analysis of ARIMA and LSTM Models for Stock Price Prediction. 2024 IEEE/ACIS 27th International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD) (pp. 240-244). IEEE.
- Pannu, Avneet. 2015. "Artificial intelligence and its application in different areas". *Artificial Intelligence* 4(10):79-84.
- Parasız, M. İlker. 2000. *Para, banka ve finansal piyasalar*. Ezgi Kitabevi Yayınları.
- Perşembe, Ali. 2013. *Teknik analiz mi dedin? Hadi canım Sen de!* Scala Yayıncılık.
- Preis, Tobias, Helen Susannah Moat, ve H. Eugene Stanley. 2013. "Quantifying trading behavior in financial markets using Google Trends". *Scientific reports* 3(1):1-6.
- Pring, Martin J. 2002. *Study guide for technical analysis explained*. C. 5. McGraw-Hill New York.
- Ramola, R. C., Yogesh Prasad, Ganesh Prasad, Sushil Kumar, ve V. M. Choubey. 2008. "Soil-gas radon as seismotectonic indicator in Garhwal Himalaya". *Applied Radiation and Isotopes* 66(10):1523-30.
- Rana, Rajib. 2016. "Gated Recurrent Unit (GRU) for Emotion Classification from Noisy Speech".

- Rathnayaka, RM Kapila Tharanga, DMKN Seneviratna, Wei Jianguo, ve Hasitha Indika Arumawadu. 2015. "A hybrid statistical approach for stock market forecasting based on artificial neural network and ARIMA time series models". Ss. 54-60 içinde *2015 International Conference on Behavioral, Economic and Socio-cultural Computing (BESC)*. IEEE.
- Renaissance Technologies. 2024. <https://www.rentec.com/Home.action?index=true>.
- Rodoplu, Gültekin. 1993. *Türkiye’de sermaye piyasası ve işlemleri*. Marmara Üniversitesi Nihad Sayar Eğitim Vakfı.
- Roondiwala, Murtaza, Harshal Patel, ve Shraddha Varma. 2017. "Predicting Stock Prices Using LSTM". *International Journal of Science and Research (IJSR)* 6. doi:10.21275/ART20172755.
- Rout, Ajit Kumar, Pradiptaishore Kishore Dash, Rajashree Dash, ve Ranjeeta Bisoi. 2017. "Forecasting financial time series using a low complexity recurrent neural network and evolutionary learning approach". *Journal of King Saud University-Computer and Information Sciences* 29(4):536-52.
- Rumelhart, David E., Geoffrey E. Hinton, ve Ronald J. Williams. 1986. "Learning representations by back-propagating errors". *nature* 323(6088):533-36.
- Russel, S., ve P. Norving. 2010. *Artificial Intelligence A Modern Approach*. 3. bs. New Jersey: Prentice Hall.
- Russell, Stuart J., ve Peter Norvig. 2016. *Artificial intelligence: a modern approach*. Pearson.
- SAKARYA, Şakir, ve Ümit YILMAZ. 2019. "Derin öğrenme mimarisi kullanarak bist30 indeksinin tahmini". *European Journal of Educational and Social Sciences* 4(2):106-21.
- Sakarya, Şakir, ve Ümit Yılmaz. 2019. "Derin öğrenme mimarisi kullanarak BİST30 indeksinin tahmini". *European Journal of Educational and Social Sciences* 4(2):106-21.

- Salehinejad, Hojjat, Sharan Sankar, Joseph Barfett, Errol Colak, ve Shahrokh Valaee. 2018. "Recent Advances in Recurrent Neural Networks". *arXiv preprint arXiv:1801.01078*.
- Samuel, A. L. 1959. "Some Studies in Machine Learning Using the Game of Checkers". *IBM Journal of Research and Development* 3(3):210-29. doi:10.1147/rd.33.0210.
- Sarıkamış, Cevat. 1995. "Sermaye Pazarı". *Alfa Basım Yayım, İstanbul*.
- Sarıkamış, Cevat. 2000. "Sermaye pazarları". *İstanbul: Alfa Yayınları*.
- SARIKOÇ, Mehmet, ve Mete Çelik. 2022. "Boyut İndirgeme Teknikleri ve LSTM Derin Öğrenme Ağı İle BIST100 Endeksi Fiyat Tahmini". *Avrupa Bilim ve Teknoloji Dergisi* (34):519-24.
- Sermaye Piyasası Araçları. 2024. https://spl.com.tr/wp-content/uploads/2024/07/1003_MKT_30062024_202407170758.pdf.
- Sermaye Piyasası ve Borsa Temel Bilgiler Kılavuzu. 1992.
- Sesit, Michael R. 1993. "Flocking to the Frontier". *Wall Street Journal* 21.
- Seyidoğlu, Halil. 2005. "*Uluslararası İktisat*", Anadolu Üniversitesi Yayınları".
- Sezer, Ömer Berat. 2018. "*Zaman serisi verilerinin derin yapay sinir ağları ile analizi ve eniyilemesi: Finansal tahmin algoritmaları*". Tobb Ekonomi ve TEknoloji Üniversitesi Fen bilimleri Enstitüsü, İstanbul.
- Shah, Dev, Wesley Campbell, ve Farhana H. Zulkernine. 2018. "A comparative study of LSTM and DNN for stock market forecasting". Ss. 4148-55 içinde *2018 IEEE international conference on big data (big data)*. IEEE.
- Shanghai Stock Exchange. t.y. <https://english.sse.com.cn/markets/indices/overview/>.
- Siame-Namini, Sima, ve Akbar Siame Namin. 2018. "Forecasting Economics and Financial Time Series: ARIMA vs. LSTM". *arXiv preprint arXiv:1803.06386*.
- Siame-Namini, Sima, Neda Tavakoli, ve Akbar Siame Namin. 2019. "A Comparative Analysis of Forecasting Financial Time Series Using ARIMA, LSTM, and BiLSTM". *arXiv preprint arXiv:1911.09512*.

- Siddiqui, Taufeeque Ahmad, ve Yusuf Abdullah. 2015. "Developing a Nonlinear Model to Predict Stock Prices in India: An Artificial Neural Networks Approach." *IUP Journal of Applied Finance* 21(3).
- Siegel, Joel G., Jae K. Shim, Anique A. Qureshi, ve Jeffrey Brauchler. 2014. *International encyclopedia of technical analysis*. Routledge.
- Sihabuddin, Agus, Dedi Rosadi, ve Nurdi Dwianto Wibowo. 2009. "Early Warning System in Forex Market". Ss. 1015-22 içinde *The First International Seminar on Science and Technology*.
- Sönmez, Oğuzhan. 2023. "Yinelemeli Sinir Ağlarında Çok Değişkenli Zaman Serisi Analizi Yöntemleri İle Süt Sığırcılığı Üreme Süreç Yönetimi". TOGÜ, TOGÜ Lisansüstü Eğitim Ens.
- S&P/BMV IPC Endeksi Bileşenler. 2024. "S&P/BMV IPC Endeksi Bileşenler – BMV:ME Hisse Senetleri". <https://tr.tradingview.com/symbols/BMV-ME/components/>.
- Spencer, Matt, Jesse Eickholt, ve Jianlin Cheng. 2014. "A deep learning network approach to ab initio protein secondary structure prediction". *IEEE/ACM transactions on computational biology and bioinformatics* 12(1):103-12.
- SPG. 2008. "AIM_Yayın_ve_Raporlar_Aylık_Yayınlar_2008_gundem_200807.pdf". https://tspb.org.tr/wp-content/uploads/2022/12/AIM_Yayın_ve_Raporlar_Aylık_Yayınlar_2008_gundem_200807.pdf.
- SPK Tahvil Yonetmeligi. 1992. <https://kobirate.com.tr/SPK-Tahvil-Yonetmeligi>.
- S&P/TSX Composite Index. t.y. <https://www.spglobal.com/spdji/en/indices/equity/sp-tsx-composite-index/>.
- SSE. 2024. "SSE". <https://sseinitiative.org/stock-exchange/bmv>.
- Steele, Ryan, ve Larbi Esmahi. 2015. "Technical Indicators as Predictors of Position Outcome for Technical trading". S. 3 içinde *Proceedings of the International Conference on e-Learning, e-Business, Enterprise Information Systems, and e-*

- Government (EEE). The Steering Committee of The World Congress in Computer Science, Computer
- Steels, L. 1993. "The Artificial Life Roots of Artificial Intelligence." *Artificial Life* 1(2):75-110.
- Şenol, EMİR. 2013. "Yapay sinir ağları ve destek vektör makineleri yöntemlerinin sınıflandırma performanslarının karşılaştırılması: borsa endeks yönünün tahmini üzerine bir uygulama". Yayınlanmamış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü
- Şişmanoğlu, Gözde, Furkan Koçer, Mehmet Ali Önde, ve Ozgur Koray SahiNgoz. 2020. "Derin Öğrenme Yöntemleri ile Borsada Fiyat Tahmini". *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi* 9(1):434-45. doi:10.17798/bitlisfen.571386.
- Țăran-Moroşan, Adrian. 2011. "The relative strength index revisited". *African Journal of Business Management* 5(14):5855-62.
- Taş, Ali İsa, Pelin Gülüm, ve Gökalp Tulum. 2021. "Finansal Piyasalarda Hisse Fiyatlarının Derin Öğrenme ve Yapay Sinir Ağı Yöntemleri ile Tahmin Edilmesi; S&P 500 Endeksi Örneği". *Düzce Üniversitesi Bilim ve Teknoloji Dergisi* 9(3):446-60.
- Tektaş, Arzu, ve Abdülmecit Karataş. 2004. "Yapay sinir ağları ve finans alanına uygulanması: Hisse senedi fiyat tahminlemesi". *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 18(3-4).
- Telli, Şahin, ve Metin Coşkun. 2016. "Forecasting the BIST 100 Index using artificial neural networks with consideration of the economic calendar". *International Review of Economics and Management* 4(3):26-46.
- The history of Borsa Italiana, the Italian Stock Exchange - Borsa Italiana. 2024. <https://www.borsaitaliana.it/borsaitaliana/storia/storia/scenari-economici-finanziari.en.htm>.
- Thomsett, Michael. 2012. "Technical Analysis of Stock Trends Explained. An Easy-to-Understand System for Trading Successfully". *Ethan Hathaway Co LTD*.

- Tomakin, Fatih. 2007. “Teknik analiz ve MACD göstergesinin İMKB’de uygulanması”. Master’s Thesis, Marmara Üniversitesi (Turkey).
- Toraman, Cengiz. 2008. “Demir-çelik sektöründe yapay sinir ağları ile hisse senedi fiyat tahmini: Erdemir AŞ ve Kardemir AŞ üzerine bir tahmin uygulaması”. *Muhasebe ve Finansman Dergisi* (39):44-57.
- TradingView. 2024a. “COMPOSITE Endeks Grafikleri ve Fiyatlar”. <https://tr.tradingview.com/symbols/INDEX-COMPOSITE/>.
- TradingView. 2024b. <https://tr.tradingview.com/markets/stocks-canada/>.
- Tükenmez, Mine, T. Susmuş, Serdar Özkan, Nilgün Kutay, Pınar Evrim, HF BAKLACI, Tülay Yücel, Erdal Özkol, Banu Durukan, ve Süleyman Yükçü. 1999. “Muhasebe Sistemi Uygulama Genel Tebliğine Göre Finansal Yönetim”. *İzmir: Vizyon Yayınları*.
- Uludağ, İlhan, ve Erişah Arıcan. 1999. “Finansal hizmetler ekonomisi”. *İstanbul, Beta Yayın*.
- Van Houdt, Greg, Carlos Mosquera, ve Gonzalo Nápoles. 2020. “A Review on the Long Short-Term Memory Model”. *Artificial Intelligence Review* 53(8):5929-55. doi:10.1007/s10462-020-09838-1.
- Vuong, Pham Hoang, Trinh Tan Dat, Tieu Khoi Mai, ve Pham Hoang Uyen. 2022. “Stock-price forecasting based on XGBoost and LSTM.” *Computer Systems Science & Engineering* 40(1).
- Wang, Xiang, Yuan Zheng, Zhenzhou Zhao, ve Jinping Wang. 2015. “Bearing fault diagnosis based on statistical locally linear embedding”. *Sensors* 15(7):16225-47.
- Widgren, Philip. 2017. “Deep learning-based forecasting of financial assets”.
- Wilder, J. Welles. 1987. *The Adam Theory of Markets Or what Matters is Profit*. Trend Research.
- Wu, Haoran, Shuqi Chen, ve Yicheng Ding. 2023. “Comparison of ARIMA and LSTM for Stock Price Prediction”. *Financial Engineering and Risk Management* 6(1). doi:10.23977/ferm.2023.060101.

- Xiao, Ruochen, Yingying Feng, Lei Yan, ve Yihan Ma. 2022. "Predict stock prices with ARIMA and LSTM." doi:<https://doi.org/10.48550/arXiv.2209.02407>.
- Yakut, Yöntemleriyle Borsa Endeksi Tahmini Yr, Emre Yakut, ve Selahattin Yavuz. 2014. "Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini". *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 19(1):139-57.
- Yan, Hongju, ve Hongbing Ouyang. 2018. "Financial time series prediction based on deep learning". *Wireless Personal Communications* 102:683-700.
- Yayar, Rüştü, ve Karaca S.Serdar. 2011. "Endeks Tahmini Ve İstanbul Menkul Kıymetler Borsası (İmkb) Sınai Endeksi Üzerine Bir Uygulama." *World of Accounting Science* 13(2).
- Yu, Lean, Shouyang Wang, ve Kin Keung Lai. 2005. "Mining Stock Market Tendency Using GA-Based Support Vector Machines". Ss. 336-45 içinde *Internet and Network Economics*. C. 3828, *Lecture Notes in Computer Science*, editör X. Deng ve Y. Ye. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Yurtoğlu, Hasan. 2005. "Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi:Bazı Makroekonomik Değişkenler İçin Türkiye Örneği". DPT Uzmanlık Tezleri.
- Zhongzhi, Shi. 2019. *Advanced artificial intelligence*. C. 4. 2. bs. Singapore: World Scientific.
- Zhu, Zhe, ve Kexin He. 2022. "Prediction of Amazon's Stock Price Based on ARIMA, XGBoost, and LSTM Models". *Proceedings of Business and Economic Studies* 5(5):127-36.

ÖZGEÇMİŞ

