

T.C.

MARMARA ÜNİVERSİTESİ

BANKACILIK VE SİGORTACILIK ENSTİTÜSÜ

SERMAYE PİYASASI VE BORSA ANABİLİM DALI

YAPAY ZEKA YÖNTEMLERİYLE HİSSE SENEDİ FİYATININ

ÖNGÖRÜLMESİ

MEHMET HARUN SONGÜN

DOKTORA TEZİ

İSTANBUL 2023

T.C.

MARMARA ÜNİVERSİTESİ

BANKACILIK VE SİGORTACILIK ENSTİTÜSÜ

SERMAYE PİYASASI VE BORSA ANABİLİM DALI

YAPAY ZEKA YÖNTEMLERİYLE HİSSE SENEDİ FİYATININ

ÖNGÖRÜLMESİ

MEHMET HARUN SONGÜN

DOKTORA TEZİ

Tez Danışmanı

PROF. DR MURAT AKBALIK

İSTANBUL 2023

İÇİNDEKİLER

İÇİNDEKİLER.....	II
TABLolar LİSTESİ.....	vi
GRAFIK LİSTESİ.....	viii
GİRİŞ.....	1
I. BÖLÜM.....	3
HİSSE SENEDİ TEMEL KAVRAMLAR.....	3
1.1. Borsanın Tanımı ve Tarihi.....	4
1.1.1. BİST30	7
1.2. Risk Kavramı	8
1.2.1. Sistematik Risk.....	11
1.2.2. Sistematik Olmayan Riskler.....	20
1.3. Hisse Senedi Kavramı	25
1.4. Hisse Senetlerinde Değer Kavramı	27
1.4.1. Nominal Değer	27
1.4.2. Gerçek Değer.....	27
1.4.3. Defter Değeri.....	28
1.4.4. Tasfiye Değeri.....	28
1.5. Hisse Senedi Değerinin Öngörülebilirliği	29
1.5.1. Rastgele Yürüyüş Hipotezi	31
1.5.2. Etkin Piyasa Hipotezi.....	32
1.5.3. Anomaliler	37
1.6. Davranışsal Finans.....	43
1.6.1. Rasyonel Davranış	46
1.6.2. İrrasyonel Davranış	48
1.7. Temel Analiz.....	49
1.7.1. Ekonomi Analizi.....	51
1.7.2. Sektör Analizi.....	53

1.7.3 Firma Analizi.....	55
1.8 Teknik Analiz	59
1.8.1.Teknik Analizin Avantajları	61
1.8.2.Teknik Analizin Sınırlamaları	62
1.8.3.Teknik Analizin Dezavantajları	62
1.9. İstatistiksel Yöntemlerle Hisse Senedi Fiyat Tahmini.....	74
1.9.1.Otoregresif (AR) Modeli	77
1.9.2. Hareketli Ortalamalar (MA) Modeli	78
1.9.3. Otoregresif Hareketli Ortalamalar (ARMA) Modeli	79
1.9.4. Otoregresif Hareketli Tamamlanmış Ortalamalar (ARIMA) Modeli.....	80
II. BÖLÜM.....	82
ZEKA, YAPAY ZEKA YÖNTEMLERİ VE TEMEL KAVRAMLAR.....	82
2.1. Zeka ve Yapay Zeka.....	82
2.1.1. Zeka	83
2.1.2. Yapay Zeka.....	84
2.1.3.Zeka ve Yapay Zeka Arasındaki Temel Farklılıklar.....	85
2.1.4.Zeka ve Yapay Zeka Arasındaki Temel Benzerlikler	85
2.1.5.Zeka ve Yapay Zeka Uygulamaları	86
2.2. Makine Öğrenmesi.....	86
2.2.1. Makine Öğreniminin Tarihi	88
2.2.2. Makine Öğrenimi Türleri	89
2.3. Makine Öğrenimi Uygulamaları.....	104
2.4. Makine Öğrenimindeki Yararlar ve Zorluklar	104
2.4.1. Makine Öğreniminin Yararları.....	105
2.4.2. Makine Öğreniminin Zor Tarafları.....	105
2.5. Temel Yapay Zekâ Teknikleri.....	106
III. BÖLÜM.....	112
BORSALARDA YAPAY ZEKANIN KULLANILMASINA İLİŞKİN ÇALIŞMALAR.....	112
3.1. Hibrit Modellerle Yapılan Çalışmalar	112
3.2. Yapay Zeka ile Yapılan Çalışmalar	120
IV. BÖLÜM.....	160
YAPAY ZEKA YÖNTEMLERİYLE HİSSE SENEDİ FİYATLARININ ÖNGÖRÜLMESİ ÜZERİNE AMPİRİK ÇALIŞMA.....	160

4.1. Çalışmanın Kapsam ve Sınırlamaları.....	161
4.1.1 Verisel Kapsam	161
4.1.2 Zamansal Kapsam	162
4.1.3 Kavramsal Kapsam.....	162
4.1.4 Sınırlamalar	162
4.2. Çalışmanın Hipotezleri.....	163
4.3. ARIMA, SVM, Holt-Winters, Karar Ağacı, DVM, Rastgele Orman ve Derin Öğrenme Modellerinin Performans Analizi	163
4.3.1. Çalışmanın Amacı ve Önemi	164
4.3.2. Veri Seti Seçimi ve Temini.....	164
4.3.3. Çalışmanın Metodolojisi.....	167
4.3.4. Makine Öğrenme Algoritmaları Uygulamaları.....	179
4.3.5. ARIMA Modeli.....	184
4.3.6. Holt-Winters Modeli	247
4.4. Sonuç İncelemesi	252
4.5. ARIMA, SVM, Holt-Winters ve Karar Ağacı Karşılaştırmalı Uygulaması	253
4.5.1. Arima Modeli	253
4.5.2. Holt-Winters	257
4.5.3. Karar Ağacı ve Destek Vektör Makineleri Modeli.....	260
4.6. SVM, Karar Ağacı, DVM, Rastgele Orman ve Derin Öğrenme Modellerinin Karşılaştırmalı Performans Analizi	268
4.6.1. Araştırmanın Amacı ve Yöntemi.....	269
4.6.2. Veri Setinin Belirlenmesi	269
4.6.3. Döneminin Belirlenmesi ve Veri Setinin Oluşturulması.....	269
4.6.4. Bağımlı ve Bağımsız Değişkenlerin Belirlenmesi	270
4.6.5. Veri Setinin Hazırlanması.....	270
4.6.6. Korelasyon Analizi.....	271
4.6.7. Verinin Eğitim Seti-Test Seti Olarak Bölümlenmesi.....	273
4.6.8. Kullanılacak Yöntemlerin/Algoritmaların Belirlenmesi	274
4.6.9. Sonuç İncelemesi.....	274
4.7. Backtest Uygulaması.....	279
4.7.1. Sonuç İncelemesi.....	284
4.7.2. Sonuç İncelemesi İki	286
4.8. Sonuçlara Genel Bakış	287

V. SONUÇ VE TARTIŞMA.....	289
KAYNAKLAR	293



TABLÖLAR LİSTESİ

TABLO 1: YAPAY ZEKA TEKNİKLERİ	106
TABLO 2: BIST 30 ENDEKSİ HİSSE SENETLERİ	166
TABLO 3: BIST 30 SEKTÖREL DAĞILIM	166
TABLO 4: MAKİNE ÖĞRENME ALGORİTMALARI GÜNLÜK GÖRELİ HATA SONUÇLARI %	179
TABLO 5: MAKİNE ÖĞRENME ALGORİTMALARI HAFTALIK GÖRELİ HATA SONUÇLARI %	182
TABLO 6: AKBANK ARİMA SONUÇLARI	184
TABLO 7: ARÇELİK ARİMA SONUÇLARI	186
TABLO 8: ASELSAN ARİMA SONUÇLARI	188
TABLO 9: BIM ARİMA SONUÇLARI	191
TABLO 10: EKGYO ARİMA SONUÇLARI	193
TABLO 11: EREGLİ ARİMA SONUÇLARI	194
TABLO 12: FROTO ARİMA SONUÇLARI	197
TABLO 13: GARAN ARİMA SONUÇLARI	198
TABLO 14: GUBRF ARİMA SONUÇLARI	200
TABLO 15: HALKB ARİMA SONUÇLARI	202
TABLO 16: HEKTS ARİMA SONUÇLARI	204
TABLO 17: İSCTR ARİMA SONUÇLARI	206
TABLO 18: KCHOL ARİMA SONUÇLARI	208
TABLO 19: KOZAA ARİMA SONUÇLARI	210
TABLO 20: KOZAL ARİMA SONUÇLARI	212
TABLO 21: KRMD ARİMA SONUÇLARI	214
TABLO 22: PETKİM ARİMA SONUÇLARI	216
TABLO 23: PGSUS ARİMA SONUÇLARI	218
TABLO 24: SAHOL ARİMA SONUÇLARI	220
TABLO 25: SASA ARİMA SONUÇLARI	222
TABLO 26: SİSE ARİMA SONUÇLARI	224
TABLO 27: TAVHL ARİMA SONUÇLARI	227
TABLO 28: TCELL ARİMA SONUÇLARI	229
TABLO 29: THY ARİMA SONUÇLARI	231
TABLO 30: TKFEN ARİMA SONUÇLARI	234
TABLO 31: TOASA ARİMA SONUÇLARI	236
TABLO 32: TTKOM ARİMA SONUÇLARI	238
TABLO 33: TUPRS ARİMA SONUÇLARI	240

TABLO 34: VESTEL ARİMA SONUÇLARI.....	242
TABLO 35: YKBNK ARİMA SONUÇLARI.....	244
TABLO 36: HOLT-WİNTERS İSTATİSTİKİ MODELİ SONUÇLARI.....	247
TABLO 37: MODELLERİN DOGRU KARAR, YANLIŞ KARAR, DOĞRU KARAR ORANI: % VE YANLIŞ KARAR ORANI: % TABLOSU	286



GRAFİK LİSTESİ

GRAFİK 1. AKBANK ARİMA FİYAT-TAHMİN GRAFİĞİ	186
GRAFİK 2. ARÇELİK ARİMA FİYAT-TAHMİN GRAFİĞİ	188
GRAFİK 3. ASELSAN ARİMA FİYAT-TAHMİN GRAFİĞİ	190
GRAFİK 4. BIM ARİMA FİYAT-TAHMİN GRAFİĞİ	192
GRAFİK 5. EKGYO ARİMA FİYAT-TAHMİN GRAFİĞİ	194
GRAFİK 6. EREGLİ ARİMA FİYAT-TAHMİN GRAFİĞİ	196
GRAFİK 7. FROTO ARİMA FİYAT-TAHMİN GRAFİĞİ	198
GRAFİK 8. GARAN ARİMA FİYAT-TAHMİN GRAFİĞİ	200
GRAFİK 9. GUBRF ARİMA FİYAT-TAHMİN GRAFİĞİ	202
GRAFİK 10. HALKB ARİMA FİYAT-TAHMİN GRAFİĞİ	204
GRAFİK 11. HEKTS ARİMA FİYAT-TAHMİN GRAFİĞİ	206
GRAFİK 12. İSCTR ARİMA FİYAT-TAHMİN GRAFİĞİ	208
GRAFİK 13. KCHOL ARİMA FİYAT-TAHMİN GRAFİĞİ	210
GRAFİK 14. KOZAA ARİMA FİYAT-TAHMİN GRAFİĞİ	212
GRAFİK 15. KOZAL ARİMA FİYAT-TAHMİN GRAFİĞİ	214
GRAFİK 16. KRMD ARİMA FİYAT-TAHMİN GRAFİĞİ	216
GRAFİK 17. PETKİM ARİMA FİYAT-TAHMİN GRAFİĞİ	218
GRAFİK 18. PGSUS ARİMA FİYAT-TAHMİN GRAFİĞİ	220
GRAFİK 19. SAHOL ARİMA FİYAT-TAHMİN GRAFİĞİ	222
GRAFİK 20. SASA ARİMA FİYAT-TAHMİN GRAFİĞİ	224
GRAFİK 21. SİSE ARİMA FİYAT-TAHMİN GRAFİĞİ	227
GRAFİK 22. TAVHL ARİMA FİYAT-TAHMİN GRAFİĞİ	229
GRAFİK 23. TCELL ARİMA FİYAT-TAHMİN GRAFİĞİ	231
GRAFİK 24. THY ARİMA FİYAT-TAHMİN GRAFİĞİ	233
GRAFİK 25. TKFEN ARİMA FİYAT-TAHMİN GRAFİĞİ	236
GRAFİK 26. TOASA ARİMA FİYAT-TAHMİN GRAFİĞİ	238
GRAFİK 27. TTKOM ARİMA FİYAT-TAHMİN GRAFİĞİ	240
GRAFİK 28. TUPRS ARİMA FİYAT-TAHMİN GRAFİĞİ	242
GRAFİK 29. VESTEL ARİMA FİYAT-TAHMİN GRAFİĞİ	244
GRAFİK 30. YKBANK ARİMA FİYAT-TAHMİN GRAFİĞİ	246
GRAFİK 31. 01 08 2022 ARİMA GRAFİĞİ	254
GRAFİK 32. 02 08 2022 ARİMA GRAFİĞİ	254
GRAFİK 33. 03 08 2022 ARİMA GRAFİĞİ	255

GRAFİK 34. 04 08 2022 ARİMA GRAFİĞİ	255
GRAFİK 35. 05 08 2022 ARİMA GRAFİĞİ	256
GRAFİK 36. 01 08 2022 HOLT-WİNTERS GRAFİĞİ.....	257
GRAFİK 37. 02 08 2022 HOLT-WİNTERS GRAFİĞİ.....	258
GRAFİK 38. 03 08 2022 HOLT-WİNTERS GRAFİĞİ.....	258
GRAFİK 39. 04 08 2022 HOLT-WİNTERS GRAFİĞİ.....	259
GRAFİK 40. 05 08 2022 HOLT-WİNTERS GRAFİĞİ.....	259
GRAFİK 41. 01 08 2022 DECİSİONTREE	261
GRAFİK 42. 01 08 2022 DVM.....	262
GRAFİK 43. 02 08 2022 KARAR AĞACI TAHMİN GRAFİĞİ.....	262
GRAFİK 44. 02 08 2022 DVM.....	263
GRAFİK 45. 03 08 2022 DECİSİONTREE TAHMİN GRAFİĞİ	263
GRAFİK 46. 03 08 2022 DVM TAHMİN GRAFİĞİ	264
GRAFİK 47. 04 08 2022 DECİSİONTREE TAHMİN GRAFİĞİ.....	264
GRAFİK 48. 04 08 2022 DVM TAHMİN GRAFİĞİ	265
GRAFİK 49. 05 08 2022 KARAR AĞACI TAHMİN GRAFİĞİ.....	265
GRAFİK 50. 05 08 2022 DVM TAHMİN GRAFİĞİ	266
GRAFİK 51. BAĞIMLI DEĞİŞKEN İLE BAĞIMSIZ DEĞİŞKENLER ARASINDA KORELASYON GRAFİĞİ	272
GRAFİK 52. BAĞIMSIZ DEĞİŞKEN-BAĞIMLI DEĞİŞKEN KORELASYON MATRİSİ	272
GRAFİK 53. RASTGELE ORMAN TAHMİN-HATA GRAFİĞİ	274
GRAFİK 54. DERİN ÖĞRENME TAHMİN-HATA GRAFİĞİ	275
GRAFİK 55. DESTEK VEKTÖR MAKİNELERİ TAHMİN-HATA GRAFİĞİ.....	276
GRAFİK 56. GBT TAHMİN-HATA GRAFİĞİ.....	277
GRAFİK 57. KARAR AĞACI TAHMİN-HATA GRAFİĞİ.....	278
GRAFİK 58. DERİN ÖĞRENME BACKTEST GRAFİĞİ.....	280
GRAFİK 59. RASTGELE ORMAN BACKTEST GRAFİĞİ	281
GRAFİK 60. DESTEK VEKTÖR MAKİNELERİ BACKTEST GRAFİĞİ	282
GRAFİK 61. GRADYAN ARTIRMA AĞAÇLARI BACKTEST GRAFİĞİ	283
GRAFİK 62. KARAR AĞACI BACKTEST GRAFİĞİ	284

SİMGELER VE KISALTMALAR

ACF : Auto-Correlation Function

ACF: Otokorelasyon fonksiyonu (Autocorrelation Function)

ANN: Yapay Sinir Ağları (Artificial Neural Network)

AR: Otoregresyon (Autoregression)

ARIMA: Otoregresif Hareketli Ortalamalar (Autoregressive Integrated Moving Average)

ARMA: Otoregresif Hareketli Ortalama (Autoregressive Moving Average)

b : Bias

C : Kesişim noktası

CAPM: Finansal Varlık Fiyatlama Modeli

DL : Derin Öğrenme

DT : Karar Ağacı

DVM : Destek Vektör Makineleri (SVM)

EPH: Etkin Piyasalar Hipotezi (EMH)

GBT : Gradyan Arttırıcı Ağaçlar

$\tilde{h} t$: Aday gizli durumu

$h^{\leftrightarrow} t$: Geri gizli durumu

$h^{\rightarrow} t$: İleri Gizli durumu

ht : Gizli durum

LSTM Uzun Kısa Süreli Bellek (Long- Short Term Memory)

MA Hareketli Ortalama (Moving Average)

MAE : Mean Absolute Error (Ortalama Mutlak Hata)

MAE Ortalama Mutlak Hata (Mean Absolute Error)

MAPE Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error)

MSE : Mean squared error (Ortalama Kare Hata)

MSE Ortalama Kare Hata (Mean Squared Error)

NN : Neural Network

PACF : Partial Auto-Correlation Function

PACF Kısmi Otokorelasyon fonksiyonu (Autocorrelation Function)

RF : Rastgele Orman

SARIMA: Mevsimsel Otoresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average)

SVM : Support Vector Machine (Destek vektör makinası)

W : Ağırlık

$\hat{y}$: Tahmin sonucu

YSA Yapay Sinir Ağları (Artificial Neural Network)

YZ : Yapay Zeka (AI)

$\tilde{C}_t$: Hafıza hücresini güncelle

C_t : Geçerli bellek hücresi

N : Gerçek test örneği sayısı

f_t : Unutma kapısı

i_t : Giriş kapısı

o_t : Çıkış kapısı

r_t : Sıfırlama kapısı

y : Gerçek sonuç

y_t : Güncel zaman serisi

ε_t : Rastgele Hata

GİRİŞ

Hisse senedi fiyat hareketlerinin öngörülmesi zorlu bir süreç olarak kabul edilmektedir. Borsalarda Yapay Zekâ destekli bilgisayar sistemi kullanımı, doğrusal olmayan hisse senedi fiyat hareketlerini yakalayabilme özelliği nedeniyle istatistiksel finansal zaman serisi analizi yöntemleri yerine kullanılan yaygın bir yöntem haline gelmiştir. Bu çalışmada Yapay Zekâ Makine öğrenmesi teknik ve modellerinin günlük hisse senedi fiyat hareketlerinin oluşturduğu finansal veri dizilerinin içindeki karmaşık ve doğrusal olmayan ilişkiyi ortaya çıkartıp, hisse senedinin belirlenen süre sonraki fiyatını doğruluk performansı yüksek bir ölçüde öngörülebilir mi sorusuna yanıt aramak ve literatüre katkıda bulunmak amacıyla, finansal yatırım araçlarından olan ve karlılık potansiyeli ile ön plana çıkan hisse senetlerinin çeşitli matematiksel model ve algoritmaların oluşturduğu çeşitli makine öğrenme teknikleriyle gün öncesi fiyat tahmini elde etmek ve sonuçların performans değerlemesini yapmak hedeflenmiştir.

Borsa İstanbul 30 endeksinde yer alan şirketlerin 18 yıllık işlem gününü kapsayan açılış, en yüksek, en düşük ve kapanış fiyatlarına ek olarak günlük hacim bilgileri Borsa İstanbul'un lisanslı veri sağlayıcısı olan Matriks veri terminalinden Excel dosyası olarak indirilecektir. Elde edilen hisse senetlerinin fiyat hareketlerinin oluşturduğu Excel dosyası makine öğrenme analizi için gerekli şartları sağlaması doğrultusunda düzenlemeleri yapılacaktır. BigML ve RapidMiner yapay zeka programları ile 5 farklı makine öğrenme modeliyle (Karar Ağacı, Derin Öğrenme, Rastgele Orman, Destek Vektör Makineleri ve Gradyan Arttırma Ağaçları) analiz edilip, sonuçların yorumlanması, BigML Holt-Winters zaman serisi tahmini sonuçları ve Eviews programı kullanılarak elde edilen Arima sonuçlarıyla karşılaştırılması bunlara ek olarak kendi yazılımımız olan bir yapay zeka algoritması 5 li karşılaştırma ve sonuç analizi. Bu yapılan analiz yöntemlerine ek olarak bu konuyla ilgili doğrudan ve dolaylı bileşenlerinin literatür taraması yapıp, literatürün genel bir özetinin sunulmasını kapsayan bir tez çalışmasıdır.

Bu tezin temel amacı literatürde yapay zeka sistemi kullanılarak zaman serisinin belirlenen süre sonraki değerini tahmin eden makine öğrenme tekniklerini tanıtmak ve başarılı tahmin gücü performansı olduğu düşünülen beş makine öğrenme

tekniklerinin kendi yazılımımızı kullanarak Borsa İstanbul 30 endeksi üzerinde 1 yıllık sureyi kapsayacak şekilde test etmek, elde edilen sonuçların doğruluk performansları ölçölüp ve değlerlenmesi sonucu ortaya çıkacak en yüksek öngörü gücüne sahip makine öğrenme tekniklerini bulmaktır.

Bu tez çalışmasının birinci bölümünde borsa, hisse senedi değeri ve öngörülebilirliği, hisse senedi analiz yöntemleri, risk ve davranışsal finans konuları ele alınmıştır. İkinci bölümünde zeka, yapay zeka ve makine öğrenimi teknikleri incelenmiştir. Üçüncü bölümde borsalarda yapay zeka kullanılmasına ilişkin akademik çalışmalara değinilmiştir. Dördüncü bölümde yapay zeka yöntemleriyle hisse senedi fiyatının öngörölmesi üzerine yapılan ampirik çalışmamız işlenmiş olup ve son olarak beşinci bölümde yapılan ampirik çalışma değlendirilmiştir.

I. BÖLÜM

HİSSE SENEDİ TEMEL KAVRAMLAR

Finans alanında borsa kadar ilgi çekici çok az konu vardır. Kökeni yüzyıllar öncesine dayanan, bugün alışık olduğumuz finansal sistemin arka planını oluşturuyor. Çoğu kişi borsayı hareketli tacirler ve dalgalanan rakamlarla ilişkilendirse de bunun ardındaki temel fikir basit: bir şirketten hisse satın almak. Ancak yine de BIST30 endeksi örnek olarak incelendiğinde, bu basitliğin altında bir karmaşıklıklar ağının yattığı fark ediliyor. Hisse senedi piyasasında her yerde var olan bir hayalet olan risk, yekpare bir kavram değildir. Daha geniş ekonomik ve jeopolitik olaylardan etkilenen kaçınılmaz sistematik riskler ve doğası gereği daha çok şirkete özgü olan sistematik olmayan riskler vardır. Yatırımcılar bilinçli kararlar vermek için genellikle hisse senetlerinin 'değerine' bakarlar. Peki değeri gerçekten oluşturan şey nedir? Nominal değer mi, mevcut piyasa değeri mi, bir şirketin mali tablolarından elde edilen defter değeri mi, yoksa bir şirket bugün iflas ederse kalacak olan değer mi? Bu karmaşıklıkların ortasında bir soru ortaya çıkıyor: Hisse senedi değerleri tahmin edilebilir mi? Rastgele Yürüyüş Hipotezi gibi bazı teoriler, hisse senedi fiyatlarının rastgele ve öngörülemez olduğunu ileri sürmektedir. Aksine, Etkin Piyasa Hipotezi, tüm bilgilerin halihazırda hisse senedi fiyatlarına dahil edildiğini ve bu durumun piyasayı yenmeyi zorlaştırdığını öne sürüyor. Ancak finansal anomaliler bu inanışlara meydan okuyor ve potansiyel piyasa verimsizliklerine işaret ediyor. Davranışsal finans alanında özetlenen yatırımcı psikolojisi, rasyonel veya irrasyonel davranışların piyasayı nasıl etkileyebileceğine dair içgörüler sunar. Bazı yatırımcılar temel analiz kullanarak ekonomik faktörleri, sektör eğilimlerini ve şirket özelliklerini titizlikle değerlendirirken, diğerleri teknik analizde kalıplara ve grafiklere güvenir, ancak ikincisinin etkinliği genellikle tartışılır.

Modern hisse analizinde istatistiksel yöntemlerin kullanımında bir artış görüldü. Otoregresif Model veya daha gelişmiş ARIMA gibi teknikler, gelecekteki potansiyel hisse senedi fiyat hareketlerini öngörmek için geçmiş verileri kullanır. Sayıların, kalıpların ve insan psikolojisinin etkileşimi, bu bölümde incelendiği gibi borsayı sürekli gelişen bir ortam haline getiriyor.

1.1. Borsanın Tanımı ve Tarihi

Borsa; alıcıların ve satıcıların veya temsilcilerinin ticaret yapmak için bir araya geldikleri, belirli kurallar çerçevesinde işleyen organize bir sistemdir. Emtia, menkul kıymetler veya değerli olarak algılanan diğer malları içeren işlemlerde (Al-Sat) bulunurlar. Bu alışverişler önceden belirlenmiş zamanlarda, bu amaçla kurulmuş fiziksel veya sanal lokasyonlarda gerçekleşir. Bu sistem, ticareti etkin bir şekilde kolaylaştırarak benzer mal veya varlıkların alım satımına izin verir¹. Genel olarak, borsa veya hisse senedi piyasası olarak da bilinen borsa, halka açık şirketlerin hisselerinin alınıp satıldığı bir sistemdir. Şirketlere sermaye sağlamak ve yatırımcılara bu şirketlerde hisse sahibi olma ve hisse fiyatının veya temettülerin değerlendirilmesi yoluyla potansiyel olarak yatırımlarından getiri elde ve yatırımcılara zenginlik yaratma fırsatı sunmak için önemlidir. Hisse senedi piyasasını, firmaların düşük hisse senedi piyasası getirilerinden önce ve yüksek getirileri takiben hisse senedi ihraç etme eğiliminde oldukları bir yer olarak tanımlanabilmektedir². Borsa küresel ekonominin temel bir bileşenidir ancak piyasa oynaklığına ve spekülasyona maruz kalması nedeniyle karmaşık ve sürekli gelişen bir sistemdir. Borsa üzerine çalışmalar finans, ekonomi ve matematik gibi çeşitli disiplinleri kapsar. En yaygın araştırma alanları arasında piyasa verimliliği, hisse senedi değerlendirilmesi, risk yönetimi, portföy yönetimi ve davranışsal finans yer alır. Birçok akademik kurum ve kuruluş borsa ile ilgili araştırmalar yapmakta ve konuya yönelik çok sayıda yayın ve dergi bulunmaktadır.

Borsanın tanımı, konuyla ilgili farklı görüş ve bakış açıları ile akademisyenler arasında genellikle bir tartışma konusudur. Genel olarak borsanın, yatırımcıların halka açık şirketlerin hisselerini alıp satabilecekleri bir pazar yeri olduğu söylenebilir. Ancak

¹ Gülsoy, Ufuk. *İstanbul Ticaret Borsası 1924-2014*. İstanbul Ticaret Borsası, 2014.s1

² Baker, Malcolm P., Ryan Taliaferro, and Jeffrey Wurgler. "Pseudo Market Timing and Predictive Regressions." NBER Working Paper No. w10823. October 2004.s 1

tanım, bu basit açıklamanın ötesine geçer ve borsanın işleyişini anlamak için kritik olan çeşitli bileşenleri içermektedir. Borsayı tanımlayan önde gelen akademisyenlerden biri, Princeton Üniversitesi'nde ekonomi profesörü ve "A Random Walk Down Wall Street" kitabının yazarı Burton G. Malkiel'dir. Borsa şirketlerde mülkiyeti temsil eden menkul kıymetlerin alım satımı yoluyla sermaye tahsis etme mekanizmasıdır, bu tanımda hisse senedi piyasasının yatırımcılar ve şirketler arasındaki sermaye akışını kolaylaştırmada oynadığı temel rolü vurgulamaktadır. Yatırımcılar hisse satın alarak şirketlere sermaye sağlarlar ve bu fonları büyüme, araştırma, geliştirme veya operasyonları için kritik olan diğer faaliyetleri finanse etmek için kullanabilirler. Bu sermayenin sağlanması karşılığında, yatırımcılar şirketin karından bir pay alırlar ve zaman içinde hisselerinin değerinde potansiyel değer artışı elde ederler³.

Borsanın tanımını yapan bir diğer akademisyen, Yale Üniversitesi'nde ekonomi profesörü ve "Irrational Exuberance" kitabının yazarı Robert J. Shiller'dir. Borsa yatırımcıların gerçek kaynaklar üzerinde finansal hak taleplerini alıp satmalarına izin veren sosyal bir kurumdur. Borsanın sosyal ve kurumsal yönlerini vurgulamak istersek insan davranışının ve duygularının piyasa sonuçlarını şekillendirmede oynadığı rol ön plana çıkmaktadır. Yatırımcıların her zaman rasyonel olmadığını ve yatırım kararlarını etkileyebilecek önyargılara ve diğer psikolojik faktörlere tabi olabileceğini savunuyor. Sonuç olarak borsa, fiyatların altta yatan temel unsurlar tarafından desteklenmeyen seviyelere yükseldiği irrasyonel taşkınlık dönemlerinin yanı sıra fiyatların asıl değerlerinin altına düştüğü irrasyonel karamsarlık dönemleri yaşayabilir⁴. Genel olarak Malkiel ve Shiller tarafından sağlanan tanımlar borsa hakkında farklı bakış açıları sunar; Malkiel sermaye tahsisi için bir mekanizma olarak rolünü ve Shiller ise onun sosyal ve kurumsal yönlerini vurgular. Her iki tanım da borsanın karmaşıklığını ve performansını etkileyebilecek çeşitli faktörleri anlamamıza yardımcı olması açısından değerlidir.

Borsa kavramı eski Roma'ya kadar uzanır. MÖ 180'de Roma İmparatorluğu'nda ilk borsa kuruldu. Antik Roma'da Romalılar büyük bir sıklıkta birbirlerine borç para verirdi. Bu kredilerden bazıları tacirlerin, özellikle gemicilik ve

³Malkiel, Burton G. A Random Walk Down Wall Street: The Time-Tested Strategy for Successful Investing. 12th edition. New York: W. W. Norton & Company, 2019.

⁴Shiller, Robert J. Irrational Exuberance. 2nd edition. Princeton University Press, 2005.

deniz ticareti ile ilgili ticari faaliyetlerini finanse etmek için kullanılıyordu diğerleri üretim veya tüketimi finanse etmek içindi⁵. Teminat, belirli bir tarihte bir borcu geri ödemeyi taahhüt eden yazılı bir belgedir ve fœnus nauticum durumunda, ticaret için mal ve gemi alımını finanse etmek için menkul kıymetler kullanılmıştır. Tacirler, borç verenlerden borç para alarak ve yatırımcılar tarafından alınıp satılan menkul kıymetler ihraç ederek yatırımlarından getiri elde etmeye çalıştı. Menkul kıymetler genellikle ticaretle ilgili malların veya gemilerin değeriyle destekleniyordu ve menkul kıymetlerin faiz oranı ticaretle ilgili risk düzeyine bağılı olarak değışiyordu. Orta Çağ'da, değerli metallerin bir değışim aracı olarak kullanıldığı Avrupa çapında pazar yerleri ve fuarlar kuruldu. Bu, "para değıştiriciler" mesleğinin ortaya çıkmasına yol açtı. Bu fuarların popülaritesi arttıkça ve ticari faaliyetler arttıkça "bono" veya "polis" olarak bilinen ticari kambiyo senetleri, büyük ölçekli ticarete tercih edilen bir ödeme yöntemi haline geldi. Sonunda 13. yüzyılda kambiyo senetleri ticari işlemlerde tercih edilen bir ödeme yöntemi haline geldi. 15. yüzyılda, kambiyo senetlerini hazırlamak ve ticaretini yapmak için "kuryeler" olarak bilinen aracılar ortaya çıktı. Bu profesyonellerin faaliyetlerini düzenlemek ve bu loncalar içinde belirli kurallar oluşturmak için de loncalar kurulmuştur. "Borsa" kelimesi, 1531'de Bruges veya Antwerp'te ilk sürekli fuarı düzenleyen Van der Beurs ailesinin adından gelmektedir. Antwerp'teki ilk fuar 1460 yılında kuruldu ve "Beursvan Antwerpen" (Antwerp Borsası) adını aldı⁶. Ancak borsa, Hollanda hükümetinin İspanya'ya karşı savaş çabalarını finanse etmek için tahvil ihraç etmeye başladığı 16. yüzyılın ortalarına kadar menkul kıymet alım satımına başlamadı. 16. yüzyılın ilk yıllarında Antwerp uluslararası ticaret için önemli bir merkez haline geldi. Avrupa'nın her yerinden ve ötesinden tüccarlar, çeşitli malları alıp satmak için şehre akın etti ve bu da sofistike bir finansal sistemin ortaya çıkmasına yol açtı. Borsa, gemi yapımı ve Hollanda Doğu Hindistan Şirketi'nin gelişimi dahil olmak üzere çeşitli projelerin finansmanında hayati bir rol oynadı. 17. yüzyıla kadar uzanan modern borsa, 1602'de Amsterdam Menkul Kıymetler Borsası'nın ve 1801'de Londra Menkul Kıymetler Borsası'nın kurulmasıyla başlamıştır ve diğerleri gibi dünyanın dört bir

⁵ Temin, Peter. "The Economy of the Early Roman Empire." The Journal of Economic Perspectives, vol. 20, no. 1, Winter 2006, pp. 133-151. American Economic Association.s143

⁶ Lockard, Craig. Societies, Networks, and Transitions: A Global History, Volume I. 4th edition. Cengage Learning, February 13, 2020.s 340 367

yanındaki finans merkezlerinde kurulmuştur⁷. Zamanla New York, Paris Şangay ve Tokyo, gibi Avrupa'nın diğer bölgelerinde başka borsalar ortaya çıktı. Bununla birlikte Antwerp Borsası, siyasi istikrarsızlık ve ekonomik gerilemenin nihai ölümüne yol açtığı 16. yüzyılın sonuna kadar önemli bir finans merkezi olarak kaldı.

1.1.1. BİST30

26 Aralık 1985'te hizmete açılan Borsa İstanbul, ilk hisse senedi işlemlerine 3 Ocak 1986'da başlamıştır. Başlangıçta 41 halka açık şirket borsaya kote olmuş, 36 borsa üyesine alım satım imtiyazı tanınmıştır⁸. Bist30 endeksi, Borsa İstanbul'da işlem gören şirketler arasından üstün piyasa değerlerine göre seçilen 30 şirketten oluşan bir borsa endeksidir. Türkiye'deki ekonomik gelişmeleri takip etmek ve borsanın genel performansını ölçmek amacıyla Borsa İstanbul tarafından hesaplanmakta ve yayınlanmaktadır. BIST30, Borsa İstanbul'un endeksi oluşturan 30 hisse senedinin seçiminde kullandığı metodoloji ve kriterler ile tanımlanmaktadır. Bu metodoloji piyasa değeri, halka açıklık, işlem hacmi ve likidite dahil olmak üzere bir dizi nicelik ve nitelik kriterleri içermektedir. Borsa İstanbul, genel piyasanın dengeli bir şekilde temsil edilmesini sağlamak için seçilen hisse senetlerinin sektörel ve coğrafi dağılımını da dikkate almaktadır. Borsa İstanbul, BIST30 endeksini tanımlamanın yanı sıra, endeks bileşenlerini düzenli olarak gözden geçirmekte ve Türk borsasının doğru bir yansıması olarak kalmasını sağlamak için ayarlamaktadır. Bu, bireysel hisse senetlerinin piyasa kapitalizasyonundaki işlem hacimlerinin ve likiditesindeki değişikliklerin yanı sıra genel piyasa koşullarında ve ekonomik görünümde bulunan değişikliklerin izlenmesini içermektedir. Bu yaklaşım, endeksin Türk borsasının doğru bir yansıması olmaya devam etmesini sağlayarak yatırımcılara ve analistlere piyasa performansını ölçmek ve yatırım fırsatlarını değerlendirmek için faydalı bir kıyaslama sağlar.

Hisse senetlerinin BIST endekslerine alınabilmesi için gerekli olan kriterler, hisse senetlerinin değerlendirme süresinin bitiminden itibaren en az 60 gün boyunca Yıldız Pazar'da işlem görmesi ve endekste yer alan hisse senetlerinin piyasa değerinin defter

⁷ Attack, Jeremy, and Larry Neal, eds. *The origins and development of financial markets and institutions: from the seventeenth century to the present*. Cambridge University Press, 2009.

⁸ Çondur, Funda, and Arş Gör Umut EVLİMOĞLU. "İMKB'NİN İŞLEVSELLİĞİNİ ARTTIRMAYA YÖNELİK ALTERNATİF POLİTİKA ÖNERİLERİ." (2007). s 3

değerinden yüksek olması şartı aranmaktadır. BIST endekslerinde değerlendirme dönemi BIST 30, 50 ve 100 endeksleri için Ocak-Mart, Nisan-Haziran, Temmuz-Eylül ve Ekim-Aralık olmak üzere üçer aylık dönemlerdir. BIST Temettü ve Temettü 25 endeksleri, Şubat-Ocak aylarını kapsayan yılda bir kez değerlendirilir. BIST endekslerindeki değişiklikler değerlendirme tarihinden en az 10 iş günü önce KAP'ta duyurulur. Bu duyurular KAP'ta "BIST Pay Endeksleri" başlığı kullanılarak yapılır ve Borsa İstanbul internet sitesinde de yayımlanır.

1.2. Risk Kavramı

Finansta risk, yatırım kararı vermede kritik bir rol oynayan önemli bir kavramdır. Bu durumda risk, getirinin sonucunda katlanılacak olasılıklardır⁹. Hayne Leland ve Klaus Bjerre Toft'un "Finansal Kısıtlamalarla Kurumsal Risk Yönetimi ve Yatırım" adlı makalesi, finansta riskin kapsamlı bir görünümünü sunuyor. Finansta riski, kurumsal yatırım, risk yönetimi ve finansman kararları ile ilgili olanlar da dahil olmak üzere çeşitli belirsizliklere maruz kalmaktan kaynaklanan kayıp potansiyeli olarak tanımlarlar. Özellikle dış finansman maliyetlerinin varlığında bu kararların iç içe geçtiğini vurgulamaktadırlar. Makale ayrıca, firmaların yatırımları finanse etme maliyetlerini düşürmede kurumsal risk yönetiminin rolünü tartışıyor¹⁰. Temel olarak risk, yatırımın geri dönüşüyle ilgili belirsizlik veya değişkenlik olarak tanımlanabilir. Bu nedenle, yatırımcılar bilinçli bir karar vermeden önce bir yatırımla ilişkili risk düzeyini değerlendirmelidir. Risk; piyasa koşulları, ekonomik faktörler, finansal istikrar ve yatırım getirisini etkileyebilecek diğer faktörler gibi çeşitli kaynaklardan kaynaklanabilir.

Risk, finans alanındaki en önemli kavramlardan biridir ve onu tanımlamaya yönelik çeşitli akademik yaklaşımlar vardır. En yaygın kullanılan ve kabul gören yaklaşımlardan biri 1952'de Harry Markowitz tarafından ortaya atılan Modern Portföy Teorisidir (MPT). MPT'ye göre risk, getirilerin değişkenliği ile ölçülebilir ve beklenen getiri ile ilişkili belirsizliğin derecesidir. MPT ayrıca yatırımcıların yalnızca bireysel varlıkların riskini değil, aynı zamanda portföylerinin tamamının riskini de dikkate

⁹ Usta, Öcal : İşletme Finansı ve Finansal Yönetim, Ankara, Detay Yayıncılık, 5. Baskı, 2012.s 253

¹⁰ Patrick Bolton, Hui Chen, and Neng Wang. "A Unified Theory of Tobin's q, Corporate Investment, Financing, and Risk Management." The Journal of Finance, vol. LXVI, no. 5, October 2011..s1545 1546

almaları gerektiğini önermektedir. Markowitz, yatırımcıların farklı risk seviyelerine sahip farklı varlıklar arasında yatırımları çeşitlendirerek getirilerden ödün vermeden portföy risklerini azaltabileceklerini savundu. Bu kavram genellikle "çeşitlendirme etkisi" olarak bilinir¹¹. Riski tanımlamaya yönelik bir başka akademik yaklaşım 1964 yılında William Sharpe tarafından ortaya atılan Sermaye Varlıkları Fiyatlandırma Modelidir (CAPM). William Sharpe'in 1964 tarihli "Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk" adlı makalesi, yatırımcıların beklenen getiri ve risklerine göre varlıkların fiyatlandırılması üzerine açıklamalar içeren finansal varlık fiyatlama modeli (CAPM) modelini sunmuştur. Sharpe, yatırımcıların riskten kaçındığını ve daha riskli varlıkları tutmak için daha yüksek bir getiri talep ettiğini, bu durumun da daha yüksek riskli varlıkların fiyatını artırdığını savunmuştur. Sharpe, bir varlığın riskini getirilerinin oynaklığı olarak tanımlamış ve tüm piyasa varlıklarını içeren iyi çeşitlendirilmiş bir portföyün, sistematik olmayan riski veya şirket özel riskini hariç tutarak yalnızca sistematik veya piyasa riskini bırakabileceğini göstermektedir. Sharpe, yatırımcıların sistemik riski almaları karşılığında tazmin edilmeleri gerektiğini savunmuş ve bu, piyasa risk primi olarak yansıtılan piyasanın beklenen getirisine oranla risksiz faiz oranı arasındaki fark ile gösterilir¹².

Finansta riski tanımlamaya yönelik diğer yaklaşımlar arasında 1976'da Stephen Ross tarafından ortaya atılan Arbitraj Fiyatlandırma Teorisi (APT) ve 1992'de Eugene Fama ve Kenneth French tarafından ortaya atılan Fama-French Üç Faktör Modeli yer alır. APT, riskin çok faktörlü olduğunu öne sürer¹³. Bir yatırımın beklenen getirisinin birden fazla sistematik faktöre maruz kalmasıyla belirlendiği Fama- French Üç Faktör Modeli, farklı hisse senetleri arasındaki getirilerdeki değişimi açıklamak için CAPM'ye boyut ve değer olmak üzere iki ek faktör ekler¹⁴.

Sonuç olarak, finansta riski tanımlamaya yönelik Modern Portföy Teorisi, Sermaye Varlıkları Fiyatlandırma Modeli, Arbitraj Fiyatlandırma Teorisi ve Fama-

¹¹Harry Markowitz. "Portfolio Selection." The Journal of Finance, vol. 7, no. 1, March 1952, pp. 77-91.s77 89

¹²William F. Sharpe. "Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk." The Journal of Finance, vol. XIX, no. 3, September 1964. ss431-432

¹³Stephen A. Ross. "The Arbitrage Theory of Capital Asset Pricing." Journal of Economic Theory, vol. 13, no. 3, 1976, pp. 341-360. s353

¹⁴Eugene F. Fama, Kenneth R. French. "The Cross-Section of Expected Stock Returns." The Journal of Finance, vol. 47, no. 2, June 1992, pp. 427-465. s452

French Üç Faktör Modeli dahil olmak üzere çeşitli akademik yaklaşımlar vardır. Her yaklaşımın güçlü ve zayıf yönleri vardır ve yatırımcılar kullanacakları bir risk ölçüsü seçerken yatırım hedeflerini ve risk toleranslarını göz önünde bulundurmalıdır.

Bireylerin finansal piyasalarda aldıkları yatırım kararları, belirsiz ve spesifik olmayan yapıların risklerini yani yatırımlardan elde etmeyi umdukları getiri ve sermaye ile ilgili bazı tehlikelerin risklerini taşır. Bu tehlikeler, farklı yatırım türleriyle ilişkili riskleri dikkatli bir şekilde değerlendirerek ve yöneterek hafifletilebilir. Yatırım kararları verirken, yatırımcıların anlaması gereken sistematik ve sistematik olmayan risk kavramları ve birkaç risk alt kategorisi vardır. Bunlar, piyasa riski, kredi riski, likidite riski, operasyonel risk ve faiz oranı riskini içermektedir. Finansal riski anlamak, yatırımcıların yatırım kararları vermeden önce göz önünde bulundurması gereken önemli bir kavramdır. Temelde risk, bir yatırımın geri dönüşünün belirsizliği veya değişkenliği ile ilişkilidir ve piyasa koşulları, ekonomik faktörler ve finansal istikrar gibi çeşitli kaynaklardan kaynaklanabilir. Bilgiye dayalı yatırım kararları vermek için yatırımcıların piyasa, kredi, likidite, operasyonel ve faiz oranı riski gibi farklı risk alt kategorilerini anlamaları gerekir. Yatırımcılar, portföylerini çeşitlendirerek, pozisyonlarını koruyarak ve piyasa koşullarını izleyerek riski etkin bir şekilde yönetebilir ve zaman içinde getirilerini maksimize edebilir. Yatırımcılar, bilinçli yatırım kararları vermeden önce farklı risk türlerini değerlendirmeli ve yönetmelidir. Farklı riskler yatırımları farklı şekillerde etkileyebilir ve yatırımcılar yatırımlarının risk-getiri değiş tokuşu konusunda net bir anlayışa sahip olmalıdır. Yatırımcılar; portföylerini çeşitlendirerek, pozisyonlarını koruyarak ve piyasa koşullarını izleyerek riski etkin bir şekilde yönetebilir ve zaman içinde getirilerini maksimize edebilir. Literatür incelendiğinde ilgili çalışmalarda, sistematik riski ölçen piyasa beta ile hisse senedi getirileri arasındaki ilişkiyi incelemektedir. Çalışmalar, piyasada daha fazla risk almanın daha yüksek getiri sağlayabileceğini gösteriyor. Bununla birlikte beta ve hisse senedi getirileri arasındaki ilişki doğrusal değildir, bu da gelişmekte olan pazarlarda risk-getiri ilişkisinin basit olmadığını düşündürmektedir.

1.2.1. Sistematik Risk

Sistematik risk finasta önemli bir kavramdır. Sistematik risk, tüm yatırımları, sektörleri ve ülkeleri etkileyebilecek risktir. Sistemdeki tüm bileşenlerin riski olarak da tanımlanabilmektedir¹⁵. Yatırımlarla ilgili belirsizlik veya değişkenlik; faiz oranlarındaki değişiklikler, enflasyon, siyasi olaylar ve ekonomik durgunluklar gibi makroekonomik faktörlerden kaynaklanan bir risk olarak tanımlanır. Sistemik risk olarak da bilinen piyasa riski, bir yatırımın değerini etkileyebilecek piyasa koşulları ve makroekonomik faktörlerden kaynaklanan kayıp riskidir. Örneğin, bir şirketin hisse senetleri, durgunluk, siyasi istikrarsızlık veya döviz kurlarındaki değişiklikler gibi olumsuz ekonomik koşullar nedeniyle değer kaybedebilir. Sistematik risk, piyasaları etkileyen bir risk olduğu için tüm piyasayı etkiler ve çeşitlendirme ile tamamen önlenemez. Beta ile ölçülen sistematik risk, bir varlığın getirilerinin genel piyasaya olan duyarlılığını ölçer. Beta değeri 1'den büyük olanlar varlığın getirilerinin piyasadan daha volatil olduğunu, beta değeri 1'den küçük olanlar ise varlığın getirilerinin piyasadan daha az volatil olduğunu gösterir. Yatırımcılar, beta katsayısını bir varlığın riskini genel piyasaya kıyaslamak için bir araç olarak kullanabilirler. Genel olarak yüksek beta değerleri daha yüksek düzeylerde sistemik riski, düşük beta değerleri ise daha düşük düzeylerde sistemik riski gösterir. Sistematik risk tamamen önlemez, ancak yatırımcılar farklı varlık sınıfları ve sektörler arasında portföylerini çeşitlendirerek yönetebilirler. Ek olarak yatırımcılar sistemik riskten korunmak için vadeli işlemler ve opsiyonlar gibi finansal araçları kullanabilirler.

Sistematik risk, finasta çok önemli bir kavramdır. Birçok akademisyen tanımlamaya ve kavramın anlaşılmasına katkıda bulunmuştur. Sistematik risk çalışmasına en çok tanınan ve etkili katkıda bulunanlardan biri, 1990'da Ekonomi alanında Nobel Ödülü alan William Sharpe'dir. Sharpe, sistematik riski tüm piyasanın veya belirli bir varlık sınıfının doğasında bulunan ve çeşitlendirilmiş bir portföye yatırım yaparak çeşitlendirilemeyen risk olarak tanımladı. Ayrıca sistematik riski ölçmenin bir yolu olarak bir varlığın piyasa hareketlerine duyarlılığını ölçen beta kavramını da tanıttı. Beta, belirli bir menkul kıymetin uygun şekilde çeşitlendirilmiş bir

¹⁵ Thomas Ilin and Liz Varga. "The Uncertainty of Systemic Risk." Risk Management, vol. 17, 2015, pp. 240-275.

yatırım portföyüne katkıda bulunduğu risk derecesini temsil eder¹⁶. Sharpe "Sermaye Varlık Fiyatları: Risk Koşulları Altında Piyasa Dengesi Teorisi" adlı ufuk açıcı makalesinde, yatırımcıların daha yüksek sistematik riske sahip varlıkları elde tutmak için daha yüksek getiriye ihtiyaç duyduklarını ve piyasadaki tüm varlıklardan oluşan piyasa portföyünün yatırımcılar için en uygun portföy olduğunu savundu¹⁷. Farklı akademisyenlerde, sistematik riskin tanımını ve anlayışını daha da geliştirmek için Sharpe'ın çalışmalarını temel aldılar. Örneğin; Eugene Fama ve Kenneth French, hisse senedi getirilerinin kesitini açıklamanın bir yolu olarak piyasa riski- büyüklük riski- değer riskini içeren üç faktörlü modeli geliştirdi. Daha yüksek piyasa betasına sahip hisse senetlerinin veya sistematik riske maruz kalmanın, daha düşük piyasa betasına sahip hisse senetlerinden daha yüksek getiri sağlama eğiliminde olduğunu bulmuşlardır. Genel olarak, sistematik riskin akademik tanımı, onun çeşitlendirilemez doğasını ve varlık fiyatları ve getirileri üzerindeki etkisini vurgular. William Sharpe'ın katkıları geniş çapta tanınmak ve etkili olmakla birlikte, diğer akademisyenler sistematik risk kavramını iyileştirmeye ve genişletmeye devam ederek finansal riski anlama ve yönetmedeki önemini vurgulamıştır.

Sistematik riskin yatırım portföyü üzerindeki etkisi yatırımcının risk toleransı, yatırım hedefleri ve zaman aralığı gibi birçok faktöre bağlı olarak değişebilir. Uzun vadeli yatırımcılar, piyasa dalgalanmalarını göz önünde tutarlar. Sistematik risk aynı zamanda iş döngüsüyle de ilgilidir çünkü enflasyon, faiz oranları ve tüketici güveni gibi ekonomik koşullar genel piyasada önemli bir etkiye sahip olabilmektedir. Örneğin; bir ekonomik durgunluk döneminde piyasa varlık fiyatlarında düşüş yaşar ve yatırımcılar genellikle riskten kaçınarak yüksek beta varlıklara olan taleplerini azaltır. Buna karşılık ekonomik genişlemeler sırasında yatırımcılar daha riskli yatırımlara daha yüksek talep gösterirler, bu da yüksek beta varlıklara olan talebin artmasına neden olur.

Özetle; sistematik risk, makroekonomik faktörlerden kaynaklanan bir yatırımın getirilerini etkileyen finasta kritik bir kavramdır. Piyasa riski olarak da bilinen sistematik risk, toplam riskin kaynaklarından biridir. Ticari bir şirketin

¹⁶ Fischer Black and Myron Scholes. "The Pricing of Options and Corporate Liabilities." Journal of Political Economy, vol. 81, no. 3, May - June 1973, pp. 637-654. The University of Chicago Press.

¹⁷Sharpe, a.g.m., s. 436.

çeşitlendirilemeyen bireysel dinamiklerinden ziyade tüm şirketleri etkileyen durgunluk, savaş, enflasyon, yüksek faiz gibi dış etkenlerden kaynaklanmaktadır. Bu risk, doğası gereği tamamen dışsaldır ve bir şirketin benzersiz dinamiklerine özgü olmaktan ziyade tüm şirketleri etkiler¹⁸.

1.2.1.1. Piyasa Riski

Piyasa riski, bir şirketin kontrolü dışındaki faktörler nedeniyle piyasa fiyatlarında meydana gelebilecek değişikliklerden kaynaklanabilecek potansiyel finansal kayıpları ifade eder. Bu tür faktörler, seçimler, artan siyasi faaliyet, bir liderin hastalığı veya ölümü, bir savaşın patlak vermesi veya aniden sona ermesi veya diğer beklenmedik olaylar gibi siyasi olayları içerebilir. Piyasa riski, bu tür faktörler piyasayı etkilediğinde bir risk kaynağı olarak kabul edilebilir. Örnek verecek olursak herhangi bir ekonomik yavaşlama; tüketici davranışındaki değişiklikler veya bir savaşın aniden ortaya çıkması ya da durması, menkul kıymetler piyasalarını ve bunların getirilerini etkileyebilmektedir. Bu etki talep ve beklentilerdeki değişikliklerden kaynaklanmaktadır. Piyasa riskinden kaçınan bireysel bir yatırımcı, almayı düşündüğü menkul kıymet fiyatının piyasa dalgalanmalarına olan duyarlılığını göz önünde bulundurmalıdır. Yüksek kaliteli veya istikrarlı yatırım araçları, altyapısı zayıf olan pazarlara göre piyasa risklerine karşı çok daha dayanıklıdır. Piyasa riski, her yatırımcının ve finansal analistin bir yatırımın potansiyel getirilerini değerlendirirken göz önünde bulundurduğu önemli bir faktördür. William Sharpe, John Lintner ve Jan Mossin dahil olmak üzere birçok akademisyen piyasa riskinin tanımına ve anlaşılmasına katkıda bulunmuştur. Ekonomi alanında Nobel ödüllü William Sharpe, 1964 yılında piyasa riskini ölçmeye yardımcı olan finansal varlık fiyatlama modeli (CAPM) tanıttı¹⁹. CAPM, bir varlığın toplam riskinin çeşitlendirilemeyen kısmı olan sistematik riskine dayalı olarak bir yatırımdan beklenen getiriyi belirlemek için finasta yaygın olarak kullanılır. Sharpe'a göre piyasa riski, piyasanın kendisinde var olan ve çeşitlendirme yoluyla ortadan kaldırılamayan risktir. CAPM, yatırımcıların risksiz getiri oranına eklenen bir risk primi kazanarak piyasa riskini aldıkları için tazmin edildiğini iddia

¹⁸ A. Ceylan, T. Korkmaz, Sermaye Piyasası ve Menkul Değerler Analizi, Ekin Kitapevi, Bursa, Nisan2004

¹⁹ Sharpe, a.g.m., s. 436.

etmektedir²⁰. John Lintner, bir varlığın piyasa riskine duyarlılığını ölçen beta kavramını tanıtarak CAPM'yi daha da geliştirdi. Beta, bir varlığın genel piyasa ile ilgili oynaklığının bir ölçüsüdür ve bir varlığın beklenen getirilerini tahmin etmek için kullanılır. Lintner'a göre daha yüksek betaya sahip bir varlık, piyasa dalgalanmalarına daha duyarlı olduğundan ve dolayısıyla piyasa riskine daha fazla maruz kaldığından daha yüksek beklenen getiriye sahip olacaktır²¹. Jan Mossin, ortalama varyans analizi kavramını tanıtarak piyasa riskinin anlaşılmasına da katkıda bulunmuştur. Mossin, yatırımcıların öncelikle iki faktörle ilgilendiğini savundu: beklenen yatırım getirisi ve bu yatırım ile ilişkili risk. Ortalama varyans analizi, yatırımcıların belirli bir risk seviyesi için beklenen getiriye maksimize eden en uygun portföyü bularak risk tercihlerine dayalı olarak yatırım kararları vermelerine olanak tanır²².

Piyasa riskinin akademik anlayışı genel olarak Sharpe, Lintner ve Mossin'in çalışmaları tarafından şekillendirilmiştir. Katkıları, yatırımcıların ve finansal analistlerin piyasa riskini daha iyi anlamalarını ve ölçmelerini sağlayan yaygın olarak kullanılan modellerin ve kavramların geliştirilmesine yardımcı olmuştur.

Piyasa riskine ilişkin akademik araştırmalar, bu riski ölçmek, yönetmek ve azaltmak için modeller ve araçlar geliştirmeye odaklanır. Bu araştırma genellikle piyasa verilerini analiz etmek, risk kaynaklarını belirlemek, risk ve getiri için daha iyi ayarlanmış portföyler oluşturmak amacıyla gelişmiş istatistiksel ve ekonometrik teknikleri kullanmayı içermektedir. Araştırmacılar ayrıca piyasa riskinin tüketim, yatırım ve ekonomik büyüme gibi çeşitli ekonomik değişkenler üzerindeki etkisini incelemekte olup, para ve maliye politikaları gibi politika müdahalelerinin piyasa riskini azaltmadaki rolünü araştırmaktadır.

1.2.1.2. Kur Riski

1973 yılında Bretton Woods sisteminin tasfiyesi ve ABD dolarının altın standardının sona ermesi, döviz kuru riski yönetiminin geliştirilmesini zorunlu

²⁰Sharpe, a.g.m., ss. 425-442.

²¹John Lintner. "The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets." The Review of Economics and Statistics, vol. 47, no. 1, February 1965, pp. 13-37. The MIT Press.

²²Jan Mossin. "Equilibrium in a Capital Asset Market." Econometrica, vol. 34, no. 4, October 1966, pp. 768-783. The Econometric Society.

kılmıştır²³. Bu deęişiklik, küresel finansal sisteme bir dereceye kadar belirsizlik getirdi ve döviz dalgalanmalarıyla ilişkili potansiyel riski azaltmak için stratejiler geliştirmeyi zorunlu hale getirdi. Döviz kuru riski olarak da bilinen kur riski, işlem veya yatırımların birden fazla para birimini içerdęi durumlarda döviz kurlarındaki dalgalanmalardan kaynaklanabilecek olası finansal kayıpları ifade etmektedir. Akademik bağlamda kur riski; sınır ötesi ticaret veya yatırımla uğraşan bireyler, şirketler ve hükümetler için önemli bir konu olduğundan genellikle uluslararası finans bağlamında incelenir. Döviz kuru riskine ilişkin akademik araştırmalar, bireylere ve kuruluşlara bu riski yönetmede yardımcı olacak teorik modeller geliştirmeye ve döviz hareketlerinin hisse senedi fiyatları, faiz oranları ve ticaret akışları gibi çeşitli finansal deęişkenler üzerindeki etkilerini keşfetmeye odaklanır. Bu çalışmalar, büyük veri setlerini analiz etmek, kur riskinin doğası ve belirleyicileri hakkındaki hipotezleri test etmek için genellikle gelişmiş istatistiksel ve ekonometrik teknikler kullanır. Kur riski, bir şirketin yabancı bir tedarikçiden mal veya hizmet satın alması, bir kişinin yabancı bir hisse senedine veya bonoya yatırım yapması, bir devletin yabancı para cinsinden borçlanması gibi çeşitli şekillerde ortaya çıkabilir. M. Ayhan Köse, Eswar S. Prasad, Kenneth S. Rogoff ve Shang-Jin Wei'nin "Finansal Küreselleşme: Yeniden Deęerlendirme" adlı makalesi, kur riski de dahil olmak üzere finansal risklerin kapsamlı bir analizini sunuyor. Kur riskini, döviz kurlarındaki deęişikliklerden kaynaklanan kayıp potansiyeli olarak tanımlarlar. Yazarlar, önemli ölçüde dış borcu olan ülkelerin, özellikle de borç döviz cinsinden olduğunda kur riskiyle karşı karşıya olduğunun altını çizmektedir. Ayrıca, yatırımcıların para biriminin deęer kaybetme riskini telafi etmek için talep ettięi ek getiri olan "kur riski primi" kavramını da tartışmaktadırlar²⁴. Pasquale Della Corte, Steven J. Riddiough ve Lucio Sarno'nun yazdığı "Döviz Deęerleri ve Küresel Dengesizlikler" başlıklı makale, kur riskini küresel dengesizlikler bağlamında tartışıyor. Kur riskini, döviz kurlarındaki dalgalanmalardan kaynaklanan potansiyel kayıplar olarak tanımlamaktadırlar. Yazarlar, net borçlu ülkelerin, para birimleri kötü zamanlarda deęer kaybettięi için negatif dış dengesizlikleri finanse etmek isteyen yatırımcıları telafi

²³ Papaioannou, M. G. (2006). Exchange rate risk measurement and management: Issues and approaches for firms. South-Eastern Europe Journal of Economics, 2, 129-146.

²⁴ M. Ayhan Kose, Eswar Prasad, Kenneth Rogoff, and Shang-Jin Wei. "Financial Globalization: A Reappraisal." IMF Staff Papers, vol. 56, no. 1, 2009, pp. 8-62.

etmek için bir kur risk primi sunduğunun altını çiziyorlar²⁵. Her durumda, döviz kurlarındaki dalgalanmalar işlemin ya da yatırımın değerini etkileyerek potansiyel olarak finansal kazanç veya kayıplara yol açabilmektedir.

1.2.1.3.Enflasyon Riski

Enflasyon riski, fiyatlardaki değişimler nedeniyle satın alma gücünde ve kazançta meydana gelebilecek potansiyel kaybı ifade eder. Enflasyon oranı belirsiz bir kavramdır ve bu belirsizlik yatırımları olumsuz etkileyebilmektedir. Bu nedenle enflasyon miktarı yatırımcılar için bir tehlike veya risk oluşturmaktadır. Tahvil veya geri alım anlaşmaları gibi sabit getirili yatırımlar, satış kârları ile orantılı olarak fiyatı artabileceği için satın alma gücü erozyonuna karşı daha dayanıklı olan hisse senetlerine göre enflasyondan çok daha fazla etkilenir. Finansta enflasyon riski çeşitli uzmanlar ve akademisyenler tarafından tanımlanmaktadır. John N. Campbell, Robert J. Shiller ve Luis M. Viceira tarafından yazılan "Enflasyona Endeksli Tahvil Piyasalarını Anlamak" makalesi, tahvil piyasaları bağlamında enflasyon riskini tartışıyor. Enflasyon riskinin, yatırımların gerçek getirisini etkileyebilecek gelecekteki enflasyon oranı üzerindeki belirsizliği ifade ettiğini ima ediyorlar. Yazarlar, enflasyona endeksli tahvillerin enflasyona göre ayarlanmış bir getiri sağlayarak bu riski azaltmak için tasarlandığını ve böylece gerçekten risksiz uzun vadeli bir yatırım sunduğunu vurgulamaktadır²⁶. Bununla birlikte, enflasyon riskinin en belirgin ve yaygın olarak kullanılan tanımlarından biri finansal risk yönetimi alanından gelmektedir. Finansal risk yönetimi uzmanlarına göre enflasyon riski, enflasyon nedeniyle paranın değerinin zaman içinde düşme olasılığını ifade etmektedir. Bu risk, enflasyonun paranın satın alma gücünün düşmesine neden olabileceği ve bunun da yatırımcılar ve işletmeler için kayıplara yol açabileceği gerçeğiyle ilişkilidir. Enflasyon riski genellikle enflasyona endeksli tahviller, emtialar ve gayrimenkul yatırımları gibi çeşitli stratejilerle yönetilir. Bu stratejiler, yatırımcıların ve işletmelerin enflasyonun yatırımları ve operasyonları üzerindeki potansiyel olumsuz etkilerine karşı korunmalarına yardımcı olabilmektedir. Enflasyon riski, tüketim seviyesini ve dolayısıyla ekonomik istikrarı etkileyebilecek

²⁵ Paolo Di Corte, Steven J. Riddiough, and Lucio Sarno. "Currency Premia and Global Imbalances." *The Review of Financial Studies*, vol. 29, no. 8, 2016, pp. 2161-2193.

²⁶ John Y. Campbell, Robert J. Shiller, and Luis M. Viceira. "Understanding Inflation-Indexed Bond Markets." *Brookings Papers on Economic Activity*, vol. 40, no. 1 (Spring 2009), pp. 79-138.

enflasyon nedeniyle varlıkların gerçek deęerindeki dalgalanma ile iliřkili risk olarakta tanımlanabilir²⁷.

Finans ve ekonomi baęlamında yatırımcılar, iřletmeler ve politika yapıcılar için enflasyon riski önemli bir husustur. Enflasyon riskiyle ilgili akademik arařtırmalar; bu riski ölçmek, yönetmek veya azaltmak için modeller ve araçlar geliřtirmeye odaklanmaktadır. Bu arařtırma genellikle tarihsel enflasyon verilerinin analiz edilmesini ve enflasyon ile faiz oranları, ekonomik büyüme ve işsizlik gibi çeřitli ekonomik deęiřkenler arasındaki iliřkinin incelenmesini içermektedir. Ek olarak, arařtırmacılar enflasyon riskinin farklı varlık sınıfları üzerindeki etkisini arařtırır ve enflasyon korumalı menkul kıymetlere veya emtialara yatırım yapmak gibi enflasyon riskinden korunmak için stratejiler geliřtirir. Politika yapıcılar, faiz oranı ayarlamaları ve zorunlu karřılıklar gibi para politikası araçları aracılığıyla da enflasyon riskini yönetmede önemli bir rol oynamaktadır. Akademik olarak, çeřitli arařtırmacılar enflasyon riski kavramını, bunun finansal piyasalar ve yatırımcılar üzerindeki etkisini arařtırdılar ve enflasyon riskinin borsa getirileri üzerinde önemli bir etkiye sahip olduęunu buldular. Fama ve French (1987) tarafından yapılan başka bir çalıřma, Amerika Birleřik Devletleri'nde enflasyon ve hisse senedi getirileri arasındaki iliřkiyi inceleyerek enflasyon riskinin hisse senedi getirilerinin önemli bir belirleyicisi olduęunu ve enflasyon riskine daha yüksek maruz kalan hisse senetlerinin daha yüksek beklenen getirilere sahip olma eğiliminde olduęunu bulmuřtur²⁸. Enflasyon riski, tahviller, hisse senetleri ve emlak dahil olmak üzere farklı varlık türlerini etkileyebilir ve para arzındaki deęiřiklikler, hükümetin maliye ve para politikası ve belirli piyasalardaki arz ve talep dengesizlikleri gibi çeřitli faktörlerden kaynaklanabilir. Enflasyon riski, yatırım getirilerinin satın alma gücünü aşındırabilir ve borçlanma ve borç geri ödeme maliyetlerini artırabilir.

²⁷ Gary B. Gorton and Guillermo Ordoñez. "The Supply and Demand for Safe Assets." National Bureau of Economic Research Working Paper No. w18732, 2013. s37

²⁸ Eugene F. Fama and Kenneth R. French. "Business Conditions and Expected Returns on Stocks and Bonds." Journal of Financial Economics, vol. 25, no. 1, 1989, pp. 23-49.

1.2.1.4.Faiz Oranı Riski

Faiz oranı riski, piyasa faiz oranlarındaki değişikliklerin bir finansal aracın fiyatı üzerindeki etkisiyle ilişkili risktir. Risk, faiz ödemelerinin gerçek değerinin firmanın nakit akışı ihtiyacını karşılamaya yetmeyeceğidir. Risk aynı zamanda piyasa enstrümanının değerinin düşmesidir²⁹. Özellikle tahvil gibi sabit getirili yatırımlar için faiz oranlarındaki değişikliklerden kaynaklanabilecek potansiyel finansal kayıpları ifade eder. Akademik çalışmalarda faiz oranı riski; finans ve ekonomi bağlamında yatırımcılar, şirketler ve politika yapıcılar için önemli bir unsur olarak incelenir. Faiz oranı riskiyle ilgili akademik araştırmalar bu riski ölçmek, yönetmek veya azaltmak için modeller ve araçlar geliştirmeye odaklanır. Bu araştırma genellikle tarihsel faiz oranı verilerinin analiz edilmesini ve faiz oranları ile enflasyon, ekonomik büyüme ve para politikası gibi çeşitli ekonomik değişkenler arasındaki ilişkinin incelenmesini içermektedir. Ek olarak araştırmacılar ayrıca faiz oranı riskinin farklı varlık sınıfları üzerindeki etkisini inceler ve değişken oranlı menkul kıymetlere yatırım yapmak veya faiz oranı türevlerini kullanmak gibi faiz oranı riskinden korunmak için stratejiler geliştirir. Politika yapıcılar ayrıca faiz oranı ayarlamada ve zorunlu karşılıklar gibi para politikası araçları aracılığıyla faiz oranı riskini yönetmede önemli bir rol oynamaktadır.

Faiz oranı riski; tahviller, krediler ve ipotekler gibi farklı varlık türlerini etkileyebilir ve merkez bankası politikalarındaki değişiklikler, ekonomik büyüme ve enflasyon beklentileri gibi çeşitli faktörlerden kaynaklanabilir. Faiz oranları yükseldiğinde, yeni tahviller daha yüksek getiri sunduğundan sabit getirili yatırımların değeri düşer ve bunun tersi de geçerlidir. Bu, uzun vadeli sabit getirili menkul kıymetler tutan yatırımcılar için önemli sermaye kayıplarına neden olabilmektedir. Özet olarak faiz oranı riski, piyasa faiz oranlarındaki gelecekteki değişiklikler nedeniyle menkul kıymet fiyatları ve getirileri üzerindeki potansiyel olumsuz etkiyi ifade eder. Bu risk farklı menkul kıymetler arasında farklılık gösterebilir ve faiz oranlarındaki değişiklikler menkul kıymet fiyatlarını zıt yönlerde etkileyebilmektedir. Faiz oranı riski, finansal piyasalarda önemli bir faktördür ve farklı yatırımlar arasında getiri farklılıklarına yol açabilmektedir.

²⁹ John Y. Campbell. "Asset Pricing at the Millennium." The Journal of Finance, vol. 55, no. 4, Aug. 2000, pp. 1515-1567. Wiley.

1.2.1.5.Politik Risk

"Politik risk" terimi; siyasi olaylar veya hükümet değişiklikleri, savaş, terörizm veya mevzuattaki değişikliklerden kaynaklanan istikrarsızlıktan doğabilecek potansiyel mali kayıpları ifade eder. Akademik çalışmalarda politik risk, finans ve ekonomi bağlamında incelenir ve yatırımcılar, şirketler ve politika yapıcılar için önemli bir konudur. Finans alanındaki politik risk, hükümet politikasındaki değişikliklerden veya ticari faaliyetleri etkileyebilecek siyasi istikrarsızlıktan kaynaklanan potansiyel kayıplardır³⁰. Yabancı yatırımcılar, özellikle kalıcı doğrudan yabancı yatırımlarla uğraşanlar, düşük düzeyde siyasi risk sergileyen ülkeleri tercih etmektedir. Ekonomik ve finansal istikrarın temeli genellikle siyasi faktörlere bağlıdır ve bu da bir ülkenin siyasi risk priminin algılanan risk seviyesi üzerinde doğrudan bir etkiye sahip olabileceği sonucuna götürür³¹. Bu, yabancı yatırımı çekmek ve elinde tutmak için ülkelerin ekonomik ve finansal sağlamlığının yanı sıra siyasi istikrara da öncelik vermesi gerektiği anlamına gelir. Politik risk üzerine yapılan akademik araştırmalar; bu riski ölçmek, yönetmek ve azaltmak için modeller ve araçlar geliştirmeye odaklanır. Bu araştırma tipik olarak siyasi olayların analiz edilmesini ve siyasi risk ile ekonomik büyüme, doğrudan yabancı yatırım ve ticaret akışları gibi çeşitli ekonomik değişkenler arasındaki ilişkinin incelenmesini içermektedir. Ek olarak, araştırmacılar politik riskin farklı varlık sınıfları üzerindeki etkisini araştırır ve politik olarak istikrarlı ülkelere yatırım yapmak veya politik risk sigortası kullanmak gibi politik risklere karşı korunmak için stratejiler geliştirir. Politika yapıcılar; çatışmaları çözmeye yönelik diplomatik çabalar, ekonomik yaptırımlar ve yatırım teşvik politikaları yoluyla siyasi riskin yönetilmesinde de önemli bir rol oynamaktadır. Politik risk piyasa riski ile yakından ilişkilidir. Dünyada veya yatırımın yapıldığı ülkede yaşanan siyasi huzursuzluklar ve ekonomik krizler, yatırım kararlarını etkileyen bir belirsizlik türüdür. Siyasi otoritenin istikrarsız bir görünüme sahip olması finansal piyasaları doğrudan etkiler çünkü siyasi istikrar yatırımcıların yatırım kararı alırken dikkate aldığı önemli bir kriterdir. Politik risk hisse senetleri, tahviller ve doğrudan yabancı yatırımlar gibi farklı

³⁰ Rui Albuquerque, Yrjö Koskinen, and Chendi Zhang. "Corporate Social Responsibility and Firm Risk: Theory and Empirical Evidence." *Management Science*, vol. 65, no. 10, October 2019, pp. 4451-4469.

³¹ TOPALOĞLU, Emre Esat, and Turhan KORKMAZ. "POLİTİK RİSKİN DOĞRUDAN YABANCI YATIRIMLAR ve PAY PİYASASI ENDEKS GETİRİLERİNE ETKİSİ: G7 ÜLKELERİ ÜZERİNE BİR UYGULAMA." *Verimlilik Dergisi* 1 (2021): 97-115.

varlık türlerini etkileyebilir ve hükümet politikalarındaki değişiklikler, ekonomik yaptırımlar, sivil huzursuzluk ve jeopolitik gerilimler gibi çeşitli faktörlerden kaynaklanabilir. Politik risk işletmelerin özellikle uluslararası riske sahip olanların karlılığını ve operasyonlarını önemli ölçüde etkileyebilmektedir.

1.2.2. Sistematik Olmayan Riskler

Sistematik olmayan risk, genel piyasa faktörleriyle ilgili olmayan belirli bir şirket ya da sektörle ilişkili bir risk türüdür. Spesifik risk, çeşitlendirilebilir risk, kendine özgü risk ve artık risk olarak da bilinen sistematik olmayan risk, yatırım yaptığınız şirket veya sektörle birlikte gelen belirsizlik türüdür. Sistematik olmayan risk, çeşitlendirme yoluyla azaltılabilir. Sistematik olmayan risk bir yatırımın performansını etkileyebilecek belirsizliklerdir³². Herhangi bir şirketin veya sektörün riski farklı varlıklardan oluşan bir portföye yayılabileceğinden, bu tür risk çeşitlendirme yoluyla azaltılabilir. Kendine özgü risk örnekleri, yönetim değişiklikleri, işçi anlaşmazlıkları ve ürünlerin geri çağırılması gibi şirkete özgü risklerin yanı sıra yönetmeliklerdeki ya da tüketici tercihlerindeki değişiklikler gibi sektöre özgü riskleri içermektedir. Sistematik riskten farklı olarak, sistematik olmayan risk çeşitlendirme yoluyla ortadan kaldırılabilir. Bununla birlikte belirli bir şirkete veya sektöre özgü olduğundan, kendine özgü risk tamamen ortadan kaldırılamaz. Bu, tek bir hisse senedine sahip olan veya tek bir sektöre yatırım yapan yatırımcıların çeşitli hisse senetleri ve sektörler arasında çeşitlenenlere göre daha yüksek düzeyde kendine özgü riske maruz kaldığı anlamına gelir. Kendine özgü risk tamamen ortadan kaldırılamasa da yatırımcılar portföylerini farklı varlık sınıfları ve sektörler arasında çeşitlendirerek yönetebilir, bu da belirli bir şirket veya sektöre ait risklere maruz kalmalarını azaltır.

Araştırmalar, yatırımcılar daha yüksek risk seviyesini telafi etmek için daha yüksek getiri talep ettiğinden kendine özgü riskin hisse senedi getirileri üzerinde önemli bir etkiye ve kendine özgü daha yüksek risk seviyelerine sahip hisse senetlerinin daha düşük getirilere sahip olabileceğini göstermektedir. Kendine özgü riskin bir yatırım portföyü üzerindeki etkisi; yatırımcının risk toleransı, yatırım hedefleri ve zaman ufku

³² Mark P. Sharfman and Chitru S. Fernando. "Environmental Risk Management and the Cost of Capital." Strategic Management Journal, vol. 29, no. 6, 2008, pp. 569-592.

gibi çeşitli faktörlere bağlıdır. Meselâ; uzun vadeli yatırımcılar, piyasa dalgalanmalarını atlatmak için daha uzun bir zaman ufkuna sahip olduklarından dolayı daha yüksek seviyelerde kendine özgü riskleri kabul etmeye daha istekli olabilirler. Buna karşılık kısa vadeli yatırımcılar, yatırımlarını tek bir şirkete veya sektöre yönelik ani şoklardan korumaya çalışabilirler ve bu nedenle daha düşük seviyelerde kendine özgü riskleri kabul edebilirler.

1.2.2.1 Finansal Risk

Finansal risk, parasal olarak bir operasyondaki bir gider veya kayıptan kaynaklanabilecek bir finansal kayıp ya da ekonomik faydada azalma olasılığını ifade eder. Yatırımcılar için finansal risk göstergeleri bir şirketin borcundaki artış, satış rakamlarındaki değişiklikler, hammadde fiyatlarındaki potansiyel artışlar, grevler, artan rekabet, yetersiz işletme sermayesi ve yeni durumlara uyum sağlama güçlüğünü içerebilir. Şirketler için finansal risk, bir şirketin, özellikle şirketin finansman yöntemleriyle ilgili olarak mali kayba maruz kalmasıdır. Şirketin sermaye yapısı, yatırım finansmanı, nakit akışı yönetimi ve yeterli finansmanın mevcudiyeti ile ilgili riskleri içermektedir³³.

Finansal risk, finansal işlemler ve yatırımlarla ilgili çeşitli riskleri kapsayan geniş bir terimdir. Pek çok akademisyen ve finans uzmanı, finansal riskin tanımlanmasına katkıda bulunmuştur ve finansal riskin en iyi akademik tanımıyla kredilendirilebilecek tek bir kişi yoktur.

Bununla birlikte, zaman içinde geliştirilen ve yaygın olarak kabul gören bazı finansal risk tanımları vardır. Örnek; finansal riski piyasa dalgalanmaları, kredi riskleri ve operasyonel başarısızlıklar gibi faktörler nedeniyle finansal işlemlerden kaynaklanan kayıp potansiyeli olarak tanımlar³⁴. Bu tanım, bazı temel finansal risk kaynaklarının altını çizer ve bu riskleri azaltmak için risk yönetimi stratejilerine olan ihtiyacı vurgular. Finansal riskin yaygın olarak kabul edilen diğer bir tanımı, Basel Bankacılık Denetim Komitesi tarafından geliştirilen ve finansal riski "bir olayın meydana gelme ve bir

³³ Kaouthar Lajili. "Corporate Risk Disclosure and Corporate Governance." Journal of Risk and Financial Management, vol. 2, no. 1, 2009, pp. 94-117.

³⁴International Organization for Standardization. ISO 31000:2018 Risk management - Guidelines. 2nd edition. February 15, 2018.

bankanın finansal hedeflerine ulaşılmasını olumsuz etkileme olasılığı" olarak tanımlayan tanımdır. Bu tanım, finansal kurumların finansal hedeflerine ulaşmalarını ve uzun vadede varlıklarını sürdürebilmelerini sağlamak için risk yönetiminin önemini vurgulamaktadır. Şirket açısından baktığımızda, şirket finansal riski, bir şirketin mali kararlarının zararlar sonulanma potansiyeline atıfta bulunur. Bu, şirketin bor, öz sermaye ve hibrit menkul kıymetler seçiminden ve ayrıca şirketin yatırımlar ve temettülerle ilgili kararlarından kaynaklanabilir³⁵.

Diğer akademisyenler ve finans uzmanları da finansal riskin tanımlanmasına katkıda bulunmuştur. Meselâ, Nobel Ödüllü ekonomist Harry Markowitz, risk ve ödölü dengeleyerek getirileri optimize etmeyi amaçlayan modern portföy teorisi kavramını geliştirdi³⁶. Markowitz'in alışmaları, günümüzde finasta yaygın olarak kullanılan eşitlendirme ve varlık tahsisi gibi risk yönetimi stratejilerinin geliştirilmesine katkıda bulunmuştur. Ayrıca araştırmacılar, finansal riskin tüketim, yatırım ve ekonomik büyüme gibi eşitli ekonomik deėişkenler üzerindeki etkisini incelemekte ve para ve maliye politikaları gibi politika müdahalelerinin finansal riski azaltmadaki rolünü araştırmaktadır.

Finansal risk, hisse senetleri, tahviller, türevler ve emtialar gibi farklı varlık türlerini etkileyebilir ve piyasa oynaklığı, kredi notları, karşı taraf riskleri ve likidite kısıtlamaları gibi eşitli faktörlerden kaynaklanabilir. Finansal risk, özellikle finansal riske önemli ölçüde maruz kalan işletmelerin karlılığını ve faaliyetlerini önemli ölçüde etkileyebilmektedir.

Finansal risk; piyasa riski, kredi riski, operasyonel risk ve likidite riski gibi eşitli türlerde sınıflandırılabilir. Her risk türü, farklı risk yönetimi stratejileri ve teknikleri gerektirmektedir. İşletmeler ve yatırımcılar giderek daha fazla finansal risklere maruz kalmayı en aza indirmeye alıştıka riskin yönetimi finasta önemli bir alışma ve uygulama alanı haline geldi.

³⁵ Monica Billio, Mila Getmansky, Andrew W. Lo, and Lorian Pelizzon. "Econometric Measures of Connectedness and Systemic Risk in the Finance and Insurance Sectors." *Journal of Financial Economics*, vol. 104, no. 3, 2012, pp. 535-559.

³⁶Harry Markowitz. "Portfolio Selection." *The Journal of Finance*, vol. 7, no. 1, March 1952, pp. 77-91.

1.2.2.2. Yönetim Riski

Yönetim riski, bir işletme veya kuruluş içindeki zayıf karar verme veya etkisiz yönetim uygulamalarından kaynaklanabilecek potansiyel mali kayıplara atıfta bulunur. Akademik literatürde yönetim riski yatırımcılar, şirketler ve politika yapıcılar için önemli bir husus olarak finans ve yönetim bağlamında incelenmektedir. İş dünyasında yönetim riski, özellikle iş modeli yeniliği bağlamında, firmanın risk almaya yönelik yönelimi ile ilişkilidir. Firmanın yenilik yapma ve uyum sağlama yeteneğini etkileyebilecek iç ve dış bilgi yönetiminde başarısızlık potansiyelini içerir³⁷. Yönetim riskine ilişkin akademik araştırma, bu riski tanımlamak, ölçmek ve azaltmak için modeller ve araçlar geliştirmeye odaklanır. Bu araştırma tipik olarak finansal ve operasyonel verilerin analiz edilmesini, yöneticilerin davranışlarının incelenmesini ve yönetim uygulamalarının ve stratejilerinin etkinliğinin değerlendirilmesini içermektedir. Araştırmacılar ayrıca yönetim riskinin istihdam, yenilikçilik ve ekonomik büyüme gibi çeşitli ekonomik değişkenler üzerindeki etkisini inceler, etkili yönetim için en iyi uygulamaları ve yönergeleri geliştirir.

Yönetim riski halka açık şirketler, özel şirketler ve kar amacı gütmeyen kuruluşlar gibi farklı işletme ve kuruluş türlerini etkileyebilir veya yetersiz planlama, verimsiz operasyonlar, etkisiz liderlik ve sorumluluk eksikliği gibi çeşitli faktörlerden kaynaklanabilir. Yönetim riski karlılığın azalmasına, pazar payı kaybına, itibarın zedelenmesine ve hatta iflasa yol açabilmektedir. Yönetim riski, kötü veya yetersiz yönetilen bir organizasyon ya da işletmeden kaynaklanabilecek zarar potansiyelidir. Tahvil sahiplerinden çok hissedarları etkilediği için yatırımcılar, yatırım yaptıkları işletmelerin yönetim algısını ve personel değişikliklerini yakından takip ederler. Bu risk, kuruluşun kurumsal yönetim ilkeleri düzeyi ile ilgilidir. Açıkçası yetersiz yönetim kadrosu veya deneyimsiz yeni yöneticilerin işe alınması gibi durumlar bu riski oluşturabilir. Yönetim hataları, hisse değerini belirleyen değişkenler üzerinde önemli bir etkiye sahip olabilmektedir. Yönetim hataları sonucunda şirket için satış seviyelerinin ve kar marjlarının düşme riski artabilir.

³⁷ Alex Edmans. "The Link between Job Satisfaction and Firm Value, with Implications for Corporate Social Responsibility." *Academy of Management Perspectives*, vol. 26, no. 4, 2012, pp. 1-19.

1.2.2.3. Endüstri Riski

Belirli bir sektöre özgü belirsizlikler ve zorluklardan kaynaklanabilecek potansiyel finansal kayıpları ifade eden sektör riski yatırımcılar, şirketler ve politika yapıcılar için finans ve ekonomide önemli bir konudur. Sektör riski bir sektördeki teknoloji, sağlık, enerji veya sigorta gibi farklı işletmeleri ve kuruluşları etkileyebilmektedir. Örnek verecek olursak; sektör riski sigortacılıkta, iş hacimleri ve marjlardaki ve mevcut poliçelerin nicelik ve kalitesindeki dalgalanmalarla ilgilidir. Piyasa daha agresif hale geldikçe şirketler iş riskleri konusunda endişelenmeye başlar. Bu risk, müşteri sadakatinden ve portföyün kalitesinden etkilenir³⁸. Teknolojik gelişmeler, düzenleyici ortam, rekabet ve tüketici davranışındaki değişiklikler gibi çeşitli faktörlerden kaynaklanabilir. Sektör riski karlılığın azalmasına, pazar payının kaybına ve hatta iflasa neden olabilmektedir. Endüstri riskine ilişkin akademik araştırmalar bu riski tanımlamak, ölçmek ve azaltmak için modeller ve araçlar geliştirmeye odaklanır. Bu araştırmalar genellikle sektöre özgü verilerin analiz edilmesini, sektördeki firmaların ve tüketicilerin davranışlarının incelenmesini, düzenleyici ve teknolojik değişikliklerin sektör üzerindeki etkisinin değerlendirilmesini içermektedir. Bir endüstrinin genel performansını etkileyen belirli bir faktör kümesinin olasılığı, endüstri düzeyinde gerileme riskiyle ilişkilidir. Örneğin, otomobil endüstrisindeki bir vergi artışı, öncelikle satış hacmindeki önemli düşüşe atfedilebilen otomobil üreticilerinin karlılığı üzerinde potansiyel olarak olumsuz etkiler yaratabilir³⁹. Ek olarak araştırmacılar endüstri riskinin iş yaratma, yenilik ve ekonomik büyüme gibi çeşitli ekonomik değişkenler üzerindeki etkilerini araştırır. Çeşitlendirme, stratejik ittifaklar ve hükümet müdahalesi gibi endüstri riskini azaltmak için stratejiler geliştirir. Bir sektörde meydana gelmesi beklenen değişimler, yalnızca o sektör kapsamındaki işletmeleri etkiler. Bir endüstride meydana gelmesi beklenen değişiklikler ekonomik koşullar, yasalar ve davranışlardaki değişikliklerden etkilenir. Bu tür değişiklikler, bir işletmenin kârını ve dolayısıyla menkul kıymetlerinin değerini olumsuz etkiler.

³⁸ Montserrat Guillen, Jens Perch Nielsen, and Ana María Pérez-Marín. "The Need to Monitor Customer Loyalty and Business Risk in the European Insurance Industry." *The Geneva Papers on Risk and Insurance - Issues and Practice*, vol. 33, 2008, pp. 207-218.

³⁹ Okan Acar and Aslı Beyhan Acar. "Modern Risk Management Techniques in Banking Sector." In *Banking, Finance, and Accounting: Concepts, Methodologies, Tools, and Applications*, edited by Information Resources Management Association, IGI Global, 2015, pp. 886-906.

Olumsuz deęişikliklere karşı savunmasız olan bir işletmede yüksek deęişkenlik nedeniyle risk yüksektir. Ayrıca ithal hammaddeye bağımlı bir sektöre ilişkin risk, yerel hammaddeleri tercih eden bir sektöre ilişkin riskten çok daha fazladır. Yatırımcılar ve paydaşlar, endüstriye özgü zorluklar ve belirsizlikler için anlayış ve hazırlık talep ederken endüstri risk yönetimi, iş veya yönetimde temel bir çalışma ve uygulama alanı haline gelmektedir. Etkili endüstri risk yönetimi stratejileri, belirli bir endüstri veya sektördeki işletmelerin ve kuruluşların hedeflerine ulaşmalarına, potansiyel kayıpları en aza indirmelerine, uzun vadeli sürdürülebilirliklerini ve başarılarını artırmalarına yardımcı olabilmektedir.

1.3. Hisse Senedi Kavramı

Hisse senedi, bir şirketin bir birimindeki mülkiyeti ifade eden bir finansal aracı temsil eder. Birey bir hisse senedi satın aldığında esasen şirkette küçük bir mülkiyet hissesi elde eder. Hisse senetleri genellikle New York Menkul Kıymetler Borsası veya Borsa İstanbul gibi borsalarda alınıp satılır, fiyatları piyasadaki arz ve talebe göre dalgalanabilir. Hisse senedi fiyatı yükseldikçe potansiyel sermaye kazancı sağlamanın yanı sıra hisse senetleri, şirketin kârının bir kısmını temsil eden temettü de ödeyebilir. Hisse senetlerine yatırım yapmak bireylerin bir şirketin büyümesine ve kârlılığına katılmasının bir yolu olabilmektedir ancak hisse senedi fiyatları deęişken olabilir, çeşitli ekonomik ve politik faktörlere baęlı olarak riskler taşıyabilir. Hisse senedi kavramı finans ve yatırımlarda temel bir kavramdır. Finansa hisse senetlerinin tanımına ve anlaşılmasına katkıda bulunan birçok akademisyen ve uzman vardır.

Bu alandaki en tanınmış ve etkili akademisyenlerden biri genellikle deęer yatırımının önde gelen ismi olarak kabul edilen Benjamin Graham'dır. Graham, ilk kez 1949'da yayınlanan klasik kitabı "The Intelligent Investor"da hisse senedi kavramı hakkında kapsamlı yazılar yazdı. Hisse senedi bir işletmede kısmi mülkiyet hakkıdır. Bir şirketin gerçek temel deęerini belirlemek, hisse senedine yatırım yapmanın potansiyel risklerini ve getirilerini deęerlendirmek için bir şirketin mali tablolarını ve dięer verilerini analiz etmenin önemini vurguluyor⁴⁰. Finans alanında etkili olan bir başka bilim insanı da etkin piyasa hipotezi üzerine yaptığı araştırmalarla tanınan Eugene

⁴⁰Benjamin Graham. The Intelligent Investor. HarperCollins Publishers, 2003.ss1-640

Fama'dır. Fama'nın çalışması, etkin bir piyasada hisse senedi fiyatlarının bir şirket hakkındaki tüm bilgileri yansıttığını ve hisse senedi seçimi yoluyla sürekli olarak piyasadan daha iyi performans göstermeyi zorlaştırdığını öne sürüyor. Ancak Fama, hisse senedi kavramını ve temsil ettikleri temel işletmeleri anlamının önemini hâlâ kabul etmektedir⁴¹. Hisse senedi kavramının anlaşılmasına katkıda bulunan diğer akademisyenler ve yatırımcılar arasında Burton Malkiel, Peter Lynch ve Warren Buffett bulunmaktadır. Bu uzmanlar hisse senetlerine yatırım yaparken uzun vadeli bir bakış açısı edinmenin ve bir şirketin rekabet avantajları, büyüme potansiyeli ve finansal sağlık gibi faktörlere odaklanmanın önemini vurguladılar. Hisse senedi kavramı, Türk Dil Kurumu sözlüğünde her biri anonim ortak sermayenin bölünmüş bir kısmına tekabül eden kanunda belirtilen niteliklere uygun olarak hazırlanmış değerli bir işlem, belge veya sertifika olarak tanımlanmaktadır. Hisse senedi kavramı "pay" teriminin açıklamasına dayanmaktadır. Bir pay, orijinal sermayenin belirli miktarlarda eşit değere bölünmüş her bir parçasını ifade eder. Dolayısıyla şirkette pay sahibi olan kişi ortak olur ve bunun getirdiği haklardan yararlanır. Ancak payla birlikte gelen yükümlülüklerden de sorumludurlar. Hisse senetleri değerli menkul kıymetler olarak kabul edilir ve belirli kural ve düzenlemelere tabidir. Hisse senetleri sahiplerine kanunla ortaklık hakkı ve mali hakları sağlamaktadır. Kanunları kısaca belirtecek olursak şirketin yıl içerisinde elde ettiği karından pay alma hakkını TTK'nın 533'üncü maddesi, şirket yönetimine dahil olma ve oy kullanma hakkını TTK'nın 373-537ci maddeleri, rüçhan hakkını TTK'nın 394cü maddesi, tasfiyeden pay alma hakkını TTK'nın 447ci maddesi ve şirketin faaliyetleri hakkında bilgilendirme hakkını TTK'nın 362ci maddesi güvence altına almaktadır⁴². Sonuç olarak hisse senedinin temsil ettiği tüm yükümlülükler ve haklar devredilmeden hisse senedi devredilemez. Hisse senetleri alınıp satılabilir olup, bunların şartları ve esasları Sermaye Piyasası mevzuatında ayrıntılı olarak düzenlenmiştir.

Genel olarak finasta hisse senedi kavramı, yıllar boyunca birçok uzman tarafından incelenen karmaşık ve çok yönlü bir kavramdır. Bu akademisyenler, hisse senetlerine yatırım yapmanın getirdiği zorlukları ve riskleri kabul ederken bilinçli

⁴¹Eugene F. Fama. "Efficient Capital Markets: A Review of Theory and Empirical Work." The Journal of Finance, vol. 25, no. 2, May 1970, pp. 383-417.

⁴²<https://www.mevzuat.gov.tr/MevzuatMetin/1.5.6102-20130328.pdf>

yatırım kararları vermek için bir şirketin finansal verilerini ve diğer ilgili bilgileri analiz etmenin önemini vurguladılar.

1.4. Hisse Senetlerinde Değer Kavramı

Hisse senetleri, bir şirkette mülkiyeti temsil eden önemli bir finansal araçtır. Hisse senetleriyle ilişkili çeşitli değer türlerini anlamak, yatırımcıların bilinçli yatırım kararları vermesi için çok önemlidir. Bu bağlamda hisse senedi piyasaları, ekonomik kalkınmaya katkıda bulunan platformlar olarak kurumsal finansman kararlarındaki rolü çok önemlidir⁴³.

1.4.1. Nominal Değer

Hisse senedi, tahvil vb. için üzerinde belirtilmiş değer. (TDK) Bir finansal varlığın nominal değeri, enflasyonun etkilerini dikkate almayan üzerinde belirtilmiş değerdir⁴⁴. Hisse senedinin orijinal maliyetidir ve mevcut piyasa değerinden farklı olabilmektedir. Başka bir deyişle nominal değer, hisse senedine ilk verildiğinde atanan ve hisse senedinin ömrü boyunca sabit kalan değerdir. Öte yandan nominal değer, genellikle şirketin yönetim kurulu tarafından belirlenen bir hisse senedinin çıkarılabileceği minimum fiyattır. Genellikle muhasebe ve yasal amaçlar için kullanılır ancak bir hisse senedinin gerçek değerini yansıtmaz. Nominal değer, şirketin yasal sermayesini belirlemek için kullanılır ve yatırımcıların her bir hisse senedi için ödemesi gereken minimum tutarı temsil eder. Bir hisse senedinin piyasa fiyatı nominal değerinin altına düşerse şirket için mali sıkıntıya işaret edebilir.

1.4.2. Gerçek Değer

Gerçek değer bir hisse senedinin sahip olan firmaya ait tüm varlıkları mevcut karlılık durumu, kar payları, sermayesi ve sermaye yapısı gibi değişkenler aracılığıyla belirlenmektedir. Yatırımcıların firmanın ileride gelir yaratma potansiyelleri ve bu hisse

⁴³ Aslı Demirgüç-Kunt and Ross Levine. "Stock Market Development and Financial Intermediaries: Stylized Facts." The World Bank Economic Review, vol. 10, no. 2, 1996, pp. 291-321.

⁴⁴ Ashoka Mody and Mark P. Taylor. "The High-Yield Spread as a Predictor of Real Economic Activity: Evidence of a Financial Accelerator for the United States." IMF Staff Papers, vol. 50, no. 3, 2003, pp. 373-402.

senedinden beklentileri göz önünde bulundurularak mevcut piyasa koşullarında o hisse senedine verilen değer şeklinde tanımlanabilmektedir.⁴⁵

1.4.3. Defter Değeri

Defter değeri, hisse senetleri için başka bir değer türüdür ve bir şirketin tüm varlıklarını tasfiye etmesi ve tüm borçlarını ödemesi durumunda bırakacağı teorik değeri temsil eder. Defter değeri, bir varlığın bilanço hesap bakiyesine göre değeridir. Varlıklar için değer, varlığın orijinal maliyetinden varlığa yapılan amortisman, itfa veya değer düşüklüğü maliyetlerinin düşülmesine dayanır⁴⁶. Bir şirketin toplam yükümlülüklerinin toplam varlıklarından çıkarılması ve sonucun ödenmemiş hisse senedi sayısına bölünmesiyle hesaplanır.

1.4.4. Tasfiye Değeri

Tasfiye değeri, bir tasfiye senaryosunda satılacaksa bir şirketin varlıklarının değeridir. Tasfiye değeri, bir firmanın varlıklarının satılması ve faaliyetlerinin durdurulması suretiyle elde edilebilecek tutardır. Tasfiye halinde firmanın alacaklılarına dağıtılacak varlıkların değeridir⁴⁷. Genellikle defter değerinden daha düşüktür ve bir şirketin varlıklarının minimum değerini belirlemek için kullanılır. Son olarak itibari değer, genellikle şirketin yönetim kurulu tarafından belirlenen bir hisse senedinin çıkarılabileceği minimum fiyattır. Genellikle muhasebe ve yasal amaçlar için kullanılır ancak bir hisse senedinin gerçek değerini yansıtmaz.

Genel olarak hisse senetleri için farklı değer terimlerini anlamak, yatırımcıların yatırımları hakkında bilinçli kararlar almaları için çok önemlidir. Yatırımcılar bir hisse senedinin piyasa değerini, gerçek değerini, defter değerini, tasfiye değerini, nominal değerini ve itibari değerini (şirketin finansal sağlığını etkileyebilecek bir hisse senedi fiyatı için minimum eşiktir) değerlendirerek bir hisse senedinin değeri, büyüme ve getiri potansiyeli hakkında kapsamlı bir anlayış kazanabilirler.

⁴⁵ Metin Kamil Ercan and Ünsal Ban. "Değere Dayalı İşletme Finansı" Finansal Yönetim. 4. baskı. Ankara: Gazi Kitabevi, 2016.

⁴⁶ John R. Graham, Campbell R. Harvey, and Shiva Rajgopal. "The Economic Implications of Corporate Financial Reporting," Journal of Accounting and Economics, vol. 40, no. 1-3, 2005, pp. 3-73.

⁴⁷ Stewart C. Myers. "The Capital Structure Puzzle." The Journal of Finance, vol. 39, no. 3, July 1984.

1.5. Hisse Senedi Değerinin Öngörülebilirliği

Borsanın öngörülebilirliği, akademik çevrelerde önemli bir tartışma konusu olmuştur. Bazı araştırmacılar tüm mevcut bilgilerin hisse senedi fiyatlarına yansıtıldığını ve bu nedenle sürekli piyasayı getirisinin üzerinde getiri elde etme konusunda zorluklar yaşanabileceğini savunarak borsanın büyük ölçüde öngörüleemeyen olduğunu iddia etmektedir. Varlık değerinin öngörülebilirliği, geçmiş performansa dayalı olarak tahmin edilecek gelecekteki getiri potansiyeline atıfta bulunur. Bu, zaman içinde riskten kaçınmadaki değişikliklerden etkilenir ve bu da önceki yatırım sonuçlarından etkilenir. Fiyatlarda önemli bir artışın ardından, yatırımcı daha az riskten kaçınır ve bu nedenle müteakip getiriler ortalama olarak daha düşüktür⁴⁸. Etkin piyasa hipotezi, hisse senedi fiyatlarını tahmin etmenin temelde rastgele bir süreç olduğunu ve hisse senedi fiyatlarındaki herhangi bir görünür modelin ya da trendin sadece tesadüfler sonucu olduğunu öne sürmektedir.

Modern finansın kurucularından biri olarak kabul edilen Eugene Fama belki de en çok varlık fiyatlarının herhangi bir zamanda mevcut tüm bilgileri tam olarak yansıttığını savunan Etkin Piyasa Hipotezi (EMH) konusundaki çalışmasıyla tanınmaktadır. 1970 tarihli "Efficient Capital Markets: A Review of Theory and Ampirical Work" adlı makalesinde Fama, hisse senedi getirilerinin tahmin edilebilirliğini tartışır ve kamuya açık bilgilere dayalı olarak kısa vadeli bir tahmin edilebilirlik olsa da uzun vadeli olduğuna dair çok az kanıt olduğunu savunur⁴⁹. Bu alandaki bir başka etkili araştırmacı davranışsal finans konusundaki çalışmaları ve son on yıldaki ortalama kazanca dayalı borsa değerlemesinin bir ölçüsü olan CAPE oranını geliştirmesiyle tanınan Robert Shiller'dir. Shiller, yatırımcılar faktörlere dayalı olarak hisse senedi fiyatlarının kısa vadede tahmin edilebileceğini ancak gelecekteki kazançları tahmin etmenin zorluğu nedeniyle uzun vadeli öngörülebilirliğin sınırlı olduğunu savundu⁵⁰. Hisse senedi değerinin öngörülebilirliği çalışmasına katkıda bulunan diğer önemli kişiler arasında Kenneth French, John Campbell ve Burton Malkiel sayılabilir.

⁴⁸ Nicholas Barberis, Ming Huang, and Tano Santos. "Prospect Theory and Asset Prices." The Quarterly Journal of Economics, vol. 116, no. 1, 2001, pp. 1-53.

⁴⁹ Eugene F. Fama. "Efficient Capital Markets: A Review of Theory and Empirical Work." The Journal of Finance, vol. 25, no. 2, 1970, pp. 383-417.

⁵⁰Robert J. Shiller. "Irrational Exuberance." 2nd ed., Princeton University Press, 2005. s. 344

Bu arařtırmacılar tarafından alınan yaklařımlar; bazıları faiz oranları ve enflasyon gibi makroekonomik faktörlere odaklanırken, diğerkleri kazanç ve temettüler gibi řirkete özgü faktörlere odaklanarak büyük farklılıklar göstermektedir. Çoğu yatırımcıda özellikle kısa vadede borsada bir dereceye kadar öngörülebilirlik olabileceğini savunmaktadır.

Hisse senedi fiyatlarını tahmin etmek için birçok ekonomik ve finansal deęiřkene dikkat eden ekonometrik modeller kullanılmaktadır. Teknik analistler, hisse senedi fiyatlarında model oluşturmak için grafikler ve diğerk araçlar kullanırlar. Temel analistler ise bir řirketin finansal tabloları ve diğerk verilerini inceleyerek řirketin gerçek deęerini belirler ve bu bilgiye dayanarak tahminlerde bulunur. Meselâ arařtırmacılar faiz oranları, enflasyon ve GSYİH büyüme oranları gibi makroekonomik verileri içeren modelleri kullanarak hisse senedi fiyatlarını tahmin etmişlerdir. Başka bir yaklařım ise finansal ve ekonomik verilerin büyük veri kümelerindeki desenleri ve trendleri belirleyebilen makine öęrenimi algoritmalarını kullanmaktır. Bu algoritmalar, gelecekteki hisse senedi fiyatları hakkında tahminler yapmak için tarihsel veriler üzerinde eęitilebilirler. Borsa tahminlerinin potansiyeline raęmen optimal derecede öngörülebilirliğin mümkün olduğunu savunanlar bile hisse senedi fiyatlarını etkileyen birçok faktörün olduğunu ve bu faktörlerin tümünü tahmin modellerinde hesaba katmanın imkansız olduğunu kabul etmektedirler. Bu nedenle borsa tahminleri mümkün olsa bile tutarlı bir řekilde doęru veya güvenilir olması olası deęildir. Ayrıca pek çok yatırımcının aynı tahmin modellerini kullanmaya çalışması, hisse senedi fiyatlarındaki herhangi bir öngörülebilir model veya eęilimin hızla istismar edileceęi ve bunların etkinliğini azaltacaęı anlamına gelir. Ayrıca doęal afetler, siyasi çalkantılar veya teknolojik aksamalar gibi beklenmedik olayların hisse senedi fiyatları üzerinde önemli bir etkisi olabilmektedir, bu da tahminleri daha da zorlařtırabilir. Genel olarak finasta hisse senedi deęerinin öngörülebilirlięi kavramı karmařık ve çok yönlü bir çalışma alanıdır ve evrensel olarak kabul edilen tek bir tanım veya yaklařım yoktur. Bunun yerine arařtırmacılar bu konuyu arařtırmak için çeřitli teori ve yöntemlerden yararlanırlar, yeni veriler ve teknikler ortaya çıktııkça alan gelişmeye devam eder.

Sonuç olarak yatırımcılara yalnızca borsa tahminlerine güvenmek yerine bilinçli yatırım kararları vermek için araştırma, analiz ve çeşitlendirmenin bir kombinasyonunu kullanmaları tavsiye edilmektedir. Yatırımcılar, portföylerini birden çok varlık sınıfı arasında çeşitlendirerek ve uzun vadeli yatırım yaparak piyasa oynaklığına maruz kalmalarını azaltmaya ve finansal hedeflerine ulaşma şanslarını artırmaya yardımcı olabilmektedir.

1.5.1. Rastgele Yürüyüş Hipotezi

Bachelier (1900), başlangıçta menkul kıymet fiyatlarının rastgele hareketler sergileyebileceği kavramını önerdi. Daha sonra rastgele yürüyüş modeli, bu önermeyi doğrulamak için teorik bir yapı olarak kapsamlı bir şekilde benimsenmiştir. Bu model; menkul kıymet fiyat dalgalanmalarının doğasında bulunan rastlantısallığın altını çizmiştir, finansal piyasaların anlaşılması ve analizinde çok önemli bir bileşen olmuştur⁵¹. Rastgele Yürüyüş Hipotezi (RYH), hisse senedi fiyatlarının ve diğer finansal varlık fiyatlarının rastgele bir yürüyüş izlediğini ve öngörülemez olduğunu yani bir hisse senedinin gelecekteki fiyat hareketinin geçmiş fiyat hareketlerine dayanarak tahmin edilemeyeceğini öne süren bir finans teorisi ve etkin piyasa hipotezi ile tutarlıdır⁵². RYH, başlangıcından bu yana çok sayıda akademik tartışmaya ve çalışmaya konu olmuştur. Rastgele Yürüyüş Hipotezinin savunucuları, hisse senedi fiyatlarındaki herhangi bir model veya anomalinin rastgele olduğu ve uzun vadede istismar edilemeyeceği için finansal piyasalarda sürekli olarak fazla getiri elde etmenin zor olduğunu savunuyorlar. Ayrıca tüm bilgiler zaten hisse senedi fiyatlarına yansıdığı için bu rastgeleliğin piyasa etkinliğinin kanıtı olduğunu savunuyorlar. Hipotez hisse senedi fiyatlarının önceden tahmin edilebilecek öngörülebilir bir yol izlemediğini, bunun yerine herhangi bir zamanda fiyat dalgalanmaları ve geçmişteki değişiklikler dışında rastgele yukarı veya aşağı hareket ettiğini ileri sürer. Rastgele Yürüyüş Hipotezini eleştirenler, uzun vadede öngörülemez olsalar bile hisse senedi fiyatlarında aşırı getiri elde etmek için kullanılabilecek belirli modeller veya anomaliler olabileceğini savunuyorlar. Ek olarak Rastgele Yürüyüş Hipotezinin hisse senedi fiyatlarını

⁵¹ Tanrıöver, Banu, and Duygu Arslantürk Çöllü. "Türkiye'de Yatırımcıların Öngörü Performanslarının Rastgele Yürüyüş Modeli Çerçevesinde Analizi/Analysis of Forecasting Performance of Investors in Turkey Within Framework of the Random Walk Model." *Business and Economics Research Journal* 6.2 (2015): 127.

⁵² Gerald L. Musgrave. "Reviewed Work: A Random Walk Down Wall Street by Burton G. Malkiel." *Business Economics*, vol. 32, no. 2, April 1997, pp. 74-75.

bozabilecek ve rastgele olmayan kalıplar yaratabilecek piyasa manipölasyonunu veya içeriden öğrenenlerin Al-Sat işlemleri hesaba katmadığını iddia ediyorlar.

RYH hakkındaki en önemli ve etkili makalelerden biri 1965'te ekonomist Eugene Fama tarafından yazıldı. Fama, hisse senedi fiyatlarının RYH'nin "zayıf formunu" izlediğini savundu; yalnızca geçmiş fiyat verilerine dayalı Al-Sat yapmak kar elde etmeyi olanaksız hale getirir. Fama daha sonra bu teoriyi genişleterek RYH'nin "yarı güçlü" ve "güçlü biçim" versiyonlarının bile geçerli olabileceğini yani ne temel analizin ne de içeriden öğrenilen bilgilerin gelecekteki hisse senedi fiyatlarını güvenilir bir şekilde tahmin etmek için kullanılamayacağı anlamına gelir⁵³. Fama'nın RYH üzerine çalışması, finansal piyasaların oldukça verimli olduğunu ve cari hisse senedi fiyatlarının mevcut tüm bilgileri yansıttığını öne süren etkin piyasa hipotezinin (EPH) geliştirilmesinin temelini attı. Fama, EPH ve RYH'ye yaptığı katkılardan dolayı 2013 yılında Ekonomik Bilimler alanında Nobel Anma Ödülü'ne layık görüldü. Fama'nın ufuk açıcı çalışmasından bu yana pek çok akademisyen RYH'yi ve bunun finansal piyasalar üzerindeki etkilerini incelemeye devam etti. Bazıları hisse senedi fiyatlarının aslında tahmin edilebilir kalıplar sergilediğini ve tacirlerin bu kalıpları kullanmaktan kazanç sağlayabileceklerini savunarak RYH'ye meydan okudu. Diğerleri ise işlem maliyetleri ve piyasa sürtüşmeleri gibi faktörleri dahil etmek için RYH'yi geliştirdi. Genel olarak, RYH tartışmalı ve tartışmalı bir teori olmaya devam etse de Fama'nın konuyla ilgili çalışması finans alanında önemli bir etkiye sahip oldu, çok sayıda başka teori ve modelin gelişimini etkiledi. Rastgele Yürüyüş Hipotezi, yatırım stratejileri, finansal modelleme ve piyasa etkinliği üzerindeki etkileri nedeniyle finans ve ekonomide önemli bir kavramdır. Hipotezin doğruluğu hakkında devam eden tartışmalar devam ederken finans ve ekonomide temel bir kavram ve akademik araştırma ve tartışmanın önemli bir konusu olmaya devam etmektedir.

1.5.2. Etkin Piyasa Hipotezi

Etkin Piyasa Hipotezi (EPH), finansal piyasaların etkin olduğunu ve kamuya açık tüm bilgilerin anında ve doğru bir şekilde finansal varlık fiyatlarına yansıdığını öne süren bir finansal teoridir. Etkin Piyasa Hipotezi (EPH), piyasayı yenmenin olanaksız

⁵³Eugene F. Fama. "The Behavior of Stock-Market Prices." The Journal of Business, vol. 38, no. 1, 1965, pp. 34-105.

olduğunu belirten bir yatırım teorisidir, çünkü borsa etkinliği mevcut hisse fiyatlarının her zaman ilgili tüm bilgileri içermesine ve yansıtmasına neden olur⁵⁴. Finans ve ekonomi alanlarında kapsamlı bir akademik tartışma ve araştırma konusudur. Etkin Piyasa Hipotezi, 1970 yılında Fama tarafından bir hipotez olarak ortaya atılmış ve o zamandan beri çeşitli araştırmacılar tarafından birçok ülkenin borsalarında teorik ve ampirik olarak test edilmiştir. Bu çalışmalardan elde edilen sonuçlar, bazı ülkelerin pazarlarının hipoteze uygun olduğu ve diğerlerinin uymadığı karışık sonuçlar vermiştir⁵⁵. EPH'nin, bir yatırımcının birincil amacının fonlarının getiri miktarını maksimize etmek olduğu, yatırımcıların gelir ve riske dayalı kararlar aldığı, gelir ve risk tercihlerinin homojen olduğu, aynı zaman ufkuna sahip olduğu gibi çeşitli varsayımları vardır ve yatırımcılar herhangi bir bilgiye ucuz ve ücretsiz olarak erişilebilirler. EPH, sürekli olarak yeni bilgileri analiz eden, yorumlayan ve yatırım kararlarını buna göre ayarlayan çok sayıda rasyonel ve bilgili yatırımcının varlığını varsayar. Bu da finansal piyasaların verimli olmasını sağlar. Sonuç olarak finansal varlık fiyatları her zaman mevcut tüm bilgileri yansıtır ve bu da yatırımcıların herhangi bir bilgi avantajından yararlanıp sürekli olarak fazla getiri elde etmelerini olanaksız hale getirir. Etkin piyasa kavramı mevcut bilginin etkinliği ile ilgilidir. Fiyat hareketlerinin piyasa etkinliği üzerindeki önemli etkisi göz ardı edilemez. Piyasalar etkinliklerine göre üç ayrı başlık altında sınıflandırılabilir: Güçlü Form, Yarı Güçlü Form ve Zayıf Form. Güçlü form, geçmiş fiyat hareketleri kamuya açık olmayan ve içeriden öğrenilen bazı özel bilgiler kullanılsa dahi tutarlı aşırı getirilerin hiçbir şekilde mümkün olmadığını, olanaksız hale getirdiğini iddia eder. Yarı-güçlü formda, geçmiş fiyat hareketlerinden ve kamuya açıklanmış bilgilerden yararlanılarak etkin piyasada olağandışı bir kazanç elde edilemeyeceğini söylemek mümkündür. Bu tür piyasalarda etkin fiyatlar mevcut tüm bilgileri yansıtır ve yatırımcılar sürekli olarak fazla getiri elde edemezler. Zayıf form, tüm geçmiş fiyatların ve işlem hacimlerinin halihazırda cari fiyatlara yansıdığını, fazla getiri elde etmede teknik analizi işe yaramaz hale getirdiğini savunur⁵⁶.

⁵⁴ Miguel R. Borges. "Efficient Market Hypothesis in European Stock Markets." *The European Journal of Finance*, vol. 16, no. 7, 2010, pp. 711-726.

⁵⁵ Fama, a.g.m, ss. 383-417.

⁵⁶ Eugene F. Fama. "Efficient Capital Markets II." *The Journal of Finance*, vol. 46, no. 5, 1991, pp. 1575-1617.

1.5.1.1.Zayıf Formda

Zayıf formda etkinlikte, cari fiyatlar, geçmiş fiyatların geçmişinde yer alan tüm bilgileri tam olarak yansıtır. Bu nedenle hiçbir yatırımcı, tarihsel verilere dayanarak işlem yaparak anormal bir getiri elde edemez⁵⁷. EPH'nin zayıf formuna göre yatırımcılar geçmiş fiyat ve hacim verilerini analiz ederek sürekli olarak fazla getiri elde edemezler çünkü bu bilgiler zaten finansal varlıkların cari fiyatlarına dahil edilmiştir. Bu nedenle gelecekteki fiyatları tahmin etmek için geçmiş fiyatları ve hacim verilerini kullanan teknik analiz, fazla getiri elde etmede yararlı değildir. EPH'nin zayıf formunu eleştirenler, geçmiş fiyat ve hacim verilerinde bu bilgilerin halihazırda mevcut fiyatlara dahil edilmiş olmasına rağmen fazla getiri elde etmek için kullanılabilecek belirli modellerin veya anomalilerin var olabileceğini iddia etmektedir. Bununla birlikte zayıf EPH formunun savunucuları, bu tür anomalilerin ya kısa ömürlü ya da rastgele olduğunu ve uzun vadede tutarlı bir şekilde istismar edilemeyeceğini savunuyorlar. Temel olarak piyasa etkinliğinin zayıf formunda tüm geçmiş bilgi ve fiyatlar bir finansal varlığın cari fiyatına yansıtılır yani bir hisse senedinin gelecekteki fiyatları geçmiş fiyatları tarafından belirlenir. Bu nedenle menkul kıymet fiyatları incelenerek anormal kar elde etmenin mümkün olmadığı savunulmaktadır. Fiyatlar rastgele bir davranış sergilediğinden, herhangi bir stratejinin, teknik analizin, özellikle uzun dönemlerin uygulanması pratik değildir⁵⁸.

Genel olarak EPH'nin zayıf biçimi, yatırım stratejileri ve piyasa verimliliği üzerindeki etkileri nedeniyle finans ve ekonomide önemli bir kavramdır. EPH'nin doğruluğu hakkında devam eden tartışmalar olsa da finans ve ekonomide temel bir kavram ve aynı zamanda önemli bir akademik araştırma ve söylem konusu olmaya devam etmektedir.

1.5.1.2.Yarı Güçlü Formda Etkinlik

Etkin Piyasa Hipotezinin (EPH) yarı güçlü formu finansal tablolar, haberler ve diğer piyasa verileri dahil olmak üzere halka açık tüm bilgilerin halihazırda finansal

⁵⁷ Mary Gbemi Ajao and Regina Osayuwu. "Testing the Weak Form of Efficient Market Hypothesis in Nigerian Capital Market." Accounting and Finance Research, vol. 1, no. 1, 2012, pp. 169-179.

⁵⁸ Ahmet Bayraktar, "Etkin piyasalar hipotezi." Aksaray Üniversitesi İİBF Dergisi, Cilt: 4, Sayı: 1 Ocak 2012, ss 37-47

varlıkların cari fiyatlarına yansıdığını varsayar. Finans ve ekonomi alanındaki akademik bir söylemde EPH'nin yarı güçlü formu önemli bir tartışma ve araştırma konusudur. Yarı güçlü biçim etkinliği, piyasa fiyatının halka açık tüm bilgileri yansıttığını ima eder⁵⁹. EPH'nin yarı güçlü formuna göre yatırımcılar, kamuya açık bilgileri analiz ederek sürekli olarak fazla getiri elde edemezler çünkü bu bilgiler zaten finansal varlıkların cari fiyatlarına dahil edilmiştir. Bu nedenle finansal varlıkların gerçek değerini belirlemek için finansal tabloların ve diğer kamuya açık bilgilerin analiz edilmesini içeren temel analiz, fazla getiri elde etmede yararlı değildir. EPH'nin yarı güçlü biçimini eleştirenler, varlık fiyatlarına hemen yansımayan ve fazla getiri elde etmek için kullanılabilecek belirli türden kamuya açık bilgiler olabileceğini savunuyor. Kamuya açıklanan bilgilerin fiyatlara hızlı bir şekilde dahil edilmesi göz önüne alındığında, yarı güçlü etkin piyasada getiri elde etme olasılığı ulaşılamaz olarak kabul edilmektedir⁶⁰. Yani bazıları bir şirketin yönetiminin veya içeriden öğrenenlerin Al-Sat faaliyetinin halka açık olmayan bilgilerinin varlık fiyatlarına hemen yansımayabileceğini ve yatırımcılara fazla getiri elde etme fırsatları sağlayabileceğini iddia etmektedir. Bununla birlikte yarı güçlü EPH formunun savunucuları, bu tür herhangi bir bilgi asimetrisinin kısa ömürlü veya rastgele olduğunu ve uzun vadede tutarlı bir şekilde istismar edilemeyeceğini savunuyorlar. Hisse senedi fiyatlarının halka açık tüm bilgileri yansıttığı yaygın olarak kabul edilmektedir. Geçmiş fiyatlar ve işlem hacimleri gibi piyasa bilgilerinin yanı sıra faiz oranlarındaki değişimler, büyüme ve enflasyon oranları gibi makroekonomik veriler, hisse senedinin ait olduğu firmanın karları, satışları, yönetim kalitesi ve işgücüne ilişkin bilgiler, bilançolar ve siyasi olaylar, teknolojik gelişmeler, doğal kaynakların keşfi gibi ekonomik olmayan olayların hisse senedi fiyatlarını etkilediği düşünülür. Özetle bir hisse senedi veya varlığın fiyatı, piyasaya ulaşan herhangi bir yeni bilgi/veri ile anında hareket eder. Bu nedenle yeni bilgileri analiz ederek Al-Sat işlemleriyle herhangi bir ekstra kazanç sağlanamayacağına inanılmaktadır.

⁵⁹ Ana Rita Dos Anjos Batista, Ualison Maia, and Andrea Romero. "Stock Market under the 2016 Brazilian Presidential Impeachment: A Test in the Semi-Strong Form of the Efficient Market Hypothesis." *Revista Contabilidade & Finanças*, vol. 29, 2018, pp. 405-417.

⁶⁰ Enver Sümer and Şakir Aybar. "Etkin Piyasalar Hipotezinin, Finansal Piyasalardaki Yetersizliği ve Davranışsal Finans." *Erzincan Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, vol. IX, no. II, 2016, pp. 75-84.

Genelde EPH'nin yarı güçlü formu, yatırım stratejileri, finansal raporlama standartları ve piyasa verimliliği üzerinde etkileri olduğu için finans ve ekonomide çok önemli bir kavramdır. EPH'nin doğruluğu hakkında devam eden tartışmalara rağmen finans ve ekonomide temel bir kavram olmaya devam ediyor ve önemli bir akademik araştırma ve tartışma konusu olmaya devam etmektedir.

1.5.1.3.Güçlü Formda Etkinlik

Etkin Piyasa Hipotezi (EPH), finansal piyasaların etkin olduğunu ve finansal varlıkların cari fiyatlarının mevcut tüm bilgileri içerdiğini iddia eden bir finansal teoridir. EPH'nin en güçlü versiyonu ister kamu ister özel sektör olsun, tüm bilgilerin hem kamu hem de özel sektördeki finansal varlık fiyatlarına anında ve doğru bir şekilde yansıdığını varsayar. Güçlü formda etkinlik, fiyatların tüm geçmiş fiyatların bilgi içeriğini yansıttığı önermesidir; bu, hiçbir analiz biçiminin bir yatırımcıya avantaj sağlamasının beklenemeyeceği anlamına gelir⁶¹.

EPH'nin güçlü biçimi altında, yatırımcılar, kamuya açık veya özel herhangi bir bilgiyi analiz ederek tutarlı bir şekilde fazla getiri elde edemezler ve içeriden öğrenenlerin Al-Sat yapmaları veya halka açık olmayan bilgilere erişim, yatırımcıların fazla getiri elde etmeleri için güvenilir bir yol sağlayamaz. Dolayısıyla, güçlü form etkinliği sergileyen bir piyasada, menkul kıymet fiyatları zaten mevcut tüm piyasa bilgilerini içerdiğinden, işletmelere ait özel bilgilerin kullanılması normalin üzerinde getirilerin elde edilmesini sağlamaz⁶². EPH'nin güçlü biçimini eleştirenler, belirli özel bilgi türlerinin varlık fiyatlarını hemen etkileyebileceğini ve fazla getiri elde etmek için kullanılabilirliğini savunuyor. Örneğin özel veri akışlarına erişimi olan yüksek frekanslı tacirler fazladan getiri elde edebilir. EPH'nin güçlü formu hem kamu hem de özel bilgi girdilerinin, piyasa etkinliğinin en gelişmiş şekli olarak kabul edilen bir hisse senedinin fiyatını doğrudan etkilediğini göstermektedir. Özel bilgilere sahip kişiler, bu bilgiler kullanılarak işlem yapılan piyasalarda normalden daha yüksek getiri elde etme şansına sahip değildir. Yani özel bilgilere sahip bir yönetici, çalışan veya yatırımcı bu

⁶¹ Matthew Chau and Dimitri Vayanos. "Strong-Form Efficiency with Monopolistic Insiders." The Review of Financial Studies, vol. 21, no. 5, 2008, pp. 2275-2306.

⁶² Hasan Eken and Sait Adalı. "Piyasa Etkinliği ve İMKB: Zayıf Formda Etkinliğe İlişkin Ekonometrik Bir Analiz." Muhasebe ve Finansman Dergisi, vol. 37, 2008.

bilgilerden dolayı ortalamanın üzerinde getiri elde edemez. Bir piyasanın etkinlik durumunu veya hangi etkinlik grubuna ait olduğunu belirlemek için dört temel koşulun doğrulanması gerekir. Bu koşullar, hisse senedi fiyatlarındaki değişikliklerin rastgele olması, hisse senedi fiyatlarının yeni bilgilere anında ve doğru bir şekilde tepki vermesine bireysel ne de profesyonel yatırımcıların sürekli olarak ek gelir elde edememesi ve alım satımla ilgili bazı yöntemlerin ek gelir sağlamamasını içermektedir.

EPH'nin doğruluğu devam eden bir tartışma konusu olsa da finans ve ekonomide temel bir kavram ve önemli bir akademik araştırma ve tartışma konusu olmaya devam etmektedir.

1.5.3. Anomaliler

Akademik çevrelerde "anomali" terimi, yerleşik modellerden veya normlardan sapmayı ifade eder.

Finansta anomali, mevcut teoriler veya modellerle açıklanamayan bir olguyu ifade eder. Bu bağlamda bir anomali, potansiyel dolandırıcılık faaliyetini gösteren, normdan sapan olağandışı kalıpları veya faaliyetleri ifade eder⁶³. Anomali kavramı finans alanında kapsamlı bir şekilde incelenmiştir ve çeşitli akademik bilim adamları tanımına katkıda bulunmuştur. Finansta anomaliyi tanımlayan en önemli bilim adamlarından biri Eugene Fama'dır. Fama, Nobel ödüllü bir ekonomist ve etkin piyasa hipotezinin öncülerinden biridir. Fama'ya göre anomali, varlık fiyatlandırma modellerinde yaygın olarak kullanılan risk faktörleri tarafından açıklanamayan bir menkul kıymetin beklenen getirisinden kalıcı bir sapmadır⁶⁴. Fama'nın anomali tanımı finans camiasında geniş çapta kabul görmüş ve konuyla ilgili birçok çalışmaya temel teşkil etmiştir. Anomalinin tanımına katkıda bulunan bir diğer akademisyen Kenneth French'dir. French, Dartmouth College'da finans profesörüdür ve en çok üç faktörlü model üzerindeki çalışmasıyla tanınır. French'e göre anomali, etkin piyasa hipotezi ile tutarsız olan ve mevcut varlık fiyatlandırma modelleriyle açıklanamayan bir olgudur. French'in anomali tanımı, piyasa etkinliğinin önemini ve piyasa davranışını açıklamada

⁶³ Dong Huang, Di Mu, Lin Yang, and Xiongcai Cai. "CoDetect: Financial Fraud Detection with Anomaly Feature Detection." IEEE Access, vol. 6, 2018, pp. 19161-19174.

⁶⁴Eugene F. Fama and Kenneth R. French. "The Cross-Section of Expected Stock Returns." The Journal of Finance, vol. 47, no. 2, 1992, pp. 427-465.

mevcut modellerin sınırlamalarını vurgulamaktadır⁶⁵. Finans ve ekonomi alanlarında anomaliler, geleneksel finansal teorilerle veya piyasa etkinliği ilkesiyle çelişen modeller veya eğilimlerdir. Yatırım stratejileri, finansal modelleme ve finansal piyasaların etkinliği üzerindeki potansiyel etkileri göz önüne alındığında anomalilerin incelenmesi finans ve ekonomide büyük önem taşımaktadır. En temel başlıklarla toplayacak olursak anomaliler: Kesitsel anomaliler, Teknik anomaliler, Politik faktörlere dayalı anomaliler ve Dönemsel (takvim) anomalileridir⁶⁶. Buna ek olarak finansal piyasalarda çok sayıda anomali türü meydana gelebilir

Finans ve ekonomi alanlarındaki araştırmacılar, anomalilerin altında yatan nedenleri tartışırken, bazıları bunları yatırımcılar arasındaki aşırı güven veya sürü davranışı gibi davranışsal önyargılara bağlarken diğerleri anomalilerin yatırımcıların fiyat farklılıklarından yararlanmalarını sağlayan piyasa verimsizliklerinden kaynaklandığını iddia etmektedir. Akademik literatürde anomali teorisine uymayan bir anomali, gözlem veya gerçeklik olarak adlandırılır. Belirli bir gözlemin mevcut teorik çerçeve içinde açıklanması zorsa veya bunu yapmak için uygun olmayan varsayımlar gerektiriyorsa bu bir anomali olarak kabul edilmektedir. Başka bir deyişle, "anomali" terimi, çoğunluk tarafından kabul edilen ilke ve varsayımların ihlalini ifade eder.

1.5.3.1. Haftanın Günü Anomalisi

Finansta haftanın günü anomalisi, hisse senedi getirilerinin haftanın farklı günlerine eşit olarak dağılmaması olgusunu ifade eder. Takvim anomalilerinin varlığı, hisse senedi getirilerinin zamanla değişmez olduğunu, yani hisse senedi getirilerinde kısa dönemli mevsimsel bir örüntü olmadığını ifade eden zayıf etkin piyasa hipotezinin reddidir⁶⁷. Fakat ampirik kanıtlar, Pazartesi günlerindeki ortalama getirinin hafta içi diğer günlerden daha düşük olma eğiliminde olduğunu Cuma günlerindeki ortalama getirinin ise daha yüksek olma eğiliminde olduğunu göstermektedir. Malezya Borsası'nda haftanın günü etkisinin var olduğu, ancak yalnızca Pazartesi etkisinin

⁶⁵Kenneth R. French and Eugene F. Fama. "Common Risk Factors in the Returns on Stocks and Bonds." *Journal of Financial Economics*, vol. 33, no. 1, 1993, pp. 3-56.

⁶⁶ Tufan, Cenk, and Reyhan SARIÇİÇEK. "Davranışsal Finans Modelleri, Etkin Piyasa Hipotezi ve Anomalilerine İlişkin Bir Değerlendirme." *Trakya Üniversitesi Sosyal Bilimler Dergisi* 15.2 (2013): 159-182. s174

⁶⁷ Md. Lutfur Rahman. "Stock Market Anomaly: Day of the Week Effect in Dhaka Stock Exchange." *International Journal of Business and Management*, vol. 4, no. 5, 2009, pp. 193-206.

olduğu tespit edilmiştir⁶⁸. Bu anomali, hisse senedi fiyatlarının mevcut tüm bilgileri yansıttığını ve bu nedenle getirilerin haftanın farklı günleri arasında rastgele dağıldığını varsayan etkin piyasa hipoteziyle çelişmektedir. Haftanın günü anomalisini açıklamak için çeşitli teoriler öne sürülmüştür. Bir teori, yatırımcıların pazartesi günleri daha iyimser ve cuma günleri daha karamsar olduğunu öne süren yatırımcı duyarlılığı kavramına dayanmaktadır. Bu durum yatırımcıların hafta sonu daha fazla olumsuz haber okuma eğiliminden kaynaklanabilir, bu da onların ruh halini ve dolayısıyla yatırım kararlarını etkiler. Benzer şekilde yatırımcılar olumlu haberler beklentisiyle cuma günleri daha iyimser olabilirler. Başka bir teori haftanın günü anomalisinin, işlem hacmi ve alış-satış marjları gibi piyasa mikro yapı faktörleriyle ilişkili olduğunu öne sürüyor. İşlem hacminin pazartesi günleri daha yüksek, cuma günleri ise daha düşük olduğu gözlemlendi. Bunun nedeni yatırımcıların hafta sonu yayınlanan haberlere cevaben portföylerini ayarlama eğiliminden kaynaklanıyor olabilmektedir ve bu da pazartesi günleri daha yüksek alım satım faaliyetiyle sonuçlanmaktadır. Sonuç olarak, teklif-satış marjları pazartesi günleri daha geniş olma eğilimindedir ve bu da daha düşük getirilere yol açabilmektedir. Yatırımcılar, cuma ve pazartesi günleri işlem yaparak anomaliden potansiyel olarak yararlanabilirler. Ancak bu stratejiler işlem maliyetlerine tabidir ve tüm yatırımcılar için uygun olmayabilir. Sonuç olarak haftanın günü anomalisi devam eden bir araştırma ve tartışma konusu olmaya devam ederken yatırımcılar potansiyel piyasa verimsizliklerinin farkında olmalı ve yatırım kararları verirken bunları dikkate almalıdır. Bu anomali literatürde hafta sonu etkisi olarak da anılmaktadır.

1.5.3.2. Ocak Ayı Anomalisi

Ocak anomalisi, hisse senedi getirilerinin Ocak ayında diğer aylara göre daha yüksek olma eğilimini ifade eder⁶⁹. Takvim anomalileri, hisse senetlerinin ocak ayında diğer aylara göre daha iyi performans gösterme eğiliminde olduğunu gösteren ocak etkisi gibi yılın belirli zamanlarında meydana gelen hisse senedi fiyat modellerini ifade

⁶⁸ Nurul Muhammad and Norazlina Mohamad Nor Azman Rahman. "Efficient Market Hypothesis and Market Anomaly: Evidence from Day-of-the-Week Effect of Malaysian Exchange." International Journal of Economics and Finance, vol. 2, no. 2, 2010, pp. 35-42.

⁶⁹ Richard H. Thaler. "Anomalies: The January Effect." Journal of Economic Perspectives, vol. 1, no. 1, 1987, pp. 197-201.

eder. Bu tür anomaliler, hisse senedi fiyatlarının rastgele ve öngörülemez olması gerektiğini öne süren etkin piyasa hipoteziyle çelişmektedir. Çeşitli piyasalarda ve zaman dilimlerinde yapılan araştırmalar, ocak ayındaki hisse senedi getirilerinin diğer aylara göre daha yüksek olduğunu, küçük çaplı hisse senetlerinin ve düşük fiyat/defter oranına sahip hisse senetlerinin daha belirgin bir etkiye sahip olduğunu ortaya koymuştur. Anomali için önerilen açıklamalar arasında yıl sonundaki satış baskısı nedeniyle ocak ayında alım fırsatları yaratan vergi zararı satışı ve yeni bir yılın başlangıcında ve iş döngüsünde daha olumlu olma eğiliminde olan yatırımcı duyarlılığı yer alıyor.

Aylık anomalileri inceleyen araştırmalar, ocak ayını sürekli olarak diğerlerine kıyasla olumlu getiri sağlayan bir ay olarak tanımlamıştır. Ancak negatif getirilerin meydana geldiği istisnalar vardır ve hisse senedi, borsa, krizler, politik veya ekonomik kararlar ve dönemler gibi faktörlere bağlı olarak değişkenlikler söz konusudur. Ocak ayında risk faktörü daha yüksektir, bu da rasyonel yatırımcıları ay içinde işlem yapmaya teşvik eder ancak anomali yanlış risk ölçümünden kaynaklanır. Yatırımcılar ayrıca kayıpları dengelemek ve vergi tabanlarını azaltmak için aralık ayında zarar eden hisse senetlerini satarak fiyatların düşmesine yol açarak ocak ayında alım fırsatları yaratır. Ayrıca özellikle ocak ayında finansal ve ekonomik alanlardaki değişim haberleri hisse senedi fiyatlarını etkilemektedir.

1.5.3.3. Ay İçi Anomalisi

Ay içi anomali, hisse senedi getirilerinin ay boyunca eşit olarak dağılmadığını ifade eder. Genellikle yatırımcı davranış kalıpları ve piyasanın haberlere verdiği tepkilerle ilişkilendirilir⁷⁰. Ay içi anomalisi menkul kıymetlerin ay ortasında daha yüksek, ay başında ve sonunda ise daha düşük getiri gösterdiği finansal piyasalarda görülen bir olgudur. Bu anomali, hisse senedi fiyatlarının mevcut tüm bilgileri yansıttığını ve getirilerinin zaman içinde rastgele dağıldığını varsayan etkin piyasa hipoteziyle çelişmektedir. Ampirik kanıtlar, çeşitli pazarlarda ve zaman dilimlerinde ay içi anomalilerin varlığını belgelemiştir. Çalışmalar menkul kıymetlerin ortalama

⁷⁰ Andrea Frazzini. "The Disposition Effect and Underreaction to News." The Journal of Finance, vol. 61, no. 4, 2006, pp. 2017-2046.

getirilerinin özellikle büyük sermayeli ve yüksek likiditeye sahip hisse senetleri için ay ortasında daha yüksek, ayın başında ve sonunda daha düşük olma eğiliminde olduğunu göstermektedir. Ay içi anomaliyi açıklamak için çeşitli açıklamalar önerilmiştir. Bir açıklama, bireylerin maaşlarını veya diğer düzenli gelirlerini aldıkları dönemde yatırım ve Al-Sat yapmada daha aktif olma eğiliminde oldukları ve bunun da ay ortasında daha yüksek satın alma baskısına ve getirilere yol açtığı yatırımcı davranışına dayanmaktadır. Diğer bir açıklama kurumsal Al-Sat işlemlerine dayanmaktadır, çünkü bazı kurumsal yatırımcılar ay boyunca düzenli aralıklarla fon alabilir ve bunları piyasaya yatırarak daha yüksek getiri sağlayabilir. Yatırımcılar için menkul kıymetler piyasasındaki anomalileri tespit etmek kar elde etmede değerli olabilmektedir. Yatırımcılar, fiyatların düşük olduğu dönemlerde menkul kıymet alıp fiyatlar yükseldiğinde satarak kar elde edebilirler.

1.5.3.4. Bayram (Tatil) Anomalisi

Finanstaki tatil anomalisi Kurban Bayramı, Şeker Bayramı, Noel, Şükran Günü veya Bağımsızlık Günü gibi belirli tatillerde hisse senedi getirilerinin anormal derecede yüksek veya düşük olma eğiliminde olduğu gözlemini ifade eder. Bu anomali, hisse senedi fiyatlarının mevcut tüm bilgileri yansıttığını ve getirilerin zaman içinde rastgele dağıldığını varsayan etkin piyasa hipotezinle çelişmektedir. Tatil anomalisi kavramı literatürde kendi adıyla anılmamakta, daha çok tatil etkisi olarak adlandırılmaktadır. Ampirik kanıtlar, tatil anomalisini farklı finansal piyasalar ve zaman dilimlerinde belgelemiştir. Tatil etkisi, tatillerden (tatil öncesi) hemen önceki işlem gününde ortalama hisse senedi getirisinin diğer işlem günlerine göre daha yüksek olduğu ifade eder⁷¹. Bu etki özellikle küçük çaplı hisse senetleri ve düşük likiditeye sahip hisse senetleri için belirgindir.

Tatil anomalisini açıklamak için çeşitli açıklamalar önerilmiştir. Yatırımcıların tatile olan duyarlılıklarına bağlı olarak tatillere karşı olumlu veya olumsuz duygular sergileyebilecekleri piyasa psikolojisine dayanmaktadır. Meselâ, yatırımcılar Kurban Bayramı döneminde ekonomi ve piyasalar hakkında daha iyimser olabilmektedir, bu da

⁷¹ Wing-Keung Wong, Aigbe Akhigbe, and Nee-Tat Wong. "The Disappearing Calendar Anomalies in the Singapore Stock Market." The Lahore Journal of Economics, vol. 11, no. 2, 2006, pp. 123-139.

tatil öncesi ve tatilden sonra daha yüksek getiri sağlar. Başka bir açıklama piyasa likiditesine dayanmaktadır, çünkü tatil dönemlerinde işlem hacimleri daha düşük olma eğilimindedir, bu da tatil sırasında daha yüksek oynaklığa ve daha düşük getirilere yol açar.

1.5.3.5. Yaz Saati Uygulaması Anomalisi

Finanstaki yaz saati uygulaması anomalisi, ilkbaharda yaz saatine geçişin ardından pazartesi günü hisse senedi getirilerinin anormal derecede düşük, sonbaharda standart saate dönüşün ardından pazartesi günü ise anormal derecede yüksek olduğu gözlemini ifade eder. Etki özellikle büyük hacimli ve oldukça likit hisse senetleri için belirgindir; ortalama getiriler, yaz saatine geçişin ardından pazartesi günü normalden düşük ve standart saate geçişin ardından pazartesi günü normalden daha yüksektir. Firmalar ayrıca, saat değiştikten sonraki ilk işlem gününde birleşme duyurularına yanıt olarak daha belirgin hisse senedi getirisi oynaklığı yaşarlar⁷².

1.5.3.6. Diğer Anomaliler

Değer Anomalisi, düşük fiyat-kazanç veya fiyat-defter oranlarına sahip hisse senetlerinin, geleneksel finans teorisiyle çelişen daha yüksek fiyat-kazanç veya fiyat-defter oranlarına sahip hisse senetlerinden daha iyi performans göstermesini içermektedir.

Momentum Anomalisi, güçlü son performansa sahip hisse senetlerinin iyi performans göstermeye devam etme eğilimindeyken, son performansı zayıf olan hisse senetlerinin düşük performans gösterme eğiliminde olduğu olgusunu tanımlar⁷³. Bu da etkin piyasa hipoteziyle çelişmektedir.

Boyut Anomalisi, uzun vadede büyük sermayeli hisse senetlerinden daha iyi performans gösteren küçük sermayeli hisse senetlerine atıfta bulunur. Bu da etkin piyasa hipoteziyle çelişmektedir.

⁷² Anastasios Siganos. "The Daylight Saving Time Anomaly in Relation to Firms Targeted for Mergers." *Journal of Banking & Finance*, vol. 105, 2019, pp. 36-43.

⁷³ Jegadeesh, N. & Titman, S. (1993), "Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency", *Journal of Finance* 48, 65-91.s 90

Sonuç olarak, finanstaki anomali kavramı süregelen bir araştırma ve tartışma konusu olmaya devam ederken, yatırımcılar potansiyel piyasa verimsizliklerinin farkında olmalı ve yatırım kararları verirken bunları dikkate almalıdır.

1.6. Davranışsal Finans

Bir ekonomist, psikoloji disiplini göz ardı etmeye çalışabilir; bununla birlikte, insan doğasını kabul etmenin kaçınılmazlığı, ekonomi ve insan davranışı arasındaki içsel bağlantı nedeniyle ortaya çıkıyor. Bir sosyal bilim olarak ekonominin özü, temel olarak karar verme, kaynak tahsisi ve piyasa dinamikleri bağlamında insan davranış kalıplarının incelenmesidir. Böylece, insan doğasının anlaşılması alan için vazgeçilmez olmaya devam etmektedir⁷⁴. Davranışsal finans, psikolojik ve bilişsel faktörlerin finansal karar verme üzerindeki etkisini inceleyen bir finans alt alanıdır. Davranışsal finans, bazı finansal aktörlerin tamamen rasyonel olmayan modeller kullanılarak bazı finansal olayların makul bir şekilde anlaşılabilirliğini savunuyor. Alanın iki yapı taşı vardır: rasyonel tacirler için daha az rasyonel tacirlerin neden olduğu bozulmaları geri almanın zor olabileceğini öne süren arbitraj limitleri ve tam akılcılıktan görmeyi bekleyebileceğimiz sapma türlerini kataloglayan psikoloji⁷⁵. Bireylerin karar verme süreçlerinde her zaman rasyonel veya objektif olmadıklarını kabul eder, bireylerin finansal seçimlerini etkileyen önyargıları ve psikolojik eğilimleri belirlemeye, onları anlamaya çalışır. Davranışsal finans, yatırımcıların piyasa işlemlerinden yüksek oranda kar elde etmelerine rağmen bazı sosyolojik ve psikolojik faktörler nedeniyle akılcı olmayan tutum ve davranışlar sergileyebileceklerini öne sürmektedir. Genel olarak davranışsal finans, diğer disiplinlerin yanı sıra ekonomi, psikoloji ve nörobilimden gelen içgörülerden yararlanan disiplinler arası bir alandır. Alanı tanımlayan tek bir kişi olmasa da yıllar boyunca birçok akademisyenin katkılarıyla şekillendi, yeni araştırmalar yapıldıkça ve yeni içgörüler kazanıldıkça gelişmeye devam etmektedir. Davranışsal finans alanında araştırmacılar, piyasadaki yatırımcıların tutum ve davranışlarını temel alan çeşitli modeller kullanmaktadır. Bu modeller yatırımcı davranışının psikolojik yönlerini yakalayan veri setleri kullanılarak

⁷⁴ Clark, John Maurice. "Economics and modern psychology: I." *Journal of Political Economy* 26.1 (1918): 1-30. s4

⁷⁵ Nicholas Barberis and Richard Thaler. "A Survey of Behavioral Finance." *Handbook of the Economics of Finance*, vol. 1, 2003, pp. 1053-1128.

oluşturulur. Bu modeller araştırmacıların, yatırımcıların davranışlarını ve piyasadaki anomalileri tanımlamasını ve gruplandırmasını sağlar.

Davranışsal finans, 1980'lerde ortaya çıkan ve son yıllarda büyük ilgi gören nispeten yeni bir alandır. Yıllar boyunca pek çok bilim insanının katkılarıyla şekillenen davranışsal finans alanını tanımlayan tek bir kişi yoktur. Alandaki en eski ve en etkili figürlerden biri davranışsal iktisat alanındaki çalışmalarıyla 2002'de Nobel Ekonomi Ödülü kazanan psikolog Daniel Kahneman'dır. Amos Tversky ile Kahneman birlikte, insanların beklenen faydaya dayalı olarak rasyonel kararlar aldığına dair geleneksel ekonomik varsayıma meydan okuyan beklenti teorisini geliştirdi. Beklenti teorisi, insanların kayıplara karşı kazançlardan daha duyarlı olduklarını ve katı mantık yerine buluşsal yöntemlere veya psikolojik eğilimlere dayalı kararlar aldıklarını varsayar⁷⁶. Davranışsal finansın gelişimindeki bir diğer önemli figür, davranışsal ekonomiye katkılarından dolayı 2017 yılında Nobel Ekonomi Ödülü'nü kazanan Richard Thaler'dir. Thaler'ın çalışması, mevcut kazançlara aşırı değer verme ve gelecekteki kayıpları hafife alma eğilimi gibi bilişsel önyargıların finansal karar verme üzerindeki etkisine odaklandı⁷⁷. Ayrıca insanların mali durumlarını bütünsel olarak görmek yerine paralarını ve varlıklarını ayrı hesaplarda bölümlere ayırmalarını öneren zihinsel muhasebe kavramını da geliştirdi⁷⁸. Davranışsal finans alanındaki diğer önemli akademisyenler arasında varlık fiyatlandırması ve piyasa irrasyonelliği üzerine yaptığı çalışmalardan dolayı 2013 yılında Nobel Ekonomi Ödülü'nü kazanan Robert Shiller ve geç dönemde "davranışsal finans" terimini icat etmesiyle tanınan Hershey Shefrin yer alıyor. Bu akademisyenler, davranışsal finansı akademik olarak nasıl tanımladıkları açısından, bilişsel önyargıların ve duygusal faktörlerin finansal karar vermeyi nasıl etkilediğinin yanı sıra bu faktörlerin varlık fiyatlandırması ve piyasa verimliliği üzerindeki etkilerini keşfetmeye odaklandılar. Ayrıca bu davranışsal faktörleri daha iyi açıklayan modeller geliştirmeye ve olumsuz etkilerini hafifletmek için stratejiler

⁷⁶Daniel Kahneman and Amos Tversky. "Prospect Theory: An Analysis of Decision Under Risk." *Econometrica*, vol. 47, no. 2, 1979, pp. 263-291.

⁷⁷ Nicholas Barberis and Richard H. Thaler. "A Survey of Behavioral Finance." *Handbook of the Economics of Finance*, vol. 1, 2003, pp. 1053-1128.

⁷⁸Richard H. Thaler. "Mental Accounting and Consumer Choice." *Marketing Science*, vol. 4, no. 3, 1985, pp. 199-214.

belirlemeye çalıştılar⁷⁹. Davranışsal finans, finansal kararların bireyler tarafından nasıl alındığını ve bu kararların psikolojik faktörlerden nasıl etkilendiğini anlamaya çalışırken hem finans hem de psikoloji ilkelerinden yararlanır. Davranışsal finans bu faktörleri anlayarak bireylerin neden belirli finansal kararlar aldıklarına ve bu kararların finansal sonuçlarını nasıl etkilediğine dair içgörü sağlayabilir. Bireysel tutum ve davranışlar, davranışsal finansın bilişsel çerçevesi içinde borsa getirilerinin ve hisse senedi fiyatlarının gelişimi ile bağlantılıdır. Başka bir deyişle davranışsal finans, piyasa verimsizliklerini veya rasyonellikten sapmaları yatırımcıların irrasyonel tutum ve davranışları açısından açıklamaya çalışır. Davranışsal finansın en önemli katkılarından biri finansal karar almayı etkileyebilecek çeşitli bilişsel önyargıların ve buluşsal yöntemlerin tanımlanmasıdır. Bu önyargılar, diğerlerinin yanı sıra aşırı güven, kayıptan kaçınma, çıpalama ve doğrulama yanlılığı gibi kategorilere ayrılabilir.

Aşırı güven, bireylerin yeteneklerini ve bilgilerini abartma eğilimini ifade eder ve bu da onların olması gerekenden daha büyük riskler almasına neden olabilmektedir. Aşırı güven modelleri, yatırımcıların bilginin kesinliğini abarttığını varsayar. Bu aşırı güven, yatırımcıların başlangıçtaki inançlarına çok sıkı bağlı kaldıkları ve yeni bilgilere yeterince uyum sağlayamadıkları çapalamaya yol açabilmektedir⁸⁰.

Kayıptan kaçınma, bireylerin eşdeğer kazançlar elde etmektense kayıplardan kaçınmayı tercih etme eğilimini ifade eder. Borsa bağlamında, yatırımcıların potansiyel kazançlardan çok potansiyel kayıplara karşı daha duyarlı olduğunu ima eder⁸¹. Diğer bir ifadeyle, kayıptan kaçınma, bireylerin kayıplardan kaynaklanan acıyı kazançlardan alınan zevkten daha fazla deneyimleme eğilimini ifade eder, bu da onları yararlı risklerden kaçınmaya yönlendirebilir.

Çıpalama, bireylerin aldıkları ilk bilgi parçasına çok fazla güvenme eğilimini ifade ederken doğrulama yanlılığı, bireylerin önceden var olan inançlarını doğrulayacak şekilde bilgiyi arama ve yorumlama eğilimini ifade eder. Çapalama önyargısı, aldığımız

⁷⁹Hersh Shefrin and Meir Statman. "The Disposition to Sell Winners Too Early and Ride Losers Too Long: Theory and Evidence." *The Journal of Finance*, vol. 40, no. 3, 1985, pp. 777-790.

⁸⁰ Markus Glaser and Martin Weber. "Overconfidence and Trading Volume." *The Geneva Risk and Insurance Review*, vol. 32, 2007, pp. 1-36.

⁸¹ David Genesove and Christopher Mayer. "Loss Aversion and Seller Behavior: Evidence from the Housing Market." *The Quarterly Journal of Economics*, vol. 116, no. 4, 2001, pp. 1233-1260.

ilk bilgiye çok fazla güvenmenizi etkileyen bilişsel bir önyargıdır. Borsa yatırımında, yatırımcıların bir hisse senedi için ödedikleri fiyata çıpalama eğilimini ifade eder⁸². Davranışsal finans, finansal karar vermede sosyal ve kültürel faktörlerin önemini de kabul eder. Açıkçası bireyler başkalarının davranışlarından, kültürel normlardan ve para ve servetle ilgili beklentilerden etkilenebilir. Sürü davranışı, bireylerin özellikle belirsiz veya muğlak durumlarda başkalarının davranışlarını taklit etme eğilimini ifade eder. Davranışsal finansın en önemli çıkarımlarından biri, bu önyargıların ve buluşsal yöntemlerin üstesinden gelmek için stratejiler geliştirme ihtiyacıdır. Bu, eğitim ve öğretim yoluyla finansal okuryazarlığın ve kişisel farkındalığın artırılmasının yanı sıra rasyonel karar almayı desteklemek için araç ve sistemlerin geliştirilmesini içerebilir.

Sonuç olarak davranışsal finans, psikolojik ve bilişsel faktörlerin finansal karar verme üzerindeki etkisini anlamaya çalışan, hızla büyüyen bir alandır. Davranışsal finans, önyargıları ve buluşsal yöntemleri belirleyip ele alarak bireylerin daha iyi finansal kararlar almalarına ve finansal sonuçlarını iyileştirmelerine yardımcı olabilmektedir.

1.6.1. Rasyonel Davranış

Bir varlığın rasyonel davranışı; bireyin davranışları en az kaynakla en iyi sonucu elde etmek veya belirli bir kaynakla mümkün olan en iyi sonucu elde etmek amacıyla düşünülmüş ve hesaplanmış kararları ve tercihleri içermektedir. Dolayısıyla buradan çıkarılabilecek bir sonuç şudur: İktisadi davranmak, rasyonel davranmakla eş anlamlıdır. Bu ilke, bireysel seçim ve davranış alanında kaynaklar ile istenen sonuçlar arasındaki temel etkileşimin altını çizerek ekonomik karar vermenin özünü özetler⁸³. Finasta rasyonel davranış kavramı, birçok ekonomik ve finansal teorinin özünü oluşturan temel bir kavramdır. Yatırımcıların, firmaların ve diğer ekonomik aktörlerin inançlarına ve tercihlerine göre kararlar aldıkları ve bu kararların iyi tanımlanmış bir dizi rasyonellik kuralıyla tutarlı olduğu varsayımını ifade eder. Bu görüşe göre ekonomik birimler, iyi tanımlanmış bir dizi rasyonellik kuralıyla tutarlı olduklarını

⁸² Lakshini Kengatharan and Niranjana Kengatharan. "The Influence of Behavioral Factors in Making Investment Decisions and Performance: Study on Investors of Colombo Stock Exchange, Sri Lanka." *Asian Journal of Finance & Accounting*, vol. 6, no. 1, 2014, pp. 1-16.

⁸³ Erkan, Hüsnü. *Sosyal piyasa ekonomisi: ekonomik sistem ve piyasa ekonomisine işlerlik kazandırması*. Konrad Adenauer Vakfı, 2001.

varsayarak mevcut bilgi ve tercihlere dayalı olarak kararlar alırlar. Bu kurallar, karar teorisinde ve mikroekonomide yaygın olarak kullanılan tamlik, geçişlilik ve bağımsızlık aksiyomlarını içerebilir. Rasyonel Beklentiler ve Fiyat Hareketleri Teorisi, John F. Muth: Modelinde, yatırımcıların mevcut tüm bilgilere dayanarak gelecekle ilgili beklentiler oluşturduğunu ve bu beklentilerin istatistiksel olarak optimal olduğunu varsayar⁸⁴. Finansta "rasyonel davranış" kavramı genellikle Amerikalı iktisatçı ve Nobel ödüllü Eugene Fama'nın çalışmasına atfedilir. Fama en çok finansal piyasaların "bilgi açısından verimli" olduğunu yani varlık fiyatlarının mevcut tüm bilgileri yansıttığını öne süren etkin piyasa hipotezi (EPH) konusundaki çalışmasıyla tanınır. Fama'nın rasyonel davranış üzerine çalışması, yatırımcıların rasyonel hareket ettikleri ve mevcut tüm bilgilere dayanarak kararlar aldıkları varsayımına dayanmaktadır. Etkin bir piyasada, rasyonel davranıştan herhangi bir sapmanın arbitraj yoluyla hızla düzeltildiğini ve bu nedenle tutarlı bir şekilde anormal getiri elde etmenin zor olduğunu savunuyor. Fama'nın rasyonel davranış konusundaki fikirleri finans alanında özellikle ampirik varlık fiyatlandırması alanında geniş ölçüde etkili olmuştur. Fama'ya ek olarak diğer akademisyenler de finansta rasyonel davranış kavramının gelişimine katkıda bulunmuştur. Özellikle başka bir Nobel ödüllü Robert Shiller, yatırımcıların psikolojik önyargılar ve diğer faktörler nedeniyle irrasyonel davranışlar sergileyebileceğini ve bunun da piyasa verimsizliklerine ve anormal getiri olasılığına yol açabileceğini savundu. Ancak bu bağlamda bile Shiller finansal piyasalarda rasyonel davranışın hala önemli bir rol oynadığını ileri sürmektedir.

Neo-klasik iktisat, faydalarını en üst düzeye çıkarmak için her zaman rasyonel seçimler ve tercihler yaparak rasyonel davranış sergileyen ekonomik bireyleri ifade eden Homo Ekonomikus kavramını ortaya attı. Rasyonellik, neo-klasik iktisat içindeki ekonomik analizde temel bir koşul olarak kabul edilmektedir. Neo-klasik iktisat, bireysel tutum ve davranışları açıklarken belirli varsayımlara dayanır. Bu varsayımlar bireylerin her koşulda akılcılık sergiledikleri, sınırsız iradeye sahip oldukları ve yalnızca bireysel çıkarları çerçevesinde hareket ettikleri düşüncesini içermektedir. Teorikteki doğruluğuna rağmen rasyonel davranış varsayımı hem akademik hem de pratik

⁸⁴ John F. Muth. "Rational Expectations and the Theory of Price Movements." *Econometrica*, vol. 29, no. 3, 1961, pp. 315-335.

ortamlarda eleştiriye ve incelemeye tabi tutulmuştur. Başlıca eleştirilerden biri rasyonel davranış varsayımının, insanın karar verme süreçlerinde var olan bilişsel önyargıları, duyguları ve sınırlamaları hesaba katmamasıdır. Davranışsal finans araştırması aşırı güven, kayıptan kaçınma, çerçeveleme etkileri ve sürü davranışı dahil olmak üzere yatırımcıların ve diğer ekonomik birimlerin karar verme sürecini etkileyen çok sayıda bilişsel önyargı ve buluşsal yöntemi belgelemiştir. Temel olarak davranışsal finans alanındaki araştırma, bireylerin standart modelden üç açıdan saptığını öne sürüyor: (1) standart olmayan tercihler, (2) standart olmayan inançlar ve (3) standart olmayan karar verme⁸⁵. Diğerlerinin yanı sıra bu önyargılar, rasyonel davranış varsayımlarıyla çelişen yetersiz karar verme ve piyasa verimsizliklerine yol açabilmektedir.

1.6.2. İrrasyonel Davranış

Davranışsal finans bilişsel önyargıların, duyguların ve diğer psikolojik faktörlerin yatırımcıların ve diğer ekonomik aktörlerin karar verme süreci üzerindeki etkisini araştırarak rasyonel davranış varsayımına meydan okuyan, finans içinde uzmanlaşmış bir alandır. Finanstaki irrasyonel davranış çalışması, piyasa verimsizliklerine ve anomalilerine ışık tutması ve fazla getiri fırsatlarını belirleme potansiyeli sunması nedeniyle önemlidir. Ancak ekonomik alanın karmaşık ve çok boyutlu yapısı nedeniyle ekonomik faaliyetlerde tam bir rasyonellik varsayımı yapmak mümkün değildir. Aksine ekonomik faaliyetlerde bulunan bireyler normlara, geleneklere ve alışkanlıklara dayalı olarak rasyonelliğe uymayabilecek tutumlar sergilerler.

Finanstaki irrasyonel davranışların incelenmesi, finansal piyasalar ve yatırımcılar için önemli çıkarımlara sahiptir. Davranışsal finans, finansal piyasaların her zaman bilgi açısından verimli olmayabileceğini, bilişsel önyargılar ve diğer psikolojik faktörler nedeniyle varlık fiyatlarının içsel değerlerinden sapabileceğini öne sürüyor. Piyasa güveninin getirilmesi, piyasa davranışındaki irrasyonelitenin olumsuz etkisini yansıtan fiyat oynaklığını artırmaktadır⁸⁶. Ocak ayı etkisi ve momentum etkisi gibi piyasa

⁸⁵ Stefano DellaVigna. "Psychology and Economics: Evidence from the Field." Journal of Economic Literature, vol. 47, no. 2, 2009, pp. 315-372.

⁸⁶ Maria Alessandra Bertella, Fernando Roberto Pires, Ling Feng, and H. Eugene Stanley. "Confidence and the Stock Market: An Agent-Based Approach." PLoS One, vol. 9, no. 1, 2014, e83488.ss. 1-8

anomalileri, rasyonel beklentilerden ziyade irrasyonel davranışlardan kaynaklanabilir. Mantıkla örtüşmeyen davranışın doğasının ve bunun finansal piyasalar ve yatırımcılar üzerindeki etkisinin anlaşılması yatırımcıların bilinçli kararlar almasına, yaygın tuzaklardan kaçınmasına ve yüksek getiri fırsatlarını belirlemesine yardımcı olabilmektedir. Ayrıca politika yapıcılara, istikrarı ve verimliliği teşvik etmek için finansal piyasalarda belirli davranış türlerini düzenlemenin potansiyel faydaları hakkında fikir verebilir.

1.7. Temel Analiz

Temel analiz, bir hisse senedi fiyatının değerlendirilmesinde en eski ve yaygın olarak kullanılan metodu temsil eder. Bu yaklaşım piyasa katılımcıları tarafından bir menkul kıymetin içsel değerini belirlemek amacıyla kullanılan baskın yöntem olarak finansal analiz alanında devam eden uygulanabilirliğini vurguluyor⁸⁷. Temel analiz, altında yatan ekonomik ve finansal faktörleri inceleyerek bir şirketin veya varlığın değerini değerlendirme yöntemidir. Basitçe söylemek gerekirse tahminlerde bulunmak için bir menkul kıymetle doğrudan veya dolaylı olarak ilişkili belirli, genel verileri ve bilgileri sistematik olarak analiz etmeyi içermektedir. Bu bilgileri toplama ve inceleme süreci üç aşamaya ayrılır: endüstri analizi, ekonomik analiz ve şirket analizi. Bu analiz bir varlığın gerçek değerini ve mevcut piyasa değerinin gereğinden az veya fazla değerlendirilmiş olup olmadığını belirlemek için hem nitel hem de nicel verilerin değerlendirilmesini içermektedir.

Temel analiz, piyasanın bir varlığın gerçek değerini her zaman doğru bir şekilde yansıtmayıp ve değerine katkıda bulunan temel faktörleri dikkatli bir şekilde analiz ederek bir yatırımcının daha bilinçli yatırım kararları verebileceği inancına dayanır. Tipik olarak temel analizde dikkate alınan niteliksel faktörler arasında rekabet ortamı, endüstri eğilimleri, yönetim kalitesi ve daha geniş ekonomik ortam yer alır. Bu faktörlerin ölçülmesi zor olabilir ancak değerlendirilmekte olan şirketin veya varlığın genel durumunu ve görünümünü anlamada önemlidir. Tipik olarak temel analizde dikkate alınan nicel faktörler, bilançolar, gelir tabloları ve nakit akış tabloları gibi mali

⁸⁷ Abdurrahman FETTAHOĞLU, 'Menkul Değerler Yönetimi', 1. Baskı, İstanbul: Rengin Yayınevi, 2003, s.226

tabloları içermektedir. Bu ifadeler bir şirketin finansal sağlığı, karlılığı ve nakit akışı yaratma yeteneği hakkında önemli bilgiler sağlar.

Bir metodoloji olarak temel analizin gelişimine katkıda bulunan birçok akademisyen ve uygulayıcı olmuştur. En etkili olanlardan bazıları Benjamin Graham, David Dodd, Warren Buffett ve John Burr Williams'dır. Benjamin Graham ve David Dodd, genellikle değer düşüklüğüne uğramış varlıkları belirlemeye çalışan temel bir analiz yaklaşımı olan değer yatırımının ilk akla gelen isimleri olarak anılır. İlk olarak 1934'te yayınlanan ufuk açıcı kitapları "Security Analysis"de temel verilere dayalı hisse senetlerini analiz etmek için kapsamlı bir çerçeve sundular⁸⁸. Warren Buffett, tüm zamanların en başarılı değer yatırımcılarından biridir ve temel analizi yatırım yaklaşımına dahil etmesiyle ünlüdür. Bir şirketin gerçek değerini belirlemek için bilançosu, gelir tablosu ve nakit akış tablosu dahil olmak üzere mali tablolarını analiz etmenin önemini vurguladı. John Burr Williams ilk olarak 1938'de yayınlanan "The Theory of Investment Value " adlı kitabında, gelecekteki nakit akışlarının bugünkü değerini belirlemek için temel analizde kullanılan popüler bir yöntem olan indirgenmiş nakit akışı analizi kavramını ortaya koydu⁸⁹. Bu öncülere ek olarak Martin Whitman, Joel Greenblatt ve Howard Marks dahil olmak üzere diğer birçok akademisyen ve uygulamacı temel analizin gelişimine katkıda bulunmuştur. Genel olarak temel analiz alanı, yeni veriler ve analitik teknikler kullanılabilir hale geldikçe gelişmeye devam etmektedir.

Temel analistler, diğerlerinin yanı sıra finansal oranlar, indirgenmiş nakit akışı modelleri ve hisse başına kazanç analizi dahil olmak üzere verileri değerlendirmek için çeşitli araç ve teknikler kullanır. Bu araçlar, analistlerin bir varlığın mevcut değerini değerlendirmesine ve geçmiş performansını diğer benzer varlıklarınkiyle karşılaştırmasına yardımcı olur. Temel analizin en önemli avantajlarından biri, güçlü uzun vadeli büyüme potansiyeline sahip olabilecek değer düşüklüğüne uğramış varlıkları belirleme yeteneğidir. Yatırımcılar, bir varlığın değerine katkıda bulunan altta yatan faktörleri dikkatli bir şekilde analiz ederek daha bilinçli yatırım kararları verebilir

⁸⁸ Benjamin Graham, David Le Fevre Dodd. Security Analysis: The Classic 1934 Edition. McGraw Hill Professional, 1934.

⁸⁹ John Burr Williams. The Theory of Investment Value. Harvard University Press, 1938.

ve potansiyel olarak daha yüksek getiri elde edebilir. Bununla birlikte temel analizin sınırlamaları vardır. Verileri düzgün bir şekilde analiz etmek zaman alabilir ve yüksek düzeyde uzmanlık gerektirebilir. Ayrıca, piyasa koşulları ve diğer dış faktörler bir varlığın değerini etkileyebilir ve her zaman tek başına temel analizle belirlenemez.

Özetle temel analiz, bir menkul kıymetin veya varlığın değerini değerlendirmek için kritik bir yöntemdir. Hem nitel hem de nicel verileri dikkatli bir şekilde analiz eden yatırımcılar, bir varlığın değerine katkıda bulunan temel faktörleri göz önünde bulundurarak daha bilinçli yatırım kararları alabilirler. Sınırlamalarına rağmen güçlü uzun vadeli potansiyele sahip düşük değerli varlıkları tespit etmek isteyen yatırımcılar için önemli bir araç olmaya devam etmektedir.

1.7.1. Ekonomi Analizi

Temel analiz, bir şirketi veya finansal varlığı içsel değerine ve ekonomik temellerine göre değerlendirme yöntemidir. Bir şirketin ekonomik analizi, bir şirketin gerçek değerini tahmin etmek için mali durumlarını, endüstri koşullarını ve pazar eğilimlerini inceleme sürecidir⁹⁰. Şirketin performansının başarısı veya başarısızlığı, faaliyet gösterdiği ekonomi ile yakından ilgilidir. Bazı şirketler faaliyet alanları gereği sadece devletin ekonomik koşullarından değil, dünya ekonomisinden de etkilenirler. Herhangi bir hisse senedinin değerlendirme sürecinde temel faktör hisse başına temettüdür. Bu nedenle bir şirketin kar elde etme ve temettülerini artırma kabiliyeti, faaliyet gösterdiği ekonominin gelişimi ile yakından ilgilidir. Ekonomi büyüme trendinde ise firmaların bu büyümeden fayda sağlayacağını ve hisse senetlerinin değerlerinde artış olacağını söylemek mümkündür. Ekonomi yavaşlamaya girerse, durgunluk şirketleri de etkiler ve hisse senetlerinin değeri düşer. Bir ekonomi açısından temel analiz genel sağlığını, büyüme potansiyelini ve gelecekteki beklentilerini anlamak için çeşitli ekonomik göstergelerin incelenmesini içermektedir.

Ekonomik analiz, finansta temel analizin yapı taşıdır. Bu alandaki önde gelen akademisyenlerden biri Benjamin Graham'dır. Graham, "The Intelligent Investor " adlı

⁹⁰ Zofio, J., Condeço-Melhorado, A., Maroto-Sánchez, A., & Gutiérrez, J. "Generalized transport costs and index numbers: A geographical analysis of economic and infrastructure fundamentals." *Transportation Research Part A: Policy and Practice*, 67(C), 2014. ss141-157.

kitabında, bir şirketin faaliyet gösterdiği daha geniş ekonomik bağlamı analiz etmenin önemini vurguladı. Bir şirketin hisse senedinin gerçek değerini belirlemede makroekonomik ortamı anlamının çok önemli olduğuna inanıyordu⁹¹. Bu alandaki bir diğer etkili bilim adamı Talep yönlü iktisat ekonomi teorisi ile tanınan John Maynard Keynes'dir. Keynes, ekonomiyi yönetmede hükümet müdahalesinin rolünü vurguladı ve ekonomiyi istikrara kavuşturmak için maliye ve para politikalarının kullanılmasını savundu. Temel analiz bağlamında Keynesyen ekonomi, makroekonomik politikaların bireysel şirketler ve bir bütün olarak borsa üzerindeki etkisini anlamak için genel bir çerçeve sağlar. Keynes'in ekonomi analizi, ekonomik karar vermede beklentilerin ve güvenin önemini de vurguladı. Beklentilerdeki değişikliklerin yatırım ve tüketimde değişikliklere yol açabileceğini ve hükümet politikasının beklentileri dengelemeye ve ekonomiye güveni artırmaya yardımcı olabileceğini savundu. Genel olarak temel analizde ekonomik analiz anlayışı geniş ve karmaşık bir alandır, farklı bakış açıları ve yaklaşımlara sahip çeşitli akademisyenlerin katkılarıyla şekillenir. Genel olarak temel analizde analiz edilen makroekonomik göstergelerden bazıları aşağıdadır⁹²:

Gayri Safi Yurtiçi Hasıla (GSYİH): GSYİH, bir ekonomide belirli bir dönemde üretilen mal ve hizmetlerin toplam değeridir. Büyüyen bir GSYİH, genellikle bir ekonomi için olumlu bir işaret olarak görülür.

İşsizlik Oranı: İşsizlik oranı, işsiz işgücünün yüzdesidir. Düşük bir işsizlik oranı genellikle sağlıklı bir ekonominin işareti olarak görülür.

Enflasyon: Enflasyon, mal ve hizmet fiyatlarındaki artış oranıdır. İlimli enflasyon seviyeleri genellikle bir ekonomi için sağlıklı kabul edilirken, yüksek enflasyon sorunlara işaret edebilir.

Faiz Oranları: Faiz oranları, ekonomik büyümeyi etkileyebilecek borçlanma ve borç vermeyi etkiler. Düşük faiz oranları ekonomik aktiviteyi canlandırabilirken, yüksek faiz oranları ekonomiyi yavaşlatabilir.

⁹¹ Benjamin Graham. The Intelligent Investor: A Book of Practical Counsel. 1. Baskı. Harper Business Essentials, 2006

⁹² LAVRENCHENKO, DMYTRO. "Application of fundamental analysis." Brno 2022

Tüketici Güveni: Tüketici güveni, tüketicilerin ekonomi ve mali durumları hakkında ne kadar iyimser olduklarını ölçer. Yüksek tüketici güveni genellikle artan harcamalara yol açar ve bu da ekonomik büyümeyi teşvik edebilir.

Temel analiz bu temel ekonomik göstergelere ek olarak hükümet politikalarını, uluslararası ticari ilişkileri ve ekonomiyi etkileyebilecek diğer faktörleri incelemeyi de içerebilir. Genel olarak bir ekonominin analizi, yatırımcılara ve analistlere büyüme potansiyeli ve yatırım fırsatları hakkında değerli bilgiler sağlayabilir. Bununla birlikte ekonomik göstergelerin değişebileceğini ve çeşitli faktörlerden etkilenebileceğini not etmek önemlidir. Bu nedenle temel analiz, diğer analiz ve araştırma biçimleriyle birlikte kullanılmalıdır.

1.7.2. Sektör Analizi

Temel analizde endüstri analizi, bir endüstrinin yapısını, rekabet ortamını ve gelecekteki görünümünü yönlendiren trendleri içeren bileşenlerini sistematik olarak inceleme sürecidir⁹³. Sektör analizi, potansiyel yatırım fırsatlarını belirlemek için ekonominin farklı sektörlerini değerlendirmeyi içeren temel bir analitik yöntemdir. Ekonomik faktörlerin yanı sıra şirketlerin faaliyet gösterdiği sektörün ekonomik durumuna olan duyarlılığı da büyük önem taşımaktadır. Genel bir ekonomik kriz döneminde bazı sektörler gelişme gösterirken bazı sektörler durgunluk yaşayabilir. İnşaat, yapı malzemeleri, otomotiv, tekstil gibi sektörler diğer sektörlerle göre oldukça hassas ve ekonomik yavaşlamaların etkisine açıktır. Borsaya yatırımı yapan bir yatırımcı, genel ekonomik koşulların yatırım için uygun olduğuna karar verdikten sonra sektör verilerini değerlendirerek hangi sektöre yatırım yapacağını belirlemelidir. Sektör benzer teknolojileri kullanarak benzer ürünler üreten sınai veya ticari faaliyet alanıdır benzer ürünleri aynı pazara sunar, benzer girdi verileri kullanır ve benzer tüketici gruplarını hedefler. Bir şirketin büyümesi ve gelişmesi, faaliyet gösterdiği sektörün kapsamına bağlıdır. Yatırımcılar, her sektörü analiz ederek en iyi performans gösteren sektörleri belirleyebilir ve bu sektörlerle yatırım yapmak için uygun hisse senetlerini seçebilir.

⁹³ Marlon Dumas, Marcello La Rosa, Jan Mendling, Hajo A. Reijers, Marlon Dumas, Marcello La Rosa, ... & Hajo A. Reijers. "Introduction to business process management." Fundamentals of business process management, vol. 1, 2018, pp. 1-33.

Temel analizde "sektör analizini" tanımlayan kesin bir kaynak veya yazar yoktur, kavram akademik literatürde ve endüstri uygulamalarında geniş çapta incelenmiş ve tartışılmıştır. Bununla birlikte finans alanında sektör analizinin anlaşılmasına katkıda bulunan bazı önemli yazarlar ve kaynaklar şunları içermektedir:

Benjamin Graham: Genellikle değer yatırımının önde gelen bireylerinden olarak kabul edilen Graham, değer düşüklüğüne uğramış hisse senetlerini belirlemek için bireysel şirketleri ve sektörleri analiz etmenin önemini vurguladı. Yeni ufuklar açan kitabı "Akıllı Yatırımcı" da yalnızca piyasa eğilimlerine veya makroekonomik faktörlere güvenmek yerine şirketleri kendi değerlerine göre analiz etmeyi içeren aşağıdan yukarıya bir yatırım yaklaşımını savundu⁹⁴. David Dreman: Dreman, hisse senedi seçiminde sektör analizinin önemi hakkında kapsamlı yazılar yazan tanınmış bir değer yatırımcısı ve yazardır. "Contrarian Investment Strategies" adlı kitabında piyasanın gözünden kaçan ve bunun sonucunda değer düşüklüğüne uğrayabilecek sektörlerin tespit edilmesi gerektiğini vurguluyor⁹⁵. Michael Porter: Porter, iş stratejisi alanında önde gelen bir akademisyendir ve rekabet avantajı konusundaki çalışmalarıyla tanınmaktadır. "Rekabet Stratejisi" adlı kitabında, karlılığın temel itici güçlerini belirlemek ve sürdürülebilir bir rekabet avantajı geliştirmek için endüstrileri ve sektörleri analiz etmenin önemini tartışıyor⁹⁶. Genel olarak sektör analizi, finansta temel analizin kritik bir bileşenidir ve belirli bir sektördeki bireysel hisse senetlerinin performansını etkileyebilecek çeşitli makroekonomik ve sektöre özgü faktörlerin analizini içermektedir. Yatırımcılar farklı sektörlerin dinamiklerini anlayarak ve bu trendlerden faydalanabilecek konumda olan şirketleri belirleyerek, sermayelerini nereye tahsis edecekleri konusunda daha bilinçli kararlar alabilirler.

Sektör analizinde ilk adım ekonominin farklı sektörlerini belirlemektir. Bazı yaygın sektörler enerji, finans, sağlık, malzeme, teknoloji ve tüketici temellerini içermektedir. Sektörler belirlendikten sonraki adım, sektör eğilimleri ve büyüme potansiyeli, rekabet ortamı ve pazar payı, düzenleyici ortam ve hükümet politikaları, sektördeki şirketlerin finansal performansı ve değerlendirme ölçütleri gibi çeşitli faktörleri

⁹⁴Graham, B., & Dodd, D. L. (2008). Security analysis: Principles and technique. McGraw-Hill.

⁹⁵David Dreman. "Contrarian Investment Strategies: The Next Generation." Simon & Schuster, 1998..

⁹⁶Michael E. Porter. "Competitive Strategy: Techniques for Analyzing Industries and Competitors." Free Press, 1980.

inceleyerek her bir sektörü analiz etmektir; Fiyat-kazanç oranı ve temettü verimi gibi. Yatırımcılar, her sektörü analiz ederek en iyi büyüme potansiyeline sahip sektörleri ve değer kaybı yaşayan sektörleri belirleyebilir. Yani, bir sektörün ürün veya hizmetlerine yönelik artan talep nedeniyle güçlü bir büyüme göstermesi bekleniyorsa yatırımcılar o sektördeki şirketlere yatırım yapmayı düşünebilir. Tersine artan rekabet veya olumsuz hükümet politikaları nedeniyle bir sektörün düşmesi bekleniyorsa yatırımcılar o sektördeki şirketlere yatırım yapmaktan kaçınmak isteyebilir. Genel olarak sektör analizi, yatırımcıların potansiyel yatırım fırsatlarını belirlemesine ve bilinçli yatırım kararları vermesine olanak tanıdığı için temel analiz için önemli bir araçtır. Bununla birlikte, iyi bilgilendirilmiş yatırım kararları almak için sektör analizinin diğer analiz ve araştırma biçimleriyle birlikte kullanılması gerektiğine dikkat etmek önemlidir.

1.7.3 Firma Analizi

Bir firmanın analizi, belirli bir şirketin yatırım potansiyelini belirlemek için finansal ve ekonomik temellerinin değerlendirilmesini içeren temel bir analiz yöntemidir. Firma analizinin amacı bir şirketin finansal tablolarını, yönetim ekibini, rekabetçi konumunu ve diğer ilgili faktörleri inceleyerek içsel değerini belirlemektir. Temel analizde şirket analizi şirketin iş modelini, operasyonel ve finansal performansını ve pazardaki rekabetçi konumunu inceleme sürecidir. Finansal sağlığının yanı sıra şirketin güçlü, zayıf yönleri, fırsat ve tehditlerinin ayrıntılı bir şekilde değerlendirilmesini içermektedir (SWOT analizi)⁹⁷.

Hisse senedi değerlemesi için ihtiyaç duyulan iki ayrı değişkeni belirlemek için firma analizi yapılır: şirketin hisse başına kazanç elde etme miktarı, hisse başına temettü dağıtma kabiliyeti ve şirketin taşıdığı toplam riske dayalı olarak geliri belirleyen oran.

Genel olarak firma analizi, temel analizin kritik bir bileşenidir ve konuyla ilgili çok sayıda literatür vardır. Benjamin Graham ve David Dodd'un çalışmaları bu alanda klasik olarak kabul edilirken, daha yeni araştırmalar bireysel şirketlerin analizine yardımcı olmak için nicel modeller geliştirmeye odaklandı. Firma analizi üzerine ufuk

⁹⁷ Pieroni, M. P., McAloone, T. C., & Pigosso, D. C. (2019). Business model innovation for circular economy and sustainability: A review of approaches. *Journal of cleaner production*, 215, 198-216.

açıcı çalışmalardan biri Benjamin Graham ve David Dodd'un ilk kez 1934'te yayınlanan "Security Analysis" kitabıdır. Bu kitapta yazarlar, bireysel şirketleri analiz etmeye dayanan değer yatırımı kavramını tanıttılar. Bir başka etkili çalışma Benjamin Graham'ın ilk kez 1949'da yayınlanan "Akıllı Yatırımcı" kitabıdır. Bu kitap, bir şirketin mali tablolarını analiz etmenin ve bu bilgileri bilinçli yatırım kararları almak için kullanmanın önemini vurgular. Son yıllarda akademik literatür bireysel şirketlerin analizine yardımcı olmak için nicel modeller geliştirmeye odaklanmıştır. Altman Z-skoru modeli, finansal oranlara dayalı olarak iflas riskini tahmin etmek için yaygın olarak kullanılan bir araçtır⁹⁸. Piotroski F-skoru, Stanford Üniversitesi'nde finans profesörü olan Joseph Piotroski tarafından geliştirilen ve güçlü finansal performansa sahip yüksek kaliteli şirketleri belirlemek için kullanılan bir finansal analiz aracıdır. F-puanı, bir şirketin finansal sağlığını ve istikrarını değerlendirmek için kullanılan bir dizi dokuz finansal orana dayanır.

Piotroski F skorunda kullanılan dokuz oran şunlardır⁹⁹:

Varlık getirisi (ROA)

Operasyonlardan elde edilen nakit akışı (CFO)

Aktif getirisindeki değişim (Δ ROA)

Tahakkuklar

Kaldıraçtaki değişim (Δ kaldıraç)

Likiditedeki değişim (Δ likidite)

Ödenmemiş hisselerdeki değişim (Δ hisseler)

Brüt kar marjındaki değişim (Δ margin)

Varlık devrindeki değişim (Δ ciro)

⁹⁸Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609.

⁹⁹Piotroski, J.D., 2000. Value investing: The use of historical financial statement information to separate winners from losers. *Journal of Accounting Research*, pp.1-41.

Her orana, belirli kriterleri karşılayıp karşılamadığına bağlı olarak 0 veya 1 puan verilir. Her oranın puanları daha sonra toplanarak 0 ile 9 arasında bir nihai puan elde edilir ve daha yüksek puanlar daha güçlü finansal performansı gösterir.

Piotroski F-skoru finansal analizde yaygın olarak kullanılan bir araç haline geldi ve yatırımcılar, analistler ve diğer paydaşlar tarafından güçlü finansal performansa sahip yüksek kaliteli şirketleri belirlemek için kullanılıyor. Gelecekteki hisse senedi getirilerini tahmin etmede etkili olduğu kanıtlanmıştır ve bir şirketin finansal sağlığını değerlendirmek için en güvenilir araçlardan biri olarak kabul edilmektedir.

Ancak, Piotroski F puanının finansal performansın mükemmel bir göstergesi olmadığını ve diğer finansal analiz araçları ve ölçümleriyle birlikte kullanılması gerektiğini not etmek önemlidir. Endüstri eğilimleri, rekabet baskıları ve yönetim kararları gibi bir şirketin finansal sağlığını etkileyebilecek diğer faktörleri de dikkate almak önemlidir. Beneish M-skoru, Indiana Üniversitesi'nde muhasebe profesörü olan Messod Beneish tarafından geliştirilen ve finansal tablo manipülasyonunu ve kazanç manipülasyonunu tespit etmek için kullanılan bir finansal analiz aracıdır. M-puanı, bir şirketin mali tablolarının kalitesini değerlendirmek için kullanılan sekiz mali oranın ve diğer ölçütlerin birleşimine dayanır.

Beneish M skorunda kullanılan sekiz oran şunlardır¹⁰⁰:

Alacak Endeksindeki Gün Satışları (DSRI)

Brüt Marj Endeksi (GMI)

Varlık Kalite Endeksi (AQI)

Satış Büyüme Endeksi (SGI)

Amortisman Endeksi (DEPI)

Satış Genel ve Yönetim Giderleri Endeksi (SGAI)

¹⁰⁰Beneish, M. D. (2013). Thebeneish M-scorefordetectingmanipulation of financialstatements: A newforensicaccountingtool. Journal of ForensicandInvestigative Accounting, 5(1), 17-34.

Kaldıraç Endeksi (LVGI)

Toplam Tahakkukların Toplam Aktiflere (TATA)

Her orana bir puan atanır ve puanlar tek bir M puanında birleştirilir. M-puanı -1.78'den büyük puanlar mali tablo manipülasyonu olasılığının yüksek olduğunu gösterir¹⁰¹. Beneish M-skoru, finansal analizde yaygın olarak kullanılan bir araç haline geldi ve yatırımcılar, analistler ve diğer paydaşlar tarafından finansal tablo manipülasyonu yapan şirketleri belirlemek için kullanılıyor. Kazanç manipülasyonunu tespit etmede etkili olduğu gösterilmiştir ve bir şirketin mali tablolarının kalitesini değerlendirmek için en güvenilir araçlardan biri olarak kabul edilmektedir.

Ancak, Beneish M-skorunun finansal tablo manipülasyonunun mükemmel bir göstergesi olmadığını ve diğer finansal analiz araçları ve ölçümleriyle birlikte kullanılması gerektiğini not etmek önemlidir. Endüstri eğilimleri, rekabet baskıları ve yönetim kararları gibi bir şirketin finansal sağlığını etkileyebilecek diğer faktörleri de dikkate almak önemlidir. gibi diğer modeller, güçlü mali performansı olan ve mali dolandırıcılıkla iştigal edebilecek şirketleri belirlemek için geliştirilmiştir¹⁰².

Firma analizinde ilk adım; genellikle gelir tabloları, bilançolar ve nakit akış tabloları dahil olmak üzere şirketin mali tablolarını incelemektir. Bu beyanlar; şirketin finansal performansının anlık görüntüsünü sağlar, yatırımcıların şirketin gelir artışını, kârlılığını, borç seviyelerini ve nakit akışı üretimini değerlendirmesine olanak tanır. Bir sonraki adım, geçmiş performansı ve deneyimi de dahil olmak üzere şirketin yönetim ekibini incelemektir. Güçlü liderlik bir şirketin başarısında kritik bir rol oynayabilir ve yatırımcılar deneyimli, yetenekli ve şeffaf yönetim ekiplerine sahip şirketler aramalıdır. Yatırımcılar, şirketin kendi sektöründeki rekabetçi konumunu da göz önünde bulundurmalıdır. Bu pazar payını, marka bilinirliğini ve yenilik yapma ve rakiplerinin önünde kalma becerisini değerlendirmeyi içermektedir. Firma analizinde dikkate alınabilecek diğer faktörler arasında düzenleyici ortam ve hükümet politikaları, faiz oranları ve enflasyon gibi makroekonomik faktörler, sektör eğilimleri ve büyüme

¹⁰¹ Beneish, Messod D., and David Craig Nichols. "Identifying overvalued equity." *Review of Financial Economics* (2009).

¹⁰² Beneish, M. D. (2013). Thebeneish M-scorefordetectingmanipulation of financialstatements: A newforensicaccountingtool. *Journal of ForensicandInvestigative Accounting*, 5(1), 17-34.

potansiyeli ve fiyat-kazanç oranları ve temettü getirileri gibi değerlendirme ölçütleri yer alır. Yatırımcılar, bu faktörleri analiz ederek şirketin ekonomik temelleri hakkında kapsamlı bir anlayış geliştirebilir ve gerçek değerini belirleyebilir. Bir şirketin gerçek değeri piyasa değerini aşarsa, değer düşüklüğü ve iyi bir yatırım fırsatı olarak kabul edilebilir. Genel olarak firma analizi, yatırımcıların potansiyel yatırım fırsatlarını belirlemesine ve bilinçli yatırım kararları vermesine olanak tanıdığı için temel analiz için önemli bir araçtır. Bununla birlikte, iyi bilgilendirilmiş yatırım kararları almak için firma analizinin diğer analiz ve araştırma biçimleriyle birlikte kullanılması gerektiğine dikkat etmek önemlidir.

1.8 Teknik Analiz

Teknik analiz, geçmiş fiyatlar ve hacim gibi piyasa faaliyetleri tarafından üretilen istatistikleri analiz ederek menkul kıymetleri değerlendirme yöntemidir. Grafik teknikleri veya matematiksel hesaplamalar kullanarak gelecekteki fiyat hareketlerini tahmin etmek amacıyla piyasa verilerindeki kalıpları ve eğilimleri belirlemek için tacirler ve yatırımcılar tarafından yaygın olarak kullanılır. Teknik analiz metodlarından elde edilen sonuçlar gereğince pozisyon alan yatırımcılar, aslında oluşmayacak bir fiyatın oluşmasına ve metottun kendini doğrulamasına yol açabilmektedir¹⁰³. Grafik oluşturma ve yorumlama olarak da kabul edilen teknik analiz, uzun yıllardır finansal pratiğin bir parçası olmuştur. Tarihsel fiyat çizelgelerinde geometrik şekillerin tanımlanmasını içeren oldukça öznel bir disiplindir¹⁰⁴. Teknik analistler, ilgili tüm piyasa bilgilerinin bir menkul kıymetin veya varlığın fiyat ve hacim verilerine yansıdığına, bu verilere ilişkin analizlerine dayanarak ne zaman alıp satacakları konusunda bilinçli kararlar verebileceklerine inanırlar. Teknik analiz, fiyat hareketi ve hacim gibi ticari faaliyetlerden toplanan istatistiksel eğilimleri analiz ederek yatırımları değerlendirmek ve ticaret fırsatlarını belirlemek için kullanılan bir ticaret disiplindir¹⁰⁵.

Teknik analizin kökenleri, 19. yüzyılın sonlarında finansal piyasaların modern teknik analizinin temelini oluşturan Dow Teorisini geliştiren Charles Dow'a kadar

¹⁰³ LIM, Mark Andrew. (2015), *The Handbook of Technical Analysis+ Test Bank: The Practitioner's Comprehensive Guide to Technical Analysis*, John Wiley & Sons.

¹⁰⁴ Lo, A. W., Mamaysky, H., & Wang, J. (2000). Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation. *The journal of finance*, 55(4), 1705-1765.

¹⁰⁵ Park, C. H., & Irwin, S. H. (2004). The profitability of technical analysis: A review.

uzanır. Dow'un çalışmaları sonucunda oluşturulan DJIA (Dow Jones Endüstriyel Ortalama) Endeksi, günümüzde Amerika Birleşik Devletleri pazarının en değerli göstergelerinden biri olarak kabul edilmekte ve yaygın olarak kullanılmaktadır. Bununla birlikte teknik analiz kavramı, çeşitli akademisyenlerin gelişimine katkıda bulunmasıyla zaman içinde gelişmiştir. Teknik analizin en tanınmış savunucularından biri 1948'de "Technical Analysis of Stock Trends" kitabını yazan Robert D. Edwards ve John Magee'dir. Teknik analizin gelişimine önemli katkılarda bulunan diğer akademisyenler arasında 1978'de göreceli güç indeksini (RSI) yaratan J. Welles Wilder Jr. ve 1980'lerde Bollinger Bantlarını yaratan John Bollinger yer alıyor. Teknik analiz, birçok akademisyen ve uygulayıcının çalışmaları sayesinde zaman içinde rafine edilmiş ve geliştirilmiştir. Artık dünya çapında tacirler ve yatırımcılar tarafından menkul kıymet alım satımı hakkında bilinçli kararlar vermek için yaygın olarak kullanılmaktadır. Technical Analysis and Individual Investors adlı makale, bireysel yatırımcılar tarafından teknik analizin kullanımını ve bunun yatırım kararları üzerindeki etkisini incelemektedir. Yazarlar, Almanya'da 4.000 bireysel yatırımcıyla bir anket gerçekleştirdi ve önemli sayıda yatırımcının yatırım kararlarını bildirmek için teknik analiz kullandığını buldu. Yazarlar ayrıca, teknik analiz kullanan yatırımcıların daha fazla risk iştahına sahip olduklarını ve spekülatif ticarete girme olasılıklarının daha yüksek olduğunu bulmuşlardır¹⁰⁶. Teknik analizde kullanılan temel araçlardan biri, kalıpları ve eğilimleri belirlemek için fiyat ve hacim verilerinin bir grafik üzerinde çizilmesini içeren çizelgelemedir. Yaygın grafik oluşturma teknikleri arasında mum grafikleri, çizgi grafikler ve çubuk grafikler bulunur. Teknik analistler ayrıca verilerdeki eğilimleri ve kalıpları belirlemeye yardımcı olmak için hareketli ortalamalar, momentum göstergeleri ve osilatörler dahil olmak üzere çeşitli teknik göstergeler kullanır. Teknik analiz arz ve talebi belirleyen psikolojik, politik, ekonomik ve finansal faktörlerin birleşimini dikkate alır. Bu faktörlerin fiyatlar üzerindeki etkisi tahmin edilemez ve arz ve talebin fiyatlar üzerindeki etkileri önceden doğru bir şekilde tahmin edilemez. Ancak teknik analistler, alıcıların ve satıcıların eğilimlerini ve beklentilerini gözlemleyerek gelecekteki fiyat hareketleri hakkında bilinçli tahminler yapabilir. Sadece son fiyat artışlarına dayanan bir hisse senedinin düşüşüyle ilgili tahminlerin

¹⁰⁶Hoffmann, A. O., & Shefrin, H. (2014). Technical analysis and individual investors. *Journal of Economic Behavior & Organization*, 107, 487-511.

doğruluğu tartışmalıdır. Bununla birlikte, mevcut arz ve talebi geçmiş fiyatlar ile karşılaştırarak fiyat hareketlerini tahmin etmek mümkündür. Teknik analiz kullananlar bir hisse senedini en düşük fiyattan alıp en yüksek fiyattan satabilirler.

1.8.1.Teknik Analizin Avantajları

Teknik analiz, fiyatın sabitlendiği belirli bir hisse senedinin alım ve satım zamanını belirlemek için kullanılır. Teknik analiz, finansal piyasalarda sıfır zekanın öngörü gücü, karmaşık stratejiler kullanılmadan bile teknik analizin değerli içgörüler sağlayabileceğini gösteriyor¹⁰⁷. Yatırım fonları, döviz kurları ve diğer finansal araçlar da teknik analiz teknikleri kullanılarak değerlendirilebilir. Geçmiş fiyatlar ve hacim gibi piyasa faaliyetleri tarafından üretilen istatistikleri analiz ederek menkul kıymetleri değerlendirme süreci teknik analiz olarak bilinir. Bu yatırım yaklaşımı genellikle bir şirketin veya varlığın ekonomik ve finansal temellerini analiz etmeyi içeren temel analizle karşılaştırılır. Teknik analiz kullanmanın bazı avantajları olmakla birlikte, dikkate alınması gereken potansiyel sınırlamalar da vardır.

Nesnel Karar Verme: Teknik analiz, yatırımcıların duygusal karar vermekten kaçınmasına ve gerçek piyasa verilerine dayalı kararlar almasına yardımcı olabilecek nesnel veri noktalarına ve istatistiksel analize dayanır.

Zaman Kazandıran: Teknik analiz, geçmiş piyasa verilerine hızlı erişim sağladığı ve daha hızlı karar alınmasına olanak sağladığı için yatırımcılar için zaman kazandıran bir yöntem olabilmektedir.

Trend Belirleme: Teknik analiz, yatırımcıların kısa vadeli Al-Sat fırsatlarını belirlemede faydalı olabilecek pazar trendlerini ve potansiyel fırsatları belirlemesine yardımcı olabilmektedir.

Teknik Analiz Göstergeleri: Hareketli ortalamalar ve göreceli güç endeksleri gibi teknik analiz göstergeleri, işlemler için potansiyel giriş ve çıkış noktalarını belirlemede faydalı olabilmektedir.

¹⁰⁷ Farmer, J. D., Patelli, P., & Zovko, I. I. (2005). The predictive power of zero intelligence in financial markets. *Proceedings of the National Academy of Sciences*, 102(6), 2254-2259.

1.8.2.Teknik Analizin Sınırlamaları

Öznellik: Teknik analiz, farklı analistler çizelgeleri ve verileri farklı şekilde yorumlayabildiğinden farklı görüş ve önerilere yol açabileceğinden öznel olabilmektedir.

Sınırlı Bilgi: Teknik analiz, geçmiş piyasa verilerinin analizi ile sınırlıdır. Ekonomik göstergeler, şirket kazanç raporları ve piyasa performansını etkileyebilecek diğer faktörler gibi diğer önemli bilgileri dikkate almayabilir.

Geçmiş Performans Gelecekteki Sonuçları Garanti Etmez: Geçmişte belirli kalıplar sergileyen bir menkul kıymetin gelecekte benzer şekilde davranacağını garanti etmez. Teknik analiz, piyasa performansını etkileyebilecek öngörülemeyen olayları dikkate almayabilir.

Göstergelere Aşırı Güven: Teknik analiz göstergelerine çok fazla güvenen yatırımcılar, bir şirketin finansal performansını etkileyebilecek önemli temel faktörleri gözden kaçırabilir.

Hisse senedi primini tahmin etmek için teknik analizin sınırlamalarını baktığımızda, öngörülebilirliğin büyük ölçüde numune içi döneme bağlı olduğunu görülmektedir. Ayrıca tahmine dayalı regresyonun istatistiksel öneminin numune dışı iyi performansı garanti etmediği de görülmüştür¹⁰⁸. Teknik analiz, tacirlere ve yatırımcılara piyasa hassasiyeti ve potansiyel fiyat hareketleri hakkında değerli bilgiler sağlayabilir. Akademik araştırmalar, teknik analizin finansal piyasalarda kısa vadeli Al-Sat kararları almak ve riski yönetmek için yararlı bir araç olabileceğini göstermektedir.

1.8.3.Teknik Analizin Dezavantajları

Alandaki herkes aynı kuralı kullandığında herhangi bir kuralın etkinliği başarısız olabilmektedir.

¹⁰⁸ Welch, I., & Goyal, A. (2008). A comprehensive look at the empirical performance of equity premium prediction. *The Review of Financial Studies*, 21(4), 1455-1508.

Aslında teknik analize ait kuralların uygulama düzeyi o kadar kolay değildir. Yorum farklılıkları, sübjektif ve objektif görüşler, aynı veriler kullanılarak farklı yatırım kararlarının alınmasına neden olabilmektedir. Fiyat oluşumları tekrar etmeyebilir. Teknik analizin birincil sınırlaması, içsel öznelliğinde yatar- tarihsel fiyat yörüngeleri içindeki geometrik modellerin ayırt edilmesi, sıklıkla bireysel algıya bağlıdır.¹⁰⁹.

Teknik analiz, istatistiksel eğilimleri ve piyasa faaliyetlerini analiz ederek menkul kıymetleri ve finansal piyasaları değerlendirme yöntemidir. Teknik analiz içinde tacirlerin ve yatırımcıların finansal piyasaları değerlendirmek için kullanabilecekleri birkaç alt kategori vardır: Teknik göstergeler, tacirlerin ve yatırımcıların potansiyel alım ve satım fırsatlarını belirlemesine yardımcı olabilecek fiyat ve/veya hacim verilerine dayalı matematiksel hesaplamalardır. Teknik göstergeler, teknik analizde yaygın olarak kullanılır ve piyasa duyarlılığı ve gelecekteki fiyat hareketleri hakkında değerli bilgiler sağlayabilir. Bu bölümde yaygın olarak kullanılan bazı teknik göstergeleri ve bunlarla ilişkili denklemleri tartışacağız.

1.8.3.1. Momentum göstergeleri

Momentum göstergeleri, gelecekteki fiyat hareketlerini tahmin etmek için fiyat değişim oranı olan momentum kavramını kullanan matematiksel araçlardır¹¹⁰. Çoğunlukla 0 ile 50 çevresinde salınımda bulunan fiyat değişimlerinin oransal biçimde ölçümünün yapıldığı gösterge momentum göstergeleri olarak isimlendirilir. Momentum göstergeleri ise temel bir gösterge ve bu temel göstergeye bağlı bulunan sinyal oluşturan diğer bir çizgi ile tanımlanır. Bu göstergeler mevcut hareketin ne yönde olduğundan çok ne kadar güçlü olduğuna dair ölçüm yapmayı hedeflerler. Fiyat grafikleri ile beraber değerlendirildiğinde meydana gelen uyumsuz durumlar trend değişiminin habercisi şeklinde düşünülür. Aynı zamanda direnç ve destek çizgilerinin kırıldığını kontrol etmek amacıyla da kullanılırlar.

¹⁰⁹ Taylor, M. P., & Allen, H. (1992). The use of technical analysis in the foreign exchange market. *Journal of international Money and Finance*, 11(3), 304-314.

¹¹⁰ Chan, R. H. F., Wong, A. W. K., & Lee, S. T. H. (2014). *Technical analysis and financial asset forecasting: From simple tools to advanced techniques*. World Scientific Publishing Company.

1.8.3.2. İndeksler

Teknik analizdeki endeks göstergeleri, gelecekteki fiyat değişikliklerini tahmin etmek için kullanılan fiyat ve hacim verilerinin matematiksel dönüşümleridir. Piyasa davranışlarını ölçmek ve görselleştirmek için bir yol sağlarlar¹¹¹. Finansal sözlükte, endeks göstergeleri tipik olarak bir menkul kıymetler piyasasındaki dalgalanmaları yakalayan istatistiksel bir metriği ifade eder. Finansal piyasalar alanında, hisse senetleri ve tahvillere ilişkin endeksler, belirli bir pazar segmentini veya tamamını özetleyen teorik bir menkul kıymetler çeşitliliğini içerir. Hisse senedi ve tahvil piyasalarına ilişkin her endeksin kendine özgü bir hesaplama metodolojisi vardır. Çoğu durumda bir endeksin göreceli değişimi, endeksi temsil eden gerçek sayısal değerden daha önemlidir.

1.8.3.3. Salınım

Salınım göstergeleri, adından da anlaşılacağı gibi ileri geri bir hareketle hareket eden göstergelerdir. Hisse senedi fiyatları yükselirken ve düşerken salınım göstergeleri bir hisse senedi fiyatının mevcut eğiliminin ne kadar güçlü olduğunu belirlemenize yardımcı olur ve bu eğilim ivme kaybetme ve tersine dönme tehlikesiyle karşı karşıya olduğunda yatırımcıyı haberdar eder. Salınım göstergesi çok yükseğe hareket ettiğinde, hisse sendi aşırı alım bölgesinde olarak kabul edilir. Hisse senedinde ve piyasada fiyatı zorlamak için yeterli alıcı kalmadığını ve momentum aşağı veya yana doğru hareket etmek için dönen eğilim içinde olduğunu bu hisse senedinin değerini kaybetme riski taşıdığını gösterir. Salınım göstergesi çok düşüğe hareket ettiğinde, piyasada hisse senedinin değerini zorlamak için yeterli satıcı kalmadığı ve hisse senedinin aşırı satım bölgesinde olduğu kabul edilir. Bu, hisse senedinin fiyat hareketinin ivme kaybetme riski altında olduğunu gösterir ve daha yükseğe veya yana doğru hareket etmek için trend değişikliğini işaret eder. Teknik analizde, bir menkul kıymetin aşırı alınıp satıldığı fiyatları bulmak için kullanılan matematiksel hesaplama yöntemi de denilebilir. Bir salınım göstergesi, çeşitli yöntemler kullanarak iki uç fiyatı bulur ve menkul kıymetin fiyatı her birine yaklaştığında al veya sat sinyallerini bulur. En yaygın salınım göstergelerinden biri Stokastik osilatördür.

¹¹¹ Dash, R., & Dash, P. K. (2016). A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science*, 2(1), 42-57.

Hareketli Ortalama Yakınsama Sapması (MACD):

Hareketli ortalama yakınsama ıraksaması (MACD), iki hareketli ortalama arasındaki farkı hesaplayan trend takip eden bir göstergedir. MACD, tacirlerin ve yatırımcıların potansiyel trend dönüşlerini belirlemesine yardımcı olabilir, altta gösterildiği gibi hesaplanır¹¹².

Denklem:

MACD çizgisi = 12 dönemlik üstel hareketli ortalama - 26 dönemlik üstel hareketli ortalama

Sinyal hattı = MACD hattının 9 dönemlik üstel hareketli ortalaması

1.8.3.4. Göstergeler (İndikatörler)

Hareketli ortalamalar en yaygın kullanılan teknik göstergelerden biridir. Bir menkul kıymetin belirli bir süre boyunca ortalama fiyatı alınarak hesaplanırlar. Hareketli ortalamalar, tacirlerin ve yatırımcıların potansiyel eğilimleri ve ters dönüşleri belirlemesine yardımcı olabilmektedir.

Denklem:

Hareketli Ortalama = Belirtilen dönemdeki fiyatların toplamı / Dönemdeki fiyat sayısı

1.8.3.5. Güç göstergeleri

Güç göstergeleri işlem hacmine dayanmaktadır. Söz konusu göstergeler, alış ile satış gücü arasında yer alan ilişkiyi açıklarken kullanılır. Teknik analiz yapılırken fiyat hareketlerinin her biri bilhassa yükseliş hareketi işlem hacmi vasıtasıyla desteklenmelidir. Yatırımcı olan bireyin fiyatları, yatırım yapmak için uygun olarak değerlendirip değerlendirmedeği işlem hacmi ile ortaya çıkarılır. Buna ek olarak işlem hacmi piyasaya karşı mevcut olan bakış açısını da ortaya koymaktadır.

¹¹² Appel, G. (1985). The Moving Average Convergence Divergence Trading Method. Dow Jones-Irwin.

Göreceli Güç Endeksi (RSI):

Göreceli güç endeksi (RSI), bir menkul kıymetin fiyat hareketinin gücünü ölçen bir momentum göstergesidir. RSI, belirli bir süre boyunca bir menkul kıymetin ortalama kazanç ve kayıplarının karşılaştırılmasıyla hesaplanır¹¹³.

Denklem:

$$RSI = 100 - (100 / (1 + RS))$$

$$RS = \text{Ortalama kazanç} / \text{Ortalama kayıp}$$

1.8.3.6. Stokastikler

Stokastik göstergesi 1950 ve takip eden dönem içerisinde George Lane vasıtası ile meydana getirilmiştir. Bu gösterge, belirli bir periyot içerisinde bulunan yüksek ve düşük veri miktarlarını mevcut olan fiyata ne kadar yakın olup olmadığını ifade etmektedir. Stokastik göstergesi teknik analiz yapılırken oldukça sık tercih edilen bir modeldir. Stokastik göstergesi, analizi gerçekleştirilecek olan yatırım vasıtasının kapanış fiyatının tespit edilen süre içerisinde yer alan fiyat aralığı ile kıyaslanabilmesi için tercih edilmektedir.

Stokastik Osilatör:

Stokastik osilatör, bir menkul kıymetin kapanış fiyatını belirli bir zaman dilimindeki fiyat aralığıyla karşılaştıran bir momentum göstergesidir. Stokastik osilatör, tacirlerin ve yatırımcıların potansiyel aşırı alım ve aşırı satım koşullarını belirlemesine yardımcı olabilir, altta gösterildiği gibi hesaplanır¹¹⁴.

Denklem:

$$\%K = (\text{Mevcut kapanış fiyatı} - \text{En düşük dip}) / (\text{En yüksek en yüksek} - \text{En düşük en düşük}) * 100$$

¹¹³Wilder, J. W. (1978). New Concepts in Technical Trading Systems: Relative Strength Index. Journal of Commodity Trading, 1(1), 49-53.

¹¹⁴Lane, G. (1957). The Stochastic Oscillator. Technical Analysis of Stocks and Commodities, 24(3), 75-79.

%D = %K'nin 3 dönemlik basit hareketli ortalaması

1.8.3.7. Volatilite göstergeleri

Volatilite diğer bir ismi ile değişkenlik piyasaya dair bir niteliktir. Volatilite kavramı hisse senedi piyasaları içerisinde ciddi şekilde araştırma konusu olmuş bir özelliktir. Öyle ki değişkenlik oranı yüksek düzeyde olan bir piyasanın sağlıklı ve düzenli bir şekilde çalışmasını beklemek pek de mümkün değildir. Yüksek düzeyde değişkenlik hususunda talep ve arzın çok değişken fiyatlarda kıyaslanması belirli bir zamanın ardından taraflardan bir tanesinin ortadan kaybolmasına neden olacak ve bu nedenle alım satım için uygun olan bir çevre ortada kalmayınca, pazardan da bahsedilemeyecektir.

Volatilitenin arttığı periyotlar yatırımcılar açısından tehlikeli zamanlardır. Volatilite öteki göstergeler ile değerlendirmeye tabii tutularak yüksek seviyeli değişkenlik kimi zaman tepede yer alan trend dönüşlerini tahmin etmek, bazı durumlarda ise oldukça düşük düzeyli değişkenlik fiyatların yukarı yönlü yeni bir trend başlangıcında bulunduğunu tespit etmek için kullanılır.

Bollinger Bantları:

Bollinger Bantları, üst ve alt bantlar oluşturmak için menkul kıymetin hareketli ortalamasını ve standart sapmasını kullanan bir volatilite göstergesidir. Bollinger Bantları, tacirlerin ve yatırımcıların potansiyel aşırı alım ve aşırı satım koşullarını belirlemelerine yardımcı olabilir, altta gösterildiği gibi hesaplanır¹¹⁵.

Denklem:

Orta Bant = 20 dönemlik basit hareketli ortalama

Üst Bant = Orta Bant + (2 * 20 dönemlik standart sapma)

Alt Bant = Orta Bant - (2 * 20 dönemlik standart sapma)

¹¹⁵Bollinger, J. (2001). Bollinger on BollingerBands. McGraw-Hill Education.

1.8.3.8.. Formasyonlar

Teknik analizde Formasyon kavramı, bir hisse senedi fiyat tablosunda ortaya çıkan belirli bir model veya şekli ifade eden yaygın olarak kullanılan bir terimdir. Genellikle potansiyel Al-Sat fırsatlarını belirlemeye yardımcı olmak için kullanılır ve teknik analizin önemli bir parçasıdır.

Akademik olarak, teknik analiz ve formasyon kavramı da dahil olmak üzere çeşitli kavramlarının geliştirilmesine ve anlaşılmasına katkıda bulunan birkaç yazar vardır. Bu alandaki en dikkate değer yazarlardan biri teknik analiz konusunda önde gelen bir uzman olarak kabul edilen John J. Murphy'dir. Murphy "Finansal Piyasaların Teknik Analizi" adlı kitabında Formasyonlar "potansiyel Al-Sat fırsatlarını belirlemeye yardımcı olmak için kullanılan, bir fiyat çizelgesinde gelişen belirli bir model veya şekil" olarak tanımlıyor. Formasyonların hem yükseliş hem de düşüş piyasa koşullarını belirlemek ve tacirlerin işlemleri için giriş ve çıkış noktalarını belirlemelerine yardımcı olmak için kullanılabileceğini açıklamaya devam etmektedir. Murphy ayrıca grafik kalıpları, mum çubuğu oluşumları ve trend çizgisi oluşumları dahil olmak üzere tacirlerin aşına olması gereken birkaç farklı formasyon türü olduğunu not eder. Al-Sat ta etkin bir şekilde nasıl kullanılacağına ilişkin yönergelerin yanı sıra her bir oluşum türü için ayrıntılı açıklamalar ve örnekler sağlar.

Teknik analizde formasyonların anlaşılmasına katkıda bulunan diğer yazarlar arasında, grafik formasyonları üzerine kapsamlı yazılar yazan Martin Pring ve Batı dünyasında mum grafiğini popülerleştirmesiyle büyük ölçüde tanınan Steve Nison yer alır.

Genel olarak teknik analizdeki Formasyonlar kavramı, yatırımcıların potansiyel Al-Sat fırsatlarını belirlemelerine ve yatırımları hakkında bilinçli kararlar almalarına yardımcı olan önemli bir araçtır. Bu kavram için kesin bir akademik kaynak bulunmamakla birlikte John J. Murphy, Martin Pring ve Steve Nison'ın çalışmaları, teknik analiz alanında yetkili metinler olarak geniş çapta tanınmaktadır.

Fiyat hareket ve dalgalanmalarının grafikler üzerinde yarattığı biçimler üzerinden analiz gerçekleştirilerek söz konusu fiyatların ne yöne gidebileceği

konusunda ön görüde bulunulması ve buradan elde edilecek sonuçlara göre yatırım yapacak kişilerin yatırım konusunda karar almasını sağlayan teknik formasyonlar olarak isimlendirilir. Teknik analiz içerisinde formasyon analizi sıklıkla fiyat miktarlarının birden çıkış ve azalışını bunlar olmadan önce belirlemek için ve söz konusu bu fiyat hareketliliği gerçekleştikten sonra fiyatın nerede duracağını belirlemek amacıyla gerçekleştirilir.¹¹⁶

Formasyonlar teknik analiz kapsamında tercih edilen en temel araçlar arasındadır. Piyasa içerisinde alıcı veya satıcılar tarafından gerçekleştirilen işlemler nedeniyle devamlı bir değişim içerisinde. Gerçekleşen değişimler neticesinde fiyat grafikleri üzerinde bazı izler oluşur. Fiyat grafiklerinde görülen bu izler ise formasyon olarak isimlendirilir. Formasyon analizi gerçekleştirilirken sabit fiyatlar tespit edilir. Tespit edilen bu fiyatlar formasyon modellemeleri sayesinde meydana gelir. Söz konusu seviyeler ise alış-veriş gerçekleştirilirken yatırım yapan kişiye yol gösterici bir rol oynar.¹¹⁷

Teknik göstergelere ek olarak, grafik biçimleri teknik analizde yaygın olarak kullanılan bir başka araçtır. Grafik kalıpları, tacirlerin ve yatırımcıların potansiyel eğilimleri ve ters dönüşleri belirlemesine yardımcı olabilecek tarihsel fiyat hareketlerinin grafiksel temsilleridir. Popüler grafik biçimleri baş ve omuzları, çift üstleri ve dipleri ve üçgenleri içermektedir. Tacirlerin ve yatırımcılar, bu kalıpları analiz ederek potansiyel piyasa hareketleri hakkında bilgi edinebilir ve yatırım stratejilerini buna göre ayarlayabilir.

Teknik analizin sınırlamaları olmadığını belirtmekte fayda var. Grafik modelleri, trend çizgileri, destek ve direnç seviyeleri, osilatörler ve diğer oluşum türleri gibi çok çeşitli teknikleri içermektedir¹¹⁸. Fiyat oluşumları mutlaka tekrar etmeyebilir ve bir kuralın etkinliği alandaki herkes tarafından aynı kuralın kullanılmasıyla tehlikeye atılabilir. Ayrıca yorum farklılıkları, sübjektif ve objektif görüşler ve aynı verilerin kullanılması farklı yatırım kararlarına yol açabileceğinden teknik analiz kurallarının

¹¹⁶ Birgili, E. ve Esen, S. (2013). Teknik analiz yönteminin bulanık mantık yaklaşımı ile uygulanması: İMKB 30 banka hisseleri örneği. Finans, Politik ve Ekonomik Yorumlar, 50(575), 95-113.

¹¹⁷ MÜNYAS VE ATASOY, a.g.e..

¹¹⁸ Kavajecz, K. A., & Odders-White, E. R. (2004). Technical analysis and liquidity provision. *Review of Financial Studies*, 17(4), 1043-1071.

uygulanması her zaman kolay değildir. Bu nedenle bilinçli yatırım kararları almak için teknik analiz diğer analiz ve araştırma biçimleriyle birlikte kullanmak esastır. Teknik analiz, geçmiş piyasa hareketlerinin çizelgelerini inceleyerek fiyat hareketlerini ve gelecekteki piyasa eğilimlerini tahmin etme yöntemidir. Baş ve omuzlar, çift üstler ve dipler, üçgenler, bayraklar ve takozlar gibi çeşitli oluşum türlerini içermektedir¹¹⁹.

Omuz Baş Omuz Formasyonu:

Baş ve omuzlar formasyonu, bir yükseliş trendinin sonunda oluşan bir düşüş eğilimi formasyonudur. Orta tepe (baş) en yüksek olmak üzere üç tepeden oluşur. Başın her iki yanındaki iki küçük tepe omuzlardır. Model, fiyat, omuzların alt kısımlarını birleştiren bir çizgi olan boyun çizgisinin altına düştüğünde tamamlanır.

Denklem:

Boyun çizgisi = Omuzların alt kısmındaki destek seviyesi

Çift Tepe ve Dip Formasyonları:

Çift tepe ve çift dip formasyonları, bir trendin sonunda meydana gelen ters formasyonlardır. Çift tepe modeli, aralarında bir oluk bulunan kabaca eşit yükseklikte iki tepe noktasından oluşur. Fiyat çukurun altına düştüğünde formasyon tamamlanır. Çift dip modeli, iki oluk ve aralarında bir tepe bulunan çift tepenin tersidir. Fiyat zirvenin üzerine çıktığında model tamamlanır.

Denklem:

Çift Tepe = İki tepe noktasındaki direnç seviyesi

Çift Dip = İki oluğun alt kısmındaki destek seviyesi

Üçgen formasyonları:

Üçgenler, fiyat bir aralıkta konsolide olurken ortaya çıkan devam formasyonlarıdır. Üç tür üçgen vardır: artan, azalan ve simetrik. Yükselen üçgenler düz

¹¹⁹ Neely, C. J., & Weller, P. A. (2012). Technical analysis in the foreign exchange market. *Handbook of exchange rates*, 343-373.

bir tepeye ve yükselen bir tabana sahipken, alçalan üçgenler düz bir tabana ve düşen bir tepeye sahiptir. Simetrik üçgenlerin hem yükselen bir tabanı hem de düşen bir tepesi vardır. Fiyat üçgenin dışına çıktığında formasyon tamamlanır.

Denklem:

Üçgen = Üçgenin altındaki ve üstündeki destek ve direnç seviyeleri

Teknik göstergeler, tacirlere ve yatırımcılara potansiyel alım ve satım fırsatlarını belirlemede yardımcı olabilecek fiyat ve/veya hacim verilerine dayalı matematiksel hesaplamalardır. Teknik analiz ile yapılan işlemlerin kârlılığı ve teknik analizin kârlı olabileceğine dair bazı kanıtlar olsa da kârlılığını etkileyebilecek birçok faktör olduğunu belirtmekte fayda vardır. Bunlar çalışılan süreyi, piyasa koşullarını, kullanılan spesifik teknik analiz yöntemini ve işlem maliyetlerini içermektedir¹²⁰. Bazı teknik gösterge örnekleri hareketli ortalamaları, göreceli güç endeksini (RSI) ve stokastik osilatörleri içerir. Bunlar genellikle teknik analizde kullanılır ve piyasa duyarlılığı ve gelecekteki fiyat hareketleri hakkında değerli bilgiler sağlayabilir. Ancak bilinçli yatırım kararları almak için teknik göstergelerin diğer analiz ve araştırma biçimleriyle birlikte kullanılması gerektiğine dikkat etmek önemlidir. Ek olarak grafik biçimleri, tacirlere ve yatırımcılara potansiyel eğilimleri ve tersine dönüşleri belirlemede yardımcı olabilecek tarihsel fiyat hareketlerinin grafiksel temsilleridir. Yaygın grafik desenleri baş ve omuzları, çift üstleri ve dipleri ve üçgenleri içerir. Teknik göstergelerde olduğu gibi, sağlam yatırım kararları almak için grafik modelleri diğer analiz ve araştırma biçimleriyle birlikte kullanılmalıdır.

Genel olarak, teknik göstergeler tacirlere ve yatırımcılara piyasa hassasiyeti ve potansiyel fiyat hareketleri hakkında değerli bilgiler sağlayabilir. Bununla birlikte, iyi bilgilendirilmiş yatırım kararları almak için teknik göstergelerin diğer analiz ve araştırma biçimleriyle birlikte kullanılması gerektiğine dikkat etmek önemlidir.

¹²⁰ Park, C. H., & Irwin, S. H. (2004). The profitability of technical analysis: A review.

Japon mum grafikleri, kalıpların fark edilmesini kolaylaştıran fiyat hareketlerini temsil etmenin bir yoludur¹²¹.Mum grafikleri, fiyat eğilimleri ve tersine dönmeler hakkında ek bilgi sağlar ve teknik analizde yaygın olarak kullanılır. Mum grafikleri ayı ve boğa piyasası yatırımcılarının fiyata dayalı psikolojisini yansıtmasının yanı sıra söz konusu açılış, kapanış, en düşük ve en yüksek fiyatları tek bir görselde konsolide ederek fiyat hareketlerinin yorumlanmasını kolaylaştırmaktadır. Tarihte ilk kez Japon pirinç pazarlarında uygulandığı ve 100'den fazla mum deseni olduğu biliniyor¹²².

Japon mum grafikleri, finansal varlıkların fiyat hareketlerini görselleştirmek için kullanılan teknik analizde popüler bir araçtır. Belirli bir zaman dilimindeki fiyat hareketlerinin görsel bir temsilini sağlarlar ve potansiyel eğilimleri ve tersine dönüşleri belirlemek için kullanılabilirler.

Japon mum grafikleri, gün, hafta veya ay gibi belirli bir dönem için fiyat hareketlerini temsil eden ayrı "mumlardan" oluşur. Her mumun dört ana bileşeni vardır: açılış, yüksek, düşük ve kapanış fiyatı. Mumun "gövdesi" açılış ve kapanış fiyatları arasındaki farkı, "gölgeler" veya "fitiller" ise dönemin en yüksek ve en düşük fiyatlarını temsil eder.

Mumun rengi, kapanış fiyatının açılış fiyatından yüksek veya düşük olmasına göre belirlenir. Bir "boğa" veya yeşil mum, kapanış fiyatı açılış fiyatından yüksek olduğunda alıcıların kontrolü elinde tuttuğunu gösterir. Tersine, kapanış fiyatı açılış fiyatından düşük olduğunda bir "düşüş" veya kırmızı mum görünür ve satıcıların kontrolün elinde olduğunu gösterir.

Tacirlerin ve yatırımcıların potansiyel eğilimleri ve ters dönüşleri belirlemek için kullandıkları birkaç yaygın mum modeli vardır:

¹²¹ Chen, Shi, Si Bao, and Yu Zhou. "The predictive power of Japanese candlestick charting in Chinese stock market." *Physica A: Statistical Mechanics and its Applications* 457 (2016): 148-165. s150

¹²² AYCEL, Üzeyir, and Yunus SANTUR. "A new algorithmic trading approach based on ensemble learning and candlestick pattern recognition in financial assets." *Turkish Journal of Science and Technology* 17.2 (2022): 167-184.

Çekiç: Hammer:

Çekiç mum, küçük bir gövdeye ve uzun bir alt gölgeye sahiptir ve düşüş trendinin dibinde oluşur. Bu kalıp, satıcıların başlangıçta kontrolün elinde olduğunu, ancak alıcıların piyasaya girerek fiyatları yükselttiklerini gösterir.

Kayan yıldız: Shooting Star:

Kayan yıldız mum, küçük bir gövdeye ve uzun bir üst gölgeye sahiptir ve bir yükseliş trendinin tepesinde oluşur. Bu model alıcıların başlangıçta kontrolün elinde olduğunu, ancak satıcıların piyasaya girerek fiyatları aşağı çektiğini gösterir.

Doji:

Bir doji mum grafiğinin küçük bir gövdesi ve kabaca eşit uzunlukta gölgeleri vardır, bu da açılış ve kapanış fiyatlarının birbirine çok yakın olduğunu gösterir. Bu formasyon, piyasadaki kararsızlığı gösterir ve potansiyel olarak bir trendin tersine döndüğünü işaret edebilir.

Yutma: Engulfing:

Yutan bir mum kalıbı, daha küçük bir mumu ters yönde daha büyük bir mum izlediğinde oluşur. Küçük bir kırmızı mumun ardından daha büyük bir yeşil mum geldiğinde yukarıya doğru potansiyel bir trendin tersine döndüğüne işaret eden bir boğa yutma paterni oluşur. Küçük yeşil bir mumun ardından daha büyük bir kırmızı mum geldiğinde aşağı yönlü bir yutma modeli oluşur ve potansiyel bir aşağı yönlü trendin tersine döndüğünü gösterir.

Genel olarak, Japon mum grafikleri, tacirlerin ve yatırımcılara piyasa hassasiyeti ve potansiyel fiyat hareketleri hakkında değerli bilgiler sağlayabilir. Bununla birlikte, bilinçli yatırım kararları almak için diğer analiz ve araştırma biçimleriyle birlikte mum kalıplarını kullanmanın gerekli olduğuna dikkat etmek önemlidir.

Elliott Dalga Teorisi: Potansiyel fiyat hareketlerini belirlemek için dalga modellerini kullanan teknik bir analiz yöntemidir. Teoriye göre piyasalar beşli ve üçlü

dalga modellerinde hareket eder, beş dalga bir trendi ve üç dalga bir düzeltmeyi temsil etmektedir.

Ralph Nelson Elliott, 1930'larda teknik analizde popüler bir yaklaşım haline gelen Elliott dalga teorisini geliştirdi. Teori finansal piyasaların, tanımlanabilen ve gelecekteki piyasa davranışını tahmin etmek için kullanılabilen tekrarlayan modeller veya dalgalar halinde hareket ettiğini ileri sürer¹²³. Elliott dalga teorisinin uygulaması finans alanında çeşitli akademisyenler ve uygulayıcılar tarafından incelenmiş ve analiz edilmiştir. Elliott dalga teorisini inceleyen bir diğer akademisyen konuyla ilgili "Elliott Dalga İlkesinde Ustalaşmak" ve "Elliott Dalgalarını Ticarete Çevirmek: Giriş ve Çıkış Hareketlerini Zamanlama İçin Kazanma Stratejileri" de dahil olmak üzere birçok kitap yazan Wayne Gorman'dır. Gorman'ın çalışması teorinin pratik uygulamasına ve Al-Sat stratejilerinde kullanımına ilişkin içgörüler sağlar. Genel olarak Elliott dalga teorisi, yıllar içinde akademisyenler ve uygulayıcılar tarafından incelendi ve rafine edildi, eleştirenleri olsa da finansal piyasalarda teknik analiz için popüler bir yaklaşım olmaya devam etmektedir.

Piyasalar Arası Analiz; hisse senetleri, tahviller ve para birimleri gibi farklı piyasalar arasındaki ilişkileri inceleyen teknik bir analiz yöntemidir. Tacirler ve yatırımcılar, farklı pazarlar arasındaki karşılıklı ilişkileri analiz ederek potansiyel eğilimleri ve tersine dönüşleri belirleyebilir.

Genel olarak teknik analizin alt kategorileri, tacirlere ve yatırımcılara piyasa duyarlılığı ve gelecekteki fiyat hareketleri hakkında değerli bilgiler sağlayabilir. Bununla birlikte iyi bilgilendirilmiş yatırım kararları almak için teknik analizin diğer analiz ve araştırma biçimleriyle birlikte kullanılmasının gerekli olduğunu unutmamak önemlidir.

1.9. İstatistiksel Yöntemlerle Hisse Senedi Fiyat Tahmini

Hisse senedi piyasası fiyatlarının tahmini hem akademisyenler hem de finansal analistlerden sürekli olarak önemli ilgi görmektedir. Hisse senedi fiyatlarının tahmin edilmesi, hisse senedi verilerinin karmaşık ve çoğu zaman değişken özelliklerinden

¹²³Elliott, R. N. (1938). TheWavePrinciple. Financial World.

dolayı oldukça zordur. Sonuç olarak, hisse senedi fiyatı tahmininin doğruluğunu artırmaya yönelik olarak özel olarak tasarlanmış verimli modeller geliştirmek için zorlayıcı bir gereklilik vardır¹²⁴.Hisse senedi fiyatı tahmini, bu konuyu ele almak için geliştirilen ve uygulanan çeşitli istatistiksel yöntemlerle finans alanında kritik bir araştırma alanıdır. Regresyon analizi, bir menkul kıymetin veya varlığın fiyatını etkileyebilecek farklı faktörler arasındaki ilişkileri belirlemek için geçmiş verilerin incelenmesini içeren, hisse senedi fiyatı tahmini için sıklıkla kullanılan bir istatistiksel yöntemdir. Bu faktörler arasında makroekonomik göstergeler, şirkete özgü ölçümler ve teknik göstergeler yer alabilir. “Regression” İngilizce bir kavramdır ve kelime anlamına bakıldığında istatistik biliminde yer alan “alışılmışa doğru çekilme” anlamını karşılamaktadır. Bugün kullanılmakta olan manası ile “regression” terimi; bağımlı değişkeni, değişik bağımsız değişkenlerle ilişki içerisine sokarak öngörü veya çıkarım yapma amacı güden istatistiksel bir tekniktir. Regresyon analizi için sınıflandırma kriterlerine göre:

Bağımsız değişkenlerin miktarı açısından, basit regresyon analizi ve çoklu regresyon analizi olarak ikiye ayrılır.

İşlevsel ilişkiye göre sınıflandırıldığında, doğrusal regresyon analizi ve doğrusal olmayan regresyon analizi ayırt edilir.

Verilerin kaynağına bağlı olarak, popülasyon verilerini kullanan regresyon analizi, örnek verileri kullanan regresyon analizi ve zaman serisi verileri üzerinde yapılan regresyon analizi arasında ayırım yapılabilir. Zaman serisi analizi, eğilimleri ve kalıpları belirlemek için geçmiş verileri analiz etmeyi içeren hisse senedi fiyatı tahmini için yaygın olarak kullanılan başka bir istatistiksel yöntemdir. Bu yöntem diğerleri arasında otoregresyon, hareketli ortalamalar ve üstel düzeltme gibi teknikleri içerebilir. Yapay sinir ağları, karar ağaçları ve rastgele ormanlar gibi makine öğrenimi yöntemleri, hisse senedi fiyatı tahminine giderek daha fazla uygulanmaktadır. Bu yöntemler, gelecekteki fiyat hareketlerini tahmin etmek için kullanılabilecek kalıpları ve eğilimleri belirlemek için büyük miktarda tarihsel veri kullanır. İstatistiksel yöntemler, geçmiş

¹²⁴ Kumawat, Subhash Kumar, Alok Bansal and Sultan Singh Saini. “Design Analysis and Implementation of Stock Market Forecasting System using Improved Soft Computing Technique.” *International Journal on Future Revolution in Computer Science & Communication Engineering* (2022): n. pag.

performanslarına dayalı olarak hisse senetlerinin gelecekteki fiyatlarını tahmin etmek için kullanılır¹²⁵. Değerlendirme metrikleri, hisse senedi fiyatı tahmin modellerinin doğruluğunu değerlendirmek için kullanılır. Yaygın metrikler diğerlerinin yanı sıra ortalama karesel hata, kök ortalama karesel hata ve ortalama mutlak hatayı içerir. Bu ölçümler, farklı modellerin performansının değerlendirilmesine ve iyileştirme alanlarının belirlenmesine yardımcı olur. Hisse senedi fiyatı tahminindeki en önemli zorluklardan biri finansal piyasaların öngörülemez doğasıdır. Beklenmeyen haberler veya olaylar, bir menkul kıymetin veya varlığın gelecekteki fiyat hareketlerini doğru bir şekilde tahmin etmeyi zorlaştırabilir. Hisse senedi fiyatı tahmininin amacı, bir menkul kıymetin veya varlığın gelecekteki fiyat hareketlerini tahmin etmektir; bu, tacirlerin ve yatırımcıların alım veya satım hakkında bilinçli kararlar vermelerine yardımcı olabilmektedir. Hisse senedi fiyatlarını tahmin etmek için ARIMA (otoregresif entegre hareketli ortalama) gibi istatistiksel yöntemlerin geliştirilmesine ve iyileştirilmesine katkıda bulunan birkaç akademisyen vardır. Bu alanda dikkate değer bir akademisyen, Chicago Üniversitesi İşletme Fakültesi'nden Profesör Ruey S. Tsay'dir. Profesör Tsay, "Finansal Zaman Serilerinin Analizi" adlı kitabında, hisse senedi fiyatları da dahil olmak üzere finansal verileri tahmin etmek ve analiz etmek için ARIMA modellerinin kullanımını kapsamlı bir şekilde tartışıyor. ARIMA modellerinin teorik temellerine ve pratik uygulamalarına kapsamlı bir genel bakış ve bu modellerin hisse senedi fiyatlarını tahmin etmek için nasıl kullanılacağına dair ayrıntılı örnekler sunuyor. Ek olarak Clive W.J. Granger, Robert F. Engle ve James D. Hamilton gibi diğer akademisyenler de ARIMA modelleri dahil olmak üzere zaman serisi analizi ve tahmin yöntemlerinin geliştirilmesine önemli katkılarda bulunmuştur. Araştırmaları, hisse senedi fiyatlarının tahmin edilmesi de dahil olmak üzere finasta istatistiksel yöntemlerin kullanımına yönelik teorik ve ampirik temellerin oluşturulmasına yardımcı olmuştur.

Sonuç olarak, hisse senedi fiyat tahmini finasta çok önemli bir araştırma alanıdır ve bu konuyu ele almak için çeşitli istatistiksel yöntemler uygulanmaktadır. Bu yöntemler yararlı içgörüler ve tahminler sağlayabilse de finansal piyasaların öngörülemez doğasını ve bunların hisse senedi fiyatı tahmin modellerinin doğruluğu

¹²⁵ Jensen, M. C. (1968). The performance of mutual funds in the period 1945-1964. *The Journal of finance*, 23(2), 389-416.

üzerindeki etkilerini dikkate almak önemlidir. İstatistiksel yöntemlerden oluşturulan al-sat tavsiyelerin, uzmanlaşmış kişilerin tavsiyelerinden daha ciddi bir şekilde dikkate alınmadığı bulunmuştur¹²⁶.

1.9.1.Otoregresif (AR) Modeli

Otoregresif (AR) modeller, geçmiş gözlemlere dayalı olarak gelecekteki değerleri tahmin etmek için zaman serisi analizinde yaygın olarak kullanılır. Bir otoregresif (AR) model, bir tür rastgele sürecin temsilidir; bu nedenle doğa, ekonomi ve davranış gibi zamanla değişen belirli süreçleri tanımlamak için kullanılır. Otoregresif model, çıktı değişkeninin doğrusal olarak kendi önceki değerlerine ve stokastik bir terime bağlı olduğunu belirtir¹²⁷. Bir otoregresif model, bir değişkeni açıklanamayan herhangi bir değişkenliği hesaba katmak için eklenen bir hata terimi ile geçmiş değerlerinin doğrusal bir kombinasyonu olarak ifade eder.

Otoregresif model matematiksel olarak şu şekilde yazılabilir¹²⁸:

$$y_t = c + \sum(\alpha_i * y_t - i) + \varepsilon_t$$

Burada y_t değişkenin t zamanındaki değeri, c sabittir, α_i otoregresif katsayılarıdır, ε_t t zamanındaki hata terimidir ve $\sum$ toplama operatörüdür.

AR modeli, değişkenin mevcut değerinin, otoregresif katsayılar tarafından verilen ağırlıklarla geçmiş değerlerinin doğrusal bir kombinasyonu olduğunu varsayar. ε_t hata terimi, değişkenin geçmiş değerleri ile açıklanamayan herhangi bir değişkenliği yakalar. AR modelinin p ile gösterilen sırası, mevcut değeri tahmin etmek için kullanılan geçmiş değerlerin sayısını belirtir. Örneğin, bir AR (1) modeli mevcut değeri tahmin etmek için değişkenin yalnızca önceki değerini kullanırken AR (2) modeli önceki iki değeri kullanır. Otoregresif katsayılar α_i , momentler yöntemi veya maksimum olabilirlik tahmini gibi çeşitli yöntemler kullanılarak tahmin edilebilir.

¹²⁶ Önkal, D., Goodwin, P., Thomson, M., Gönül, S., & Pollock, A. (2009). The relative influence of advice from human experts and statistical methods on forecast adjustments. *Journal of Behavioral Decision Making*, 22(4), 390-409.

¹²⁷ Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6), 716-723.

¹²⁸ Ding, Z., & Granger, C. W. (1996). Modeling volatility persistence of speculative returns: a new approach. *Journal of econometrics*, 73(1), 185-215.

Katsayılar tahmin edildikten sonra, model değişkenin gelecekteki değerlerini tahmin etmek için kullanılabilir.

Sonuç olarak, otoregresif model, geçmiş gözlemlere dayalı olarak gelecekteki değerleri tahmin etmek için yararlı bir araçtır. Değişkenin mevcut değerinin, açıklanamayan herhangi bir değişkenliği yakalamak için eklenen bir hata terimi ile geçmiş değerlerinin doğrusal bir kombinasyonu olduğunu varsayar. Modelin sırası tahminde kullanılan geçmiş değerlerin sayısını belirler. Otoregresif katsayılar çeşitli yöntemler kullanılarak tahmin edilebilir ve modelin performansı AIC ve BIC gibi ölçütler kullanılarak değerlendirilebilir.

1.9.2. Hareketli Ortalamalar (MA) Modeli

Hareketli ortalamalar (MA) modelleri, tahminde yaygın olarak kullanılan bir zaman serisi modelleri sınıfıdır. Gelecekteki değerleri tahmin etmek için geçmiş gözlemlerin hareketli ortalamasını hesaplamayı içerirler. Hareketli ortalama modelleri, belirli bir zaman serisini veya sinyali anlamak için zaman serisi analizinde kullanılan sonlu sıralı otoregresif hareketli ortalama modelleri sınıfıdır¹²⁹. Hareketli ortalama modelleri, kısa vadeli dalgalanmaları yumuşatmak ve daha uzun vadeli eğilimleri veya döngüleri vurgulamak için zaman serisi analizinde kullanılır¹³⁰.

MA modeli matematiksel olarak şu şekilde yazılabilir¹³¹:

$$y_t = \mu + \varepsilon_t + \sum(\beta_i * \varepsilon_t - i)$$

Burada y_t değişkenin t zamanındaki değeri, μ serinin ortalaması, ε_t t zamanındaki hata terimi, β_i hareketli ortalama katsayıları ve $\sum$ toplama operatörüdür. MA modeli, değişkenin mevcut değerinin hareketli ortalama katsayıları tarafından verilen ağırlıklarla geçmiş hata terimlerinin doğrusal bir kombinasyonu olduğunu varsayar. ε_t hata terimi, geçmiş hata terimleriyle açıklanamayan herhangi bir

¹²⁹ Alexander, C. (2008). Moving average models for volatility and correlation, and covariance matrices. *Handbook of finance*, 3(5), 62.

¹³⁰ Burman, P. (1989). A comparative study of ordinary cross-validation, v-fold cross-validation and the repeated learning-testing methods. *Biometrika*, 76(3), 503-514.

¹³¹ Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control* (5th ed.). Wiley.

değişkenliği yakalar. MA modelinin q ile gösterilen sırası, tahminde kullanılan geçmiş hata terimlerinin sayısını belirtir. Örneğin, bir MA (1) modeli mevcut değeri tahmin etmek için yalnızca önceki hata terimini kullanırken, MA (2) modeli önceki iki hata terimini kullanır.

Hareketli ortalama katsayıları β_t , maksimum olasılık tahmini gibi çeşitli yöntemler kullanılarak tahmin edilebilir. Katsayılar tahmin edildikten sonra model değişkenin gelecekteki değerlerini tahmin etmek için kullanılabilir. MA modeli, geçmiş hata terimlerine dayalı olarak gelecekteki değerleri tahmin etmek için yararlı bir araçtır. Değişkenin mevcut değerinin, hareketli ortalama katsayıları tarafından verilen ağırlıklarla geçmiş hata terimlerinin doğrusal bir kombinasyonu olduğunu varsayar. Modelin sırası, tahminde kullanılan geçmiş hata terimlerinin sayısını belirler. Hareketli ortalama katsayıları çeşitli yöntemler kullanılarak tahmin edilebilir ve modelin performansı MSE ve AIC gibi ölçütler kullanılarak değerlendirilebilir.

1.9.3. Otoregresif Hareketli Ortalamalar (ARMA) Modeli

Otoregresif hareketli ortalamalar (ARMA) modeli, otoregresif (AR) modeli ile hareketli ortalamalar (MA) modelini birleştiren yaygın olarak kullanılan bir zaman serisi modelidir. ARMA modeli, gelecekteki değerleri anlamak ve tahmin etmek için zaman serisi analizinde kullanılan bir araçtır. İki bileşeni birleştirir: bir otoregresif (AR) kısım ve bir hareketli ortalama (MA) kısım¹³². Özellikle kısa ufuklarda etkilidir¹³³."

ARMA modeli matematiksel olarak şu şekilde yazılabilir¹³⁴:

$$y_t = \mu + \sum(\varphi_i y_t - i) + \sum(\theta_i \varepsilon_t - i)$$

Burada y_t değişkenin t zamanındaki değeri, μ serinin ortalaması, φ_i otoregresif katsayılar, θ_i hareketli ortalama katsayıları ve ε_t t zamanındaki hata terimidir. Modelin AR kısmı, değişkenin mevcut değeri ile geçmiş değerleri arasındaki doğrusal ilişkiyi

¹³² Wang, W. C., Chau, K. W., Cheng, C. T., & Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3-4), 294-306.

¹³³ Baumeister, C., & Kilian, L. (2012). Real-time forecasts of the real price of oil. *Journal of business & economic statistics*, 30(2), 326-336.

¹³⁴Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2008). Time series analysis: Forecasting and control (4th ed.). John Wiley & Sons.

yakalarken, MA kısmı, değişkenin mevcut değeri ile geçmiş hata terimleri arasındaki doğrusal ilişkiyi yakalar. (p,q) ile gösterilen ARMA modelinin sırası, sırasıyla tahminde kullanılan geçmiş değerlerin ve geçmiş hata terimlerinin sayısını belirtir. Otoregresif katsayılar φ_i , geçmiş değerlerin değişkenin mevcut değeri üzerindeki etkisini temsil ederken, hareketli ortalama katsayıları θ_i geçmiş hata terimlerinin değişkenin mevcut değeri üzerindeki etkisini temsil eder. Katsayılar, maksimum olabilirlik tahmini gibi çeşitli yöntemler kullanılarak tahmin edilebilir.

ARMA modeli, geçmiş değerlere ve geçmiş hata terimlerine dayalı olarak gelecekteki değerleri tahmin etmek için yararlı bir araçtır. Verilerdeki her iki doğrusal ilişkiyi de yakalamak için AR ve MA modellerini birleştirir. Modelin sırası, tahminde kullanılan geçmiş değerlerin ve geçmiş hata terimlerinin sayısını belirler. Katsayılar çeşitli yöntemler kullanılarak tahmin edilebilir ve modelin performansı MSE ve AIC gibi ölçütler kullanılarak değerlendirilebilir.

1.9.4. Otoregresif Hareketli Tamamlanmış Ortalamalar (ARIMA) Modeli

Otoregresif entegre hareketli ortalama (ARIMA) modeli, tahmin için yaygın olarak kullanılan bir zaman serisi modelidir. Durağan olmayan zaman serilerini işlemek için bir fark alma adımı içeren otoregresif hareketli ortalama (ARMA) modelinin bir uzantısıdır.

ARIMA modeli matematiksel olarak şu şekilde yazılabilir¹³⁵:

$$y_t = c + \sum (\varphi_i y_t - i) + \sum (\theta_i \varepsilon_t - i) + \varepsilon_t$$

Burada y_t değişkenin t zamanındaki değeri, c sabit bir terimdir, φ_i otoregresif katsayılarıdır, θ_i hareketli ortalama katsayılarıdır, ε_t t zamanındaki hata terimidir ve $\sum (\varphi_i y_t - i)$ terimi şunu temsil eder: otoregresif bileşen, $\sum (\theta_i \varepsilon_t - i)$ hareketli ortalama bileşenini temsil eder ve ε_t beyaz gürültü bileşenini temsil eder. Modelin tümleşik bileşeni $(1 - B)^d * y_t$ terimiyle temsil edilir; burada B , geri kaydırma operatörüdür ve d , durağanlığa ulaşmak için serinin farklarının alınması gereken sayıdır. Fark alma adımı, verilerdeki eğilimleri veya mevsimsel kalıpları

¹³⁵Brockwell, P. J., & Davis, R. A. (2016). Introduction to time series and forecasting (3rd ed.). Springer.

kaldırmak için ardışık gözlemler arasındaki farkın alınmasını içermektedir. (p,d,q) ile gösterilen ARIMA modelinin sırası, sırasıyla modelde kullanılan otoregresif terimlerin, fark alma adımlarının ve hareketli ortalama terimlerinin sayısını belirtir. Katsayılar, maksimum olabilirlik tahmini gibi çeşitli yöntemler kullanılarak tahmin edilebilir.

ARIMA modeli, özellikle durağan olmayan örüntülere sahip olan zaman serisi verilerini tahmin etmek için yararlı bir araçtır. Durağan olmayan verileri işlemek için otoregresif ve hareketli ortalama modellerini bir fark alma adımıyla birleştirir. Modelin sırası, modelde kullanılan otoregresif terimlerin, fark alma adımlarının ve hareketli ortalama terimlerinin sayısını belirler ve katsayılar çeşitli yöntemler kullanılarak tahmin edilebilir. Modelin performansı, MSE ve AIC gibi ölçütler kullanılarak değerlendirilebilir.

II. BÖLÜM

ZEKA, YAPAY ZEKA YÖNTEMLERİ VE TEMEL KAVRAMLAR

Doğal bir insan yetisi hem de Yapay Zeka (AI) olarak adlandırılan makinelerin içindeki bir yapı olarak zekanın ayrıntılı bir şekilde incelediğimiz bu bölümde öncelikle insan zekasının doğal nitelikleri yapay benzerlerinden ayrılıyor ve hem kesişimleri hem de sapmaları vurgulanıyor. Böyle bir karşılaştırmalı yaklaşım, yapay zekanın insanın bilişsel işlevlerini taklit etme veya artırma konusundaki evrimini ve potansiyelini anlamaya yardımcı olur. Daha sonra odak noktası yapay zekanın önemli bir alt kümesi olan makine öğrenimini irdelemektedir. Bu bölüm, tarihsel gelişimini şematize ederek temel türlerini ve pratik uygulamalarını kategorize ederek modern hesaplamalı araştırmalardaki önemini vurgulamaktadır. Ayrıca, makine öğreniminin avantajları ve zorlukları hakkında dengeli bir tartışma sunulmakta ve bu sayede makinenin çok yönlü doğasına ilişkin kapsamlı bir anlayış sağlanmaktadır. Bölüm, bu dönüştürücü teknolojiye ilişkin akademik söylemi ilerleten temel yapay zeka tekniklerini tanıtarak sona ermektedir.

2.1. Zeka ve Yapay Zeka

Zeka ve yapay zeka, yaşama ve çalışma şeklimizi şekillendirmede kritik öneme sahip oldukları için son yıllarda önemli ölçüde ilgi gören iki kavramdır. Genellikle birbirlerinin yerine kullanılsalar da aynı şey değildirler. Zeka; öğrenme, anlama, akıl yürütme ve sorunları çözme yeteneğidir. Yapay zeka ise tipik olarak insan zekası gerektiren görevleri yerine getirebilen makinelerin yaratılmasını ifade eder. Yapay zekanın (AI) keşfi, altmış beş yılı aşkın bir süredir devam eden bir bilimsel ve mühendislik arayışı olmuştur. Bu araştırmanın altında yatan temel öncül, insan zekasının ürünü olan makinelerin, yalnızca yoğun emek gerektiren görevleri yerine getirmenin ötesine geçen yeteneklere sahip olduğudur; potansiyel olarak insan seviyesindeki zekayı taklit etme yeteneğine sahiptirler. Bu önerme, yapay zekanın

dönüştürücü potansiyelinin ve makine kapasitesinin parametrelerini yeniden tanımlama kapasitesinin altını çizmektedir.¹³⁶

2.1.1. Zeka

Zeka, psikologlar ve bilişsel bilimciler tarafından kapsamlı bir şekilde incelenen karmaşık ve çok boyutlu bir kavramdır. Deneyimlerden öğrenme, problem çözme, akıl yürütme ve karmaşık fikirleri anlama yeteneği olarak tanımlanabilir. Zeka ayrıca bilişsel zeka, duygusal zeka ve sosyal zeka gibi farklı türlerde kategorize edilebilir. "İnsan zekası" terimi, çeşitli akademik disiplinlerden pek çok araştırmacı tarafından tanımlanmış ve üzerinde çalışılmış karmaşık ve çok yönlü bir kavramdır. İnsan zekasının en etkili ve en çok alıntı yapılan tanımlarından biri 1983'te çoklu zeka kuramı öneren psikolog Howard Gardner'dan gelmektedir. Gardner'ın teorisine göre, farklı kültürlerde ve faaliyet alanlarında değer verilen sekiz farklı zeka türü vardır. Bu zekalar aşağıda yer almaktadır¹³⁷:

Dil zekası: Dili hem sözlü hem de yazılı olarak etkili bir şekilde kullanma becerisi.

Mantıksal-matematiksel zeka: Mantık ve nicel analiz kullanarak akıl yürütme ve sorunları çözme yeteneği.

Mekansal zeka: Nesneleri üç boyutlu uzayda görselleştirme ve manipüle etme yeteneği.

Bedensel-kinestetik zeka: Spor veya dans gibi durumlarda kişinin vücudunu ve fiziksel koordinasyonunu etkin bir şekilde kullanma yeteneği.

Müzikal zeka: Müziği tanıma ve besteleme ve onun duygusal ve yapısal yönlerini anlama yeteneği.

Kişilerarası zeka: Başkalarını anlama ve etkili bir şekilde etkileşim kurma yeteneği.

¹³⁶ Jiang, Yuchen, et al. "Quo vadis artificial intelligence?." *Discover Artificial Intelligence* 2.1 (2022): 4.

¹³⁷Gardner, H. (1983). *Frames of mind: The theory of multiple intelligences*. Basic Books.

Kişisel zeka: Kişinin kendi duygularını, motivasyonlarını ve düşüncelerini anlama ve düzenleme yeteneği.

Doğal zeka: Bitkiler ve hayvanlar gibi doğal dünyadaki nesneleri tanıma ve sınıflandırma yeteneği.

Gardner'ın çoklu zeka kuramı, eğitimsel ve psikolojik araştırmalarda geniş ölçüde etkili olmuş ve insan yetenek ve yeteneklerinin çeşitliliğinin daha fazla takdir edilmesine yol açmıştır. Diğer araştırmacılar, Robert Sternberg'in geleneksel bilişsel yetenek ölçülerine ek olarak pratik zeka ve yaratıcılığın önemini vurgulayan triarşik zeka teorisi gibi farklı insan zekası modelleri önerdiler. İnsan zekası kavramı, çeşitli disiplinlerden akademisyenler tarafından birçok farklı açıdan araştırılan zengin ve karmaşık bir çalışma alanıdır.

2.1.2. Yapay Zeka

Yapay zeka (AI) insan düşünce süreçlerini, öğrenme kapasitesini ve bilgi depolamayı taklit etmeyi amaçlayan bir bilgisayar bilimi alanıdır¹³⁸. Yapay zeka, makine öğrenimi algoritmaları, doğal dil işleme ve makinelerin verilerden öğrenmesini, kalıpları tanımasını ve tahminler veya kararlar almasını sağlayan diğer tekniklerin bir kombinasyonu kullanılarak oluşturulmuştur.

"Yapay zeka" (AI) terimi ilk olarak 1956'da Dartmouth Konferansı'nda ortaya atıldı ve o zamandan bu yana çok sayıda akademisyen ve araştırmacı tarafından tanımlandı ve yeniden tanımlandı. Etkili bir tanım, yaygın olarak alanın kurucularından biri olarak kabul edilen bilgisayar bilimcisi ve bilişsel psikolog John McCarthy'den gelmektedir. 1955'te McCarthy, AI kavramını "akıllı makineler yapmanın bilimi ve mühendisliği" olarak önerdi. Yapay zekanın "şu anda insanların daha iyi olduğu şeyleri bilgisayarlara nasıl yaptırılacağına araştırılmasını" içerdiğini öne sürmeye devam etti¹³⁹. McCarthy'nin ilk tanımından bu yana AI kavramı makine öğrenimi, doğal dil işleme, robotik ve bilgisayar görüşü dahil olmak üzere çok çeşitli teknikleri ve yaklaşımları kapsayacak şekilde gelişti.

¹³⁸ Mutasa, S., Sun, S., & Ha, R. (2020). Understanding artificial intelligence based radiology studies: What is overfitting?. *Clinical imaging*, 65, 96-99.

¹³⁹ McCarthy, J. (1956). Proposal for the Dartmouth Summer Research Project on Artificial Intelligence.

AI'nın bazı çağdaş tanımları şunları içermektedir:

Makinelerin algılama, öğrenme, problem çözme ve karar verme gibi normalde insan zekası gerektiren görevleri yerine getirme yeteneği.

Bir insan tarafından yapıldığında insan zekası gerektiren görevleri yerine getirebilen bilgisayar sistemlerinin geliştirilmesi.

Öğrenme, akıl yürütme ve kendini düzeltme dahil olmak üzere bilgisayar sistemleri tarafından insan zekası süreçlerinin simülasyonu.

Genel olarak, araştırmacılar ve uygulayıcılar yeni yaklaşımlar ve teknikler keşfettikçe ve makine ve sistemlerin yetenekleri büyümeye devam ettikçe yapay zekanın tanımı gelişmeye devam etmektedir.

2.1.3.Zeka ve Yapay Zeka Arasındaki Temel Farklılıklar

Zeka ve yapay zeka bazı benzerlikleri paylaşıyor da iki kavram arasında önemli farklılıklar vardır. Açıkçası, zeka insanların ve hayvanların sahip olduğu doğal bir yetenekken yapay zeka insan yapımı bir yaratımdır. Zeka da çok boyutludur ve kesin olarak ölçülemezken, AI ölçülebilir bir yapıdır. Ek olarak AI, insanlara özgü duygusal ve sosyal zekadan yoksundur. Sonuç olarak zeka ve yapay zeka birbiriyle ilişkili kavramlar olsa da aynı şey değildir. Zeka insanlar ve hayvanlar tarafından sahip olunan doğal bir yetenekken AI, insan zekasının belirli yönlerini taklit eden insan yapımı bir yaratımdır. AI; öğrenme, akıl yürütme ve problem çözme yeteneğini içermesi bakımından insan zekasına benzer. Ancak farklı ilkelere göre çalışması ve farklı kısıtlamalara ve sınırlamalara tabi olması bakımından farklıdır¹⁴⁰.Bu kavramlar arasındaki farklılıkları ve benzerlikleri anlamak, gelecekte teknolojiyi kullanma ve geliştirme şeklimizi şekillendirmek için çok önemlidir.

2.1.4.Zeka ve Yapay Zeka Arasındaki Temel Benzerlikler

Zeka ve yapay zeka arasındaki farklılıklara rağmen bazı önemli benzerlikler de vardır. AI insan zekasına benzer, makinelerde geliştirilen ve kullanılan bir zeka

¹⁴⁰ Price, W. N., & Cohen, I. G. (2019). Privacy in the age of medical big data. *Nature medicine*, 25(1), 37-43.

biçimidir. İnsan zekası süreçlerinin makineler, özellikle bilgisayar sistemleri tarafından simülasyonunu içermektedir. Bu süreçler arasında öğrenme, akıl yürütme, problem çözme, algılama ve dil anlayışı¹⁴¹. Her ikisi de örüntü tanımaya dayanır ve zaman içinde gelişme potansiyeline sahiptir.

2.1.5.Zeka ve Yapay Zeka Uygulamaları

Hem Zeka hem de yapay zeka, sağlık, finans, eğitim ve ulaşım gibi çeşitli alanlarda çok çeşitli uygulamalara sahiptir. Örnek, yapay zeka destekli sohbet robotları sağlık hizmetlerinde hastalara kişiselleştirilmiş bakım sağlamak için kullanılabilirken zeka, öğrencilerin eleştirel düşünme ve problem çözme yeteneklerini geliştirerek eğitim sonuçlarını iyileştirmek için kullanılabilir. AI, insan zekasını taklit etmek için yetkin bir şekilde çalışır. Bu sonuç odaklı teknoloji de uygun tarama, analiz, tahmin ve takip için kullanılır¹⁴².

2.2. Makine Öğrenmesi

Makine öğrenimi, algoritmaların ve istatistiksel paradigmaların formülasyonuna odaklanan, bilgi işlem sistemlerini verilerden içgörü elde etmek için güçlendiren, açık programlama direktifleri olmadan tahmine dayalı veya karar verme yeteneklerini kolaylaştıran bilimsel bir alan oluşturur. Makine Öğrenimi, verilerdeki kalıpları otomatik olarak algılayabilen ve ardından ortaya çıkarılan kalıpları gelecekteki verileri tahmin etmek için veya belirsizlik altında başka türden karar vermeyi (daha fazla verinin nasıl toplanacağını planlamak gibi) gerçekleştirmek için kullanan bir dizi yöntemdir¹⁴³. Makine öğrenimi alanı verilerin, hesaplama kaynaklarının ve algoritma ve tekniklerdeki ilerlemelerin artması nedeniyle son yıllarda hızla büyüyor. Makine öğrenimi bir bilgisayar sisteminin açıkça programlanmadan deneyimlerden otomatik olarak öğrenmesini ve geliştirmesini sağlama süreci olarak tanımlanabilir. Verileri analiz edebilen ve onlardan öğrenebilen, kalıpları ve ilişkileri tanımlayabilen ve bu

¹⁴¹ Jordan, M. I. (2019). Artificial intelligence—the revolution hasn't happened yet. *Harvard Data Science Review*, 1(1), 1-9.

¹⁴² Vaishya, R., Javaid, M., Khan, I. H., & Haleem, A. (2020). Artificial Intelligence (AI) applications for COVID-19 pandemic. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 14(4), 337-339.

¹⁴³ Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.

öğrenmeye dayalı olarak tahminler veya kararlar verebilen algoritmaların ve istatistiksel modellerin geliştirilmesini içermektedir.

Makine öğrenimini tanımlayan birçok akademisyen vardır ancak en öne çıkanlarından biri Carnegie Mellon Üniversitesi'nde bilgisayar bilimcisi ve makine öğrenimi uzmanı olan Tom Mitchell. Mitchell, makine öğrenimini deneyim yoluyla otomatik olarak gelişen algoritmaların incelenmesi olarak tanımlar Mitchell'in tanımı algoritmaların performansını iyileştirmede deneyimin veya verilerin önemini vurgular. Başka bir deyişle makine öğrenimi algoritmaları verilerden öğrenmek üzere tasarlanmıştır ve performanslarını zaman içinde iyileştirmek için istatistiksel modeller ve algoritmalar kullanır. Mitchell ayrıca üç tür makine öğrenimi tanımladı: denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme. Denetimli öğrenme yeni, etiketlenmemiş veriler hakkında tahminler yapmak için etiketli veriler üzerinde bir algoritmanın eğitilmesini içermektedir. Denetimsiz öğrenme, verilerdeki kalıpları ve ilişkileri bulmak için etiketlenmemiş veriler üzerinde bir algoritma eğitmeyi içermektedir. Takviyeli öğrenme, eylemleri için ödülleri veya cezalar şeklinde geri bildirim aldığı deneme yanılma yoluyla bir algoritmayı eğitmeyi içermektedir¹⁴⁴. Makine öğrenimi alanındaki diğer önde gelen akademisyenler arasında Andrew Ng, Geoff Hinton, Yann LeCun ve Yoshua Bengio yer alıyor. Arthur Samuel: Bilgisayar oyunları ve yapay zeka alanında Amerikalı bir öncü olan Arthur Samuel, 1959'da "makine öğrenimi" terimini icat etmesiyle tanınır. Samuel, makine öğrenimini "bir makinenin, deneyimi kullanarak performansını iyileştirme yeteneği" olarak tanımladı. Samuel'in tanımı, performansını iyileştirmede geri bildirimin veya deneyimlerden öğrenmenin önemini vurgular¹⁴⁵. Çeşitli akademisyenlerin kabul görmüş tanımları şu şekildedir; "bilgisayarları açıkça programlanmadan harekete geçirme bilimi" bu tanım, bilgisayarların açık programlama olmadan öğrenmesini ve karar vermesini sağlamak için veri ve algoritmaların kullanımını vurgular. Birdiğer tanım ise, makine öğrenimini "verilerden öğrenme yeteneği" olarak tanımlar bu tanım, makinelerin öğrenmelerini ve performanslarını geliştirmelerini sağlamada verilerin önemini vurgulamaktadır. Bir başka akademisyen, makine öğrenimini "bir sistemin veri ve algoritmalar kullanarak

¹⁴⁴Mitchell, T. M. (1997). Machine learning. McGraw Hill.

¹⁴⁵Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. IBM Journal of Research and Development, 3(3), 210-229. doi: 10.1147/rd.33.0210

belirli bir görevdeki performansını iyileştirme yeteneği" olarak tanımladı, bu tanım makinelerin verilerden öğrenmesini ve belirli görevlerde performanslarını geliştirmesini sağlamak için algoritmaların kullanımını vurgulamaktadır.

Genel olarak, bu akademisyenler ve araştırmacılar tarafından makine öğreniminin tanımları, makinelerin öğrenmesini ve belirli görevlerde performanslarını geliştirmesini sağlamada verilerin, algoritmaların ve geri bildirimin önemini vurgulamaktadır.

2.2.1. Makine Öğreniminin Tarihi

Makine öğreniminin tarihi, araştırmacıların yapay zeka fikrini keşfetmeye başladığı 20. yüzyılın ortalarına kadar uzanıyor. Örüntü tanıma ve hesaplamalı öğrenme teorisi çalışmasından gelişen bir alan olarak makine öğreniminin tarihi 1950'lere dayanır. Yıllar boyunca makine öğrenimi, istatistik, bilgi teorisi ve karmaşıklık teorisi dahil olmak üzere diğer birçok alandan yararlandı¹⁴⁶. 1956'da "yapay zeka" terimi John McCarthy tarafından icat edildi ve araştırmacılar makinelere öğrenmeyi öğretmek için farklı teknikler keşfetmeye başladı. İlk yaklaşımlardan biri, 1950'lerin sonlarında Frank Rosenblatt tarafından geliştirilen bir tür sinir ağı olan algılayıcıydı. Bunu 1960'larda karar ağacı algoritmalarının geliştirilmesi ve 1969'da ilk yapay sinir ağının oluşturulması izledi. 1970'ler, metin ve resimler gibi sayısal olmayan verileri işleyebilen makine öğrenimi algoritmalarının geliştirilmesine tanık oldu. 1980'lerde, diğer uygulamaların yanı sıra konuşma tanıma, el yazısı tanıma ve bilgisayar görüşü için makine öğrenimi teknikleri uygulandı. 1990'larda destek vektör makinelerinin (DVM'ler) ve Bayes ağlarının geliştirilmesi makine öğrenimi algoritmalarının yeteneklerini daha da genişletti. 2000'lerden bu yana büyük miktarda verinin kullanılabilirliği ve bilgi işlem gücündeki ilerlemeler nedeniyle makine öğrenimi giderek daha popüler hale geldi. Makine öğreniminin tarihsel gelişimini vurgulayan bir çalışma Pedro Domingos'un "Makine Öğrenimi Hakkında Bilmeniz Gereken Birkaç Yararlı Şey" adlı çalışmasıdır. Bu yazıda Domingos, makine öğrenimi algoritmalarının

¹⁴⁶ Foote, K. D. (2019). A brief history of machine learning. *Dataversity webpage*, March, 26.

tarihsel gelişimini ve bunların çeşitli alanlara uygulanmasını tartışıyor¹⁴⁷. Dikkate değer başka bir çalışma da Alon Halevy, Peter Norvig ve Fernando Pereira tarafından yazılan "Verilerin Mantıksız Etkinliği"dir. " Bu makale, makine öğrenimi algoritmalarının geliştirilmesinde verilerin rolünü ve bu algoritmaların eğitimi ve test edilmesi için büyük veri kümelerine sahip olmanın önemini tartışmaktadır¹⁴⁸. Makine öğreniminin tarihi, bu sistemlerin yeteneklerini zaman içinde genişleten yeni algoritmaların ve tekniklerin geliştirilmesiyle karakterize edilmektedir. Daha fazla veri kullanılabilir hale geldikçe ve bilgi işlem gücü artmaya devam ettikçe, makine öğreniminin gelecekte daha da yaygınlaşması muhtemeldir.

2.2.2. Makine Öğrenimi Türleri

Makine öğrenimi, algoritmalar, sistemler tasarlamak ve oluşturmakla ilgilidir¹⁴⁹. Tüm makine öğrenimi türlerini kapsamlı bir şekilde tanımlayan tek bir kesin kaynak yoktur. Bununla birlikte, yaygın olarak tanınan bazı makine öğrenimi türleri ve her biri için kısa tanımlar aşağıda verilmiştir:

Denetimli Öğrenme: Modelin etiketli veriler üzerinde eğitildiği, girdi verilerine dayalı olarak sonuçları tahmin etmeyi öğrendiği bir makine öğrenimi türüdür¹⁵⁰. Denetimli öğrenme, giriş verilerinin doğru çıktı veya sınıfla etiketlendiği anlamına gelen etiketli verileri kullanarak bir makine öğrenimi modelinin eğitilmesini içermektedir. Model, girdi verilerine ve ilişkili etiketlere dayalı olarak doğru çıktıyı tahmin etmeyi öğrenir. Denetimli öğrenme algoritmalarına örnek olarak doğrusal regresyon, lojistik regresyon, karar ağaçları ve sinir ağları verilebilir

Denetimsiz öğrenme, etiketli yanıtlar olmadan girdi verilerinden oluşan veri kümelerinden çıkarımlar yapmak için kullanılan bir tür makine öğrenimi algoritmasıdır.

¹⁴⁷Domingos, P. (2012). A few usefull things to know about machine learning. Communications of the ACM, 55(10), 78-87. doi: 10.1145/2347736.2347755

¹⁴⁸Halevy, A., Norvig, P., & Pereira, F. (2009). The unreasonable effectiveness of data. IEEE Intelligent Systems, 24(2), 8-12. doi: 10.1109/MIS.2009.36

¹⁴⁹ Flach, P. (2012). *Machine learning: the art and science of algorithms that make sense of data*. Cambridge university press.

¹⁵⁰ Conneau, A., Kiela, D., Schwenk, H., Barrault, L., & Bordes, A. (2017). Supervised learning of universal sentence representations from natural language inference data. *arXiv preprint arXiv:1705.02364*.

Genellikle veriler içindeki gizli kalıpları veya içsel yapıları keşfetmek için kullanılır¹⁵¹. Yani verilerin yalnızca giriş özelliklerini içerdiği ve karşılık gelen çıkış etiketlerini içermediği bir tür makine öğrenimi. Denetimsiz öğrenme, etiketlenmemiş veriler kullanılarak bir modelin eğitilmesini içermektedir. Model, doğru çıktı veya sınıf hakkında herhangi bir ön bilgi olmaksızın verilerdeki kalıpları ve ilişkileri belirlemelidir. Denetimsiz öğrenme algoritmalarına örnek olarak k-ortalama kümeleme, hiyerarşik kümeleme ve temel bileşen analizi (PCA) verilebilir.

Yarı Denetimli Öğrenme: Modelin etiketli ve etiketsiz verilerin bir kombinasyonu üzerinde eğitildiği bir tür makine öğrenimi. Yarı denetimli öğrenme, belirli öğrenme görevlerini gerçekleştirmek için etiketli ve etiketsiz verilerin kullanılmasıyla ilgili makine öğreniminin dalıdır. Kavramsal olarak denetimli ve denetimsiz öğrenme arasında yer alır¹⁵². Bu, etiketli veriler pahalı veya elde edilmesi zor olduğu durumlarda yararlı olabilmektedir. Yarı denetimli öğrenme algoritmalarına örnek olarak kendi kendine eğitim ve birlikte eğitim verilebilir.

Takviyeli Öğrenim: Modelin dinamik bir ortamla deneme yanılma etkileşimleri yoluyla davranışı öğrendiği¹⁵³, eylemlerine göre ödüller veya cezalar şeklinde geri bildirim aldığı bir tür makine öğrenimi. Model, zaman içinde beklenen ödülleri en üst düzeye çıkaran kararlar vermeyi öğrenir. Takviyeli öğrenme, çevresinden gelen geri bildirim dayalı kararlar almak için bir modelin eğitilmesini içeren bir makine öğrenimi türüdür. Model, deneme yanılma yoluyla öğrenir, doğru kararlar için ödüller ve yanlış kararlar için cezalar alır. Takviyeli öğrenme algoritmalarına örnek olarak Q-learning ve derin takviyeli öğrenme verilebilir

Derin Öğrenme: Birden çok işlem katmanından oluşan hesaplama modellerinin, birden çok soyutlama düzeyine sahip verilerin temsillerini öğrenmesine olanak tanıyan¹⁵⁴. Girdiler ve çıktılar arasındaki karmaşık ilişkileri modellemek için

¹⁵¹ Doherty, K. A., Adams, R. G., & Davey, N. (2007). Unsupervised learning with normalised data and non-Euclidean norms. *Applied Soft Computing*, 7(1), 203-210.

¹⁵² Van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine learning*, 109(2), 373-440.

¹⁵³ Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.

¹⁵⁴ LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

yapay sinir ağlarını kullanan bir tür makine öğrenimi. Derin öğrenme özellikle bilgisayar görüşü, konuşma tanıma ve doğal dil işleme gibi alanlarda başarılı olmuştur.

Bu tür makine öğrenimi birbirini dışlamaz ve birçok makine öğrenimi modeli, birden çok türde öge içermektedir. Ek olarak, bu geniş kategoriler tarafından ele alınmayan başka makine öğrenimi türleri de olabilir.

2.2.2.1. Denetimli Öğrenme

Denetimli öğrenme, bir algoritmanın etiketli bir veri kümesine dayalı olarak girdi verilerini bir dizi çıktı verisine eşlemeyi öğrendiği bir makine öğrenimi türüdür. Algoritma, her girdi için doğru çıktının bilindiği bir veri kümesi üzerinde eğitilir ve tahmin edilen çıktı ile gerçek çıktı arasındaki farkı en aza indirmek için parametrelerini ayarlar. Bu, modelin etiketlenmemiş bir veri kümesi üzerinde eğitildiği ve verilerdeki yapıyı ve kalıpları kendi başına keşfetmesi gereken denetimsiz öğrenmenin tersidir. Yıllar boyunca denetimli öğrenmenin birçok akademik tanımı yapılmıştır. Etkili bir tanım ise bilgisayar bilimcisi ve makine öğrenimi araştırmacısı olan Tom Mitchell'den gelmektedir. Mitchell, "Makine Öğrenimi" adlı kitabında denetimli öğrenmeyi her biri iki kategoriden birine ait olarak işaretlenmiş bir dizi eğitim örneği verildiğinde, denetimli bir öğrenme algoritması örnekleri analiz eder ve yeni örnekleri iki kategoriden birine eşlemek için kullanılabilecek bir işlev üretir, olarak ifade eder. Bu tanım, yeni verilere genellenebilen bir haritalama işlevini öğrenmek olan denetimli öğrenmenin özünü yakalar. Temel fikir algoritmanın etiketli örneklerden öğrenmesi ve bu bilgiyi yeni, görünmeyen veriler üzerinde tahminler yapmak için kullanmasıdır¹⁵⁵. Andrew Ng ve Yann LeCun gibi makine öğrenimi alanındaki diğer önde gelen araştırmacılar, etiketlenmiş verilerin önemini ve yeni örneklerle genelleme hedefini vurgulayarak benzer denetimli öğrenme tanımları sağladılar.

Bazı kaynaklarda denetimli öğrenme, “gözetimli öğrenme” şeklinde de isimlendirilmektedir. Denetimli öğrenme iki alt grupta incelenebilir. Bunlar; Regresyon ve Sınıflandırmadır.

¹⁵⁵Mitchell, T. M. (1997). Machine learning. McGraw Hill.

2.2.2.1.1. Regresyon

Regresyon, bağımsız değişkenler ile sürekli bir bağımlı değişken arasında bir ilişki kurmak için regresyon kullanılır. Regresyon analizinin amacı, değişkenler arasındaki ilişkiyi temsil eden en uygun çizgiyi (veya eğriyi) bulmaktır. Bu çizgi daha sonra bağımsız değişkenlerin değerlerine dayalı olarak bağımlı değişken hakkında tahminler yapmak için kullanılabilir. Regresyon, denetimli öğrenmede yaygın olarak kullanılan bir tekniktir. Denetimli öğrenme regresyonu, bir algoritmanın girdi-çıkı çiftlerinden öğrendiği ve bu öğrenilen ilişkiye dayalı olarak tahminler yaptığı bir süreçtir. Bir veya birden fazla öngörücü değişkene (X) dayalı olarak sürekli bir sonuç değişkenini (Y) tahmin etmek için kullanılır¹⁵⁶. Regresyonun en dikkate değer tanımlarından biri, genellikle matematiksel istatistiğin atası olarak anılan Dr. Karl Pearson'ın ufuk açıcı çalışmasından gelmektedir. Dr. Pearson'ın regresyon üzerine çalışması 1800'lerin sonlarına ve 1900'lerin başlarına kadar uzanıyor. Regresyonu bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi araştırmak için kullanılan istatistiksel bir yöntem olarak tanımladı. Ayrıca iki değişken arasındaki ilişkinin gücünün bir ölçüsü olan korelasyon kavramını da tanıttı¹⁵⁷. O zamandan beri diğer birçok bilim insanı Dr. Pearson'ın çalışmalarını genişletti ve ek regresyon tanımları sağladı. Dikkate değer bir örnek, 1920'lerde "değişkenlerdeki hatalar" regresyonu fikrini ortaya atan Dr. Frank Ramsey'dir. Bu yaklaşım, bir regresyon modelindeki hem bağımlı hem de bağımsız değişkenlerin ölçüm hatalarına sahip olabileceğini dikkate alır. Regresyon tanımına bir diğer önemli katkı da 1970'lerde genelleştirilmiş doğrusal modeller fikrini ortaya atan Dr. Arthur Dempster ve Dr. Nan Laird'den geldi. Bu çerçevede regresyonu, yanıt değişkeninin sürekli olmadığı veya normal dağılmadığı ve yanıt ile öngörücü değişkenler arasındaki ilişkinin doğrusal olmadığı durumlara genişletir. Genel olarak, regresyon denetimli öğrenmede temel bir tekniktir ve tanımı yıllar boyunca birçok akademisyen tarafından rafine edilmiş ve genişletilmiştir. Değişkenler arasındaki ilişkileri araştırmak ve tarihsel verilere dayalı olarak gelecekteki sonuçlar hakkında tahminler yapmak için güçlü bir araçtır.

¹⁵⁶ Vogel, R., Bellet, A., & Cléménçon, S. (2018, July). A probabilistic theory of supervised similarity learning for pointwise ROC curve optimization. In *International Conference on Machine Learning* (pp. 5065-5074). PMLR.

¹⁵⁷ Pearson, K. (1900). On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. *Philosophical Magazine Series 5*, 50(302), 157-175. doi: 10.1080/14786440009463897

Regresyon, çıktı değişkeninin sürekli bir sayısal değer olduğu denetimli öğrenme problemlerinin en yaygın türlerinden biridir. Regresyon algoritmaları; satışları tahmin etmek, hisse senedi fiyatlarını tahmin etmek veya bir olayın olasılığını tahmin etmek gibi çeşitli görevler için kullanılabilir. Doğrusal regresyon, karar ağacı regresyonu, rastgele orman regresyonu ve sinir ağı regresyonu dahil olmak üzere çeşitli regresyon algoritmaları vardır. Her algoritmanın kendi güçlü ve zayıf yönleri vardır; algoritma seçimi, belirli soruna ve veri kümesine bağlıdır. Denetimli makine öğrenimi regresyonu, bir veya daha fazla girdi değişkenine dayalı olarak sürekli bir sayısal çıktı değişkenini tahmin etmek için bir modelin eğitilmesini içeren bir algoritma türüdür. Girdi değişkenleri tahmin ediciler veya özellikler olarak da bilinirken, çıktı değişkeni yanıt değişkeni veya hedef değişken olarak bilinir. Bir regresyon modelinin eğitim süreci, girdi değişkenlerinin ve karşılık gelen çıktı değişkeni değerlerinin sağlandığı etiketli bir veri kümesinin kullanılmasını içermektedir. Model; yeni, görünmeyen veriler üzerinde doğru tahminler yapabilmesi için girdi değişkenleri ile çıktı değişkeni arasındaki temel kalıpları ve ilişkileri öğrenmek üzere eğitilmiştir. Regresyona yönelik yaygın bir yaklaşım, girdi değişkenleri ile çıktı değişkeni arasındaki ilişkinin düz bir çizgi olarak modellenmesini içeren doğrusal regresyondur. Bu, ilişkinin doğrusal olduğunu, yani çıktı değişkenindeki değişikliğin girdi değişkenlerindeki değişiklikle orantılı olduğunu varsayar. Doğrusal regresyon, sırasıyla yalnızca bir veya daha fazla girdi değişkeninin olduğu basit ve çoklu regresyon problemleri için kullanılabilir. Bir başka popüler regresyon algoritması, ağaç benzeri bir karar modeli ve bunların olası sonuçlarının oluşturulmasını içeren karar ağacı regresyonudur. Model, verileri girdi değişkenlerine göre daha küçük gruplara ayırır ve her grup için çıktı değişkeninin ortalama veya medyan değerlerine dayalı olarak tahminler yapar. Karar ağacı regresyonu, girdi değişkenleri ile çıktı değişkeni arasında doğrusal olmayan ilişkiler olduğunda özellikle yararlıdır. Rastgele orman regresyonu, birden fazla karar ağacı oluşturmayı ve aşırı uyum riskini azaltmak için tahminlerini birleştirmeyi içeren bir karar ağacı regresyonu varyasyonudur. Bu, verilerdeki farklı kalıpları yakalamaya yardımcı olan her karar ağacı için verilerin alt kümelerini ve girdi değişkenlerini rastgele seçerek yapılır. Sinir ağı regresyonu, insan beynindeki nöronların davranışını simüle etmeyi içeren daha karmaşık bir regresyon algoritmasıdır. Model, her biri girdi değişkenleri üzerinde matematiksel bir işlem gerçekleştiren çok sayıda düğüm

katmanından oluşur. Modelin çıktısı, girdi değişkenleri ile çıktı değişkeni arasındaki karmaşık ilişkileri yakalayabilen ve girdi değişkenlerinin doğrusal olmayan bir fonksiyonudur. Tahmin bağlamında, geçmiş verilere dayalı olarak bir değişkenin gelecekteki değerlerini tahmin etmek için bir regresyon kullanılabilir. Örneğin; bir şirket geçmiş satış verilerine, ekonomik göstergelere ve pazarlama kampanyalarına dayalı olarak gelecekteki satışları tahmin etmek için regresyon kullanabilir. Bir banka kredi puanlarına, gelir seviyelerine ve diğer faktörlere dayalı olarak kredi temerrütlerini tahmin etmek için regresyon kullanabilir. Regresyon modelleri, değişkenler arasındaki ilişkiyi analiz etmek ve çıktı değişkenini etkileyen önemli faktörleri belirlemek için de kullanılabilir. Buradaki amaç; etiketli bir giriş-çıkış çiftleri seti verildiğinde, x girişlerinden y çıkışlarına bir eşleme öğrenmektir. Çıktı, 'maaş' veya 'ağırlık' gibi gerçek veya sürekli bir değer olduğunda kullanılır¹⁵⁸. Bu, bir sistemin altında yatan mekanizmaları anlamamıza ve daha iyi kararlar almamıza yardımcı olabilmektedir. Açıkçası bir regresyon modeli, eğitim düzeyi ile gelir arasında güçlü bir pozitif ilişki olduğunu ortaya çıkarabilir ve bu, eğitim finansmanı ve işgücünün geliştirilmesine ilişkin politika kararları için bilgi sağlayabilir. Sonuç olarak denetimli makine öğrenimi regresyonu; girdi değişkenlerine dayalı sayısal değerleri tahmin etmek için güçlü bir araçtır, çeşitli endüstrilerde ve alanlarda uygulanabilir. Algoritma seçimi, belirli soruna ve veri kümesine bağlıdır ve doğruluk ve güvenilirliklerini sağlamak için regresyon modellerini dikkatlice değerlendirmek ve doğrulamak önemlidir.

Denetimli makine öğrenimindeki en önemli zorluklardan biri, modelin temel kalıplar yerine verilerdeki gürültüyü sığdırmayı öğrendiği aşırı uyumdur. Aşırı uyumu önlemek için çapraz doğrulama, düzenlileştirme ve erken durdurma gibi tekniklerin kullanılması önemlidir. Denetimli öğrenmede bir diğer önemli husus, modelin performansının değerlendirilmesidir. Bu, modelin tahminlerinin doğruluğunu ölçen ortalama hata karesi, ortalama mutlak hata veya R-kare gibi metrikler kullanılarak yapılabilir. Denetimli makine öğreniminin finans, sağlık, pazarlama, psikoloji ve mühendislik dahil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır. Sözelimi bir banka, müşteri verilerine dayalı olarak kredi riskini tahmin etmek için

¹⁵⁸ Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87.

makine öğrenimini kullanabilirken bir hastane, tıbbi kayıtlara dayalı olarak hasta sonuçlarını tahmin etmek için makine öğrenimini kullanabilir. Lineer regresyon, polinom regresyon ve lojistik regresyon gibi her birinin kendine özgü uygulamaları ve varsayımları olan çeşitli regresyon algoritmaları vardır.

2.2.2.1.2. Sınıflama

Veri madenciliğinde en popüler iş sınıflamadır. Girilen verilerin farklı özelliklerine uygun şekilde bir sınıflayıcı (model) vasıtasıyla gruplara ayrılmasını kapsayan işlemdir. Mevcut bulunan cisimlerin bir gruba verilip verilemeyeceğini veya grupların hangisine verileceğinin tespit edilmesi işidir. Diğer bir deyişle, cisimler ya da durumlar için uygun olan grubun ön görülmesidir. Sınıflama girdileri, her biri bir sınıfa ait etiketler ile işaretlenecek örneklerden ya da gözlemden meydana gelen bir eğitim sınıfıdır. Model tarafından gözlemlerden her biri için özellikleri baz alarak gerçekleştirilen atanan sınıflara ait etiketler ise çıktı şeklinde isimlendirilir. Makine öğrenmesine ait en mühim araçlardan biri de sınıflamadır. Denetimli öğrenme modelleri ve bunların yüksek öğretim senaryosuna uygulanan model sınıflandırma değerlendirmeleri model tarafından sağlanan hata geri yayımlı öğrenme algoritması, bir dizi doğrusal olmayan gerçek zamanlı problem için çok verimli olabilmektedir¹⁵⁹. Eğitime ait örneklerden meydana gelen bir eğitim grubu ve test numunelerinden meydana gelen bir test grubu tüme varımsal şekilde gerçekleştirilen öğrenmenin esas hatlarını meydana getirir. Yapılan sınıflama iki ayrı basamaktan oluşmaktadır. Bu adımlardan ilki verilerin eğitimi ve ikincisi ise modelin testidir. Eğitim grubundan çıkarım yapılarak modelin hazırlanması süreci eğitim adımını kapsar. Test adımında ise test kümesi aracılığıyla modelin kesin olup olmama durumu test edilir. Modellere ait kesinlik seviyesinin tespit edilmesi için test numunelerinin iyi olarak tanınan sınıfı, model vasıtası ile ön görülen sınıf ile kıyaslar. Test numunelerinin model aracılığıyla doğru biçimde sınıflanma yüzdesi kesinlik oranını bulmayı sağlar. Girdi verilerini kullanarak söz konusu çıktıları oluşturan model, ardından sınıf etiketi kaybolmuş olan veya bilinmeyen yeni gözlem ya da numunelerin sınıf etiketini bulmak amacıyla da tercih edilebilir. Bayesgil sınıflayıcıları; karar ağaçları, diskriminant analizi, kaba

¹⁵⁹ Sathya, R., & Abraham, A. (2013). Comparison of supervised and unsupervised learning algorithms for pattern classification. *International Journal of Advanced Research in Artificial Intelligence*, 2(2), 34-38.

kümeler, duruma dayalı uslamlama, bulanık kümeler, lojistik regresyon, eğer-sonra kuralları (kural çıkarımı), öteki mantığa dayalı formüller, yapay sinir ağları şeklinde temel sınıflama metotları olarak listelenebilir.¹⁶⁰

Denetimli öğrenmede sınıflandırmanın tanımlanmasına ve geliştirilmesine katkıda bulunan birçok araştırmacı vardır. Dikkate değer bir örnek, konu hakkında kapsamlı yayınlar yapan bir bilgisayar bilimcisi ve makine öğrenimi uzmanı olan Tom M. Mitchell'dir. Mitchell'e göre sınıflandırma, daha önce gözlemlenen girdilere benzerliğine dayalı olarak yeni bir girdiye bir etiket veya kategori atamayı içeren bir denetimli öğrenme türüdür. Amaç farklı kategoriler arasında ayırım yapmak için en alakalı olan özellik veya niteliklere dayalı olarak yeni girdiler için doğru etiketi doğru bir şekilde tahmin edebilen bir model öğrenmektir.

Uygulamada sınıflandırma, her girdinin bilinen bir etiket veya kategori ile ilişkilendirildiği etiketli bir veri kümesi üzerinde bir modelin eğitilmesini içermektedir. Model, her bir etiketle ilişkili girdi özelliklerindeki kalıpları veya ilişkileri tanımlamayı öğrenir ve bu kalıpları yeni, görünmeyen girdiler için etiket hakkında tahminler yapmak üzere kullanır. Karar ağaçları, destek vektör makineleri, lojistik regresyon ve sinir ağları dahil olmak üzere birçok farklı sınıflandırma algoritması vardır. Bu algoritmaların her birinin kendi güçlü ve zayıf yönleri vardır ve girdi özelliklerinin karmaşıklığına ve etiketlerin doğasına bağlı olarak farklı sınıflandırma görevleri türleri için daha uygun olabilmektedir. Genel olarak sınıflandırma; görüntü ve konuşma tanımadan dolandırıcılık tespitine, kişiselleştirilmiş önerilere kadar çeşitli alanlardaki uygulamalarla makine öğrenimi ve veri biliminde yaygın olarak kullanılan bir tekniktir.

2.2.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, algoritmaya herhangi bir etiketli veri verilmediği yani çıktı değişkeni hakkında önceden bilgi olmadığı anlamına gelen bir makine öğrenimi türüdür. Bunun yerine, algoritma herhangi bir yönlendirme olmadan verilerdeki kalıpları ve yapıyı tanımlamalıdır. Sistemin girdi verilerindeki kalıpları kendi kendine

¹⁶⁰EMEL, Gül GÖKAY; TAŞKIN, Çağatan. (2005). Araç Rotalama Problemlerinin İki Aşamalı Çözümünde Genetik Algoritma Kullanımı. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7.1: 1-17.

tanımayı öğrendiği bir makine öğrenimi biçimidir¹⁶¹. Bu; denetimsiz öğrenmeyi özellikle keşfedici veri analizi, gizli değişken modeller öğrenilmesi, kümeleme, anormallik ve aykırılık tespiti için kullanışlı hale getirir. Ancak bunların arasında yer alan ve en yaygın olarak kullanılan denetimsiz öğrenme tekniği, gizli modelleri tespit edebilmek ya da verileri kümelemek amacıyla kullanılmakta olan kümeleme analizi tekniğidir. Denetimsiz öğrenmenin çeşitli alanlarda çok sayıda uygulaması vardır. Bunlardan bazıları:

Anormallik Tespiti: Denetimsiz öğrenme, dolandırıcılık tespiti, izinsiz giriş tespiti ve ekipman arızası tahmini için yararlı olabilecek verilerdeki anormallikleri veya aykırı değerleri tespit etmek için kullanılabilir. Anormallik algılama algoritmaları, normdan önemli ölçüde sapan veri noktalarını tanımlar ve daha fazla araştırma için işaretler. Bunun yanında verilerdeki gizli kalıpları veya içsel yapıları keşfetmesini sağlar¹⁶².

Doğal Dil İşleme: Denetimsiz öğrenme, metin belgelerini içeriklerine göre kümelemek, gruplandırmak veya bir belgeler topluluğundan anlamlı konuları çıkarmak için kullanılabilir. Konu modelleme, doğal dil işleme için kullanılan yaygın bir denetimsiz öğrenme yaklaşımıdır.

Bilgisayarla Görü: Denetimsiz öğrenme görüntü bölümleme, nesne algılama ve görüntü kümeleme için kullanılabilir. Amaç, verileri keşfetmek ve nesneler arasındaki benzerlikleri keşfetmektir. Benzerlikler kümeler olarak adlandırılan nesne gruplarını tanımlamak için kullanılır¹⁶³. Örneğin kümeleme algoritmaları benzer görüntüleri bir arada gruplayabilirken boyutluluk azaltma teknikleri, hesaplama verimliliğini artırmak için görüntü sunumundaki özelliklerin sayısını azaltabilir.

Denetimsiz öğrenmenin sayısız uygulamasına ve faydasına rağmen ele alınması gereken çeşitli zorluklar ve sınırlamalar da vardır. Başlıca zorluklardan biri, özellikle anormallik tespiti veya konu modelleme gibi karmaşık görevler için

¹⁶¹ Diehl, P. U., & Cook, M. (2015). Unsupervised learning of digit recognition using spike-timing-dependent plasticity. *Frontiers in computational neuroscience*, 9, 99.

¹⁶² Doherty, K. A., Adams, R. G., & Davey, N. (2007). Unsupervised learning with normalised data and non-Euclidean norms. *Applied Soft Computing*, 7(1), 203-210.

¹⁶³ Tarca, A. L., Carey, V. J., Chen, X. W., Romero, R., & Drăghici, S. (2007). Machine learning and its applications to biology. *PLoS computational biology*, 3(6), e116.

kullanıldıklarında denetimsiz öğrenme algoritmalarının sonuçlarını değerlendirmenin ve yorumlamanın zorluğudur. Diğer bir zorluk da algoritmanın anlamlı kalıpları öğrenebilmesini sağlamak için büyük ve çok çeşitli veri kümelerine duyulan ihtiyaçtır. İleriye bakıldığında yüksek boyutlu ve heterojen verileri işleyebilen daha gelişmiş kümeleme algoritmalarının geliştirilmesi gibi denetimsiz öğrenme için birkaç potansiyel gelecek yönü vardır. Ayrıca denetimsiz öğrenme algoritmalarının gerçek dünya uygulamalarında konuşlandırılmasını sağlamak için yorumlanabilirliği ve açıklanabilirliği hakkında daha fazla araştırmaya ihtiyaç vardır. Bunlara rağmen denetimsiz öğrenme, çeşitli uygulamalar için kullanılabilen güçlü ve çok yönlü bir tekniktir.

Denetimsiz öğrenmenin iki ana türü vardır: Kümeleme ve Faktör Analizi-Boyut azaltma.

2.2.2.2.1. Kümeleme Analizi

Kümeleme, algoritmanın benzer nesneleri özelliklerine göre gruplandırmak için kullanıldığı bir denetimsiz öğrenme türüdür. En yaygın denetimsiz öğrenme yöntemi küme analizidir¹⁶⁴. Algoritma, grupların neyi temsil etmesi gerektiğini bilmez; bunun yerine veri noktaları arasındaki benzerlikleri belirler ve bunları buna göre gruplandırır. Bu analiz çeşidi, birbiri ile benzerlik gösteren veri nesneleri tamamını aynı kümenin içerisinde yer alacak biçimde gruplarken; farklı özelliklere sahip olan veri nesneleri ise birbirinden ayrı biçimde kümeleyerek verileri gruplandırır. Meydana gelen veri bölümü, verilerin daha iyi algılanmasını sağlar ve içeriğini ortaya koyar. Kümeleme algoritmaları tarafından bir veri grubu sınıflara ayrılır ya da gruplandırılır. Bu işlem esnasında benzerlik gösteren veri nesneleri aynı gruba atanmalıdır. Birbiri ile farklı olan veri nesneleri ise ayrı kümelere verilmelidir. Kümeleme, müşteri segmentasyonu, görüntü segmentasyonu ve gen ekspresyonu analizi gibi çeşitli uygulamalar için

¹⁶⁴ Freund, Y., & Haussler, D. (1991). Unsupervised learning of distributions on binary vectors using two layer networks. *Advances in neural information processing systems*, 4.

kullanılabilir. Kümeleme algoritmaları, bir dizi veri noktasını alt kümeler veya kümeler halinde gruplandırır¹⁶⁵.

Yaygın bir kümeleme algoritması, k-ortalama kümelemedir. Bu algoritma, özelliklerin benzerliğine dayalı olarak verileri k kümeye ayırır. Algoritma ilk olarak ilk küme merkezleri olarak k noktayı rasgele seçer ve ardından küme merkezlerini yakınsayana kadar yinelemeli olarak iyileştirir. Diğer bir yaygın kümeleme algoritması, birleştirici ya da bölücü yaklaşımlar kullanarak kümelerin hiyerarşik yapısını oluşturan hiyerarşik kümelemedir. İlk kümeleme analizi kavramını ortaya atan kişi Robert C. Tryon'dur. Geride kalan son birkaç senede kümeleme analizi finansal ve ekonomik alanlarda oldukça kıymetli bir teknik olduğu anlaşılmıştır.

2.2.2.2.2. Faktör Analizi Boyut Azaltma

Faktör analizi, çok sayıda değişkeni gözlemlediğiniz ve gözlemlenen değişkenleri açıklayabilen daha az sayıda gözlemlenmemiş değişken bulmaya çalıştığınız denetimsiz bir öğrenme biçimidir¹⁶⁶. Boyut indirgeme, varyansın mümkün olduğunca çoğunu korurken verilerdeki değişkenlerin veya özelliklerin sayısını azaltmayı amaçlayan başka bir denetimsiz öğrenme türüdür. Bu indirgeme, yüksek boyutlu verileri görselleştirmek, hesaplama karmaşıklığını azaltmak ve gürültüyü ve fazlalığı ortadan kaldırmak için kullanışlıdır. Temel Bileşen Analizi (PCA), verilerdeki maksimum varyansı yakalayan bir dizi ortogonal eksen bulmayı amaçlayan yaygın bir boyutluluk azaltma algoritmasıdır. Diğer boyutluluk indirgeme teknikleri, negatif olmayan Matris Faktörizasyon (NMF), t-dağıtılmış Stokastik Komşu Gömme (t-SNE) ve Otomatik Kodlayıcıları içerir. Denetimsiz öğrenme boyut küçültme, bilgi teorisi aracılığıyla nicel olarak değerlendirilir. Bağımsız bileşen analizi (ICA), ana bileşen analizi (PCA), sıfır fazlı beyazlatma ve tahmine dayalı kodlama ile elde edilmektedir¹⁶⁷.

Faktör analizinin gerçekleştirilmesindeki en temel amaç ortaya konan araştırmadan elde edilen verilerin yapı geçerliliğini denemesidir. Bunun yanı sıra

¹⁶⁵ Fahad, A., Alshatri, N., Tari, Z., Alamri, A., Khalil, I., Zomaya, A. Y., ... & Bouras, A. (2014). A survey of clustering algorithms for big data: Taxonomy and empirical analysis. *IEEE transactions on emerging topics in computing*, 2(3), 267-279.

¹⁶⁶ Hofmann, T. (2001). Unsupervised learning by probabilistic latent semantic analysis. *Machine learning*, 42, 177-196.

¹⁶⁷ Bethge, M. (2006). Factorial coding of natural images: how effective are linear models in removing higher-order dependencies?. *JOSA A*, 23(6), 1253-1268.

çalışmadaki değişkenler tarafından yaratılan yapının tanımlanmasına da fayda sağlar. Literatür içerisinde gerçekleştirilmiş çalışmalara bakıldığında faktör analizi kalitesinin incelenmesi hususunda birtakım ölçülerden yararlanılmaktadır. Bahsi geçen bu ölçülerden en az faktör yükü örnek grubu büyüklüğü için Kaiser-Meyer-Olkin (KMO) örneklem uygunluk ölçüsü aracılığı ile bulunurken, Barlett küresellik testi ve örneklem uygunluk ölçüsü şeklindeki analiz çeşitlerinden de faydalanılmaktadır.¹⁶⁸ Faktör analizinin “kabul edilebilir olması için bir faktörün minimum üç ayrı ifadeye sahip olması zorunludur.”¹⁶⁹

Klasik algoritmaların gruplandırılma prensibini kendiliğinden meydana getirmesini sağlaması gereksinimini gidermek için ortaya koyulan makine öğrenmesi, parçaya ait yapı üzerinde inceleme yapma ve sonunda ise elde edilen verilerin analizini yaparak parçaları uygun olan ölçüde en iyi hale getirebilecek yapıya ulaşmışlardır. Neticeye varan yollara ait parametreleri tespit eden, parametre değişimlerin neticesi hangi boyutta etkilediği konusunda inceleme yapabilen, var olan veriler vasıtası ile belirsizlikleri açıklayabilen ve öngörülerini doğru bir biçimde modelleme yaparken kullanabilme kapasitesine sahip olan makine öğrenmesi yöntemleri kullanılmaktadır

2.2.2.3. Yarı Denetimli Öğrenme

Yarı denetimli makine öğrenimi hem etiketlenmiş hem de etiketlenmemiş verileri kullanarak bir modelin eğitilmesini içeren bir algoritma türüdür. Bu, modelin yalnızca etiketlenmiş veriler üzerinde eğitildiği denetimli öğrenmenin ve modelin yalnızca etiketlenmemiş veriler üzerinde eğitildiği denetimsiz öğrenmenin karmasıdır. Yarı denetimli öğrenmede etiketli veriler, modeli etiketli örnekler üzerinde tahminler yapacak şekilde eğitmek için kullanılırken etiketlenmemiş veriler, verilerdeki temel yapıdan yararlanarak modelin genelleme performansını iyileştirmek için kullanılır. Bu, modelin tipik olarak mevcut olan çok miktarda etiketlenmemiş veriyi kullanmasına izin verdiğinden, etiketli verilerin elde edilmesinin pahalı veya etiketli verilerin az olduğu senaryolarda özellikle kullanışlıdır. Yarı denetimli öğrenme olan ilgi son yıllarda

¹⁶⁸Hair, J.F., Black, W.C., Babin, B.J., Anderson, R.E. (2009), Multivariate Data Analysis, 7th Ed., PrenticeHall, London, UK

¹⁶⁹Tabachnick, B.G. & Fidell, L.S. (2007). Using Multivariate Statistics (5th ed.). Pearson Education, Inc. / Allyn and Bacon.

özellikle resim, metin ve biyoinformatik gibi etiketlenmemiş verilerin bol olduğu uygulama alanları nedeniyle artmıştır¹⁷⁰.

Kendi kendine eğitim, ortak eğitim ve çoklu görünüm öğrenme dahil olmak üzere birkaç tür yarı denetimli öğrenme algoritması vardır. Kendi kendine eğitim, daha sonra modeli yeniden eğitmek için kullanılan ek etiketli veriler oluşturmak için modelin etiketlenmemiş veriler üzerindeki tahminlerini kullanmayı içerir. Ortak eğitim, iki veya daha fazla modelin farklı özellik kümeleri üzerinde eğitilmesini ve birbirlerinin modellerini güncellemek için etiketlenmemiş veriler üzerindeki tahminlerini kullanmayı içerir. Çoklu-görünümlü öğrenme, farklı modaliteler veya temsiller gibi aynı verilerin farklı görünüşleri üzerinde çoklu modellerin eğitilmesini ve performansı artırmak için tahminlerinin birleştirilmesini içermektedir. Yarı denetimli öğrenmedeki en önemli zorluklardan biri, hangi etiketlenmemiş örneklerin kullanılacağına seçimidir. Aktif öğrenme, modelin tahminlerindeki belirsizliğe veya güvene dayalı olarak etiketleme için en bilgilendirici örneklerin seçilmesini içeren popüler bir tekniktir. Yarı denetimli öğrenme; doğal dil işleme, bilgisayar görüşü ve konuşma tanıma gibi çeşitli alanlarda başarıyla uygulanmıştır. Meselâ doğal dil işlemede, büyük miktarda etiketlenmemiş metin verisinden yararlanarak duygu analizi veya adlandırılmış varlık tanıma görevlerinin performansını iyileştirmek için yarı denetimli öğrenme kullanılabilir.

Sonuç olarak yarı denetimli makine öğrenimi, makine öğrenimi modellerinin performansını iyileştirmek için hem etiketlenmiş hem de etiketlenmemiş verileri kullanmamıza izin veren güçlü bir yaklaşımdır. Her biri kendi güçlü ve zayıf yönlerine sahip birkaç tür yarı denetimli öğrenme algoritması mevcuttur. Aktif öğrenme, etiketleme için bilgilendirici örnekleri seçmek için popüler bir tekniktir. Yarı denetimli öğrenmenin çeşitli alanlarda çok sayıda uygulaması vardır ve gelecekteki araştırmalar için umut verici bir yöndür.

2.2.2.4. Takviyeli Öğrenme

Takviyeli öğrenme, stokastik birimler içeren bağlantıcı ağlar için genel bir ilişkiyel pekiştirmeli öğrenme algoritmaları sınıfıdır. Güçlendirilmiş algoritmalar olarak

¹⁷⁰ Chapelle, O., Scholkopf, B., & Zien, A. (2009). Semi-supervised learning (chapelle, o. et al., eds.; 2006)[book reviews]. *IEEE Transactions on Neural Networks*, 20(3), 542-542.

adlandırılan bu algoritmalar hem ani pekiştirme görevlerinde hem de belirli sınırlı gecikmeli pekiştirme görevlerinde beklenen pekiştirmenin gradyanı boyunca uzanan bir yönde ağırlık ayarlamaları yapar¹⁷¹. Diğer bir deyişle bir ortamdan gelen geri bildirimle dayalı kararlar almak için bir modelin eğitilmesini içeren bir makine öğrenimi türüdür. Takviyeli öğrenmenin amacı, bir dizi karar verme adımı üzerinden kümülatif bir ödül sinyalini en üst düzeye çıkarmaktır. Bu, modelin etiketli veriler üzerinde eğitildiği denetimli öğrenmenin ve modelin etiketlenmemiş veriler üzerinde eğitildiği denetimsiz öğrenmenin tersidir.

Takviyeli öğrenmede model, harekete geçerek ve ödül veya ceza şeklinde geri bildirim alarak bir çevre ile etkileşime girer. Model, zaman içinde beklenen kümülatif ödülü maksimize etmek için durumları eylemlere eşleyen bir politikayı optimize ederek daha iyi kararlar almayı öğrenir. Takviyeli öğrenme algoritmaları; oyun oynamak, robotları kontrol etmek ve enerji sistemlerini yönetmek gibi çok çeşitli sorunları çözmek için kullanılabilir. Değere dayalı yöntemler, politikaya dayalı yöntemler ve aktör-eleştirmen yöntemleri dahil olmak üzere birkaç tür pekiştirmeli öğrenme algoritması vardır. Değere dayalı yöntemler, her durumdan beklenen kümülatif ödülü tahmin eden bir değer fonksiyonunun öğrenilmesini içermektedir. İlke tabanlı yöntemler, durumları eylemlerle eşleyen bir ilkeyi doğrudan öğrenir. Aktör-eleştirmen yöntemleri hem bir değer işlevi hem de bir politika işlevi öğrenerek hem değere dayalı hem de politikaya dayalı yaklaşımları birleştirir.

Takviyeli öğrenmedeki en önemli zorluklardan biri, yeni stratejiler keşfetmek için yeni eylemleri denerken, mevcut politikaya dayalı olarak en iyi bilinen eylemi gerçekleştirmek arasında denge kurmaktır. Diğer bir zorluk, hangi eylemlerin belirli bir ödüle katkıda bulunduğunu belirlemesi ile uğraşmaktır. Takviyeli öğrenme oyun oynama, robotik ve sağlık hizmetleri gibi çeşitli alanlarda başarıyla uygulanmıştır. Örneğin, robotları nesneleri bir araya getirmek veya engeller arasında gezinmek gibi karmaşık görevleri yerine getirmek üzere eğitmek için pekiştirmeli öğrenme kullanılmıştır. Sağlık hizmetlerinde, kronik hastalıkları olan hastalar için tedavi planlarını optimize etmek için pekiştirici öğrenme kullanılmıştır.

¹⁷¹ Williams, R. J. (1992). Simple statistical gradient-following algorithms for connectionist reinforcement learning. *Reinforcement learning*, 5-32.

Özetle takviyeli öğrenme, bir ortamdan gelen geri bildirime dayalı kararlar almak için bir modelin eğitilmesini içeren güçlü bir makine öğrenimi yaklaşımıdır. Her biri kendi güçlü ve zayıf yönlerine sahip olan çeşitli pekiştirmeli öğrenme algoritmaları mevcuttur.

2.2.2.5. Derin (Pekiştirmeli) Öğrenme

Derin öğrenme, karmaşık verilerin temsillerini öğrenme yeteneği nedeniyle son yıllarda çok dikkat çeken makine öğreniminin bir alt alanıdır. Derin Öğrenme özelliklerin manuel olarak tasarlanmak yerine girdi verilerinin bir işlevi olarak öğrenildiği, veriye dayalı özellik öğrenimi için ideal olan bir temsili öğrenme yaklaşımıdır. Sinir ağlarında öğrenmeye yönelik güçlü bir teknikler dizisidir. Birçok alanda başarı ile uygulanmaktadır¹⁷². Görüntüler, ses ve metin gibi ham verilerden özellikleri otomatik olarak çıkarmak için çok katmanlı sinir ağlarını eğitmeyi içermektedir. Derin öğrenme bilgisayar görüşü, doğal dil işleme ve konuşma tanıma dahil olmak üzere çeşitli alanlarda dikkate değer sonuçlar elde etti. Derin öğrenmenin arkasındaki ana fikir, her katmanın girdi verilerinin aşamalı olarak daha soyut temsillerini öğrendiği hiyerarşik bir katman mimarisi kullanmaktır. Bu; modelin, insan algı ve yetenekleri kullanarak ortaya çıkarması zor veya imkansız olan verilerdeki karmaşık kalıpları yakalamasına olanak tanır. Derin öğrenme modelleri etiketli verilerin mevcudiyetine bağlı olarak denetimli, denetimsiz veya yarı denetimli öğrenme yaklaşımları kullanılarak eğitilebilir.

Derin öğrenme, çeşitli soyutlama katmanlarındaki veri gösterimlerini kavramak için çok katmanlı süreçlere sahip hesaplama mimarilerini kolaylaştırır. Bu tür metodolojiler, konuşma tanıma, görsel nesne tanımlama ve nesne algılama gibi alanlarda, ilaç keşfi ve genomik de dahil olmak üzere diğer alanlarda çağdaş gelişmeleri belirgin şekilde geliştirmiştir¹⁷³. En başarılı derin öğrenme mimarilerinden biri, nesne algılama ve sınıflandırma gibi görüntü tanıma görevleri için kullanılan evrimsel sinir ağıdır (CNN). CNN'ler, görüntülerden özellikler çıkarmak için bir dizi evrimsel katman ve özellik haritalarının boyutsallığını azaltmak için havuzlama katmanları kullanır.

¹⁷² Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2016). Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.

¹⁷³ LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

Diğer bir popüler mimari, dil çevirisi ve duyarlılık analizi gibi doğal dilleri işleme görevleri için yaygın olarak kullanılan tekrarlayan sinir ağıdır (RNN). RNN'ler, bir cümledeki kelimeler arasındaki bağlamı ve bağımlılıkları yakalamak için bir dizi gizli durum kullanır. Derin öğrenme, daha da etkileyici sonuçlar elde etmek için takviyeli öğrenme ve üretken rakip ağlar (GAN'lar) gibi diğer tekniklerle birleştirilmiştir. Eski Çin oyunu Go'da dünya şampiyonunu yenen bir sistem olan Deep Mind'ın Alpha Go sistemi, oyunu insanüstü bir seviyede oynamayı öğrenmek için derin sinir ağları ve takviyeli öğrenmenin bir kombinasyonunu kullandı. GAN'lar ise oyun benzeri bir ortamda iki sinir ağını eğiterek gerçekçi görüntüler, videolar ve hatta müzik oluşturmak için kullanılır.

Başarılarına rağmen derin öğrenme aşırı uyum, büyük ve karmaşık veri kümelerini işleme ve öğrenilen temsilleri yorumlama gibi birçok zorlukla karşı karşıyadır. Bununla birlikte derin öğrenme, gelecekteki araştırmalar için birçok heyecan verici yönü olan ve hızla gelişen bir alan olmaya devam etmektedir.

2.3. Makine Öğrenimi Uygulamaları

Makine öğreniminin sağlık, finans, pazarlama ve daha fazlası dahil olmak üzere çeşitli alanlarda çok sayıda uygulaması vardır. Sağlık hizmetlerinde makine öğrenimi, hastalık teşhisini iyileştirmek, hasta sonuçlarını tahmin etmek ve tedavi planlarını kişiselleştirmek için kullanılabilir. Finansta makine öğrenimi dolandırıcılık tespiti, kredi puanlama ve yatırım tahminleri için kullanılabilir. Pazarlamada makine öğrenimi müşteri segmentasyonu, ürün önerileri ve müşteri davranışını tahmin etmek için kullanılabilir.

2.4. Makine Öğrenimindeki Yararlar ve Zorluklar

Bilgisayar bilimi ile istatistiğin kesiştiği noktada ve yapay zeka ile veri biliminin merkezinde yer alan günümüzün en hızlı büyüyen teknik alanlarından

biridir¹⁷⁴. Makine öğreniminin sayısız faydası vardır ancak bazı zorluklar da doğurur. Makine öğreniminin yararları ve zorluklarından bazıları şunlardır:

2.4.1. Makine Öğreniminin Yararları

Geliştirilmiş doğruluk: Makine öğrenimi algoritmaları, doğru tahminler ve kararlar almak için büyük ve karmaşık veri kümelerini analiz edebilir.

Zaman kazandırma: Makine öğrenimi, tekrar eden ve zaman alan görevleri otomatikleştirerek insanların daha karmaşık ve yaratıcı işlere odaklanmasına olanak tanır.

Ölçeklenebilirlik: Makine öğrenimi algoritmaları, büyük veri kümelerini ve karmaşık sorunları işlemek için ölçeklenebilir.

Kişiselleştirme: Makine öğrenimi algoritmaları, önerileri ve tahminleri bireysel kullanıcı verilerine göre kişiselleştirebilir.

Rekabet avantajı: Makine öğrenimi, işletmelere veri odaklı kararlar almalarını sağlayarak rekabet avantajı sağlayabilir.

2.4.2. Makine Öğreniminin Zor Tarafları

Makine öğreniminin zorluğu, geliştirilmesinde ve değerlendirilmesinde yatmaktadır¹⁷⁵.

Önyargı: Makine öğrenimi algoritmaları, eğitim verilerinin önyargılı olması veya algoritmaların etik ve sosyal konular dikkate alınmadan tasarlanması durumunda önyargılı olabilmektedir.

Yorumlanabilirlik: Birçok makine öğrenimi algoritması, kararlarına nasıl ulaştıklarını anlamayı zorlaştıran kara kutu modelleridir.

¹⁷⁴ Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.

¹⁷⁵ Williams, A., Nangia, N., & Bowman, S. R. (2017). A broad-coverage challenge corpus for sentence understanding through inference. *arXiv preprint arXiv:1704.05426*.

Aşırı uyum: Makine öğrenimi algoritmaları, eğitim verilerine gereğinden fazla uyum sağlayabilir ve bu da yeni verilerde düşük performansa neden olabilmektedir.

Veri kalitesi: Makine öğrenimi algoritmaları büyük ölçüde verilere dayanır, bu nedenle düşük veri kalitesi performansı olumsuz etkileyebilmektedir.

Kaynak yoğun: Makine öğrenimi, pahalı olabilen büyük miktarda bilgi işlem gücü ve veri depolama gerektirmektedir.

Makine öğreniminin yararlarını ve zorluklarını tartışan bir çalışma, makine öğreniminin çeşitli alanlardaki potansiyelini incelemekte ve bu potansiyeli gerçekleştirmek için ele alınması gereken bazı zorlukları tartışmaktadır¹⁷⁶. Makine öğreniminin zorluklarını vurgulayan bir başka çalışma da kara kutu makine öğrenimi modellerinin kararlarını yorumlamadaki zorlukları ve daha şeffaf, yorumlanabilir modellere olan ihtiyacı tartışmaktadır¹⁷⁷. Makine öğrenimi çok sayıda endüstri ve alanda devrim yaratma potansiyeline sahiptir ancak aynı zamanda olası zorluklardan ve etik sorunlardan kaçınmak için dikkatli bir değerlendirme ve dikkat gerektirmektedir.

2.5. Temel Yapay Zekâ Teknikleri

Aşağıdaki tabloda 1763 yılından 2023 yılına kadar geçen süredeki yapay zeka algoritmalarının genel bir özeti sunulmaktadır.

Tablo 1: Yapay Zeka Teknikleri

YIL	ALGORİTMA	GELİŞTİREN	AÇIKLAMA
1763	Naive Bayes - Naif Bayes	Thomas Bayes	Bayes teoremine dayalı sınıflandırma görevlerinde kullanılan olasılıksal bir algoritma.
1847	Gradient descent - GradyanAzalma	Cauchy, Augustin-Louis	Parametrelerini iteratif olarak ayarlayarak bir fonksiyonun minimumunu bulmak için birinci dereceden bir optimizasyon algoritması kullanılır.
1900	Linear regression - Doğrusal Regresyon	Gauss, Legendre	Bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modellemek için doğrusal bir yaklaşım.

¹⁷⁶Domingos, P., 2012. A few useful things to know about machine learning. *Communications of the ACM*, 55(10), pp.78-87.

¹⁷⁷Pearson, K., 1900. X. On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 50(302), 157-175.

1933	Principal component analysis - Temel Bileşen Analizi	Harold Hotelling	Değişkenleri yeni bir kümeye dönüştürerek bir veri kümesinin boyutsallığını azaltmak için kullanılan istatistiksel bir algoritma.
1936	Linear discriminant analysis - Doğrusal Ayrımcılık Analizi	Ronald A. Fisher	İki veya daha fazla sınıfı ayıran özelliklerin doğrusal bir kombinasyonunu bulmak için kullanılan bir sınıflandırma algoritması.
1940s	Neural networks - Yapay sinir ağları	Warren McCulloch, Walter Pitts	Örüntü tanıma ve işlev yaklaşımı için kullanılan biyolojik sinir ağından ilham alan bir model.
1944	Logistic regression - Lojistik regresyon	Joseph Berkson, David Cox	Bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi analiz etmek için kullanılan istatistiksel bir model.
1951	K-nearest neighbors - K-En Yakın Komşu	Eugene L. Fix, Joseph A. Hodges	Özellik alanındaki en yakın eğitim örneğini tanımlayan ve sınıf getirmeyi atayan bir sınıflandırma algoritması.
1957	K-means clustering - K-Ortalamlar Kümeleme	Stuart Lloyd	Verileri benzerliğe göre kümelemek için kullanılan denetimsiz bir öğrenme algoritması.
1960	Hidden Markov Models - Saklı Markov Modelleri	Leonard Baum	Gözlem dizileri üzerindeki olasılık dağılımını temsil etmek için kullanılan istatistiksel bir model.
1960	Backpropagation through time - Zaman İçinde Geri Yayılım	Paul Werbos	Tekrarlanan bir sınırın zaman içindeki gradyanını hesaplamak için kullanılan bir yöntem.
1970	Decision trees - Karar Ağaçları	Ross Quinlan, J. R. Quinlan	Verileri özellik değerlerine göre yinelemeli olarak bölerek sınıflandırma ve regresyon için kullanılan denetimli öğrenme algoritması.
1970	Gaussian mixture model - Gauss karışım modeli.	Arthur Dempster, Nan Laird, Donald Rubin	Kümeleme ve yoğunluk tahmini için kullanılan olasılıksal bir model.
1970	Bayesian belief networks - Bayes modeli ve inanç ağı	Judea Pearl	Bir dizi rastgele değişken üzerindeki ortak dağılımı temsil etmek için kullanılan olasılıksal bir grafik model.
1975	Multilayer perceptron - Çok Katmanlı Algılayıcı	Paul Werbos	Sınıflandırma ve regresyon için kullanılan çok katmanlı bir ileri beslemeli sinir ağıdır.
1980	Backpropagation - Geri Yayılım	Arthur E. Bryson Jr., Paul Werbos, David Rumelhart	Hatayı ağ boyunca geriye doğru yayarak bir sınırın gradyanını hesaplamak için kullanılan bir yöntem.
1980	Hopfield network - Hopfield, yapay sinir ağı	John Hopfield, David Rumelhart	İçerik adreslenebilir bellek ve optimizasyon problemleri için kullanılan bir ağ modeli.
1980	Autoencoders - OtomatikKodlayıcı	David Rumelhart, Geoffrey Hinton	Girdi verilerini azaltılmış boyutlu bir temsilden yeniden yapılandırarak denetimsiz öğrenme için kullanılan bir sinir ağı.
1990	Support vector machines- VektörDestekMakineleri	Vladimir Vapnik	Verileri ayıran bir hiper düzlem bularak sınıflandırma ve regresyon için kullanılan denetimli bir öğrenme algoritması.
1990	Gradient boosting - GradyanArttırma	Jerome H. Friedman, Trevor Hastie, Rob Tibshirani	Güçlü bir sınıflandırıcı oluşturmak için zayıf sınıflandırıcıları birleştirmek için kullanılan bir makine öğrenimi topluluğu yöntemi.
1990	Ant colony optimization-	Marco Dorigo	Karıncaların yiyecek arama davranışlarından

	Karınca kolonisi optimizasyon		ilham alan metasezgisel bir algoritma.
1990	Particle swarm optimization - Parçacık Sürü Optimizasyonu	James Kennedy, Russell Eberhart	Nüfusa dayalı bir stokastik optimizasyon tekniği.
1990	Recurrent neural networks - Yinelemeli Sinir Ağları	John Hopfield, David Rumelhart	Düğümlemler arasındaki bağlantıların zamansal bir sırayla yönlendirilmiş bir grafik oluşturduğu bir tür yapay sinir ağı.
1990	Adaboost -Uyarlanabilir Yükseltme	Yoav Freund, Robert Schapire	İkili sınıflandırma için bir makine öğrenimi algoritması.
1990	K-medoids	Leonard Kaufman, Peter J. Rousseeuw	Veri noktalarını K kümeye bölen bir kümeleme algoritması.
1990	Convolutional neural networks - Evrişimli Sinir Ağı	Yann LeCun, Bengio, Hinton	Görüntü tanıma ve analizi için çok uygun bir tür yapay sinir ağı.
2000	Apriori algorithm - Apriori Algoritması	Rakesh Agrawal	İşlemsel veri tabanları üzerinden sık öge seti madenciliği ve ilişkilendirme kuralı öğrenimi için bir algoritma.
2000	Artificial immune systems -Yapay bağışıklık sistemleri	Jon Timmis	Bağışıklık sisteminden ilham alan hesaplamalı bir paradigma.
2000	Differential evolution - Diferansiyel evrim algoritması	Rainer Storn, Kenneth Price	Stokastik, popülasyon tabanlı bir optimizasyon algoritması.
2001	Random forests - Rastgele orman	Leo Breiman	Çok sayıda karar ağacı oluşturarak çalışan bir makine öğrenimi algoritması.
2010	Generative adversarial networks - Üretici Çekişmeli Ağlar	Ian Goodfellow	Denetimsiz öğrenme için kullanılan bir tür sinir ağı.
2010	Long short-term memory - Uzun kısa süreli bellek	Sepp Hochreiter, Jürgen Schmidhuber	Gelişmiş bellek özelliklerine sahip bir tür tekrarlayan sinir mimarisi.
2010	Attention mechanisms - Attention(Dikkat) mekanizması	DzmitryBahdanau, Kyunghyun Cho, YoshuaBengio	Bir girdinin belirli bölümlerine seçici olarak odaklanmak için derin öğrenmede kullanılan bir mekanizma.
2010	Capsule networks - Kapsül Ağları	Geoffrey Hinton	Mevki, boyut, yönlendirme benzer özellikleri öğrenebilen algoritmalar denilebilir.
2010	Transformer networks - TransformerDönüştürmeağları	Vaswani, Shazeer, Parmar, et al.	Doğal dil işleme için kullanılabilen bir tür sinir ağı mimarisi.
2010	Generative adversarial networks - Çekişmeli Üretici Ağla	Ian Goodfellow	Üretken modelleme için kullanılan bir tür denetimsiz makine öğrenimi algoritması.
2010	Long short-term memory	Sepp Hochreiter, Jürgen Schmidhuber	Uzun dizileri işleyebilen ve zaman içinde belleği koruyabilen yinelemeli bir sinir ağı mimarisi.
2010	Attention mechanisms	DzmitryBahdanau, Kyunghyun Cho, YoshuaBengio	Girdi verilerinin bilgisine seçici olarak odaklanarak sinir ağlarının performansını iyileştirmek için bir yöntem.

2010	Capsule networks	Geoffrey Hinton	Girdi verilerinde hiyerarşik yapıları temsil etmek için nörogrupları veya "kapsülleri" kullanan bir sinir ağı mimarisi.
2010	Transformer networks	Vaswani, Shazeer, Parmar, et al.	Sıralı verileri daha verimli bir şekilde işlemek için kendi kendine dikkat mekanizmalarını kullanan bir tür sinir ağı mimarisi.
2012	Deep belief networks - Derin inanç ağları	Geoffrey Hinton	Denetimsiz öğrenme ve üretken modelleme için kullanılan bir tür sinir ağı mimarisi.
2012	Dropout regularization - Sönümlemeregülasyonu	Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov	Eğitim sırasında bazı birimleri rastgele bırakarak (yani "kapatarak") sinir ağlarındaki yayılma uyumunu azaltmak için bir teknik.
2013	Batch normalization - Toplannormaleştirme	Sergey Ioffe, Christian Szegedy	Girdi verilerini her katmana normalleştirerek sinir ağlarının performansını ve kararlılığını geliştirmeye yönelik bir teknik.
2014	Generative moment matching networks	Dougal Maclaurin, David Duvenaud, Ryan Adams	Gerçek veri dağıtım anlarını eşleştirmek için çekirdek yoğunluğu tahminini kullanan bir tür üretken modelleme algoritması.
2014	Siamese neural networks - Siyam Sinir Ağları,	Gregory Koch, Richard Zemel, Ruslan Salakhutdinov	Tek seferlik öğrenme ile girdiler arasındaki benzerliğin karşılaştırılması için kullanılan bir tür sinir ağı mimarisi.
2015	Deep residual networks - Derin Kalıntı Ağları	Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun	Çok derin ağlarda daha iyi öğrenme sağlamak için kısayol bağlantılarını kullanan, görüntü sınıflandırması için kullanılan bir tür sinir ağı mimarisi.
2015	Neural style transfer - SinirselStilAktarımı	Leon A. Gatys, Alexander S. Ecker, Matthias Bethge	Sinir ağlarını kullanarak bir görüntünün (örneğin bir tablonun) stilini başka bir görüntünün (örneğin bir fotoğrafın) içeriğine uygulamak için kullanılan bir teknik.
2015	Reinforcement learning with deep neural networks - DerinSinirAğlarıilePekiştirmeliöğrenme	Volodymyr Mnih, et al.	Ödül veya ceza şeklinde geri bildirim alarak dinamik bir ortamda kararlar almak için ağları eğitmek için bir teknik.
2016	Neural machine translation	DzmitryBahdanau, Kyunghyun Cho, YoshuaBengio	Bir dilden diğerine eşlemeyi doğrudan modellemek için sinir ağlarını kullanan bir tür makine çevirisi sistemi.
2016	Variational autoencoders - Varyasyonel Otokodlayıcı	Diederik P. Kingma, Max Welling	Girdi verilerinin sıkıştırılmış bir temsilini öğrenmek için değişken ayıklamayı kullanan bir tür üretken modelleme algoritması.
2017	AlphaGo Zero	DeepMind Technologies	DeepMind tarafından geliştirilen ve insanüstü bir düzeyde Go kutu oyununu oynamak için derin pekiştirmeli öğrenmeyi kullanan bir bilgisayar programı.
2017	CycleGAN	Jun-Yan Zhu, Taesung Park, Phillip Isola, Alexei A. Efros	Eşleştirilmiş eğitim verileri olmadan farklı görüntü alanları arasında çeviri yapmayı öğrenebilen bir tür üretken modelleme algoritması.

2018	BERT	Jacob Devlin, Ming-Wei Chang, Kenton Lee, Kristina Toutanova	Çeşitli doğal dil işleme görevleri için ince ayar yapılabilen bir eğitim öncesi dil modeli.
2018	Generative Pre-trained Transformer 2 (GPT-2)	OpenAI	Yüksek kaliteli metin üretebilen büyük ölçekli denetimsiz dil modeli.
2018	Neural Architecture Search (NAS)	Barret Zoph, Quoc Le	Sinir ağlarını tasarlamak için otomatikleştirilmiş bir yöntem.
2018	CycleGAN	Jun-Yan Zhu, Taesung Park, Phillip Isola, Alexei A. Efros	Eşleştirilmiş eğitim verileri olmadan görüntüleri farklı alanlar arasında çevirmeyi öğrenebilen bir tür üretken çekişme ağı (GAN).
2019	AlphaStar	DeepMind	StarCraft II, video oyununu profesyonel düzeyde oynayabilecek gelişmiş bir öğrenme aracıdır.
2019	StyleGAN	TeroKarras, Samuli Laine, Timo Aila	Görsel görünüm üzerinde hassas kontrol ile yüksek kaliteli görüntüler oluşturabilen bir tür. GAN.
2019	BERT Large	Jacob Devlin, Ming-Wei Chang, Kenton Lee, Kristina Toutanova	Çeşitli yerel dil işleme görevlerinde son derece mükemmel sonuçlar elde eden daha büyük bir BERT sürümü.
2020	GPT-3	OpenAI	Birkaç adımda öğrenerek çok çeşitli doğal dil işleme görevlerini gerçekleştirebilen çok büyük ölçekli denetimsiz bir dil modeli.
2020	T5	Colin Raffel, Noam Shazeer, Adam Roberts, Katherine Lee, Sharan Narang, Michael Matena, Yanqi Zhou, Wei Li, Peter J. Liu	Birçok doğal dil işleme görevinde son derece iyi sonuçlar elde eden bir metinden metne dönüştürücü modeli.
2020	DeOldify	Jason Antic	Siyah beyaz resimlere ve videolara renk eklemek için derin öğrenmeyi kullanan bir resim ve video renklendirme aracı.
2021	GPT-3.5	OpenAI	GPT-3'ün daha inandırıcı insan benzeri metinler oluşturabilen geliştirilmiş bir sürümü.
2021	DALL-E	OpenAI	Metinsel açıklamalardan görüntüler oluşturabilen bir akış.
2021	CLIP	OpenAI	Görüntüler ve metin üzerinde sıfır adımlı öğrenme gerçekleştirebilen bir sınır çizgisi.

Kaynak: Tarafımızdan oluşturulmuştur, 2023.

Sonuç olarak, AI alanı son 50 yılda algoritmalarda önemli ilerlemeler gördü. 1990'dan 2021'e kadar AI algoritmalarına genel bakış alanın geleneksel yöntemlerden

derin öğrenme gibi daha modern yaklaşımlara doğru evrimini gösterdi. AI algoritmalarının gelişimi, verilerin mevcudiyeti, bilgi işlem gücü ve teknolojideki ilerlemelerden kaynaklanmıştır. En eski AI algoritmalarından biri olan Destek Vektör Makinesi (SVM) 1990 yılında tanıtıldı ve bugün hala yaygın olarak kullanılıyor. SVM, sınıflandırma ve regresyon analizi için bir makine öğrenimi algoritmasıdır. SVM tanıtılmasından bu yana biyoinformatik, metin sınıflandırma ve görüntü tanıma gibi çeşitli alanlarda uygulanmıştır. Bir başka popüler algoritma olan Karar Ağaçları, 1993 yılında tanıtıldı ve o zamandan beri sınıflandırma ve regresyon görevleri için yaygın olarak kullanılıyor. Karar Ağaçları, tıbbi teşhis ve kredi riski değerlendirmesi dahil olmak üzere birçok uygulamada kullanılmıştır. 1990'ların sonlarında sinir ağlarının gelişimi, modern AI algoritmalarının yolunu açtı. Sinir ağlarının bir alt kümesi olan derin öğrenme, son yıllarda yapay zeka alanında devrim yarattı. Evrişimli Sinir Ağları (CNN'ler), özellikle görüntü ve video tanıma görevlerinde başarılı olmuştur. Tekrarlayan Sinir Ağları (RNN'ler), doğal dil işleme ve konuşma tanıma başarılı olmuştur. Rastgele Ormanlar, Gradyan Artırma Makineleri (GBM'ler) ve Yapay Sinir Ağları (YSA'lar) gibi diğer modern AI algoritmaları, çeşitli uygulamalarda umut verici sonuçlar göstermektedir. Rastgele Ormanlar ve GBM'ler, sınıflandırma ve regresyon görevleri için popüler makine öğrenimi algoritmalarıdır. YSA'lar özellikle görüntü ve konuşma tanıma görevlerinde başarılıdır. Genel olarak AI algoritmalarının evrimi, AI alanının ilerlemesinde önemli bir rol oynamıştır. Artan veri kullanılabilirliği ve bilgi işlem gücü ile daha karmaşık algoritmaların geliştirilmesinin devam etmesi bekleniyor. Yapay zekanın sağlık, finans ve ulaşım dahil olmak üzere çeşitli alanlara entegrasyonunun önümüzdeki yıllarda toplum üzerinde önemli bir etkiye sahip olması bekleniyor. AI alanı sürekli gelişmektedir ve yeni algoritmaların geliştirilmesinin bu alanda daha fazla ilerleme sağlaması beklenmektedir. AI'nın geleceği toplum için büyük umut vaat etmektedir ve bu teknolojilerin etkisinin geniş kapsamlı olması bekleniyor.

III. BÖLÜM

BORSALARDA YAPAY ZEKANIN KULLANILMASINA İLİŞKİN ÇALIŞMALAR

Son yıllarda borsada Yapay Zeka (AI) uygulaması artan bir ilgi bulunmaktadır. Ampirik araştırmalar, yapay zekanın borsa yatırımı alanında bilinçli karar vermeyi kolaylaştırmak, yatırım stratejilerini iyileştirmek ve hisse senedi fiyatlarını doğru bir şekilde tahmin etmek dahil olmak üzere çok sayıda avantaj sunabileceğini göstermektedir¹⁷⁸. Yapılan literatür çalışmasında görülmüştür ki yapay zekanın borsadaki birincil uygulamalarından biri hisse senedi fiyat tahminidir. Yapay zeka algoritmaları büyük hacimli tarihsel verileri analiz ederek hisse senedi fiyatlarını etkileyebilecek temel kalıpları ve eğilimleri belirleyebilir, gelecekteki hisse senedi fiyat hareketlerine ilişkin doğru tahminler üretebilir. Bu da yatırımcılara hisse senedi piyasasına ilişkin değerli içgörüler sağlayarak bilinçli yatırım kararları almalarını ve potansiyel olarak daha yüksek yatırım getirisi elde etmelerini sağlayabilir. Yapay zeka ayrıca portföy yönetimi alanında da kullanılmaktadır. Yapay zeka algoritmaları, bir yatırımcının portföyünü analiz ederek zayıflık veya fırsat alanlarını belirleyebilir. Çeşitli yatırımlarla ilişkili risk düzeyini değerlendirebilir ve riski en aza indirirken getirileri en üst düzeye çıkarmak için portföyü optimize edebilir. Yapay zeka ayrıca yatırımcılara yatırım hedefleri ve risk tercihleriyle uyumlu potansiyel yatırımları belirlemede yardımcı olabilmektedir. Aşağıda belirttiğimiz başlıklarda konuyla ilgili yapılan çalışmalardan örnekler sunulmuştur.

3.1. Hibrit Modellerle Yapılan Çalışmalar

Donaldson R. Glen ve Mark Kamstra 1997 yılında Londra, New York, Tokyo ve Toronto borsalarındaki hisse senedi fiyat hareketi verilerini kullanarak ANN-GARCH tahmin modellerinin hisse senedi getiri oynaklığı performansını inceliyor¹⁷⁹.

¹⁷⁸ Kumar, Deepak, Pradeepta Kumar Sarangi, and Rajit Verma. "A systematic review of stock market prediction using machine learning and statistical techniques." *Materials Today: Proceedings* 49 (2022): 3187-3191.

¹⁷⁹ Donaldson, R. Glen, and Mark Kamstra. "An artificial neural network-GARCH model for international stock return volatility." *Journal of Empirical Finance* 4.1 (1997): 17-46.

"Uluslararası hisse senedi getiri oynaklığı için yapay bir sinir ağı ANN-GARCH modeli" başlıklı makale: Yapay Sinir Ağı (YSA) literatürüne dayanan yarı parametrik, doğrusal olmayan bir GARCH modeli sunmaktadır. Model Londra, New York, Tokyo ve Toronto'da hisse senedi getiri oynaklığını tahmin etme yeteneği açısından değerlendirilmiştir. Yazarlar, mevcut modellerin yakalayamadığı önemli asimetrik etkileri yakalayabilen koşullu hisse senedi oynaklığı için yeni bir model geliştirdiler. Bu model, Yapay Sinir Ağları (YSA) alanındaki son çalışmalardan esinlenmiştir ve geçmiş getiri yenilikleri ile gelecekteki oynaklık arasındaki doğrusal olmayan ilişkiyi yakalamak için işlevsel esnekliğe sahiptir.

Yazarlar; GARCH, EGARCH, GJR ve YSA modelleri dahil olmak üzere çeşitli oynaklık modellerinin performansını karşılaştırdı. Londra, New York, Tokyo ve Toronto olmak üzere dört farklı uluslararası pazardan 1970-1990 yılları arasındaki günlük hisse senedi getiri verilerini kullandılar. Bu karşılaştırma, çeşitli piyasalardaki oynaklık arasındaki ilginç farklılıkları belgelemelerine olanak sağladı.

Yazarlar, her gün sürekli olarak güncellenen parametre tahminlerini kullanarak YSA'nın ve çeşitli geleneksel oynaklık modellerinin örnek dışı performansını araştırdılar. Bu yaklaşım, oynaklık modellerinin çalışmasının amaçlandığı koşullu tahmin ortamlarında model performansını daha iyi değerlendirmelerine izin verdi.

YSA modeli, hisse senedi getiri oynaklığını tahmin etmede genel olarak popüler alternatiflerden daha iyi performans göstermektedir. Yazarlar ayrıca GARCH'ın geçmişteki negatif getiri inovasyonlarının pozitif getiri inovasyonlarından daha fazla oynaklığa yol açtığı ampirik düzenliliği yakalamada çoğu zaman başarısız olduğunu da belirtmişlerdir. Bu, çalışılan tüm endeksler için geçerliydi.

Donaldson ve Kamstra'nın "An artificial neural network-GARCH model for international stock return volatility" başlıklı makalesinde, yazarlar Yapay Sinir Ağı (YSA) literatüründen yararlanarak yeni bir yarı-parametrik olmayan doğrusal olmayan GARCH modeli önermektedir. Model, dört büyük uluslararası pazarda hisse senedi

getiri oynaklığını tahmin etme yeteneği açısından değerlendiriliyor: Londra, New York, Tokyo ve Toronto¹⁸⁰.

Yazarlar, YSA modellerinin geleneksel GARCH, EGARCH ve GJR modelleri tarafından göz ardı edilen volatilité etkilerini yakaladığını iddia etmektedir. Hem örneklem içi hem de örneklem dışı karşılaştırmalar, YSA modelinin diğer modellerden olanları kapsayan örneklem dışı oynaklık tahminleri ürettiğini ortaya koymaktadır. Yazarlar ayrıca Kuzey Amerika ve Avrupa pazarlarına göre Japonya'daki oynaklık etkilerinin önemli ölçüde devam etmesi gibi uluslararası pazarlardaki oynaklıktaki önemli farklılıkların altını çizmektedir.

Makale ayrıca geçmiş negatif getiri yeniliklerinin pozitif getiri yeniliklerinden daha fazla oynaklığa yol açtığı ampirik düzenliliği yakalamada mevcut modellerin sınırlamalarını tartışmaktadır. Yazarlar, işlevsel esnekliği ile YSA modelinin, geçmiş getiri yenilikleri ile gelecekteki oynaklık arasındaki doğrusal olmayan ilişkiyi daha iyi yakalayabileceğini savunuyorlar.

Yazarlar, farklı uluslararası piyasalar ve zaman dilimlerinde GARCH, EGARCH, GJR ve YSA modelleri dahil olmak üzere çeşitli oynaklık modellerinin kapsamlı bir değerlendirmesini üstlenirler. YSA modellerinin genellikle hem örneklem içi hem de örneklem dışı popüler alternatiflerden daha iyi performans gösterdiğini bulmuşlardır.

Bu makale, mevcut modellerin gözden kaçırdığı önemli asimetrik etkileri yakalayabilen koşullu hisse senedi oynaklığı için yeni bir model sunarak literatüre katkıda bulunmaktadır. Ayrıca farklı uluslararası piyasalarda ve zaman dilimlerinde, çeşitli volatilité modellerinin kapsamlı bir değerlendirmesini sunarak finansal ekonometride gelecekteki araştırmalar ve pratik uygulamalar için değerli bilgiler sunar.

Ballings, M., Van den Poel, D., Hespeels, N., ve Gryp, R.'nin . "A hybrid stock trading framework integrating technical analysis with machine learning techniques." adlı makalesinde yazarlar hisse senedi tahmini ve ticareti için teknik analiz

¹⁸⁰ Donaldson, R. Glen, and Mark Kamstra. "An artificial neural network-GARCH model for international stock return volatility." *Journal of Empirical Finance* 4.1 (1997): 17-46.

ve makine öğrenimi tekniklerini birleştiren hibrit bir Al-Sat sistemi önermektedir. Yazarlar, geçmişte teknik analiz ve makine öğrenimi tekniklerinin ayrı ayrı kullanılmasına rağmen bunların entegrasyonunun gelişmiş Al-Sat performansına yol açabileceğini savunuyorlar¹⁸¹.

Yazarlar hisse senedi fiyat hareketlerinin yönünü tahmin etmek için karar ağaçları, rastgele ormanlar, gradyan artırma ve destek vektör makineleri dahil olmak üzere çeşitli makine öğrenme teknikleri kullanıyor. Tahminler daha sonra Al-Sat sinyalleri oluşturmak için kullanılır. Yazarlar ayrıca hareketli ortalamalar ve momentum göstergeleri gibi teknik analiz göstergelerini modellerine dahil etmektedir.

Hibrit model, S&P 500 endeksinden alınan veriler kullanılarak değerlendirilir. Yazarlar hibrit modellerinin performansını bir satın alma ve tutma stratejisiyle ve yalnızca teknik analiz veya makine öğrenimi kullanan modellerle karşılaştırıyorlar. Sonuçlar; hibrit modelin yatırım getirisi ve riske göre ayarlanmış getiri açısından diğer stratejilerden daha iyi performans gösterdiğini göstermektedir.

Bu makale, teknik analiz ve makine öğrenimi tekniklerini bir hisse senedi Al-Sat sistemine entegre etmenin etkinliğini göstererek literatüre katkıda bulunmaktadır. Bulgular, bu tekniklerin kombinasyonunun finansal piyasa tahmini alanındaki tacirler, finansal analistler ve araştırmacılar için değerli bilgiler sağlayarak gelişmiş ticaret performansına yol açabileceğini göstermektedir

Booth, Ash, EnricoGerding, ve f-Frank makalesi "High frequency trading strategies, market fragility and price spikes: an agent-based model perspective" son otuz yılda finansal ticaret ekosistemlerinde insan odaklı sistemlerden ağırlıklı olarak bilgisayar odaklı sistemlere geçiş yapan önemli dönüşümü tartışmaktadırlar ¹⁸². Algoritmik ticaretin yükselişi; yüksek oynaklık ve aşırı hisse senedi fiyatı davranışı dönemleriyle ilişkilendirilmiştir. Makale, algoritmik ticaret stratejilerinin analizi için tamamen işleyen bir limit emir defterine ve ortak piyasa davranışlarını ve stratejilerini

¹⁸¹ Dash, Rajashree, and Pradipta Kishore Dash. "A hybrid stock trading framework integrating technical analysis with machine learning techniques." *The Journal of Finance and Data Science* 2.1 (2016): 42-57.

¹⁸² McGroarty, Frank, et al. "High frequency trading strategies, market fragility and price spikes: an agent based model perspective." *Annals of Operations Research* 282 (2019): 217-244.

temsil eden temsilci popölasyonlarına odaklanan, aracı tabanlı bir simölasyon ortamı önermektedir.

Model, farklı zaman ölçeklerinde faaliyet gösteren ve stratejik davranışları diğer piyasa katılımcılarına bağılı araçları içermektedir. Sonuçlar modelin fiyat getirilerinin otokorelasyon, oynaklık kümelemesi, basıklık, fiyat getirisinin varyansı ve emir-defteri zaman serileri ve bireysel emirlerin fiyat etki fonksiyonu için ampirik olarak gözlemlenen değerleri doğru bir şekilde yeniden ürettiğini göstermektedir. Yüksek frekanslı ticaret aracı kurumlarının varlığı, aşırı fiyat olaylarının ortaya çıkmasına neden olur. Modelin parametre değişimine duyarlılığı değerlendirilir ve borsadaki yüksek frekanslı stratejilerin oranının borsa dinamikleri üzerinde en büyük etkiye sahip olduğu bulunur.

“Binary gravity search algorithm and support vector machine for forecasting and trading stock indices” adlı çalışma, beş büyük küresel hisse senedi endeksinin günlük getirilerini tahmin etmek için Destek Vektör Makinesi (SVM) ve İkili Yerçekimi Arama Algoritmasını (BGSA) birleştiren hibrit bir model önermektedir. Benzersizlik, SVM'nin parametrelerini ve girişlerini optimize etmek ve tahmin doğruluğunu artırmak için BGSA'nın kullanılmasında yatmaktadır. BGSA-SVM modelinin ortalama doğruluğunun %52,87 olduğu ve geleneksel modellerden ve kıyaslamalardan daha iyi performans gösterdiği ortaya çıktı. Araştırma, BGSA'dan yararlanılarak SVM'nin performansının finansal zaman serisi tahmininde önemli ölçüde artırılabilceğini gösteriyor. Pratik bir uygulama olarak bu model, gerçek borsalarda karlı ticaret stratejileri oluşturmak için kullanılabilir¹⁸³.

Yazarlar; Hadavandi, Esmaeil, Hassan Shavandi, ve Arash Ghanbari'nin, "Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting" adlı makalesimde bir uzman sistem oluşturmak için kümeleme-genetik bulanık mantık sistemi (CGFS) adı verilen yeni bir hibrit yapay zeka yöntemi sunuyor.

¹⁸³ Kang, Haijun, Xiangyu Zong, Jianyong Wang, and Haonan Chen. "Binary gravity search algorithm and support vector machine for forecasting and trading stock indices." *International Review of Economics & Finance* 84 (2023): 507-526.

Yazar, piyasa hareketlerinde yer alan belirsizlikler nedeniyle borsa tahmininin zorlu bir görev olduğunu kabul etmektedir¹⁸⁴.

CGFS modeli üç ana aşamada oluşturulmuştur. İlk aşama, modelde dikkate alınacak anahtar değişkenleri seçmek için aşamalı regresyon analizinin kullanıldığı değişken seçimini içermektedir. İkinci aşama, veri setini kümeler halinde kategorize etmek için bir kendi kendine organizasyon haritası (SOM) sinir ağının kullanılmasını içermektedir. Üçüncü aşama, bir uzman sistem oluşturmak için her bir kümeyi sağlam bir genetik bulanık yaklaşıma beslemeyi içermektedir.

Yazarlar; BT sektöründen IBM ve Dell Şirketlerinin, Havayolu sektöründen İngiliz havayolları ve Ryanair havayollarının günlük hisse senedi fiyatını kullanarak önerilen CGFS'yi test ediyor. Tahmin değişkeni bir sonraki günün kapanış fiyatıdır. Sonuçlar, CGFS modelinin tahmin doğruluğunu geliştirdiğini göstermektedir.

Bu makale hisse senedi fiyat tahmini için yeni bir hibrit yapay zeka yöntemi sunarak literatüre katkıda bulunmaktadır. Bulgular, genetik bulanık sistemlerin ve yapay sinir ağlarının kombinasyonunun yatırımcılar ve finansal analistler için değerli bilgiler sağlayarak gelişmiş tahmin performansına yol açabileceğini göstermektedir.

Yazar S. Asadi'nin Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction" başlıklı makalesinde, borsa tahmini için genetik algoritmaları ve ileri beslemeli sinir ağlarını birleştiren hibrit bir model sunuyor. Önceden işlenmiş evrimsel Levenberg-Marquardt sinir ağları (PELMNN) olarak bilinen model, tahmin yeteneklerini geliştirmek için veri ön işleme ve son işleme kavramlarını da içermektedir¹⁸⁵.

Yazar, özellikle finansal piyasalar bağlamında karar vermede ve gelecek için planlamada doğru tahminin önemini vurgulamaktadır. PELMNN modeli, bir zaman serisinin gelecekteki değerlerini serinin kendisinden veya dışsal verilerden geçmiş gözlemlere dayalı olarak tahmin etmek için tasarlanmıştır. Yazar, bu modeli Tayvan

¹⁸⁴ Hadavandi, Esmail, Hassan Shavandi, and Arash Ghanbari. "Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting." *Knowledge-Based Systems* 23.8 (2010): 800-808.

¹⁸⁵ Asadi, Shahrokh, et al. "Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction." *Knowledge-Based Systems* 35 (2012): 245-258.

Menkul Kıymetler Borsası endeksi (TSE), Tahran Menkul Kıymetler Borsası endeksleri (TEPIX), Dow Jones Endüstriyel Ortalama Endeksi (DJIA) ve Nasdaq Endeksi dahil olmak üzere çeşitli borsa endekslerine uygular.

Çalışmanın bulguları, PELMNN modelinin tahmin doğruluğunu iyileştirebileceğini göstermektedir. Yazar, genetik algoritmalar ve sinir ağları gibi farklı yöntemleri birleştirmenin tahmin sonuçlarını geliştirmenin etkili bir yolu olabileceği sonucuna varıyor. Veri ön işleme ve son işleme kavramlarının kullanılması, modelin performansını daha da güçlendirir.

Bu makale borsa tahmini için yeni bir hibrit yapay zeka yöntemi sunarak literatüre katkıda bulunmaktadır. Bulgular genetik algoritmaların, sinir ağlarının ve veri işleme tekniklerinin entegrasyonunun; finansal piyasa tahmini alanındaki yatırımcılar, finansal analistler ve araştırmacılar için değerli bilgiler sağlayarak gelişmiş tahmin performansına yol açabileceğini göstermektedir.

2010, E. Hadavandi, H. Shavandi ve A. Ghanbari: "Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting", "Hisse senedi fiyat tahmini için genetik bulanık sistemlerin ve yapay sinir ağlarının entegrasyonu" adlı çalışmalarında, yazarlar hisse senedi fiyatlarını tahmin etmek için bulanık mantık ve sinirsel ağ yaklaşımını birleştiriyorlar¹⁸⁶.

Hadavandi, Shavandi ve Ghanbari tarafından yapılan çalışma, genetik bulanık sistemleri (GFS) ve yapay sinir ağlarını (ANN) birleştiren entegre bir yaklaşımla borsa tahmininin zorlu görevini geliştirmeyi amaçlamaktadır. Performansı en üst düzeye çıkarırken gerekli girdi verilerini ve model karmaşıklığını en aza indiren bir hisse senedi fiyat tahmini uzman sistemi oluşturmayı öneriyorlar.

Yazarlar, borsa eğilimlerini tahmin etmedeki doğal belirsizliklerin farkındadır ve bunları hibrit yaklaşımlarıyla hafifletmeyi amaçlamaktadır. Başarılı bir tahmin sisteminin anahtarının, hisse senedi fiyatlarını etkileyen önemli değişkenlerin

¹⁸⁶ Hadavandi, Esmail, Hassan Shavandi, and Arash Ghanbari. "Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting." *Knowledge-Based Systems* 23.8 (2010): 800-808.

tanımlanması olduğunu ve bunun da kademeli regresyon analizi ile elde edildiğini belirtmektedirler.

Yazarlar üç aşamalı bir yaklaşım sunar: ilk aşama kademeli regresyon analizi yoluyla değişken seçimi içerir, ikinci aşama verileri kendi kendini organize eden harita (SOM) sinir ağlarını kullanarak k gruplarına ayırır ve son aşama bu kümeleri bağımsız GFS modellerine besler. Kümeleme-genetik bulanık sistem (CGFS) olarak bilinen bu yaklaşım, hisse senedi fiyat tahmini için sağlam bir uzman sistemi oluşturmayı amaçlamaktadır.

Önerilen CGFS yöntemi, IBM, Dell, İngiliz havayolları ve Ryanair havayolları dahil olmak üzere BT ve Havayolları sektörlerindeki şirketlerden günlük hisse senedi fiyatı verilerine uygulandı. CGFS'nin performansı, ortalama mutlak yüzde hatası (MAPE) kullanılarak değerlendirildi; sonuçlar CGFS yaklaşımının önceki yöntemlerden daha iyi performans gösterdiğini ve hisse senedi fiyatı tahmini için umut verici bir araç haline geldiğini gösterdi.

2012, S. Asadi, E. Hadavandi, F. Mehmanpazir ve M. M. Nakhostin: "Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction" araştırması, borsa tahminini geliştirmek için sinir ağları ve veri ön işlemenin bir kombinasyonunu kullandı¹⁸⁷.

Asadi, Hadavandi, Mehmanpazir ve Nakhinti, Yapay Zeka (AI) modellerini kullanarak borsa tahmininin zorlu problemini ele alıyor. Piyasa hareketlerindeki yüksek belirsizlik seviyelerini kabul eden yazarlar, borsa endekslerini tahmin etmek için hibrit bir akıllı model önermektedir. Model; veri ön işleme yöntemlerini, genetik algoritmaları ve Levenberg-Marquardt (LM) algoritmasını, AI'nın insan akıl yürütmesini taklit etme kapasitesinden yararlanarak besleme ileri sinir ağlarını eğitmek için entegre eder.

Araştırmacılar doğru tahminin karar vermeyi ve gelecek planlamasını önemli ölçüde geliştirebileceğini iddia ediyorlar. Modelleri, doğal belirsizlikler nedeniyle

¹⁸⁷ Asadi S, Hadavandi E, Mehmanpazir F, Nakhostin MM. Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction. Knowledge-Based Systems. 2012 Nov 1;35:245-58.

karmaşık hale getirilen bir görev olan borsa hareketlerini tahmin etmeye odaklanıyor. Başarılı finansal planlama ve kuruluşların finansal istikrarını korumak için doğru tahmin metodolojisini seçmenin ve uygulamanın önemini vurgulamaktadırlar.

Kullanılan metodoloji, sinir ağlarına evrimsel bir yaklaşım içermektedir. Bu süreç başlangıçta sinir ağı ağırlıklarını geliştirmek için genetik algoritmaların kullanılmasını içerir ve bunlar daha sonra LM algoritması ile ayarlanır. Yazarlar ayrıca model doğruluğunu artırmak için veri dönüştürme ve girdi değişkenleri seçimi gibi veri ön işleme yöntemlerini de kullanmaktadır. Zaman serisi veri noktalarını göz önünde bulundurarak, yöntem geçmiş gözlemlere dayanarak gelecekteki değerleri tahmin etmeyi amaçlamaktadır.

Önerilen yöntemin kapasitesi, Tayvan Menkul Kıymetler Borsası endeksi (TSE), Tahran Menkul Kıymetler Borsası endeksleri (TEPIX), Dow Jones Endüstriyel Ortalama Endeksi (DJIA) ve Nasdaq Endeksi dahil olmak üzere çeşitli borsa endekslerinde test edilmiştir. Sonuçlar hibrit modelin piyasa dalgalanmalarıyla iyi başa çıktığını, tatmin edici tahmin doğruluğu elde ettiğini ve finansal tahminde girdiler ve çıktılar arasındaki karmaşık ilişkileri modelleme yeteneğini gösterdiğini göstermektedir.

3.2. Yapay Zeka ile Yapılan Çalışmalar

Müller K-R, Alexander J Smola, Gunnar Ratsch, Bernhard Schölkopf, Jens Kohlmorgen, Vladimir Vapnik 1997 yılında Destek Vektör Makineleri zaman serisi tahmini için kullanır ve radyan tabanlı fonksiyon ağlarıyla karşılaştırır. Destek Vektörü yaklaşımı, kıyaslamadaki en iyi bilinen sonucu %29 oranda iyileştirdiğini ortaya koymaktadır¹⁸⁸.

Yazarlar, Destek Vektör Makineleri (SVM'ler) kavramını ve bunların zaman serisi tahminindeki uygulamalarını tanıtmaktadır. Farklı türde kayıp fonksiyonlarının kullanımını ve Destek Vektörü Regresyonu (SVR) kavramını tartışır. Makale ayrıca SVR'de eşik nasıl hesaplanacağını ve bu modellerde düzenleme parametrelerinin nasıl seçileceğini de açıklamaktadır.

¹⁸⁸ Müller, K-R., et al. "Predicting time series with support vector machines." *International conference on artificial neural networks*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1997.

SVR yöntemlerinin, veriler seyrek olduğunda özellikle iyi çalıştığını göstermektedir. Makale ayrıca, kayıp fonksiyonu seçiminin SVM'lerin performansını önemli ölçüde etkileyebileceğini vurgulamaktadır.

DVM'lerin zaman serisi tahmininde mükemmel performans gösterdiği sonucuna varmaktadır. Bununla birlikte yazarlar, SVM'ler için uygun parametreleri belirlemenin hala yetersiz ve hesaplama açısından yoğun olduğunu kabul etmektedir. Gelecekteki çalışmaların teorik sınırları geliştirmeye veya bu parametreleri seçmek için basit buluşsal yöntemler geliştirmeye odaklanabileceğini öne sürüyorlar.

Fan, Alan, Marimuthu Palaniswami 2001 yılında Avustralya Menkul Kıymetler Borsası'nda işlem gören hisse senetlerini Destek Vektör Makineleri tarafından seçilen eşit ağırlıklı bir hisse senedi portföyünün beş yıllık bir dönemde %208 getiri sağlarken klasik yöntemlerle oluşturulan portföyün %71 getiri sağladığını savunmuşlardır¹⁸⁹.

Yazarlar, 'pazarı yenmek' için SVM'leri kullanma kavramını ortaya koyuyor. İstisnai getirileri olması muhtemel hisse senetlerini belirlemek için Avustralya Menkul Kıymetler Borsasında işlem gören hisse senetlerinin muhasebe ve fiyat bilgilerini kullanırlar. Yazarlar ayrıca SVM'nin çıktısını bir olasılık ölçüsü olarak yorumlayarak ve sıralayarak sınıf duyarlılığı değiş tokuşu ile yeni bir bakış açısı getiriyor.

Yazarlar, 1992-2000 yılları arasında Avustralya Menkul Kıymetler Borsasında işlem gören hisse senetlerinin finansal bilgilerini inceliyor. Boyut küçültme için temel bileşen analizini kullanırlar ve performansını belirtmek için her hisse senedine bir sınıf atarlar. Problem daha sonra iki sınıflı bir örüntü tanıma görevi olarak formüle edilmektedir.

Yazarlar doğrusal SVM'leri, doğrusal olmayan SVM'leri ve dengesiz veriler için SVM'leri tartışarak SVM'lere genel bir bakış sunar. Geri yayılım gibi gradyan iniş teknikleri için olası yerel minimumun aksine DVM'ler tarafından sağlanan benzersiz çözümü vurgularlar.

¹⁸⁹ Fan, Alan, and Marimuthu Palaniswami. "Stock selection using support vector machines." *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No. 01CH37222)*. Vol. 3. IEEE, 2001.

Yazarlar analizler yapar ve SVM'den seçilen hisse senedi tarafından üretilen getiriyi bir kıyaslama ile karşılaştırır. Sonuçlar yaklaşımlarının seçilmesiyle oluşturulan eşit ağırlıklı portföyün, test edilen beş yılın her biri için piyasa ölçütünün üzerinde fazla getiri ürettiğini göstermektedir. Yazarlar, SVM'lerin hisse senedi seçiminde yararlı olduğunun gösterildiği ve karşılaştırmalı değerlendirmeden önemli ölçüde daha iyi performans gösterdiği sonucuna varıyorlar.

Chen, Wun-Hua, Jen-YingShih ve SoushanWu 2006 yılında Asya kıtasında işlem gören 6 hisse senedi borsasında finansal zaman serilerine ilişkin Destek Vektör Makinelerin performansını incelemişlerdir¹⁹⁰.

Bu araştırma, endeks opsiyon fiyatlarının tahmininde farklı model seçim prosedürlerinin performansını karşılaştırmaktadır. Yazarlar özellikle destek vektör makinesi (SVM) olmak üzere parametrik olmayan bir yaklaşım kullanır ve bunu parametrik modellerle karşılaştırır. Buradaki amaç endeks opsiyon fiyatlarını tahmin etmek için en iyi modeli belirlemektir.

Çalışma altı büyük Asya borsa endeksini kullanıyor: Nikkei 225 (NK), Tüm Olağanlar (AU), Hang Seng (HS), Straits Times (ST), Tayvan Ağırlıklı (TW) ve 1971'den 2002'ye kadar KOSPI (KO) verileri. Yazarlar sorunu, bir seçeneğin mevcut ve geçmiş fiyatlarına dayalı olarak gelecekteki fiyatını tahmin etmeyi amaçlayan bir regresyon görevi olarak formüle ettiler. Zorluk, verilerin yüksek boyutluluğunda ve doğrusal olmamasında kaynaklanmaktadır.

Yazarlar, yüksek boyutlu ve doğrusal olmayan verileri işleme becerisiyle bilinen bir makine öğrenimi tekniği olan SVM yaklaşımını kullanıyor. Bunu Black-Scholes modeli ve Heston modeli gibi parametrik modellerle karşılaştırırlar. Karşılaştırma, tahmin edilen fiyatların ortalama mutlak hatasına (MAE) dayanmaktadır.

Analizler, SVM yaklaşımının MAE açısından parametrik modellerden daha iyi performans gösterdiğini göstermektedir. Bu da DVM gibi parametrik olmayan modellerin endeks opsiyon fiyatlarını tahmin etmede daha etkili olabileceğini

¹⁹⁰ Chen, Wun-Hua, Jen-Ying Shih, and Soushan Wu. "Comparison of support-vector machines and back propagation neural networks in forecasting the six major Asian stock markets." *International Journal of Electronic Finance* 1.1 (2006): 49-67.

düşündürmektedir. Yazarlar model seçim prosedürlerinin tahmin doğruluğunda çok önemli bir rol oynadığı sonucuna varmışlardır.

Atsalakis, George S., ve Kimon P. Valavanis 2009 yılında literatür taraması sonucunda hisse senedi getir tahmini analizlerinde makine öğrenme teknikleri ile genel olarak geleneksel modellerden daha iyi performans gösterdiği sonucuna varmışlardır¹⁹¹.

Makale, borsa tahmini için nöral ve nöro-bulanık tekniklerin kullanımına odaklanan 100'den fazla makaleyi araştırıyor. Yazarlar bu makaleleri kullanılan girdi verilerine, tahmin metodolojisine, performans değerlendirmesine ve performans ölçütlerine göre sınıflandırır. Temel fikir; gerekli minimum girdi verilerini ve en az karmaşık borsa modelini kullanarak en iyi sonuçları elde etmektir.

Yazarlar, incelenen makalelerde kullanılan çeşitli borsaları ve girdi değişkenlerini gözden geçiriyorlar. Her modelde kullanılan girdi değişkenlerinin sayısı ortalama dört ile on arasında değişir. Ayrıca tahmin süreci için en önemli girdi değişkenlerini seçmek için kullanılan belirli teknikleri tartışmaktadırlar.

Yazarlar, incelenen her makaleyi veri ön işleme, örneklem büyüklüğü, uygulanan tekniğin türü, doğrulama veri setleri ve eğitim yöntemine göre sınıflandırır. Girdi verilerini ön işleme ve uygun örneklemenin tahmin performansını önemli ölçüde etkileyebileceğini vurguluyorlar. Yazarlar ayrıca gereksiz girdileri ortadan kaldırmak için girdi olarak göstergelerin seçilmesinde duyarlılık analizinin kullanımını tartışmaktadırlar.

Yazarlar sonuçları beş özet tablo şeklinde sunarlar. Bu tablolar, modellenen ilgili hisse senedi piyasalarını, kullanılan girdi değişkenlerini, hisse senedi piyasalarını tahmin etmek için kullanılan belirli metodolojileri ve model parametrelerini, her yazarın özel yaklaşımının modelleme ölçütlerini ve incelenen her modeli değerlendirmek için kullanılan performans ölçülerini listeler. Çalışma, sinir ağlarının ve nöro-bulanık modellerin borsa tahmini için uygun olduğu ve genellikle geleneksel modellerden daha iyi performans gösterdiği sonucuna varıyor.

¹⁹¹ Atsalakis, George S., and Kimon P. Valavanis. "Surveying stock market forecasting techniques-Part II: Soft computing methods." *Expert Systems with applications* 36.3 (2009): 5932-5941.

Ahmed, Nesreen K., Amir F., Atiya, Neamat Al Gayar, ve Hisham El-Shishiny 2010 yılında zaman serisi veri örneği kullanarak birçok makine öğrenme yönteminin karşılaştırmalı analizini yapmışlardır¹⁹².

Çalışma, tahmin için sekiz makine öğrenimi modelinin yani çok katmanlı algılayıcı, Bayesci sinir ağları, radyal tabanlı fonksiyonlar, genelleştirilmiş regresyon sinir ağları, K-en yakın komşu regresyonu, CART regresyon ağaçları, destek vektörü regresyonu ve Gauss süreçleri karşılaştırmasına odaklanmaktadır. Modeller, zaman serisinden oluşan M3 rekabet verileri kullanılarak değerlendirilmiştir. Çalışma ayrıca ön işleme yöntemlerinin, bu modellerin performansı üzerindeki etkisini de incelemektedir.

Bu çalışmada kullanılan M3 rekabet verileri; mikro, endüstri, finans, demografik ve diğerleri dahil olmak üzere 3003 iş türü zaman serisinin bir koleksiyonudur. Üç aylık ve yıllık zaman serileri genellikle çok kısa olduğundan çalışma aylık zaman serilerine odaklanmaktadır. Ele alınan zaman serileri için eğitim periyodunun uzunluğu 63 ila 108 veri noktası arasında değişmektedir.

Makine öğrenimi modelleri, temel biçimlerinde değişiklik yapılmadan uygulanır. Çalışma aynı zamanda makine öğrenimi modellerinde sıklıkla kullanılan zaman serilerinin farklılaştırılması ve hareketli ortalamaların alınması gibi ön işleme stratejilerini de araştırıyor. Modellerin performansı, M3 rekabet verilerini tahmin etme yeteneklerine göre değerlendirilir.

Çalışma, modeller ve ön işlemenin performans üzerindeki etkisi arasında önemli farklılıklar buldu. En iyi iki model, çok katmanlı algılayıcı ve Gauss süreçleriydi. Modellerin sıralaması genel olarak geniş tabanlıydı ve zaman serisinin farklı kategorileri veya özellikleri ile pek değişmedi. Çalışma, performanslarına olumlu yansiyabilecek bu modellerin iyileştirilmesi için hala alan olduğu sonucuna varıyor.

¹⁹² Ahmed, Nesreen K., et al. "An empirical comparison of machine learning models for time series forecasting." *Econometric reviews* 29.5-6 (2010): 594-621.

Rasekhschaffe, KeywanChristian, ve Robert C. Jones 2019 yılında hisse senedi getirilerini tahmin etmek için makine öğrenmesi kullanırken aşırı uyum sorununun üstesinden gelmenin yolunun farklı makine öğrenme yöntemlerinin, farklı veri setleriyle oluşturulacak bir tahmin olduğunu savunurlar¹⁹³.

Makale, niceliksel finasta makine öğreniminin artan önemini ve tartışmasını tartışıyorlar. İnce, bağlamsal ve doğrusal olmayan ilişkileri ortaya çıkarma yetenekleri göz önüne alındığında, makine öğrenimi tekniklerinin pratik yatırım araçları olup olamayacağını araştırıyor. Bununla birlikte, beyaz gürültülü tarihsel verilerden sinyaller çıkarılırken aşırı uyumun zorluğu da kabul edilmektedir. Yazarlar, makine öğrenimi hakkında temel bir anlayış sağlamayı ve yatırımcıların aşırı uydurmayı sınırlarken hisse senedi getirilerinin kesitini tahmin etmek için bu teknikleri nasıl kullanabileceklerini göstermeyi amaçlıyor.

Yazarlar, geleneksel nicel faktör modellerinin 2008 mali krizinden bu yana mücadele ettiğini ve bunun da bazı piyasa katılımcılarının hisse senedi seçimine yönelik geleneksel yaklaşımların ötesine bakmalarına yol açtığını belirtiyor. Makine öğrenimi algoritmaları, geçmiş verilerden dinamik olarak öğrenme yetenekleri nedeniyle potansiyel bir çözüm olarak önerilmektedir. Yazarlar ayrıca artan bilgi işlem gücü, veri kullanılabilirliği, bilgisayar bilimi ve istatistikten yeni teknikler gibi pratik makine öğreniminde ilerlemeler sağlayan gelişmeleri tartışmaktadırlar.

Makale makine öğrenimine genel bir bakış sunarak, bunu makinelerin açık programlama talimatları olmadan kalıpları ortaya çıkarmasına olanak tanıyan bir yöntem olarak tanımlıyor. Hisse senedi seçimi bağlamında, Makine öğrenimi algoritmaları hangi faktörlerin önemli olduğunu ve bunların gelecekteki getirilerle nasıl ilişkili olduğunu öğrenmek için kullanılır. Yazarlar, gradyan artırılmış regresyon ağaçları, yapay sinir ağları, rastgele ormanlar ve destek vektör makineleri gibi çeşitli Makine öğrenimi algoritmalarının geliştirilmesini ve iyileştirilmesini tartışmaktadırlar.

Yazarlar birçok makalenin belirli algoritmaların uygulanmasına odaklandığına dikkat çekerek, finasta makine öğrenimi tekniklerinin uygulanmasını tartışmaktadırlar.

¹⁹³ Rasekhschaffe, Keywan Christian, and Robert C. Jones. "Machine learning for stock selection." *Financial Analysts Journal* 75.3 (2019): 70-88.

Zamanlama faktörü getirileri için doğrusal olmayan modellerin faydalarını vurgularlar ve bu faktör tahminlerini kesitsel modellere dahil etmenin statik faktör modellerinden daha iyi performans gösterebileceğini gösterirler. Yazarlar, birçok makine öğrenimi algoritmasının doğrusal regresyondan daha iyi performans gösterebileceği ve tahmin kombinasyonlarının genellikle hem ABD'de hem de diğer bölgelerde bileşenlerden daha iyi performans gösterdiği sonucuna varıyor.

Güdelek M.U. 2019 yılında çeşitli zaman serisi problemlerini incelemiş ve yaklaşımları anlatmıştır. Finans verileri üzerine derin öğrenme modeli oluşturulmuş, oluşturulan modelin başarıya ulaştığı savunulmuştur¹⁹⁴.

Bu tez çeşitli zaman serisi konularını incelemekte ve ilgili yaklaşımları önermektedir. Durum bilgisi olan ve durum bilgisi olmayan Uzun Kısa Süreli Bellek (LSTM) modellerini karşılaştırır, iç yapılarını inceler ve bunları basit problemlere uygular. Çalışma aynı zamanda derin öğrenme modeli olan Konvolüsyonel Sinir Ağları (CNN) ile gelecekteki değerleri tahmin etmek için finansal verilerden hesaplanan teknik analiz özelliklerinin kullanımını araştırıyor. Ancak bu teknik göstergelerin CNN modeli için girdi olarak 2 boyutlu görüntülere dönüştürülmesi keşfedilmemiş bir alan sunuyor.

Araştırma 2B görüntü oluşturma için dendrogram kümeleme algoritmasını kullanır. Eksen korelasyon için, zaman serilerinin otokorelasyonu kullanılır. Sonuçları yöntemin belirli dönüşümler uygulandıktan sonra başarılı bir şekilde eğitilebileceğini göstermektedir. Çalışma, geliştirilen yöntemin potansiyelini başarıyla ortaya koydu ve finans verilerine uygulanan dönüşümlerin diğer zaman serisi verileriyle ilgili olabileceğini öne sürdü. Bu da farklı alanlarda farklı mimarilere sahip modelleri kullanma olasılığını açar.

Ghosh, Neufeld ve Sahoo tarafından hazırlanan araştırma makalesi, gün içi ticarete S&P 500 hisse senetlerinin yön hareketlerini tahmin etmek için LSTM ağlarının ve Rastgele Ormanların tahmin yeteneklerini inceliyor. Açılış fiyatları ve gün içi getiriler gibi daha dinamik özellikleri dahil ederek geleneksel olarak kullanılan özellik kümesini genişlettiler. Ampirik sonuçları (LSTM için %0,64, Rastgele ormanlar

¹⁹⁴ Güdelek, Mehmet Uğur. *Zaman serisi analiz ve tahmini: Derin öğrenme yaklaşımı*. MS thesis. TOBB University of Economics and Technology, Graduate School of Engineering and Science, 2019.

için %0,54), önerilen çok özellikli modelin günlük getiriler açısından geleneksel tek özellikli modellere göre daha karlı olduğunu göstermektedir. Özellikle LSTM ağı, bu kurulumda Rastgele Ormanlara kıyasla daha yüksek bir getiri oranı gösterdi¹⁹⁵.

Gu, Shihao, Bryan T. Kelly ve Dacheng Xiu 2020 yılında makine öğrenimi tekniklerinin (ağaçlar ve sinir ağları), finansal varlığın gelecekteki değerini tahmin etmede geleneksel kesit ve zaman serisi modellerinden daha iyi performans gösterebileceğini savunmuşlardır¹⁹⁶.

Belge; Shihao Gu, Bryan Kelly ve Dacheng Xiu tarafından yazılan "Makine Öğrenimi Yoluyla Ampirik Varlık Fiyatlandırması" başlıklı bir araştırma makalesidir. Makale makine öğrenimi yöntemlerinin finans alanında, özellikle öz sermaye risk priminin ölçülmesinde uygulanmasını araştırıyor. Yazarlar, makine öğrenimi yöntemlerinin ve bunların hisse senedi getirilerini tahmin etmedeki etkinliklerinin karşılaştırmalı bir analizini yürütüyor. Makine öğreniminin, geleneksel tahmin yöntemlerine kıyasla beklenen getiri davranışının gelişmiş bir tanımını sunduğunu bulmuşlardır. Makale ayrıca ağaçlar ve sinir ağları gibi en iyi performans gösteren yöntemleri tanımlar ve diğer yöntemlerle gözden kaçan doğrusal olmayan tahmin edici etkileşimlerin payına kadar tahmine dayalı kazançlarının izini sürer.

Makalenin girişi, yazarların finasta ve özellikle de hisse senedi risk primini ölçmede makine öğrenimi yöntemlerinin karşılaştırmalı bir analizini yapma amacını özetlemektedir. Araştırmalarının iki temel katkısını vurguluyorlar: risk primini ölçmede makine öğrenimi yöntemlerinin tahmini doğruluğu için kıyaslamalar sağlamak ve ampirik varlık fiyatlandırma literatürünü makine öğrenimi alanıyla sentezlemek. Ayrıca makine öğreniminin tanımını ve bunun varlık fiyatlandırmasına uygulanmasını da tartışmaktadırlar.

Yazarlar, 1957'den 2016'ya kadar 60 yıl boyunca yaklaşık 30.000 bireysel hisse senedini araştıran büyük ölçekli bir ampirik analiz kullanıyor. Tahmin setleri, her hisse

¹⁹⁵ Ghosh, Pushpendu, Ariel Neufeld, and Jajati Keshari Sahoo. "Forecasting directional movements of stock prices for intraday trading using LSTM and random forests." *Finance Research Letters* 46 (2022): 102280.

¹⁹⁶ Gu, Shihao, Bryan Kelly, and Dacheng Xiu. "Empirical asset pricing via machine learning." *The Review of Financial Studies* 33.5 (2020): 2223-2273.

senedi için 94 özellik, her bir özelliğin sekiz toplu zaman serisi değişkeni ile etkileşimi ve 74 endüstri sektörü kukla değişkeni içeriyor. Ayrıca makine öğreniminin sınırlamalarını ve varlık fiyatları ile koşullandırma değişkenleri arasındaki derin temel ilişkileri belirleyememesini de tartışmaktadırlar.

Yazarlar, özetlenen ampirik zorlukları ele almak için potansiyel olarak uygun olan bir dizi aday model seçmektedir. Bunlar, doğrusal regresyon, cezalandırılmalı genelleştirilmiş doğrusal modeller, temel bileşenler regresyonu (PCR) ve kısmi en küçük kareler (PLS) aracılığıyla boyut küçültme, regresyon ağaçları (artırılmış ağaçlar ve rastgele ormanlar dahil) ve sinir ağlarını içermektedir.

Çalışmanın sonuçları, makine öğreniminin beklenen varlık getirilerinin ampirik olarak anlaşılmasını geliştirme potansiyeline sahip olduğunu gösteriyor. Yazarlar, ağaçların ve sinir ağlarının, %0,33 ile %0,40 arasındaki aylık hisse seviyesi R^2 'leri ile getiri tahminini açık bir şekilde iyileştirdiğini bulmuşlardır. Ayrıca en başarılı tahmini yapan algoritmaların fiyat eğilimlerini, piyasada likidite ve oynaklık olduğunda da başarıyla buluyorlar. Makine öğrenimi tahminlerinden elde edilen ekonomik kazanımlar büyüktür ve makine öğrenimi getiri tahminlerinden yararlanan portföy stratejileri, 2,0'ın üzerinde yıllık Sharpe oranları kazandırmaktadır.

K-R Muller, AJ Smola, G Ratsch, B Scholkopf, J Kohlmorgen ve V Vapnik'in "Predicting Time Series with Support Vector Machines" adlı makalesinde yazarlar, zaman serisi tahmini için Destek Vektör Makineleri (SVM'ler) uygulamasını araştırıyorlar. Çalışma, SVM eğitimi için iki farklı maliyet işlevi kullanarak SVM'lerin performansını radyal tabanlı işlev ağlarıyla karşılaştırır: duyarsız kayıp ve Huber'in sağlam kayıp işlevi. Yazarlar, bu modellerde düzenlileştirme parametrelerinin seçimini tartışıyor ve iki uygulama sunuyorlar: gürültülü bir Mackey Glass denklemi ve Santa Fe rekabet seti D^{197} .

SVM'ler her iki uygulamada da mükemmel performans gösterdi. Santa Fe rekabet seti D durumunda, SVM yaklaşımı kıyaslamada en iyi bilinen sonucu önemli

¹⁹⁷ Müller, K-R., et al. "Predicting time series with support vector machines." *International conference on artificial neural networks*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1997.

ölçüde iyileştirdi. Yazarlar DVM'lerin başarısını, özellikle seyrek verilerle yani yüksek boyutlu bir uzayda sınırlı verilerle iyi çalışan doğal düzenleme özelliklerine bağlar.

Makale ayrıca farklı türde kayıp fonksiyonlarının kullanımını tartışır; radyal tabanlı fonksiyon ağlarının performansını uyarlamalı merkezler, varyanslar ve SVM'ler ile karşılaştırır. Yazarlar, Mackey Glass verileri için yüksek gürültü rejiminde SVM'ler için bir avantajla birlikte her iki yaklaşımın da benzer şekilde mükemmel performans gösterdiğini savunurlar. Yazarlar, uygun parametreleri belirlemeye yönelik mevcut yöntemin yetersiz ve hesaplama açısından yoğun olmasına rağmen sonuçların, özellikle yüksek boyutlu uzaylarda seyrek verilerle uğraşırken DVM'lerin zaman serisi tahmini için güçlü bir araç olduğunu gösterdiği sonucuna varıyorlar. Düzenleştirme parametrelerinin seçimini ve yöntemin hesaplama verimliliğini iyileştirmek için gelecekteki çalışmalar önerilmektedir.

Huang, Wei, Yoshiteru Nakamori, ve Shou-Yang Wang'ın "Forecasting stock market movement direction with support vector machine" makalesinde yazarlar, borsa hareketlerinin yönünü tahmin etmek için Destek Vektör Makinelerinin (SVM'ler) kullanımını araştırıyor. DVM'ler, karar fonksiyonunun kapasitesinin kontrolü, çekirdek fonksiyonlarının kullanımı ve çözümün seyrekliği ile karakterize edilen özel bir öğrenme algoritması türüdür. Yazar, NIKKEI 225 endeksinin haftalık hareket yönünü tahmin etmek için SVM'leri uygular ve performansını Lineer Diskriminant Analizi, Kuadratik Diskriminant Analizi ve Elman Geri Yayılma Sinir Ağları ile karşılaştırır¹⁹⁸.

Rapor; veri yoğunluğu, gürültü, durağan olmama, yapılandırılmamış doğası, yüksek derecede belirsizlik ve gizli ilişkiler ile karakterize edilen finansal piyasaların karmaşıklığını vurgulamaktadır. Yazar, benzersiz yapısal risk minimizasyon ilkesine sahip DVM'lerin aşırı uyum sorununa dirençli olduğunu ve yüksek bir genelleme performansı elde ettiğini savunuyor. DVM'nin çözümü, yerel minimumda takılıp kalabilen sinir ağları eğitiminin aksine her zaman benzersiz ve küresel olarak optimaldir. Deneysel sonuçlar, SVM'nin NIKKEI 225 endeksinin haftalık hareket yönünü tahmin etmede diğer sınıflandırma yöntemlerinden daha iyi performans

¹⁹⁸ Huang, Wei, Yoshiteru Nakamori, and Shou-Yang Wang. "Forecasting stock market movement direction with support vector machine." *Computers & operations research* 32.10 (2005): 2513-2522.

gösterdiğini göstermektedir. Ayrıca DVM'yi diğer sınıflandırma yöntemleriyle bütünleştiren ve tüm tahmin yöntemleri arasında en iyi performansı gösteren bir birleştirme modeli önermektedir.

Bu makale, DVM'lerin borsa hareketlerinin yönünü tahmin etmedeki etkinliğini göstererek literatüre katkıda bulunmaktadır. Finansal tahminde DVM'lerin uygulanmasına ilişkin değerli bilgiler sağlar ve geliştirilmiş tahmin performansı için SVM'yi diğer sınıflandırma yöntemleriyle bütünleştiren yeni bir birleştirme modeli sunar. Bu çalışmanın bulguları, finansal tahminciler ve tacirler için potansiyel olarak sermaye kazançlarına yol açan önemli etkilere sahiptir.

Boginski, Butenko ve Pardalos'un "Mining market data: A network approach" adlı makalesinde yazarlar, piyasa grafiği olarak adlandırılan borsa verilerinin bir ağ temsili tanıtıyorlar. Bu grafik, belirli bir zaman dilimindeki açılış fiyatları verilerine dayalı olarak hisse senedi çiftleri arasındaki çapraz korelasyonların hesaplanmasıyla oluşturulmuştur. Yazarlar, piyasa grafiğinin yapısal özelliklerinin zaman içindeki gelişimini incelemekte ve elde edilen sonuçların yorumlanmasına dayalı olarak borsa gelişiminin dinamiklerine ilişkin sonuçlar çıkarmaktadır¹⁹⁹.

Makale veri yoğunluğu, gürültü, durağan olmama, yapılandırılmamış veri, yüksek derecede belirsizlik ve gizli ilişkiler ile karakterize edilen finansal piyasaların karmaşıklığını vurgulamaktadır. Yazarlar borsa verilerinin ağ temsili, borsa verilerinin özetlenmesi ve görselleştirilmesi için yeni bir yol sağladığını ve bunun da kişinin piyasa davranışı hakkında faydalı bilgiler elde etmesine olanak sağladığını iddia etmektedir.

Yazarlar ayrıca farklı türde kayıp fonksiyonlarının kullanımını tartışıyor; radyal tabanlı fonksiyon ağlarının performansını uyarlamalı merkezler, varyanslar ve SVM'ler ile karşılaştırıyor. Mackey Glass verileri için yüksek gürültü rejiminde SVM'ler için bir avantajla birlikte her iki yaklaşımın da benzer şekilde iyi performans gösterdiğini bulmuşlardır.

¹⁹⁹ Boginski, Vladimir, Sergiy Butenko, and Panos M. Pardalos. "Mining market data: A network approach." *Computers & Operations Research* 33.11 (2006): 3171-3184.

Yazarlar uygun parametreleri belirlemeye yönelik mevcut yöntemin yetersiz ve hesaplama açısından yoğun olmasına rağmen sonuçların, DVM'lerin, özellikle yüksek boyutlu uzaylarda seyrek verilerle uğraşırken zaman serisi tahmini için güçlü bir araç olduğunu göstermektedir. Düzenleme parametrelerinin seçimini ve yöntemin hesaplama verimliliğini iyileştirmek için gelecekteki çalışmalar önerilmektedir.

Bu makale, mevcut modellerin gözden kaçırdığı önemli asimetrik etkileri yakalayabilen koşullu hisse senedi oynaklığı için yeni bir model sunarak literatüre katkıda bulunmaktadır. Ayrıca farklı uluslararası piyasalarda ve zaman dilimlerinde çeşitli volatilité modellerinin kapsamlı bir değerlendirmesini yaparak, finansal ekonometride gelecekteki araştırmalar ve pratik uygulamalar için değerli bilgiler sunar.

Alberto Fernández, Sergio Gómez'in "Portfolio selection using neural networks" adlı makalesinde, portföy seçimi problemiyle ilişkili verimli sınırın izini sürmek için yapay sinir ağlarına (NN) dayalı sezgisel bir yöntem uyguluyor. Yazar, kardinalite ve sınırlama kısıtlamalarını içeren standart Markowitz ortalama-varyans modelinin bir genellemesini ele alıyor. Bu kısıtlamalar, belirli sayıda farklı varlığa yatırım yapılmasını sağlar ve her bir varlığa yatırılacak sermaye miktarını sınırlar²⁰⁰.

Makale veri yoğunluğu, beyaz gürültü, durağan olmama, yapılandırılmamış doğası, yüksek derecede belirsizlik ve gizli ilişkiler ile karakterize edilen finansal piyasaların karmaşıklığını vurgulamaktadır. Yazar işlevsel esnekliği ile YSA modelinin, geçmiş getiri yenilikleri ile gelecekteki oynaklık arasındaki doğrusal olmayan ilişkiyi daha iyi yakalayabileceğini savunuyor.

Yazar, YSA buluşsal yöntemiyle elde edilen deneysel sonuçları sunar ve bunları önceki üç buluşsal yöntemle elde edilen sonuçlarla karşılaştırır. Portföy seçimi problemi, standart Markowitz ortalama-varyans modeli dikkate alındığında ikinci dereceden programlama problemleri ailesinden bir örnektir. Ancak bu model kardinalite ve sınırlama kısıtlamalarını içerecek şekilde geliştirilirse, o zaman portföy seçimi problemi karma bir ikinci dereceden ve tamsayı programlama problemi haline gelir.

²⁰⁰ Fernández, Alberto, and Sergio Gómez. "Portfolio selection using neural networks." *Computers & operations research* 34.4 (2007): 1177-1191.

Bu makale, portföy seçimi için mevcut modellerin gözden kaçırdığı önemli asimetrik etkileri yakalayabilen yeni bir model sunarak literatüre katkıda bulunmaktadır. Ayrıca farklı uluslararası pazarlar ve zaman dilimlerinde çeşitli portföy seçim modellerinin kapsamlı bir değerlendirmesini sunarak, finansal ekonometride gelecekteki araştırmalar ve pratik uygulamalar için değerli bilgiler sunar. Bu çalışmanın bulguları, finansal tahminciler ve tacirler için potansiyel olarak sermaye kazançlarına yol açan önemli etkilere sahiptir.

Robert P. Schumaker ve Hsinchun Chen tarafından 2009'da yayınlanan "Textual Analysis of Stock Market Prediction Using Breaking Financial News: The AZFinText System" başlıklı araştırma makalesi, finans haberlerine uygulanan makine öğrenimi tekniklerini kullanarak borsa hareketlerini tahmin etmeye yönelik yenilikçi bir yaklaşım sunuyor. Çalışma, üç farklı metin temsili tahmin gücünü araştırıyor: Torba Sözcükler, İsim Öbekleri ve Adlandırılmış Varlıklar²⁰¹.

Yazarlar, beş haftalık bir süre boyunca S&P 500 hisseleriyle ilgili 9.211 finansal haber makalesini ve 10.259.042 hisse senedi fiyatını analiz etti. Amaç, bir haber makalesi yayımlandıktan yirmi dakika sonra ayrı bir hisse senedi fiyatı tahmin etmektir. Araştırmacılar, farklı hisse senedine özgü değişkenler içeren ayrık sayısal tahmin ve modeller için özel olarak tasarlanmış bir Destek Vektör Makinesi (SVM) türevi kullandılar.

Çalışmanın bulguları hem haber makalesi terimlerini hem de haber makalesinin yayımlandığı tarihteki hisse senedi fiyatını içeren modelin, gelecekteki gerçek hisse senedi fiyatına yakınlık (MSE 0.04261) açısından en iyi performansı gösterdiğini ortaya koydu; gelecekteki fiyatla aynı fiyat hareketi yönü (%57,1 yön doğruluğu) ve simüle edilmiş bir ticaret motoru kullanılarak en yüksek getiriyi (%2,06 getiri) hesaplamaya çalıştılar.

Çalışma ayrıca Özel İsim şemasının, üç ölçütün tamamında da Kelime Çantası'nın fiili standardından daha iyi performans gösterdiğini buldu. Bu araştırma borsa hareketlerini tahmin etmede makine öğrenimi ve metinsel analizin potansiyelini

²⁰¹ Schumaker, Robert P., and Hsinchun Chen. "Textual analysis of stock market prediction using breaking financial news: The AZFin text system." *ACM Transactions on Information Systems (TOIS)* 27.2 (2009): 1-19.

göstererek, yatırımcılar ve finansal analistler için değerli bilgiler sağlayarak alana katkıda bulunuyor.

Johan Bollen, Huina Mao ve Xiao-Jun Zeng'in yazdığı "Twitter mood predicts the stock market" adlı makalesinde yazarlar büyük ölçekli Twitter akışlarında ifade edildiği şekliyle halkın ruh halleri ile Dow Jones Endüstriyel Ortalama'daki (DJIA) dalgalanmalar arasındaki ilişkiyi araştırıyorlar. Yazarlar, Etkin Piyasa Hipotezi (EMH) gibi geleneksel piyasa teorilerine meydan okuyan bir kavram olan halkın duyarlılığının borsa hareketlerini tahmin etmede önemli bir faktör olabileceğini öne sürüyorlar²⁰².

Yazarlar, günlük Twitter paylaşımlarının metin içeriğini analiz etmek için iki ruh hali izleme aracı, Opinion Finder ve Google-Mood Durumları Profili kullanıyor. Bu araçlar, zaman içindeki öngörü güçlerini değerlendirmek için daha sonra DJIA ile ilişkilendirilen ruh hali zaman serileri oluşturur. Yazarlar, genel ruh hali durumlarının DJIA kapanış değerlerindeki değişiklikleri tahmin ettiği hipotezini test etmek için bir Granger nedensellik analizi ve Kendi Kendini Organize Eden Bulanık Sinir Ağı kullanır. Çalışmanın sonuçları, DJIA tahminlerinin doğruluğunun belirli genel ruh hali boyutlarının dahil edilmesiyle önemli ölçüde iyileştirilebileceğini göstermektedir. Yazarlar, DJIA'nın kapanış değerlerindeki günlük yukarı ve aşağı değişimleri tahmin etmede %86,7'lik bir doğruluk ve Ortalama Yüzde Hatasında (MAPE) %6'dan fazla bir azalma olduğunu bildiriyor.

Bu makale, borsa hareketlerini tahmin etmede sosyal medya duyarlılık analizinin potansiyelini göstererek literatüre katkıda bulunmaktadır. Bulgular Twitter aracılığıyla ifade edilen toplumların kolektif ruh halinin, borsa yatırımları gibi ekonomik kararlar da dahil olmak üzere toplu karar alma süreçlerini önemli ölçüde etkileyebileceğini gösteriyor.

Michael Hagenau, Michael Liebmann ve Dirk Neumann'ın "Automated news reading: Stock price prediction based on financial news using context-capturing features" adlı makalesi, otomatik metin madenciliğinin finansal haberlere dayalı hisse senedi fiyatlarını tahmin etmedeki potansiyelini araştırıyor. Yazarlar bu görevdeki

²⁰² Bollen, Johan, Huina Mao, and Xiaojun Zeng. "Twitter mood predicts the stock market." *Journal of computational science* 2.1 (2011): 1-8.

önceki girişimlerin, tahmin etme olasılığına yakın tahmin doğrulukları sağladığını ve daha karmaşık yöntemlere ihtiyaç olduğunu öne sürdüğünü savunuyorlar²⁰³.

Yazarlar, metni temsil etmek için daha anlamlı özellikler kullanan ve özellik seçim sürecinin bir parçası olarak piyasa geri bildirimlerini kullanan gelişmiş bir metin madenciliği yaklaşımı önermektedir. Önerilen yöntem, bağlamı ve anlamı daha iyi yakalamak için iki kelimelik bir metin temsil şemasının ve en alakalı özellikleri seçmek için piyasa geri bildirimini kullanan bir özellik seçim sürecinin kullanılmasını içermektedir.

Yazarlar, yaklaşımlarını bir kurumsal açıklama veri kümesi üzerinde test ediyor ve mevcut yaklaşımlarla karşılaştırıyor. Sonuçlar, yöntemlerinin sınıflandırma doğruluklarını önemli ölçüde geliştirdiğini ve pratikte uygulandığında karlı olduğunu göstermektedir. Yazarlar, metodolojilerinin metin bilgisi ve karşılık gelen etki verileri sağlayan herhangi bir başka uygulama alanına aktarılabilceğini öne sürüyorlar.

Bu makale, hisse senedi fiyatlarını tahmin etmede gelişmiş metin madenciliği yöntemlerinin potansiyelini göstererek literatüre katkıda bulunmaktadır. Bulgular, bağlam yakalama özellikleri ve geri bildirimle dayalı özellik seçimi kombinasyonunun tahmin doğruluklarını önemli ölçüde iyileştirebileceğini ve yatırımcılar finansal analistler ile finansal piyasa tahmini alanındaki araştırmacılar için değerli bilgiler sağlayabileceğini göstermektedir.

Yazarlar Xiaodong Li , Haoran Xie , Li Chen , Jianping Wang , Xiaotie Deng "News impact on stock price return via sentiment analysis" adlı makalesinde, finans haber makalelerinin hisse senedi fiyatı getirileri üzerindeki etkisini araştırıyor. Yazarlar önceki çalışmaların, kelime istatistiksel kalıpları ve hisse senedi fiyat hareketleri arasındaki gizli ilişkiyi analiz eden bir kelime-çantası alanında haber parçalarını modellediğini ancak haberlerin duyarlılığının kelimedenden haritalama

²⁰³ Hagenau, Michael, Michael Liebmann, and Dirk Neumann. "Automated news reading: Stock price prediction based on financial news using context-capturing features." *Decision support systems* 55.3 (2013): 685-697.

zincirinde çok önemli bir halka olduğunu savunuyor. Fiyat hareketlerine ilişkin kalıplar, büyük ölçüde göz ardı edilmiştir²⁰⁴.

Yazarlar, duyarlılık analizini içeren genel bir hisse senedi fiyatı tahmin çerçevesi önermektedir. Yazarlar, üzerine metinsel haber makalelerinin nicel olarak ölçüldüğü ve yansıtıldığı bir duygu alanı oluşturmak için Harvard psikolojik sözlüğünü ve Loughran-McDonald finansal duyarlılık sözlüğünü kullanıyor. Yazar, modellerin tahmin doğruluğunu değerlendirir ve performanslarını farklı pazar sınıflandırma düzeylerinde ampirik olarak karşılaştırır.

Ampirik sonuçlar, duyarlılık analizine sahip modellerin hem doğrulama hem de bağımsız test setlerinde kelime çantası modelinden daha iyi performans gösterdiğini göstermektedir. Bununla birlikte duygu polaritesini kullanan modeller, yararlı tahminler sağlamaz. İki farklı duygu sözlüğü kullanan modeller arasında küçük bir fark vardır.

Bu makale, hisse senedi fiyat getirilerini tahmin etmede duyarlılık analizinin potansiyelini göstererek literatüre katkıda bulunmaktadır. Bulgular; duyarlılık analizinin tahmin çerçevesine entegrasyonunun tahmin doğruluklarını önemli ölçüde artırabileceğini ve yatırımcılar, finansal analistler ve finansal piyasa tahmini alanındaki araştırmacılar için değerli içgörüler sağlayabileceğini göstermektedir.

Jigar Patel, Sahil Shah, Priyank Thakkar ve K Kotecha'nın "Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques" makalesi, Hindistan borsaları için hisse senedi ve hisse senedi fiyat endeksinin hareket yönünü tahmin etme problemini ele alıyor. Yazar, dört tahmin modelini karşılaştırıyor: Yapay Sinir Ağı (YSA), Destek Vektör Makinesi (SVM), rastgele orman ve naive-Bayes, bu modellere giriş için iki yaklaşım kullanıyorlar²⁰⁵.

Girdi verileri için ilk yaklaşım, hisse senedi alım satım verilerini (açılış, yüksek, düşük ve kapanış fiyatları) kullanarak on teknik parametrenin hesaplanmasını

²⁰⁴ Li, Xiaodong, et al. "News impact on stock price return via sentiment analysis." *Knowledge-Based Systems* 69 (2014): 14-23.

²⁰⁵ Patel, Jigar, et al. "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques." *Expert systems with applications* 42.1 (2015): 259-268.

içerirken, ikinci yaklaşım bu teknik parametrelerin trend belirleyici veriler olarak temsil edilmesine odaklanır. Yazar, RelianceIndustries ve Infosys Ltd. adlı iki hisse senedinin ve CNX Nifty ve S&P Bombay (BSE) Sensex Borsası olmak üzere iki hisse senedi fiyat endeksinin 2003'ten 2012'ye kadar 10 yıllık tarihsel verilerini kullanarak iki girdi yaklaşımının her biri için tahmin modellerinin doğruluğunu değerlendirmektedir. Deneysel sonuçlar, on teknik parametrenin sürekli değerler olarak temsil edildiği girdi verilerinin ilk yaklaşımı için rastgele ormanın genel performansta diğer üç tahmin modelinden daha iyi performans gösterdiğini göstermektedir. Deneysel sonuçlar ayrıca tüm tahmin modellerinin performansının, bu teknik parametreler trend deterministik verileri olarak temsil edildiğinde iyileştiğini göstermektedir.

Chalvatzis ve Hristu-Varsakelis ‘‘ High-performance stock index trading via neural networks and trees’’ adlı makalelerinde, karlılık ile tahmin doğruluğunu birbirine bağlayan yeni bir otomatik ticaret yapısını tanımaktadır. Tahmin modellerini ticaret stratejilerinden ayıran geleneksel yöntemlerin aksine, bu çalışma, bir modelin verimliliği ile eşleştirilmiş ticaret stratejisi arasındaki karmaşık ilişkiden yararlanarak bunları bir arada optimize ediyor. Yenilikçi yaklaşımları yalnızca fiyat hareketi tahminlerine göre hareket etmiyor; bu tahminlerin spesifik dağılımını daha derinlemesine inceliyor. Bu dağılımdaki bir tahminin konumunun, bir ticaretin beklenen karlılığı hakkında çok önemli bilgiler sağlayabileceğini savunuyorlar. Ağaç tabanlı modeller ve uzun kısa süreli bellek (LSTM) sinir ağını kullanarak, bu yaklaşımı 2010 ile 2019 arasındaki büyük hisse senedi endekslerinde test ettiler. Modelleri, S&P 500'de %350'ye ve NASDAQ'ta %497 varan yüksek kümülatif getiri elde ederek kıyaslamaları gölgede bıraktı²⁰⁶.

Rodolfo C. Cavalcante , Rodrigo C. Brasileiro , Victor L.F. Souza , Jarley P. Nobrega , Adriano L.I. Oliveira'nın "Computational Intelligence and Financial Markets: A Survey and Future Directions" adlı makalesinde. Yazarlar, finansal piyasa sorunlarına uygulanan hesaplamalı zeka tekniklerinin kapsamlı bir incelemesini

²⁰⁶ Chalvatzis, Chariton, and Dimitrios Hristu-Varsakelis. "High-performance stock index trading via neural networks and trees." *Applied Soft Computing* 96 (2020): 106567.

sunuyor. Yazarlar, dünya ekonomisinde finansal faaliyetlerin önemini ve kaliteli bilgi ile karar verme hızının yatırımcı başarısındaki rolünü vurgulamaktadır²⁰⁷.

Yazarlar finansal piyasa davranışlarını analiz etmek ve tahmin etmek için iki yaygın yaklaşımı tartışıyor: temel analiz ve teknik analiz. Birincisi piyasa hareketlerini etkileyen ekonomik faktörleri incelerken, ikincisi bir finansal varlığın tarihsel davranışını bir zaman serisi olarak modeller.

Makale finansal verilerin ön işlenmesi ve kümelenmesi, gelecekteki piyasa hareketlerinin tahmin edilmesi ve finansal bilgilerin madenciliği dahil olmak üzere finansal piyasa sorunlarını çözmek için uygulanan çeşitli makine öğrenimi yöntemlerini incelemektedir. Yazarlar ayrıca bu araştırma alanındaki zorlukları ve açık sorunları tartışarak gelecekteki araştırmalar için bir temel sağlar.

Bu makale, finansal piyasalara uygulanan hesaplamalı zeka tekniklerinin kapsamlı bir incelemesini sunarak literatüre katkıda bulunmaktadır. Bulgular, makine öğrenimi yöntemlerinin çeşitli finansal piyasa sorunlarını etkili bir şekilde çözebileceğini ve finansal piyasa tahmini alanındaki araştırmacılara değerli bilgiler sağlayabileceğini gösteriyor.

Eunsuk Chong , Chulwoo Han , Frank C. Park'ın "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies"adlı makalesinde yazarlar, borsa analizi ve tahmini için derin öğrenme ağlarının kullanımına ilişkin kapsamlı bir analiz sunuyor. Yazarlar, derin öğrenme ağlarının verilerden soyut özellikler çıkarma ve gizli doğrusal olmayan ilişkileri belirleme potansiyelini vurgulayarak onları mevcut modellere ve yaklaşımlara bir alternatif olarak özellikle çekici kılıyor²⁰⁸.

Yazarlar, standart bir derin sinir ağına giriş verileri olarak hisse senedi getirilerini kullanıyor ve denetimsiz üç özellik çıkarma yönteminin (temel bileşen analizi, otomatik kodlayıcı ve kısıtlı Boltzmann makinesi) ağı gelecekteki piyasa

²⁰⁷ Cavalcante, Rodolfo C., et al. "Computational intelligence and financial markets: A survey and future directions." *Expert Systems with Applications* 55 (2016): 194-211.

²⁰⁸ Chong, Eunsuk, Chulwoo Han, and Frank C. Park. "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies." *Expert Systems with Applications* 83 (2017): 187-205.

davranışını tahmin etme genel yeteneği üzerindeki etkilerini inceliyor. Ağın performansı, Kore KOSPI borsasından alınan yüksek frekanslı gün içi veriler için standart bir otoregresif model ve YSA modeliyle karşılaştırıldı.

Ampirik analiz, derin öğrenme ağlarının tahmini performansının karışık olduğunu ve hem çevresel hem de kullanıcı tarafından belirlenen çok çeşitli faktörlere bağlı olduğunu göstermektedir. Bununla birlikte derin özellik öğrenmenin, bir otoregresif modeli tamamlamak için kullanıldığında özellikle etkili olduğu ve hisse senedi getiri tahminini önemli ölçüde iyileştirdiği ortaya konmuştur.

Bu makale, derinlemesine özellik öğrenmeye dayalı hisse senedi getirisi tahmin modellerinin nasıl oluşturulabileceğini ve değerlendirilebileceğini göstererek literatüre katkıda bulunmaktadır. Bulgular derin öğrenme ağlarının, uygun veri temsili yöntemleriyle birleştirildiğinde gelecekteki piyasa davranışının tahminini önemli ölçüde iyileştirebileceğini ve finansal piyasa tahmini alanındaki araştırmacılara değerli bilgiler sağlayabileceğini göstermektedir.

Thomas Fischer ve Christopher Krauss'ın "Deep learning with long short-term memory networks for financial market predictions" adlı makalesinde yazarlar finansal piyasa tahmini için uzun kısa süreli bellek (LSTM) ağlarının kullanımının kapsamlı bir analizini sunar. Yazarlar, LSTM ağlarının verilerden soyut özellikler çıkarma ve gizli doğrusal olmayan ilişkileri belirleme potansiyelini vurgulayarak onları mevcut modellere ve yaklaşımlara bir alternatif olarak özellikle çekici kılıyor²⁰⁹.

Yazar, standart bir derin sinir ağına giriş verileri olarak hisse senedi getirilerini kullanıyor ve denetimsiz üç özellik çıkarma yönteminin (temel bileşen analizi, otomatik kodlayıcı ve kısıtlı Boltzmann makinesi) ağın gelecekteki piyasa davranışını tahmin etme genel yeteneği üzerindeki etkilerini inceliyor. Ağın performansı, Kore KOSPI borsasından alınan yüksek frekanslı gün içi veriler için standart bir otoregresif model ve YSA modeliyle karşılaştırıldı.

²⁰⁹ Fischer, Thomas, and Christopher Krauss. "Deep learning with long short-term memory networks for financial market predictions." *European journal of operational research* 270.2 (2018): 654-669.

Ampirik analiz, derin öğrenme ağlarının tahmini performansının karışık olduğunu ve hem çevresel hem de kullanıcı tarafından belirlenen çok çeşitli faktörlere bağlı olduğunu göstermektedir. Bununla birlikte derin özellik öğrenmenin, bir otoregresif modeli tamamlamak için kullanıldığında özellikle etkili olduğu ve hisse senedi getiri tahminini önemli ölçüde iyileştirdiği bulunmuştur.

Bu makale, derinlemesine özellik öğrenmeye dayalı hisse senedi getirisi tahmin modellerinin nasıl oluşturulabileceğini ve değerlendirilebileceğini göstererek literatüre katkıda bulunmaktadır. Bulgular LSTM ağlarının, uygun veri temsil yöntemleriyle birleştirildiğinde finansal piyasa tahmini alanındaki araştırmacılar için değerli bilgiler sağlayarak gelecekteki piyasa davranışının tahminini önemli ölçüde iyileştirebileceğini göstermektedir.

Long, Wen, Zhichen Lu, ve Lingxiao Cui'nin "Deep learning-based feature engineering for stock price movement prediction" makalesi, finansal zaman serisi örneklerinde özellik çıkarımı ve fiyat hareketi tahmini için özel olarak tasarlanmış çoklu filtreli sinir ağı (MFNN) adlı yeni bir uçtan uca model sunar. Yazarlar, derin öğrenme ağlarının verilerden soyut özellikler çıkarma ve gizli doğrusal olmayan ilişkileri belirleme potansiyelini vurgulayarak onları mevcut modellere ve yaklaşımlara bir alternatif olarak özellikle çekici kılıyor²¹⁰.

Yazarlar, standart bir derin sinir ağına giriş verileri olarak hisse senedi getirilerini kullanıyor ve denetimsiz üç özellik çıkarma yönteminin (temel bileşen analizi, otomatik kodlayıcı ve kısıtlı Boltzmann makinesi) ağın gelecekteki piyasa davranışını tahmin etme genel yeteneği üzerindeki etkilerini inceliyor. Ağın performansı, Çin pazar endeksinden (CSI 300) alınan yüksek frekanslı gün içi veriler için standart bir otoregresif model ve YSA modeliyle karşılaştırılır.

Ampirik analiz, derin öğrenme ağlarının tahmini performansının karışık olduğunu ve hem çevresel hem de kullanıcı tarafından belirlenen çok çeşitli faktörlere bağlı olduğunu göstermektedir. Bununla birlikte, derin özellik öğrenmenin, bir

²¹⁰ Long, Wen, Zhichen Lu, and Lingxiao Cui. "Deep learning-based feature engineering for stock price movement prediction." *Knowledge-Based Systems* 164 (2019): 163-173.

otoregresif modeli tamamlamak için kullanıldığında özellikle etkili olduğu ve hisse senedi getiri tahminini önemli ölçüde iyileştirdiği bulunmuştur.

Bu makale, derinlemesine özellik öğrenmeye dayalı hisse senedi getirisi tahmin modellerinin nasıl oluşturulabileceğini ve değerlendirilebileceğini göstererek literatüre katkıda bulunmaktadır. Bulgular MFNN ağlarının, uygun veri temsil yöntemleriyle birleştirildiğinde gelecekteki piyasa davranışının tahminini önemli ölçüde iyileştirebileceğini ve finansal piyasa tahmini alanındaki araştırmacılar için değerli bilgiler sağlayabileceğini göstermektedir.

Gu, Kelly ve Xiu'nun "Empirical Asset Pricing via Machine Learning" çalışmasında yazarlar, varlık risk primlerini ölçmeye yönelik ampirik varlık fiyatlandırma sorunu için makine öğrenimi yöntemlerinin karşılaştırmalı bir analizini yürütürler. Yazarlar, yatırımcıların makine öğrenimi tahminlerini kullanarak önemli ekonomik kazançlar elde edebildiklerini ve bazı durumlarda literatürdeki önde gelen regresyona dayalı stratejilerin performansını ikiye katlayabildiklerini gösteriyor. Tanımlanan en iyi performans gösteren yöntemler, diğer yöntemlerle kaçırılan doğrusal olmayan tahmin edici etkileşimlere izin verilmesine atfedilen tahmine dayalı kazançlarıyla ağaçlar ve sinir ağılarıydı. Çalışma ayrıca tüm yöntemlerin momentum, likidite ve oynaklık üzerindeki varyasyonları içeren aynı baskın tahmin sinyalleri üzerinde anlaştığını da buldular²¹¹.

Yazarların birincil katkıları iki yönlüdür. İlk olarak, toplam pazarın ve bireysel hisse senetlerinin risk primlerini ölçmede makine öğrenimi yöntemlerinin tahmini doğruluğu için yeni bir dizi kıyaslama sağlarlar. İkinci olarak, makine öğrenimi tahminlerini kullanarak yatırımcılara büyük ekonomik kazançlar gösteriyorlar. Örneğin, S&P 500'ü nöral ağ tahminleriyle çarpan bir portföy stratejisi, satın al ve tut yatırımcısının 0,51 Sharpe oranına karşı 0,77'lik yıllık örneklem dışı Sharpe oranına sahiptir.

Yazarlar ayrıca ampirik varlık fiyatlandırma literatürünü makine öğrenimi alanıyla da sentezliyor. Potansiyel öngörücü değişkenlerin çok daha geniş bir listesini

²¹¹ Gu, Shihao, Bryan Kelly, and Dacheng Xiu. "Empirical asset pricing via machine learning." *The Review of Financial Studies* 33.5 (2020): 2223-2273.

ve işlevsel formun daha zengin özelliklerini barındırma becerisiyle makine öğreniminin risk primi ölçümünün sınırlarını zorlayabileceğini savunuyorlar. Yazarlar ayrıca "makine öğrenimi" tanımının genellikle bağlama özgü olduğunu ve bu terimi model seçimi ve aşırı uyumun azaltılması için düzenleme yöntemleriyle birleştirilmiş istatistiksel tahmin için yüksek boyutlu modellerin çeşitli bir koleksiyonunu tanımlamak için kullandıklarını belirtiyorlar.

Çalışma, makine öğreniminin temelde bir tahmin sorunu olan risk primi ölçümünü iyileştirmek için büyük bir potansiyele sahip olduğu sonucuna varıyor. Ancak yazarlar, bu gelişmiş tahminlerin yalnızca ölçümler olduğu ve bize ekonomik mekanizmalar veya dengeler hakkında bilgi vermediği konusunda uyarıyorlar. Amaç ekonomik mekanizmaları anlamak olduğunda, makine öğreniminin hala yararlı olabileceğini ancak ekonomistin tahmin problemine yapı eklemesini ve bu yapıya tabi bir makine öğrenimi algoritmasının nasıl tanıtılacağına karar vermesini gerektirdiğini öne sürüyorlar.

2021'de PeerJ Comput Sci'de yayınlanan Pooja Mehta, Sharnil Pandya ve Ketan Kotecha'nın "Harvesting social media sentiment analysis to enhance stock market prediction using deep learning" başlıklı makalesi, hisse senedi piyasası tahminine yeni bir yaklaşım sunuyor. Yazarlar internetin, özellikle sosyal medya platformlarının, borsa hareketlerini tahmin etmek için kullanılabilecek zengin bir kamu duyarlılığı kaynağı olduğunu savunuyorlar²¹².

Yazarlar, diğer parametrelerin yanı sıra kamu duyarlılığını da dikkate alan bir hisse senedi fiyatı tahmin aracı önermektedir. Bir şirketin hisse senedi fiyatları ile halkın şirket hakkındaki düşünceleri arasındaki ilişkiyi analiz etmek için Destek Vektör Makinesi, MNB sınıflandırıcı, doğrusal regresyon, Naïve Bayes ve Uzun Kısa Süreli Bellek (LSTM) dahil olmak üzere makine öğrenimi ve derin öğrenme yöntemleri kullanırlar. Çalışmanın metodolojisi; çeşitli sosyal medya kaynaklarından veri toplama, veri ön işleme, haberlerin duygu analizi, çeşitli makine öğrenimi yaklaşımlarının uygulanması ve derin öğrenme modeli kullanılarak borsa tahmini içermektedir.

²¹² Mehta, Pooja, Sharnil Pandya, and Ketan Kotecha. "Harvesting social media sentiment analysis to enhance stock market prediction using deep learning." *PeerJ Computer Science* 7 (2021): e476.

Yazarların yaklaşımı, sosyal ağ sitelerinin borsa trendlerini etkileyebilecek güncel olaylar hakkında halkın görüşlerini yansıttığı önermesine dayanmaktadır. Finansal haberlerin hisse senedi trend fiyatlarının getirisini etkileyebileceğini ve veri madenciliği tekniklerinin borsadaki dalgalanmaları ele alabileceğini savunuyorlar. Yazarların analizleri, önerdikleri metodolojinin başarısını doğrulayarak sosyal medya duyarlılık analizinin borsa tahminini artırabileceğini öne sürüyor.

Çalışma sosyal medya analitiği, duygu analizi ve finansal piyasa tahmininin kesişimine ilişkin büyüyen literatüre katkıda bulunuyor. Tahmine dayalı analitik için sosyal medya verilerinin gücünden yararlanma konusunda derin öğrenme tekniklerinin potansiyelinin altını çizmektedir. Yazarların metodolojisi ve bulguları, özellikle büyük veri ve yapay zeka çağında borsa tahmininde gelecekteki araştırma ve uygulamaları bilgilendirebilir.

2005, W. Huang, Y. Nakamori ve S.-Y. Wang: "Forecasting stock market movement direction with support vector machine", başlıklı makalelerinde yazarlar, borsa hareketlerinin yönünü tahmin etmek için bir tür makine öğrenme modeli olan Destek Vektör Makinelerini (SVM'ler) uyguladılar²¹³.

Bu makale, finansal hareket yönünü tahmin etmek için benzersiz bir öğrenme algoritması olan Destek Vektör Makinesi'nin (SVM) kullanımına odaklanmaktadır. SVM'nin tahmin potansiyelini, NIKKEI 225 Endeksi'nin haftalık hareket yönünü inceleyerek araştırır. SVM'nin etkinliğini değerlendirmek için çalışma DVM'yi Doğrusal Diskriminant Analizi, Kuadratik Diskriminant Analizi ve Elman Geri Yayılım Sinir Ağları gibi diğer sınıflandırma yöntemleriyle karşılaştırmaktadır.

Makale, Tokyo Menkul Kıymetler Borsası'nda işlem gören 225 yüksek sermayeli hisse senedinden oluşan Nihon Keizai Shinbun Inc. tarafından hesaplanan önemli bir endeks olan NIKKEI 225 Endeksi'ndeki haftalık değişikliklerin ampirik bir analizini kullanmaktadır. Bu endeks Japon endüstrilerinin geniş bir kesitini yansıtır ve küresel olarak işlem görür. Hareket yönünü doğru bir şekilde tahmin etme yeteneği,

²¹³ Huang, Wei, Yoshiteru Nakamori, and Shou-Yang Wang. "Forecasting stock market movement direction with support vector machine." *Computers & operations research* 32.10 (2005): 2513-2522.

araştırmacılar, uygulayıcılar, yatırımcılar, spekülâtorler ve arbitrajcılar için büyük önem taşımaktadır.

Tahmin modelleri örnek içi veriler kullanılarak tahmin edilmektedir ve doğrulanır. Örneklem dışı verilere dayanan ampirik bir değerlendirme, model tahmini seçim sürecini izler. Çalışma modellerin göreceli performansını ölçmek için isabet oranını kullanır. SVM'nin amacı, ampirik riski en aza indirmeye çalışan önceki tekniklerden farklı olarak, genelleme hatasının bir üst sınırını en aza indirmek ve böylece aşırı uyum problemini azaltmaktır.

Çalışma, SVM'nin tüm bireysel tahmin yöntemleri arasında en yüksek tahmin doğruluğunu gösterdiği sonucuna varmıştır. Ayrıca SVM'nin diğer tahmin yöntemleriyle entegrasyonunun genel tahmin performansını iyileştirdiğini vurgulamaktadır. Bu nedenle makale SVM'yi diğer sınıflandırma yöntemleriyle bütünleştiren, her yöntemin güçlü yönlerinin diğerinin zayıf yönlerini dengelemesini sağlayan ve sistematik olarak etkili bir modelle sonuçlanan birleşik bir model önermektedir.

2006, V. Boginski, S. Butenko ve P. M. Pardalos: research "Mining market data: A network approach" adlı araştırmaları, öngörücü amaçlar için piyasa verilerinden bilgi çıkarmak için ağ tabanlı bir yaklaşımı nasıl kullandıklarını tartışmaktadırlar²¹⁴.

Bu makalenin yazarları, sürekli artan karmaşıklığı ve büyük miktarda verisi ile işaretlenen ABD borsasından gelen verileri verimli bir şekilde özetleme ve görselleştirme görevini üstlenmektedir. Hisse senedi fiyatlarını yansıtan geleneksel grafikler yerine, fiyat dalgalanmalarının çapraz korelasyonlarını temsil eden bir piyasa grafiği oluşturan ve böylece borsanın yapısı hakkında değerli bilgiler sağlayan bir ağ yaklaşımı kullanırlar.

Metodoloji, köşelerin hisse senetlerini temsil ettiği ve kenarların aralarındaki korelasyonları temsil ettiği bir piyasa grafiği oluşturmayı içermektedir. Korelasyon belirli bir dönemdeki hisse senedi fiyatlarına göre hesaplanır. Korelasyonları belirli bir

²¹⁴ Boginski, Vladimir, Sergiy Butenko, and Panos M. Pardalos. "Mining market data: A network approach." *Computers & Operations Research* 33.11 (2006): 3171-3184.

eşığı aşarsa, zaman içinde benzer şekilde davrandıklarını gösteren iki hisse senedi arasında bir kenar çizilir. Bu yaklaşım, pazarın dinamiklerini ve birbirine bağlılığını ortaya çıkarmayı amaçlamaktadır.

Yazarlar daha önce 2000-2002 yıllarında 500 işlem gününden elde edilen verileri kullanarak piyasa grafiğini araştırmışlar ve grafiğin bir güç yasası modelini izlediğini bulmuşlardır. Ayrıca piyasanın bu korelasyona dayalı özelliklerini, piyasa grafiğinin kombinatorial özelliklerine bağlarlar. Bu makalenin temel amacı, piyasa grafiğinin yapısal özelliklerinde zaman içinde meydana gelen değişiklikleri araştırmak ve böylece borsadaki eğilimleri ortaya çıkarmaktır.

Çalışma, 1998-2002 yılları arasındaki 1000 işlem günü dönemini dikkate almakta ve bu dönemdeki on bir 500 günlük vardiyayı analiz etmektedir. Sonuçları piyasa grafiğinin güç yasası yapısının dikkate alınan aralıklarda istikrarlı olduğunu göstermektedir. Bu ağ yaklaşımı, borsanın iç yapısına yeni bir bakış açısı getirerek dinamikleri hakkında yeni bir anlayış sunar.

2007, A. Fernández ve S. Gómez: "Portfolio selection using neural networks" çalışması, sinir ağlarının portföy seçim kararlarını yönlendirmek için nasıl kullanılabileceğini tanıtmaktadır²¹⁵.

Bu çalışma, özellikle Hopfield ağına odaklanarak yapay sinir ağlarına (NN) dayanan sezgisel bir yöntem uygulayarak portföy seçim problemine yeni bir yaklaşım getirmektedir. Yazarlar, Markowitz'in portföy yönetiminde pratik uygulama için gerekli olan kardinalite ve sınırlayıcı kısıtlamaları içeren ortalama-varyans modelinin genelleştirilmiş bir versiyonu olan portföy seçim modeli için verimli sınırın izini sürmek için çalışıyorlar.

Portföy seçimi problemi, riski en aza indirmek ve getirileri en üst düzeye çıkarmak için çeşitli varlıklar arasında yatırımın optimal dağılımına odaklanmaktadır. Bu çalışmada uygulanan genel model, kardinalite kısıtlamalarını belirli sayıda farklı varlığa yatırımın sağlanmasını ve her bir varlığa yatırılan sermayeyi sınırlayan sınırlama

²¹⁵ Fernández, Alberto, and Sergio Gómez. "Portfolio selection using neural networks." *Computers & operations research* 34.4 (2007): 1177-1191.

kısıtlamalarını içermektedir. Standart ortalama-varyans modeli, bu kısıtlamaları içerecek şekilde genişletilir ve bu da sorunu karışık bir ikinci dereceden ve tamsayı programlama problemi haline getirir.

Çalışma, sorunu çözmek için Hopfield ağı olarak bilinen bir sinir ağı modeli kullanıyor. Kombinatoryal optimizasyon problemleri için Hopfield ağlarını kullanmak yaygın olsa da araştırmacılar portföy seçim problemindeki objektif fonksiyonun biçimini ele alma yeteneğinden yararlandılar. Sorun, Hopfield ağının en aza indirmeye çalıştığı bir enerji fonksiyonuna dönüştürülür.

Yazarlar, yaklaşımlarını beş büyük borsa endeksinden karşılaştırma veri setlerini kullanarak test ettiler. Sonuçlar daha önce belirlenmiş üç sezgisel yöntem kullanılarak elde edilenlerle karşılaştırılmıştır. Sinir ağı modellerini, özellikle de Hopfield ağını çoklu kısıtlamalarla karmaşık portföy seçim problemlerini optimize etmek için kullanma potansiyelini göstermektedir.

2008, C. Huang, D. Yang ve Y. Chuang: "Application of wrapper approach and composite classifier to the stock trend prediction", başlıklı çalışmalarında, yazarlar borsa eğilimlerini tahmin etmek için birden fazla makine öğrenme modelini entegre ettiler²¹⁶.

2009, R. P. Schumaker ve H. Chen: "Textual analysis of stock market prediction using breaking financial news" başlıklı makaleleri, son dakika haberlerine dayalı hisse senedi tahmini için doğal dil işlemenin kullanımını vurguladılar²¹⁷.

Schumaker ve Chen tarafından yapılan çalışma, finansal haber makaleleri için bir makine öğrenimi yaklaşımı kullanarak borsa eğilimlerini tahmin etmeyi araştırıyor. Kelime Torbası, İsim İfadeleri ve Adlandırılmış Varlıklar gibi çeşitli metinsel temsiller kullanırlar. Modellerini beş hafta boyunca 9.211 finansal haber makalesi ve S&P 500 hisse senetleriyle ilgili 10 milyondan fazla hisse senedi fiyatı üzerinde test ettiler.

²¹⁶ Huang, Chenn-Jung, Dian-Xiu Yang, and Yi-Ta Chuang. "Application of wrapper approach and composite classifier to the stock trend prediction." *Expert Systems with Applications* 34.4 (2008): 2870-2878.

²¹⁷ Schumaker, Robert P., and Hsinchun Chen. "Textual analysis of stock market prediction using breaking financial news: The AZFin text system." *ACM Transactions on Information Systems (TOIS)* 27.2 (2009): 1-19.

Hem Temel hem de Teknik analiz yöntemlerinin sınırlamaları olduğunu kabul eden araştırmacılar, metinsel verilere dayanan yeni bir yaklaşım önermektedir. Üç aylık raporlardan veya son dakika haberlerinden elde edilen bilgilerin hisse senedi fiyatlarını önemli ölçüde etkileyebileceğini öne sürüyorlar. Geçmiş hisse senedi fiyatlandırma bilgileriyle birleştirilen daha kesin metinsel gösterimlerin öngörülebilirliği artırabileceğini varsayıyorlar.

Araştırmacılar, farklı dilsel metinsel temsiller ve makine öğrenme teknikleri kullanarak çeşitli modeller geliştirdiler. Özellikle ayırık sayısal tahmin için tasarlanmış ve hisse hisseye özgü değişkenleri içeren bir Destek Vektör Makinesi türevine odaklandılar. Her modelin performansı daha sonra üç metriğe göre değerlendirildi: gelecekteki gerçek hisse senedi fiyatına yakınlık, fiyat hareketinin yönlü doğruluğu ve simüle edilmiş bir ticaret motorundan geri dönüş.

Hem makale terimlerini hem de makalenin yayınlandığı tarihteki hisse senedi fiyatını kullanan model, tüm metriklerde en iyi performansı gösterdi. Ayrıca Uygun İsim metinsel temsili, Kelime Torbası yaklaşımından daha iyi performans gösterdi. Araştırmacılar gelecekteki araştırmaların diğer makine öğrenme tekniklerini keşfedebileceğini, hisse senedi seçimini genişletebileceğini ve gelişmiş tahmin doğruluğu için daha seçici makale eğitimi deneyebileceğini öne sürüyorlar.

2011, J. Bollen, H. Mao ve X. Zeng: "Twitter mood predicts the stock market" adlı çalışmaları, sosyal medya duyarlılığının borsa hareketlerini tahmin etmek için nasıl kullanılabileceğini gösterdiler²¹⁸. Bu çalışmaya yapılan 6599 atıf bulunmuştur.

Bollen, Mao ve Zeng, Twitter beslemeleri aracılığıyla ölçülen kolektif ruh hali durumlarının Dow Jones Endüstriyel Ortalaması (DJIA) üzerindeki etkisini araştırıyor. Çalışma, büyük ölçekli Twitter ruh hali verilerinin borsa değişikliklerinin erken bir göstergesi olabileceğini öne sürüyor. Duyarlılık izleme araçlarını, OpinionFinder'ı ve Google-Duygudurum Durumlarının Profili'ni (GPOMS) kullanarak borsa tahmin doğruluğunun belirli genel ruh hali boyutlarını göz önünde bulundurarak geliştirilip geliştirilemeyeceğini değerlendirirler.

²¹⁸ Bollen, Johan, Huina Mao, and Xiaojun Zeng. "Twitter mood predicts the stock market." *Journal of computational science* 2.1 (2011): 1-8.

Yazarlar, 28 Şubat- 19 Aralık 2008 tarihleri arasındaki Twitter yayınlarını inceleyerek 2,7 milyon kullanıcıdan yaklaşık 9,85 milyon tweet kaydetti. Araştırmacılar, bu tweetlere yansıyan kolektif ruh halinin ekonomik göstergeleri etkileyebileceğini ve böylece haberleri borsa fiyatlarının birincil itici gücü olarak gören Etkin Piyasa Hipotezi'ne (EMH) meydan okuyabileceğini iddia ediyorlar.

Twitter verilerinin duyarlılık analizi iki araç kullanılarak gerçekleştirilir: Olumlu ve olumsuz duygulara dayalı günlük bir zaman serisi oluşturan OpinionFinder, ve GPOMS, belirli ruh hali boyutları boyunca altı boyutlu bir günlük ruh hali serisi sağlar (Sakin, Uyanık, Emin, Hayati, Nazik, Mutlu). Bu ruh hali zaman serilerini DJIA ile ilişkilendirerek yazarlar borsa değişiklikleri üzerindeki öngörücü yeteneklerini değerlendirirler.

Sonuçlar GPOMS tarafından ölçülen belirli ruh hali boyutlarının, özellikle de 'Sakin' ve 'Mutluluk' un dahil edilmesinin, DJIA tahminlerinin doğruluğunu önemli ölçüde artırdığını göstermektedir. Çalışma, DJIA kapanış değerlerindeki günlük değişiklikleri tahmin etmede % 86.7'lik bir doğruluk bularak, geleneksel yöntemleri aşıyor. Bununla birlikte tüm duygudurum boyutları öngörücü etkinliğe katkıda bulunmaz, bu da duygudurum göstergelerinin seçici olarak dikkate alınması ihtiyacını ortaya koymaktadır.

2013, M. Hagenau, M. Liebmann ve D. Neumann: Yazarlar "Automated news reading: Stock price prediction based on financial news using context-capturing features", başlıklı makalelerinde, hisse senedi fiyatlarını tahmin etmek için otomatik haber okuma ve bağlam yakalama özelliklerini kullanıyorlar²¹⁹.

Hagenau, Liebmann ve Neumann, finansal haberlerden metinsel bilgileri analiz ederek hisse senedi fiyat tahminini geliştirme potansiyelini araştırıyor. Yazarlar, daha etkileyici özellikler kullanarak ve pazar geri bildirimlerini özellik seçim sürecine entegre ederek mevcut metin madenciliği yöntemlerini geliştirmeyi amaçlamaktadır.

²¹⁹ Hagenau, Michael, Michael Liebmann, and Dirk Neumann. "Automated news reading: Stock price prediction based on financial news using context-capturing features." *Decision support systems* 55.3 (2013): 685-697.

Yöntemleri, karmaşık unsur türleriyle birleştirildiğinde sınıflandırma doğruluklarını önemli ölçüde artırabilen daha sağlam bir özellik seçimi oluşturmaya odaklanmıştır.

Yazarlar, piyasa katılımcısı beklentilerini etkileyen hem nicel hem de nitel bilgileri içeren haberlerin hisse senedi fiyat değerlemesindeki kritik rolünü vurgulamaktadır. Gelişmiş bilgi aracılığı nedeniyle mevcut bilgilerdeki çarpıcı artışla birlikte, önemli bilgilerin otomatik olarak sınıflandırılması ihtiyacı artmıştır. Mevcut girişimlere rağmen tahmin doğrulukları genellikle tahmin olasılığını zar zor aşılıyor ve bu da önemli iyileştirmelere ihtiyaç duyulduğunu gösteriyor.

Araştırmacılar, kelime kombinasyonları gibi daha karmaşık ve etkileyici özellikleri sağlam bir seçim prosedürüyle birleştiren gelişmiş bir madencilik yöntemi önermektedir. Seçim prosedürü, yalnızca frekansa dayalı istatistiklere güvenmek yerine piyasa geri bildirimlerini kullanarak olumlu veya olumsuz hisse senedi fiyatı etkileri arasında en iyi ayrımı yapabilen özelliklere öncelik verir. Yazarlar ayrıca aynı veri kümesi üzerinde kıyaslama yaparak metodolojilerinin önceki yaklaşımlarla karşılaştırılabilir olmasını sağlarlar.

Çalışma bağlamı yakalayan özelliklerin, yani kelimelerin kombinasyonlarının, pazar geri bildirimini içeren özellik seçimi ile eşleştirildiğinde tahmin doğruluklarını önemli ölçüde artırdığını göstermektedir. Pratik uygulanabilirlik, basit bir ticaret stratejisinin bile oldukça karlı olabileceğini ortaya koyan bir ticaret simülasyonu ile gösterilir. Yaklaşım, önceki araştırma yöntemlerini çok aşarak %76'ya varan bir doğruluk seviyesine ulaşmakta ve finansal haberlere dayalı hisse senedi fiyat tahmini için bu yeni yöntemin değerini doğrulamaktadır.

2014, X. Li, H. Xie, L. Chen, J. Wang ve X. Deng: "News impact on stock price return via sentiment analysis" çalışması, haber duyarlılığının hisse senedi fiyat getirileri üzerindeki etkisini araştırıyor²²⁰.

Çalışma, hisse senedi fiyat getirilerini etkilemede finansal haber makalelerinin önemini vurgulamaktadır. Geleneksel kelime torbası modelleri yerine, yazarlar tahmin

²²⁰ Li, Xiaodong, et al. "News impact on stock price return via sentiment analysis." *Knowledge-Based Systems* 69 (2014): 14-23.

çerçevelerinin temel bir yönü olarak duyarlılık analizini tanıtmaktadır. Piyasa duyarlılığını anlamanın, yatırımcıların daha bilinçli kararlar almasına ve tahmine dayalı doğruluğu artırmasına yardımcı olabileceğini savunuyorlar.

Araştırmacılar, farklı tahmin modellerini entegre edebilen kapsamlı bir çerçeve oluşturdular. Haber makalelerini analiz etmek için bir duygu alanı oluşturmak için Harvard psikolojik sözlüğünü ve Loughran-McDonald finansal duyarlılık sözlüğünü kullanıyorlar. Modellerin tahmin doğruluğu, Hong Kong Menkul Kıymetler Borsası'ndan alınan beş yıllık verilere dayanarak test edilir ve karşılaştırılır.

Odak noktası, Hong Kong Menkul Kıymetler Borsası'nda listelenen hisse senetleri, özellikle de Hang Seng Endeksi (HSI) bileşenleridir. Çalışma daha yüksek haber kapsamı nedeniyle aktif olarak işlem gören hisse senetlerine yöneliyor. Duygu sözlükleri ve kelime torbası dahil olmak üzere altı farklı analitik yaklaşım uygulanmakta ve karşılaştırılmaktadır. Haber makalelerinin ve fiyatların veri kümeleri, karşılaştırma için zaman eksenine boyunca üç bölüme ayrılmıştır. Birkaç ilke bu bölme yöntemine rehberlik eder ve modelin performansının titizlikle test edilmesini sağlar.

Sonuçlar, duyarlılık analizinin bireysel hisse, sektör ve endeks düzeylerinde kelime torbası modelinden daha iyi performans gösterdiğini göstermektedir. Ancak duyarlılık kutupluluğunu kullanan modeller yararlı tahminler sağlayamadı. Farklı duyarlılık sözlükleri kullanan modeller arasında küçük bir fark bulundu. Bu bulgular, hisse senedi fiyat getirilerini tahmin etmede duyarlılık analizinin değerini vurgulamaktadır.

2015, J. Patel, S. Shah, P. Thakkar ve K. Kotecha: "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques" adlı makalede, yazarlar borsa endekslerini tahmin etmek için trend tabanlı veri hazırlama ve makine öğreniminden yararlandılar²²¹.

²²¹ Patel, Jigar, Sahil Shah, Priyank Thakkar, and Ketan Kotecha. "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques." *Expert systems with applications* 42, no. 1 (2015): 259-268.

Verilen makale, makine öğrenimi tekniklerini kullanarak Hindistan piyasaları için hisse senedi ve hisse senedi fiyat endeksi hareketinin tahminine odaklanmaktadır. Dört farklı model karşılaştırılır: Yapay Sinir Ağları (ANN), Destek Vektör Makinesi (SVM), rastgele orman ve naif-Bayes. Modeller iki farklı girdi verisi kümesine uygulanır: birincisi ticaret verilerinden hesaplanan on teknik parametreyi içerirken, ikincisi aynı parametrelerin trend deterministik veri temsidir.

Çalışmanın 2003'ten 2012'ye kadar iki hisse senedinin (Reliance Industries ve Infosys Ltd.) ve iki hisse senedi fiyat endeksinin (CNX Nifty ve S&P Bombay Menkul Kıymetler Borsası Sensex) 10 yıllık tarihsel verilerine dayanarak yaptığı değerlendirmeler, rastgele ormanın girdi verilerinin ilk yaklaşımını kullanırken genel performans açısından diğer modellerden daha iyi performans gösterdiğini göstermektedir. Burada on teknik parametre sürekli değerler olarak temsil edilir. Sonuçlar ayrıca bu parametreler trend deterministik verileri olarak temsil edildiğinde tüm modellerin performansının arttığını göstermektedir.

Çalışma, çeşitli belirsizlikler nedeniyle hisse senedi tahmininin zorluğunun altını çiziyor ancak ticaret verilerinden elde edilen bilgileri verimli bir şekilde önceden işleyerek eğilimleri tahmin etme olasılığına işaret etmektedir. Ayrıca tahmin doğruluğunu iyileştirmede özellik seçiminin önemini vurgulamakta ve kullanılan algoritmaların sınırlamalarını ve güçlü yönlerini tartışmaktadır.

Sonuç olarak, yazarlar araştırmalarının bulgularını özetlemekte ve sürekli değerli girdileri trend deterministik verilere dönüştürme yaklaşımlarının tahmin modellerinin doğruluğunu artırmada yardımcı olabileceğini öne sürmektedir. Yazarlar ayrıca borsa verilerinin karmaşıklığını ve dış faktörlerin eğilimleri nasıl etkileyebileceğini vurgulayarak, bu faktörlere uyum sağlamak için tahmin modellerine duyulan ihtiyacı göstermektedir.

2016, R. C. Cavalcante, R. C. Brasileiro, V. L. F. Souza, J. P. Nobrega, ve A. L. I. Oliveira: "Computational intelligence and financial markets: A survey and future

directions" başlıklı makalede yazarlar finansal piyasalarda kullanılan yapay zeka yaklaşımlarının kapsamlı bir incelemesini sunmaktadır²²².

Bu makale, finansal piyasa problemlerine uygulanan hesaplamalı zeka metodolojilerinin kapsamlı bir incelemesini yürütmektedir. Bu alanda akıllı sistemler kullanan çok sayıda araştırmaya rağmen bu geniş kapsamlı kapsamı yakalayan sınırlı inceleme çalışmaları mevcuttur. Makale 2009'dan itibaren birincil literatürü tarayarak veri ön işleme, piyasa tahmini ve finansal bilgi madenciliği gibi alanları kapsayarak bu boşluğu doldurmaktadır.

İncelenen birincil çalışmalar 2009-2015 yılları arasında Science Direct, Google Scholar ve IEEEExplore dijital kütüphanelerinden alınmıştır. Çalışma, bu alandaki kapsamlı inceleme makalelerinin kabul edilen eksikliği nedeniyle seçildi. Araştırma, hesaplamalı zeka algoritmaları tarafından ele alınan finansal piyasa problemlerinin türleri de dahil olmak üzere üç ana soru tarafından yönlendirildi.

Çok çeşitli makine öğrenme yöntemleri, özellikle de önceden girdi bilgisi olmadan doğrusal olmayan veri analizi yapabilenler incelenmiştir. Özellikle yapay sinir ağları, doğrusal olmayan finansal zaman serisi verilerini modelleme potansiyelleri nedeniyle tanındı. Ek olarak, piyasa davranışını tahmin etmek için giderek daha popüler hale gelen metinsel bilgi madenciliği uygulamasına dikkat edildi.

Makale birincil çalışmalara yapılandırılmış bir genel bakış sunmakta ve bunları birincil hedeflerine göre gruplandırmaktadır. Yazarlar, akıllı ticaret sistemleri oluşturmak için sistematik bir prosedür önerdiler, alandaki zorlukları ve açık araştırma alanlarını belirttiler. Çalışma, hızla gelişen bu alanda gelecekteki araştırma yönleri hakkında tartışmalarla sona ermektedir.

2017, E. Chong, C. Han ve F. C. Park: "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies"

²²² Cavalcante, Rodolfo C., Rodrigo C. Brasileiro, Victor LF Souza, Jarley P. Nobrega, and Adriano LI Oliveira. "Computational intelligence and financial markets: A survey and future directions." *Expert Systems with Applications* 55 (2016): 194-211.

adlı çalışmaları, borsa analizi ve tahmini için derin öğrenmenin uygulanmasını tanıtmaktadır²²³.

Chong, Han ve Park tarafından yapılan bu çalışma, borsa tahmini ve analizi için derin öğrenme ağlarının kapsamlı bir analizini sunmaktadır. Bu algoritmaların potansiyel faydalarını ve dezavantajlarını araştırır, yüksek frekanslı gün içi hisse senedi getirilerini girdi verileri olarak kullanır. Çalışma, üç denetimsiz özellik çıkarma yöntemine odaklanmaktadır: ana bileşen analizi, otomatik kodlayıcı ve kısıtlı Boltzmann makinesi.

Borsaların bir dereceye kadar öngörülebilir olduğu gösterilmiştir, hisse senedi getirisi tahmini için geçmiş yöntemler ağırlıklı olarak önceki piyasa hareketlerini analiz eden ekonometrik veya istatistiksel yöntemlere dayanmaktadır. Daha yeni ilgi, büyük ölçüde görüntü sınıflandırma ve doğal dil işleme gibi alanlardaki başarıları nedeniyle yapay sinir ağlarına (ANN'ler) yönelmiştir.

Bununla birlikte, ANN'ler giriş değişkenlerinin ve ağ parametrelerinin titizlikle seçilmesini gerektirmektedir. Çok katmanlı sinir ağlarını kullanan makine öğreniminin bir alt alanı olan derin öğrenme, verilerden özellikleri otomatik olarak çıkardığı ve özellik seçimi sırasında minimum insan müdahalesi gerektirdiği için çekici bir alternatif sunar.

Yazarlar, makroekonomik değişkenler gibi öngörücülerde uzmanlığa duyulan ihtiyacı ortadan kaldırarak büyük bir ham seviye veri seti kullanmayı önermektedir. Bu çalışma, Kore borsasından gelen yüksek frekanslı verileri kullanmaktadır, daha büyük bir veri kümesine izin verdi ve sinir ağı modellerinde ortaya çıkabilecek veri gözetleme ve aşırı uyum sorunlarından kaçınmak için çok önemli olan daha fazla ticaret fırsatı sağlamaktadır.

Bu çalışmada, derin öğrenme ağlarının öngörücü performansının karışık, çevresel ve kullanıcı tarafından belirlenen faktörlere bağlı olduğu bulunmuştur. Bununla

²²³ Chong, Eunsuk, Chulwoo Han, and Frank C. Park. "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies." *Expert Systems with Applications* 83 (2017): 187-205.

birlikte, derin öğrenme, otoregresif bir modeli tamamlamak için kullanıldığında hisse getirisi tahminini önemli ölçüde geliştirmiştir. Ayrıca, model, kovaryans tabanlı piyasa yapısı analizine uygulandığında kovaryans tahminini iyileştirmede etkili olmuştur.

Genel olarak, çalışma, hisse getirisi tahmini için derin öğrenmenin potansiyelini vurgulamakta ve derin özellikli öğrenme tabanlı hisse getirisi tahmin modellerinin oluşturulması ve değerlendirilmesinin yanı sıra gelecekteki araştırmalar için talimatlar sunmaktadır.

2018, T. Fischer ve C. Krauss: "Deep learning with long short-term memory networks for financial market predictions" başlıklı makalelerinde, finansal piyasaları tahmin etmek için bir tür derin öğrenme modeli olan Uzun Kısa Vadeli Bellek (LSTM) ağılarını uyguladılar²²⁴.

Finansal zaman serilerinin tahmini, piyasa gürültüsü ve verimliliği nedeniyle her zaman zorlu bir görev olmuştur. Geleneksel finansal modeller, finansal piyasa verilerinin doğasında bulunan karmaşık doğrusal olmayan bağımlılıkları kavramakta zorlanmıştır. Derin öğrenme yöntemleri son zamanlarda bu doğrusal olmayan yapıların tanımlanmasında potansiyel göstermektedir, ancak büyük ölçekli finansal piyasa tahmin görevlerinde uygulamaları seyrek olmuştur. Bu çalışma, finansal piyasa tahminleri için dizi öğrenme görevleri için bilinen gelişmiş derin öğrenme mimarileri olan Uzun Kısa Süreli Bellek (LSTM) ağılarının kullanımına odaklanmaktadır.

Bu çalışma için Thomson Reuters'ten S&P 500 endeks bileşenleri kullanılmıştır. Hayatta kalanların önyargısını önlemek için, kurucu listeler, bir sonraki ayda bir hisse senedinin kurucu durumunu gösteren ikili bir matris halinde birleştirildi. Tahmin görevi, 1992'den 2015'e kadar kurucu hisse senetleri için örneklem dışı yönlü hareketleri tahmin etme etrafında formüle edilmiştir.

Çalışmada beş adımlı bir metodoloji kullanılmıştır. Ham verileri eğitim ve ticaret kümelerine bölmeyi, özellik alanını ve hedefleri tanımlamayı, LSTM ağılarını

²²⁴ Fischer, Thomas, and Christopher Krauss. "Deep learning with long short-term memory networks for financial market predictions." *European journal of operational research* 270, no. 2 (2018): 654-669.

uygulamayı ve bir ticaret yaklaşımı geliştirmeyi içeriyordu. Karşılaştırma ayrıca rastgele ormanlar, derin sinir ağları ve lojistik regresyon modelleri gibi diğer yöntemlerle de yapıldı.

Çalışma, LSTM ağlarının belleksiz sınıflandırma yöntemlerinden daha iyi performans gösterdiğini ve günlük yüzde 0,46'lık getiri sağladığını buldu. Kârlılık 1992'den 2009'a kadar belirgindi, bundan sonra aşırı getiriler tahkim edilmiş gibi görünüyor. Ayrıca, seçilen hisse senetlerinde ortak modeller gözlemlendi ve bu da işlem maliyetlerinden önce yüzde 0,23 getiri sağlayan kurallara dayalı kısa vadeli bir tersine çevirme stratejisinin formüle edilmesine yol açmıştır.

2019, W. Long, Z. Lu ve L. Cui: "Deep learning-based feature engineering for stock price movement prediction" başlıklı makaleleri, hisse senedi fiyat hareketi tahmininde tahmine dayalı özellikler oluşturmak için derin öğrenmenin kullanımını vurgulamaktadır²²⁵.

Bu çalışma, finansal zaman serisi verilerinden özellik çıkarma ve hisse senedi fiyat hareketi tahmini için Multi-Filters Neural Network (MFNN) adı verilen yeni bir uçtan uca model önermiştir. MFNN, evrişimli ve tekrarlayan birimleri entegre ederek farklı özellik alanlarından ve pazar görünümünden içgörüler elde etmesini sağlar. Özellik mühendisliği için derin öğrenme metodolojilerini kullanarak, hisse senedi fiyat hareketi tahmininde doğruluk, kârlılık ve istikrara odaklanarak geleneksel istatistiksel yöntemlerden ve makine öğrenimi modellerinden daha iyi performans göstermeyi amaçlamıştır.

Hisse senedi fiyat tahmini görevi, her zaman adımında 1 dakikalık sıklıkta elde edilen altı gösterge kullanılarak ele alındı. Bu göstergeler açık fiyat, kapanış fiyatı, en yüksek fiyat, en düşük fiyat ve hacmi içermektedir. Kullanılan veriler, Çin borsa endeksi CSI 300'den yüksek frekanslı piyasa örnekleriydi. Yaklaşım, aşırı piyasaları tanımayı ve beş farklı tahmin penceresinde altı tür aşırı piyasa tanımlayarak uygun ticaret sinyallerinden yararlanmayı amaçladı.

²²⁵ Long, Wen, Zhichen Lu, and Lingxiao Cui. "Deep learning-based feature engineering for stock price movement prediction." *Knowledge-Based Systems* 164 (2019): 163-173.

MFNN, çok deęişkenli finansal zaman serisi verilerinden ve sınıflandırma tabanlı tahminden özellik ayıklama için özel olarak tasarlanmıştır. Çoęu iki aşamalı özellik ayıklama ve tahmin çalışmasının aksine, bu model tüm özellik ayıklama ve tahmin sürecini entegre etti. Yaklaşım, bu tür verilerin ve tahmin görevlerinin spesifik özelliklerini dikkate alarak, finansal zaman serileri için uyarlanmış bir derin öğrenme modeli sağlamayı amaçlamıştır.

MFNN'nin etkinliği, performansını geleneksel makine öğrenimi, istatistiksel modeller ve sinir aęlarıyla karşılaştıran bir deneyle deęerlendirildi. 30 veri seti arasında en iyi performans gösteren model, piyasa simülasyonu için kullanıldı ve tahmin sonuçları ticaret sinyalleri olarak hizmet etti. Sonuçlar, MFNN'nin hisse senedi fiyat hareketi tahmininde doğruluk, karlılık ve istikrar açısından geleneksel yöntemlerden daha iyi performans gösterdiğini göstermektedir.

2020, Gu, Shihao, Bryan T. Kelly ve Dacheng Xiu: "Empirical Asset Pricing via Machine Learning" başlıklı makalelerinde yazarlar, makine öğreniminin ampirik varlık fiyatlandırmasındaki gücünü gösterdiler ve sinir aęlarını ve regresyon aęaçlarını en iyi performans gösteren yöntemler olarak tanımladılar²²⁶.

"Makine Öğrenimi Yoluyla Ampirik Varlık Fiyatlandırması" başlıklı bu 2020 makalesinin yazarları, finasta kritik bir konu olan özkaynak risk primlerini deęerlendirmek için makine öğrenimi (ML) metodolojilerinin kullanımına ilişkin kapsamlı bir araştırma yürütmektedir. Çeşitli ML yöntemlerini kullanarak, risk primlerinin ölçülmesinde öngörücü doğruluk için yeni bir kriter oluşturmayı amaçlamaktadır. Bu çalışma, ampirik varlık fiyatlandırma literatürünü makine öğrenimi ile sentezleyerek, öngörücü doğrulukta önemli gelişmeler ve yatırımcılar için önemli ekonomik kazançlar potansiyelini vurgulamaktadır.

Çalışma, kullanılan makine öğrenimi yöntemlerini detaylandırmak, istatistiksel modelleri, parametre tahmini için objektif fonksiyonları ve optimum spesifikasyon tanımlaması için hesaplama algoritmalarını açıkça özetlemek için derinlemesine bir yaklaşım benimsemektedir. Bu bileşenler, temel sorunun üstesinden gelmek için uyum

²²⁶ Gu, Shihao, Bryan Kelly, and Dacheng Xiu. "Empirical asset pricing via machine learning." *The Review of Financial Studies* 33, no. 5 (2020): 2223-2273.

içinde çalışır: borsanın kesitinde ve zaman serilerinde getirileri tahmin etmek. Bu metodolojik yaklaşım, potansiyel aşırı uyum sorunlarıyla başa çıkmada ve numune dışı performansı iyileştirmede çok önemlidir.

Yazarlar, risk primlerini tahmin etme kapasitelerine odaklanan bir makine öğrenme teknikleri koleksiyonunu gün ışığına çıkarıyor. Üstün performans gösteren sinir ağlarına ve regresyon ağaçlarına özel dikkat gösterilmektedir. Bu tekniklerin başarısı öncelikle geleneksel yöntemlerle göz ardı edilen doğrusal olmayan etkileşimleri yakalama yeteneklerine atfedilir. Yazarlar ayrıca, finansal piyasalar bağlamında "derin" öğrenmeye göre "sığ" öğrenmenin yararları hakkında anlayışlı bir tartışma sunmaktadır.

Karşılaştırmalı analiz, özellikle daha büyük ve daha likit hisseler ve portföyler için hisse getirilerini tahmin etmede makine öğrenimi yöntemlerinin üstün performansını ortaya koymaktadır. Özellikle, tüm yöntemler, fiyat eğilimleri, likidite, oynaklık ve değerlendirme oranları dahil olmak üzere benzer bir dizi baskın tahmin sinyali üzerinde birleşti. Sonuçlar, ML'nin hem ekonomik modelleme hem de portföy seçiminin pratik yönlerindeki vaadini vurgulamakta ve varlık fiyatlandırmasının arkasındaki risk primleri ve ekonomik mekanizmaların daha kesin bir şekilde anlaşılmasını teşvik etmektedir.

2021, Prashant Mehta, Sachin Pandya, Ketan Kotecha: "Harvesting social media sentiment analysis to enhance stock market prediction using deep learning" adlı çalışmaları, borsa hareketlerinin tahminini geliştirmek için derin öğrenme ile sosyal medya duygu analizini kullanmaktadırlar²²⁷.

Bu çalışma, çeşitli sosyal medya kaynaklarından ve finansal haber platformlarından elde edilen verilerden yararlanarak borsa eğilimlerini tahmin etmek için makine öğrenimi ve duygu analizi tekniklerinin kullanımını araştırmaktadır. Odak noktası Hindistan Borsasıdır ve incelenen zaman dilimi 1 Ekim 2014'ten 31 Aralık 2018'e kadar uzanmaktadır. Araştırma, kamuoyu duyarlılığının bir şirketin hisse senedi fiyatlarındaki değişikliklerle nasıl ilişkili olduğunu belirlemeyi amaçlamaktadır.

²²⁷ Mehta, Pooja, Sharnil Pandya, and Ketan Kotecha. "Harvesting social media sentiment analysis to enhance stock market prediction using deep learning." *PeerJ Computer Science* 7 (2021): e476.

Araştırmacılar sosyal medya platformlarından ve finansal haber kaynaklarından veri topladılar. Daha sonra bu veriler üzerinde duyarlılık analizi yaptılar ve gelecekteki eğilimleri tahmin etmek için tarihsel hisse senedi fiyatlarıyla birlikte kullandılar. Hareketli Ortalama yöntemi, fiyat bozulmasını azaltmaya yardımcı olan teknik bir analiz aracı olarak kullanılmıştır. Duyarlılık analizi, haber duyarlılığını olumlu veya olumsuz olarak sınıflandırmayı ve böylece hisse senedi eğilimlerini tahmin etmeyi amaçladı.

Destek Vektör Makinesi, MNB sınıflandırıcısı, doğrusal regresyon, Naif Bayes ve Uzun Kısa Süreli Bellek (LSTM) gibi çeşitli makine öğrenme tekniklerinin yanı sıra derin öğrenme teknikleri de kullanılmıştır. Yaklaşım hem geçmiş hisse senedi fiyatlarını hem de haber/sosyal medya verilerini dikkate alarak belirli bir dönemdeki haber verileri ile hisse senedi trend değerleri arasındaki korelasyonu analiz etmeyi amaçlamıştır.

Sonuçlar, önerilen metodolojinin fizibilitesini gösterdi ve LSTM tekniği% 92.45 ile en yüksek doğruluk oranını verdi. Bulgular ayrıca, olumlu haber duyarlılığı ile artan borsa değerleri arasında potansiyel bir korelasyon olduğunu öne sürerken, olumsuz haberlerin daha düşük trend değerlerine karşılık geldiği bulunmuştur. Sonuçlar, daha doğru borsa tahmini için makine öğrenimi yöntemleriyle birlikte duyarlılık analizinin potansiyelini doğrulamaktadır.

Sonuç olarak borsa tahmini için çeşitli makine öğrenmesi ve derin öğrenme tekniklerinin kullanımı son yıllarda aktif bir araştırma alanı haline gelmiştir. Bu yazıda sunulan tablolar, konuyla ilgili son literatüre kapsamlı bir genel bakış sunmaktadır. Tablolar yazarları, yayın yılını, çalışmanın/makalenin adını ve yazarlar tarafından kullanılan yaklaşımın kısa bir özetini içermektedir.

Borsa tahmini için en popüler yaklaşımlardan biri, finansal haberler ve sosyal medya verileri üzerinde duygu analizinin kullanılmasıdır. Tablolarda listelenen çalışmaların birçoğu, haberlerin ve sosyal medya verilerinin duyarlılığını analiz etmek ve borsa hareketlerini tahmin etmek için çeşitli makine öğrenimi tekniklerini kullandıkları bu yaklaşıma odaklanmaktadır. Bu çalışmaların sonuçları, birçok yazarın borsa trendlerini tahmin etmede yüksek doğruluk oranlarını bildirmesiyle umut verici

olmuştur. Sinir ağıları, tekrarlayan sinir ağıları (RNN'ler) ve uzun kısa süreli bellek (LSTM) ağıları gibi derin öğrenme teknikleri de borsa tahmininde yaygın olarak kullanılmaktadır. Bu tekniklerin avantajı, girdi verilerinden karmaşık ilişkileri ve kalıpları öğrenebilmeleri, doğru tahminler yapabilmeleridir. Tablolarda listelenen birkaç çalışma, derin öğrenme tekniklerini kullanmıştır ve bunların sonuçları derin öğrenmenin borsa tahmininde geleneksel makine öğrenimi tekniklerinden daha iyi performans gösterebileceğini göstermektedir.

Birçok çalışmanın ortak bir kısıtlılığı, gelecekteki borsa hareketlerini tahmin etmek için geçmiş borsa verilerini kullanmalarıdır. Bu yaklaşım geçerli olmakla birlikte, gelecekteki pazarın geçmiş pazara benzer şekilde davranacağını varsayar. Ancak bu varsayım her zaman geçerli olmayabilir ve gelecekteki pazar geçmiş verilerde bulunmayan faktörlerden etkilenebilir. Bu sınırlamayı gidermek için bazı araştırmalar, borsa tahmini doğruluğunu iyileştirmek için haberler ve sosyal medya duyarlılığı gibi piyasa dışı verileri dahil etti. Birçok çalışmanın diğer bir sınırlılığı ise gerçek hisse senedi fiyatları yerine borsa trendlerini tahmin etmeye odaklanmalarıdır. Eğilimleri tahmin etmek yararlı olsa da yatırımcılar nihai olarak gerçek hisse senedi fiyatlarını tahmin etmekle ilgilenirler. Bu nedenle gelecekteki araştırmalar, hisse senedi fiyatlarını doğru bir şekilde tahmin edebilen modeller geliştirmeye odaklanmalıdır, bizim çalışmadaki hedefimiz de bu yöndedir.

Bugün geline nokta bakarsak görünen odur ki finans kuruluşları ve bazı devletler bu konuya çok büyük yatırımlar yapmakta, literatürün çok daha ilerisinde bir seviyede bulunmaktadır. Hisse senedi piyasalarındaki yüksek kar potansiyeline karşın yapay zeka tabanlı bilgisayar sistemlerinin etkili ve yaygın bir şekilde kullanılmasının ekonomik açıdan çok maliyetli olması sebebiyle akademik anlamda gelişimi daha geriden takip ettiği anlaşılmaktadır.

Özetle, borsa tahmini için makine öğrenimi ve derin öğrenme tekniklerinin kullanımı hızla gelişen bir araştırma alanıdır. Bu belgede sunulan tablolar, konuyla ilgili son literatürün kapsamlı bir özetini sunmaktadır. Bu çalışmaların sonuçları, duygu analizi ve derin öğrenme tekniklerinin borsa trendlerini tahmin etmede etkili olabileceğini göstermektedir. Bununla birlikte, tarihsel verilerin kullanımı ve hisse

senedi fiyatı tahmini yerine trend tahminine odaklanma gibi ele alınması gereken sınırlamalar vardır. Gelecekteki arařtırmalar, gerek hisse senedi fiyatlarını daha iyi tahmin edebilen daha doėru ve saėlam modeller geliřtirmeye odaklanmalıdır.



IV. BÖLÜM

YAPAY ZEKA YÖNTEMLERİYLE HİSSE SENEDİ FİYATLARININ ÖNGÖRÜLMESİ ÜZERİNE AMPİRİK ÇALIŞMA

Yapay zeka makine öğrenimi algoritmaların borsa işlemleri alanında tahmine dayalı modelleme giderek daha önemli hale gelmektedir. Hisse senedi fiyatlarını ve trendlerini doğru bir şekilde tahmin etme yeteneği, finansal piyasada başarıya ulaşmada çok önemli bir bileşendir. Temel analiz ve teknik analiz gibi geleneksel yöntemlerin sınırlamaları vardır ve genellikle piyasa eğilimlerini bazı piyasa koşullarında doğru bir şekilde tahmin etmede yetersiz kalmaktadır. Makine öğrenimi algoritmaları çok büyük miktarda veriyi gerçek zamanlı olarak analiz edebilen, karmaşık kalıpları tanımlayabilen ve doğru tahminler yapabilen yeni bir yaklaşım sunmaktadır. Bu algoritmalar, insan gözüyle görülemeyebilecek kalıpları ve eğilimleri tanımlayabilir ve bu da daha bilinçli Al-Sat kararlarına yol açar. Makine öğrenimi algoritmalarının bir başka avantajı da yeni verilere uyum sağlama ve bunlardan öğrenme yetenekleridir. Finans piyasası geliştikçe makine öğrenimi algoritmaları değişen koşullara uyum sağlayabilir ve zaman içinde doğruluklarını iyileştirmek için yeni verilerden öğrenebilir. Alım satım analizine yönelik bu uyarlanabilir yaklaşım, koşulların hızla değişebildiği günümüzün hızlı tempolu finans piyasasında çok önemlidir.

Bu tezin ampirik bölümünde, araştırmamızı her biri iki alt bölümden oluşan iki kısma ayırdık. İlk bölümün ilk kısmı için RapidMiner tarafından sağlanan SVM, RF, DT, GBT ve DL gibi bir dizi makine öğrenimi algoritmasını BigML'den Holt-Winter ve EViews'tan ARIMA gibi geleneksel tahmin yaklaşımlarıyla yan yana kullanıyoruz. Bu yazılım paketlerinden ve algoritmalarından yararlanmadaki amaç; BİST 30 endeksinde işlem gören 30 şirketin bir sonraki işlem günü fiyatlarını tahmin etmek koşuluyla kendi özelliklerinde 18 yılı kapsayan eğitim ve test dönemine ait performans yeterliliklerini değerlendirmek, böylece etkinliklerinin nüanslarını aydınlatmaktır.

İlk bölümün ikinci kısmında, modern makine öğrenimi yaklaşımları ile geleneksel metodolojilerin kapsamlı bir şekilde yan yana getirilmesini sunar. Burada BIST30 endeksinden türetilen 18 yıllık eğitim ve test veri setinden yararlanarak oluşturulan bir kesit zaman dilimini kapsayan-üzerinden bir karşılaştırma platformu sağlıyoruz. Analizimizin kesinliğini desteklemek için mutlak hata, göreceli hata ve yüzde hata gibi güçlü performans ölçütleri uyguluyoruz. Bu karşılaştırmalı çalışmanın amacı, yalnızca gelişmiş makine öğrenimi ve geleneksel tahmine dayalı metodolojilerin göreceli güçlerini ve sınırlamalarını betimlemek değil, aynı zamanda finansal tahmin alanındaki etkinliklerine dair derin içgörüler sunmaktır.

Ampirik uygulamamızın ikinci bölümün ilk kısmı, yapay zeka makine öğrenimi algoritmalarının performansını geliştirmek ve değerlendirmek için Python kullanımını içermektedir. Ortalama bağıl hata, sağlam bir performans ölçüsü olarak kullanılmaktadır. Bu algoritmaların potansiyel pratik uygulanabilirliğini doğrulamak için, gerçek dünya senaryolarını kopyalayan titiz bir simülasyon testi uyguluyoruz. Simülasyon, bir yıl boyunca günlük alım-satım işlemlerinin bir geriye dönük test olarak yürütülmesini içerir ve böylece bize bu algoritmaların gerçek piyasa koşulları altındaki performansının somut bir görüntüsünü sağlar. Bu metodolojinin kapsamlı doğası, yalnızca bulgularımızı desteklemekle kalmaz, aynı zamanda araştırmamızın sağlamlığını ve güvenilirliğini de belirler.

Ampirik uygulamamızın ikinci bölümün ikinci kısmı, yapılan backtest uygulamasının makine öğrenme modellerine göre doğru karar, yanlış karar, doğru karar oranı ve yanlış karar oranı hesaplanarak karşılaştırmalı olarak incelenmesini içermektedir.

4.1. Çalışmanın Kapsam ve Sınırlamaları

Çalışma verisel kapsamı, zamansal kapsamı, kavramsal kapsam ve sınırlamaları alt başlıklar halinde aşağıda belirtilmiştir.

4.1.1 Verisel Kapsam

Bu çalışma, Borsa İstanbul 30 endeksinde yer alan şirketlerin ve BIST30 endeksinin günlük, açılış, kapanış, gün içi en yüksek fiyat, gün içi en düşük fiyat ve hacim bilgileri odaklanmaktadır. Çalışma veri seti, her bir hisse senedi için bir tane

olmak üzere 30 farklı alt kümeye bölünmüştür ve her bir alt küme minimum 2915 ve maksimum 4707 işlem gününü kapsamaktadır.

4.1.2 Zamansal Kapsam

Çalışma 08.12.2003 ile 31.01.2022 tarihleri arasındaki 18 yıllık dönemin işlem günü fiyat ve hacim bilgilerini kapsamaktadır. 7 Ocak 2022 Cuma itibarıyla BIST 30 endeksinde işlem gören 30 hisse senedinin ve BIST30 Endeksinin veri setidir. Her bir hisse için başlangıç tarihi, hisse senedinin BIST 30 endeksinde işlem görmeye başlamasına göre değişiklik göstermektedir.

4.1.3 Kavramsal Kapsam

Çalışma Yapay Zeka Makine öğrenimi tekniklerinin ve modellerinin, günlük hisse senedi fiyat veya BIST30 endeks hareketlerinden oluşan finansal veri serileri içindeki karmaşık ve doğrusal olmayan ilişkiyi tahmin etme ve hisse senedinin belirli bir süre sonra fiyatını yüksek doğruluk performansı ile tahmin etme yeteneğini keşfetmekle sınırlıdır.

4.1.4 Sınırlamalar

Çalışmanın bulguları, Borsa İstanbul'un lisanslı veri sağlayıcısından Matriksten alınan verilerdeki olası hatalar nedeniyle yanlış olabilmektedir. Ayrıca, çalışmanın bulguları, bu çalışmanın kapsamı dışındaki diğer borsalara veya finansal araçlara genellenemez. Son olarak, çalışmanın doğruluğu, kullanılan makine öğrenimi modellerinin tahmin gücü ve bu modelleri geliştirirken yapılan varsayımlarla sınırlı olabilmektedir.

Bist30'da işlem gören şirketlerin sektörleri, makine öğrenimi çalışması veri setinde analiz edilen gün sayısı ve veri setlerinin başlangıç tarihi Tablo 2'de ve Tablo 3'te sunulmaktadır. Analiz edilen hisseler bankacılık, dayanıklı tüketim, iletişim cihazları, perakende, gayrimenkul yatırım, demir-çelik, otomotiv, tarım kimyasalları, holding, madencilik, petrol ve petrol ürünleri, havayolları ve hizmetleri, endüstriyel tekstiller ve camdır.

Analizi yapılan hisse senetlerinin bir kısmının 2004 yılından sonra BIST 30 endeksinde işlem görmeye başladığını belirtmekte fayda var. Bu hisse senetlerinin analizine başlama tarihi, 2003 yılından farklı olarak işlem görmeye başladıkları ilk Pazartesi günüdür. Örnek olarak EKGYO için analiz başlangıç tarihi, bu hissenin borsada ilk işlem gördüğü Pazartesi olan 06.12.2010'dur. Analiz başlangıç tarihi olarak 08.12.2003 tarihinin seçilmesinin nedeni hacim bilgilerine ilk olarak bu tarihte ulaşılmış olmasıdır.

4.2. Çalışmanın Hipotezleri

Hipotez 1: Makine öğrenimi modelleri, günlük borsa fiyat hareketleri ile kapanış, fiyatlarını tahmin etmede yüksek doğruluk gösterecek.

Hipotez 2: Kendi yazılımımızla geliştirdiğimiz makine öğrenimi modelimiz, hisse senedi fiyatlarını tahmin etmede diğer makine öğrenimi modellerinden daha iyi performans gösterecektir.

Hipotez 3: Makine öğrenimi modelleri, hisse senedi fiyatlarını tahmin etmede farklı performans gösterecek ve bazı modeller diğerlerinden daha yüksek doğruluk gösterecek.

Hipotez 4: Çalışmamızdan elde edilen sonuçlar, makine öğrenimi tekniklerinin hisse senedi fiyat hareketlerini tahmin etmede kullanımına ilişkin mevcut bilgi birikimine katkıda bulunacak ve finansal yatırım için pratik uygulamalara sahip olacaktır.

4.3. ARIMA, SVM, Holt-Winters, Karar Ağacı, DVM, Rastgele Orman ve Derin Öğrenme Modellerinin Performans Analizi

Makine öğrenimi tekniklerinin (derin öğrenme, karar ağacı ve rastgele orman, destek vektör makinesi (SVM), gradyan destekli ağaç) doğruluğunu ve verimliliğini gerçek dünya veri kümelerinde geleneksel zaman serisi tahmin yöntemleriyle otoregresif entegre hareketli ortalama (ARIMA) ve (Holt's-doğrusal- yöntemi) mutlak hata, göreceli hata ve yüzde hata gibi güçlü performans ölçütleri kullanarak kendi özelinde karşılaştırmaktır

4.3.1. Çalışmanın Amacı ve Önemi

Bu çalışmanın temel amacı, makine öğrenimi tekniklerinin zaman serisi verilerini tahmin etmedeki etkinliğini ve sınırlamalarını araştırmaktır. Makine öğrenimi tekniklerinin (derin öğrenme, karar ağacı ve rastgele orman, destek vektör makinesi (SVM), gradyan arttırma ağaçları) doğruluğunu ve verimliliğini gerçek dünya veri kümelerinde geleneksel zaman serisi tahmin yöntemleriyle otoregresif entegre hareketli ortalama (ARIMA) ve (Holt's-doğrusal- yöntemi) kendi özellerinde değerlendirmek buna ek olarak mutlak hata, göreceli hata ve yüzde hata gibi güçlü performans ölçütleri kullanarak karşılaştırmaktır. Yapay Zeka (AI) destekli bilgisayar sistemlerinin kullanımı yoluyla hisse senedi fiyat tahmini konusundaki bilgi birikimine katkıda bulunma potansiyeli bulunmaktadır. Bu çalışma, beş farklı makine öğrenimi modelinin (derin öğrenme, karar ağacı ve rastgele orman, destek vektör makinesi (SVM), gradyan destekli ağaç) performansını değerlendirerek bu modellerin günlük hisse senedi fiyat hareketlerinden oluşan finansal veri serileri içindeki karmaşık ve doğrusal olmayan ilişkiyi doğru bir şekilde tahmin edip edemeyeceği sorusuna cevap aramaktadır. Bu çalışmanın bulguları, bu modellerin yüksek doğruluk performansı ile gün öncesi fiyat tahminlerini tahmin etmedeki etkinliğine ilişkin içgörü sağlayabilir. Ayrıca araştırma bulgularının pratik uygulamaları finansal yatırım için önemli olabilir. Hisse senedi fiyatlarının doğru tahminleri, yatırımcılara hisse senedi alım satımı hakkında bilinçli kararlar vermeleri için değerli bilgiler sağlayabilir ve bu da sonuçta daha iyi yatırım getirilerine yol açabilmektedir. Bu çalışma aynı zamanda yatırımcılara, finansal analistlere ve finans sektöründeki diğer paydaşlara fayda sağlayabilecek borsa analizi için daha etkili ve verimli YZ destekli bilgisayar sistemlerinin geliştirilmesine katkıda bulunabilir.

4.3.2. Veri Seti Seçimi ve Temini

Veri toplama ve temizleme, özellikle yapay zeka tabanlı Al-Sat stratejileri bağlamında tahmine dayalı modelleme sürecindeki temel adımlardır. Bu ilk aşamalar, analiz ve modelleme için kullanılan verilerin kalitesinin ve güvenilirliğinin sağlanmasında kritik bir rol oynar. Modelleri eğitmek ve test etmek için kullanılan verilerin kalitesi, doğruluk ve genelleme yeteneklerini önemli ölçüde etkileyebilmektedir. Bu nedenle güvenilir kaynaklardan yüksek kaliteli veriler elde

etmek ve kullanımdan önce uygun şekilde temizlendiğinden ve ön işleme tabi tutulduğundan emin olmak önemlidir.

Bu araştırmamızda BIST30 endeksinde işlem gören 30 hisse senedi ve BIST30 endeksi için günlük en yüksek, en düşük, açılış, kapanış ve hacim verilerini elde ettik. Veriler Matriks Terminal'in veri dışı aktarma özelliği kullanılarak toplandı, sonraki işleme ve temizleme için bir Excel dosya formatında saklandı. Ortaya çıkan veri seti, 18 yıllık bir zaman dilimini kapsayan 30 hisse senedi ve BIST30 endeksi için yukarıda bahsedilen veri özniteliklerini içermektedir. Veri bütünlüğünü sağlamak için yinelenen girişleri ortadan kaldırarak ve eksik değerleri ele alarak temizleme sürecini başlattık. Ek olarak veri kümesindeki aykırı değerleri belirledik ve düzelttik. Son olarak rafine edilmiş veri setini daha fazla analiz ve araştırma için hazır olacak şekilde bir Excel dosya formatında kaydettik.

Matriks veri terminali, hisse senedi fiyatları ve hacim bilgileri dahil olmak üzere finansal piyasa verilerini elde etmek için tercih edilen bir platformdur. Dünya çapındaki çeşitli finansal piyasalardan verilere erişmek ve verileri almak için kullanıcı dostu bir arayüz sağlar. Matriks Terminal, gerçek zamanlı verilerin yanı sıra birkaç yıla yayılabilen geçmiş verileri de sunar. Matriks Terminalinden veri toplamak için kullanıcılar Piyasa Verileri bölümüne gidebilir ve istenen finansal piyasayı seçebilir. Seçildikten sonra kullanıcılar günlük yüksek, düşük, açılış, kapanış ve hacim bilgileri dahil olmak üzere çeşitli hisse senetleri verilerine erişebilir. Ancak Matriks Terminalinden alınan ham veriler; verilerin kalitesini etkileyebilecek hatalar, aykırı değerler, eksik değerler ve diğer sorunları içerebilir. Bu nedenle, kalitesini ve tahmine dayalı modellemede kullanıma uygunluğunu sağlamak için verileri temizlemek ve önceden işlemek çok önemlidir. Verilerin temizlenmesi ve ön işlenmesi, eksik değerlerin belirlenmesi ve işlenmesi, aykırı değerlerin çıkarılması, verilerin normalleştirilmesi dahil olmak üzere çeşitli teknikleri içermektedir. Bu teknikler; verilerin kalitesini iyileştirmeyi, gürültüyü ve yanlılığı azaltmayı ve tahmine dayalı modellerin daha iyi sonuçlar vermesini sağlar.

Tablo 2: BIST 30 Endeksi Hisse Senetleri

Hisse Kodu	Sektör	Veri seti Başlangıç Tarihi	Veri Seti Gün Sayısı
AKBNK	BANKACILIK	08/12/2003	4684
ARCLK	DAYANIKLI TÜKETİM	08/12/2003	4684
ASLSN	İLETİŞİM CİHAZLARI	08/12/2003	4673
BIMAS	PERAKENDE	18/07/2005	4280
EKGYO	GAYRİMENKUL YATIRIM ORTAKLIĞI	06/12/2010	2915
ERGL	DEMİR, ÇELİK TEMEL	08/12/2003	4681
FROTO	OTOMOTİV	08/12/2003	4684
GARAN	BANKACILIK	08/12/2003	4684
GUBRF	TARIM KİMYASALLARI	08/12/2003	4684
HALKB	BANKACILIK	14/05/2007	3815
HEKTS	TARIM KİMYASALLARI	15/12/2003	4679
ISCTR	BANKACILIK	08/12/2003	4684
KCHOL	HOLDİNG	08/12/2003	4676
KOZAA	MADENCİLİK	09/12/2003	4682
KOZAL	MADENCİLİK	15/02/2010	3128
KRDMD	DEMİR, ÇELİK TEMEL	08/12/2003	4685
PETKM	PETROL VE PETROL ÜRÜNLERİ	08/12/2003	4675
PGSUS	HAVA YOLLARI VE HİZMETLERİ	06/05/2013	2316
SAHOL	HOLDİNG	08/12/2003	4684
SASA	ENDÜSTRİYEL TEKSTİL	08/12/2003	4684
SISE	CAM	08/12/2003	4684
TAVHL	HAVA YOLLARI VE HİZMETLERİ	05/03/2007	3870
TCELL	İLETİŞİM	08/12/2003	4679
THYAO	HAVA YOLLARI VE HİZMETLERİ	08/05/2003	4707
TKFEN	HOLDİNG	23/11/2007	3686
TOASO	OTOMOTİV	08/12/2003	4684
TTKOM	İLETİŞİM	26/05/2008	3560
TUPRS	PETROL VE PETROL ÜRÜNLERİ	08/12/2003	4676
VESTL	DAYANIKLI TÜKETİM	08/12/2003	4684
YKBNK	BANKACILIK	08/12/2003	4679

Kaynak: Kendi tarafımızdan üretilmiştir. (2023)**Tablo 3: BIST 30 Sektörel Dağılım**

Sektör Adı	Toplam Şirket Adedi
BANKACILIK	5
HAVAYOLLARI VE HİZMETLERİ	3
HOLDİNG	3
DAYANIKLI TÜKETİM	2
DEMİR ÇELİK TEMEL	2
İLETİŞİM	2
MADENCİLİK	2
OTOMOTİV	2
PETROL VE PETROL ÜRÜNLERİ	2
TARIM KİMYASALLARI	2
CAM	1
ENDÜSTRİYEL TEKSTİL	1
GAYRİMENKUL YATIRIM ORTAKLIĞI	1

İLETİŞİM CİHAZLARI	1
PERAKENDE	1

Kaynak: Kendi tarafımızdan üretilmiştir. (2023)

4.3.3. Çalışmanın Metodolojisi

Araştırma metodolojisi; Matrix veri terminalinden veri toplama, temizleme, biçimlendirme ve aykırı değer tespitini içeren veri hazırlama, RapidMiner kullanarak makine öğrenimi (derin öğrenme, karar ağacı ve rastgele orman, destek vektör makinesi (SVM), gradyan destekli ağaç) analizi, istatistiksel araçlarla desteklenen sonuçların yorumlanması, EViews kullanarak ARIMA ve BigML kullanarak Holt-Winters geleneksel istatistiksel yöntemlerle sonuçların karşılaştırılması ve sonuçların yorumlanmasını içermektedir.

Özellik mühendisliği ve seçim, bir veri kümesinden ilgili bilgileri çıkarma sürecindeki çok önemli adımlardır. Özellik mühendisliği, makine öğrenimi algoritmalarının performansını iyileştirmek veya sonuçların yorumlanabilirliğini arttırmak amacıyla bir veri kümesindeki mevcut değişkenlerden yeni değişkenlerin veya özelliklerin oluşturulmasını içermektedir. Bu süreç ölçeklendirme, normalleştirme, ayırıklaştırma, ikilileştirme ve özellik çıkarma gibi işlemleri içerebilir. Örneğin; finansal veri analizinde özellik mühendisliği, belirli bir görev için daha bilgilendirici özellikler sağlayabilen hareketli ortalamalar veya oynaklık ölçüleri gibi orijinal değişkenlerden yeni değişkenler oluşturmayı içerebilir. RapidMiner, BigML ve EViews, finansal veri analizinde özellik mühendisliği ve seçim için kullanılabilecek yazılım araçlarına örnektir. RapidMiner, BigML ve EViews gibi araçların kullanımı bu süreci kolaylaştırabilir ve sonuçların doğruluğunu ve yorumlanabilirliğini geliştirebilir.

RapidMiner, finansal veri analizinde özellik mühendisliği ve seçim için kullanılabilecek yazılım araçlarına biridir. RapidMiner veri ön işleme, özellik çıkarma, özellik seçimi dahil olmak üzere özellik mühendisliği ve seçimi için çeşitli araçlar ve teknikler sağlayan makine öğrenimi platformlarıdır.

BigML; özellik mühendisliği ve seçimi, model oluşturma ve değerlendirme için araçlar sağlayan bulut tabanlı bir makine öğrenimi platformudur. Özellik mühendisliği yetenekleri, özellik seçimi, çıkarma ve dönüştürmeyi içermektedir. BigML'nin otomatikleştirilmiş özellik seçme algoritmaları, model oluşturmada kullanılacak en alakalı özellikleri belirleyebilir ve bu da aşırı uyumu azaltmaya ve model performansını iyileştirmeye yardımcı olur.

EViews, öncelikle zaman serisi analizi ve ekonometri için kullanılan istatistiksel bir yazılım paketidir. Özellik mühendisliği ve seçimi için veri dönüştürme, gecikme ve fark alma dahil olmak üzere çok çeşitli araçlar sağlar. EViews ayrıca zaman serisi verilerini modellemek ve tahmin etmek için özel araçlar sunar. Öte yandan EViews, finansal veri analizinde özellik mühendisliği ve seçimi için bir dizi ekonometrik araç ve teknik sağlayan istatistiksel bir yazılım paketidir.

Çalışmanın bu bölümünde, çeşitli analiz yöntemlerinin uygulamalarını özetliyor ve açıklıyoruz. Bunlar; derin öğrenme, karar ağacı ve rastgele orman algoritmalarının yanı sıra destek vektör makinesi (SVM), gradyan destekli ağaç, otoregresif entegre hareketli ortalama (ARIMA) ve Holt'un doğrusal yöntemlerini içermektedir. Analiz sürecinde bu yöntemlerin nasıl uygulandığına dair ayrıntılı adımlar sunulmaktadır.

4.3.3.1 Derin Öğrenme Algoritması

Derin öğrenme, verileri işlemek ve verilerden öğrenmek için çok katmanlı yapay sinir ağları kullanan yapay zeka kapsamındaki bir metodolojidir²²⁸. H2O (büyük veri ortamları için özel olarak tasarlanmış, veri analizi ve makine öğrenimi için açık kaynaklı bir yazılım) kullanan Derin Öğrenme algoritması, geri yayılım kullanılarak stokastik gradyan inişiyle eğitilmiş çok katmanlı ileri beslemeli yapay sinir ağları oluşturmaya yönelik deterministik bir yaklaşımdır. Algoritma uyarlanabilir öğrenme

²²⁸ Şimşek, Mehmet Ali, and Zeynep Orman. "A Study on Deep Learning Methods in the Concept of Digital Industry 4.0." *Handbook of Research on Management and Strategies for Digital Enterprise Transformation*. IGI Global, 2021. 318-339.

hızı, hız tavlama, momentum eğitimi, bırakma ve L1 veya L2 düzenlemesi gibi gelişmiş özellikleri bir araya getirerek yüksek tahmin doğruluğu sağlamaktadır²²⁹:

Aşama 1: H2O Derin Öğrenme operatörü, oluşturulan bir veri kümesinin sayısal etiket niteliğini tahmin etmek için kullanılır. Etiket gerçek olduğunda regresyon gerçekleştirilir.

Aşama 2: Veriler oluşturulur, ardından Verileri Böl işleci ile iki parçaya bölünür. İlk çıktı eğitim olarak ikincisi ise puanlama veri seti olarak kullanılır.

Aşama 3: L1 ve L2 düzenlemesi, makine öğreniminde modellerin aşırı uyumu önlemek için kullanılan tekniklerdir. Tanh, doğrultucu, maxout gibi çeşitli aktivasyon fonksiyonlarına sahip nöronlardan oluşan çok sayıda gizli katman içerebilir. Maxout işlevi, doğrultucu işlevinin bir genellemesidir; burada çıktı, girdinin bir dizi doğrusal işlevinin maksimumudur.

Aşama 4: Algoritma, epsilon ve rho parametrelerine dayalı olarak öğrenme oranını otomatik olarak belirler. Varsayılan olmayan tek parametre, her biri 50 nöron içeren 3 katmanın kullanıldığı gizli katman boyutlarıdır.

Aşama 5: Test örneklem setine uygulandıktan sonra etiketlenen veriler işlem çıkışına bağlanır.

4.3.3.2. Rastgele Orman Algoritması

Rastgele orman, sınıflandırma ve regresyon görevleri için kullanılan bir topluluk öğrenme yöntemidir. Her biri girdi veri setinin önceden yüklenmiş bir alt kümesi üzerinde eğitilmiş bir dizi karar ağacından oluşur. Rastgele Orman algoritması, eğitim veri setinden çok sayıda ilişkisiz karar ağacı üretmek çalışır. Bu yaklaşım, tek bir çözüm ağacında yoğunlaşmayı önleyerek geleneksel karar ağaçlarıyla ilişkili aşırı uyum riskini azaltır²³⁰. Rastgele Orman regresyonu, genellikle 'orman' olarak adlandırılan bir karar ağaçları koleksiyonundan bileşik bir tahmin oluşturucu oluşturan denetimli bir

²²⁹https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/neural_nets/deep_learning.html

²³⁰ SERTKAYA, Cengiz, and K. Ö. S. E. Zekeriya. "Yapay Zeka ile Tasarruf Finansmanı Sektörü Firmalarının Sosyal Medya Etkinliklerinin Tahmin Edilmesi." *International Journal of Advanced Natural Sciences and Engineering Researches* 7.3 (2023): 109-114.

öğrenme tekniğidir. Bu karar ağaçları, veri kümesinin ön yüklemeli alt örneklerinden büyütülür; bunlar, esasen değiştirme ile çizilmiş rastgele seçilmiş örneklerdir²³¹.

Algoritma karar ağacının her düğümünde verileri bölmek için göz önünde bulundurulacak özelliklerin rastgele bir alt kümesini seçer. Bölme kuralı, farklı sınıflara ait değerlerin ayrılmasını optimize eden veya regresyondaki hatayı en aza indiren bir kritere göre seçilir. Rastgele orman algoritması bu şekilde birden fazla ağaç üretir ve bunları bir oylama modeli oluşturmak için birleştirir. Model, sınıflandırma için tek tek ağaçlardan en çok oyu alan sınıfı seçer. Regresyon için model, tek tek ağaçlardan tahmin edilen değerlerin ortalamasını alır. Rastgele ormanın, bireysel karar ağaçlarına göre çeşitli avantajları vardır. Nitelik ağırlıkları, rastgele ormanın genel kararı için girdi özelliklerinin önemine ilişkin içgörüler sağlar²³²:

Aşama 1: İlk olarak birden fazla ağaç kullanarak ve her düğümde özelliklerin rastgele alt kümelerini seçerek verilerdeki gürültüye fazla uyum riskini azaltır.

Aşama 2: İkincisi, birden fazla ağacın tahminlerini toplayarak herhangi bir tek ağaçtan daha sağlam ve doğru bir tahmin sağlar.

Aşama 3: Rastgele orman, modeldeki her bir özelliğin önemini hesaplayarak özellik seçimi için de kullanılabilir.

Aşama 4: Özelliğin önemi, bu özelliği modeldeki tüm ağaçlara bölerek elde edilen safsızlık veya hatadaki toplam azalma ile belirlenir. Modelin karmaşıklığı tahmin gücü az olan alt ağaçları ortadan kaldıran bir süreç olan budama ile kontrol edilebilir. Çeşitli budama yöntemleri mevcuttur ve yöntem seçimi belirli soruna ve veri kümesine bağlıdır.

Aşama 5: Her ağacın tahmin sürecine katkıda bulunduğu bir karar ağaçları koleksiyonu oluşturur. Ortaya çıkan model, görünmeyen veri kümeleri için etiketleri veya hedef değerleri tahmin etmek için kullanılır.

²³¹ Godoy, V. A., Napa-García, G. F., & Gómez-Hernández, J. J. (2022). Ensemble random forest filter: An alternative to the ensemble Kalman filter for inverse modeling. *Journal of Hydrology*, 615(Part B), 128642.s5

²³²https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/parallel_random_forest.html

4.3.3.3. Karar Ağacı Algoritması

Karar ağacı, bir veri kümesindeki özniteliklerin değerlerine dayalı olarak karar vermek için kullanılan ağaç benzeri bir yapıdır. Ağacın her düğümü, belirli bir öznitelik için bir bölme kuralını temsil eder. Bu bölme kuralı, sınıflandırma durumunda farklı sınıflara ait değerleri ayırmak veya regresyon durumunda seçilen parametre kriteri için hatayı optimal bir şekilde azaltmak için kullanılır. Karar Ağacı (DT) algoritması, bilgi kazanım fonksiyonunu optimize etmeye çalışır, böylece düğümün bölünmesini veya en yüksek bilgi içeriğine sahip özniteliği ilk bölme olarak tercih eder²³³. Bir karar ağacı oluşturma süreci, bir durdurma kriteri karşılanana kadar seçilen özniteliklerin değerlerine dayalı olarak verilerin yinelemeli olarak bölünmesini içermektedir. Üretim sırasında yaprak düğüme ulaşan örneklerin çoğunluğu belirlenerek sınıf etiketi özniteliği için bir tahmin yapılırken, bir yapraktaki değerlerin ortalaması alınarak sayısal bir değer için bir tahmin elde edilir. Etiket özniteliği sınıflandırma için nominal ve regresyon için sayısal olmak zorunda olsa da bu operatör hem nominal hem de sayısal öznitelikleri içeren veri kümelerini işleme yeteneğine sahiptir. Karar ağacı modeli oluşturulduktan sonra Modeli Uygula Operatörü kullanılarak yeni örneklerle uygulanabilir. Her örnek bir yaprağa ulaşana kadar ağacın dallarını bölme kurallarına uygun olarak takip eder. Karar ağacını yapılandırmak için her düğümde en iyi ayrımı seçmek için kullanılan kriterin seçimi, maksimum ağaç derinliği, yaprak başına minimum örnek sayısı ve bölme için minimum kazanç dahil olmak üzere bir dizi parametre mevcuttur²³⁴.

Aşama 1: Modeli eğitmeden önce veri seti, bir eğitim seti ve bir test seti olarak ayrılır. Bu, modelin görünmeyen verileri tahmin etmedeki doğruluğunu değerlendirmek için yapılır. Veri kümesini böldükten sonra, eğitim verilerini kullanarak model eğitmek için Karar Ağacı operatörü kullanılır.

Aşama 2: Operatör, girdi özniteliklerinin değerlerine dayalı olarak verileri yinelemeli olarak alt kümelere bölerek ağaç benzeri bir model oluşturur. Ağacın her

²³³ Bansal, M., Goyal, A., & Choudhary, A. (2022). A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, 3, 100071.

²³⁴ https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/parallel_decision_tree.html

düğümü, bir özniteliğe ve değerine dayalı bir kararı temsil eder ve yapraklar, girdi için tahmin edilen hedef değeri temsil eder.

Aşama 3: Model eğitildikten sonra, modeli test veri setine uygulamak için Modeli Uygula operatörü kullanılır. Operatör, test veri setindeki her örnek için hedef değeri tahmin eder ve tahmin edilen değerleri gerçek hedef değerlerle birlikte verir.

Aşama 4: Son olarak, modelin performansını hesaplamak için Performans (Regresyon) operatörü kullanılır. Operatör, tahmin edilen hedef değerleri test setindeki gerçek hedef değerlerle karşılaştırır ve ortalama mutlak hata, ortalama karesel hata ve ortalama karesel hata gibi çeşitli performans ölçümlerini hesaplar. Bu performans ölçümleri, görünmeyen veriler için hedef değerleri tahmin etmede modelin doğruluğuna ilişkin bilgiler sağlar.

4.3.3.4. Gradyan Artırma Ağaçları Algoritması

Gradyan Artırma Ağaçları (GBT) algoritması, gelişmiş tahmine dayalı sonuçlar elde etmek için birden fazla karar ağacını ileri öğrenme tarzında birleştiren bir topluluk yöntemidir. Hem sınıflandırma hem de regresyon problemleri için kullanılabilir. Güçlendirme, artımlı olarak değiştirilen verilere zayıf sınıflandırma algoritmalarını sırayla uygulayarak karar ağaçlarının doğruluğunu artıran doğrusal olmayan bir regresyon tekniğidir. Gradyan Artırma Regresyon Ağaçları (GBRT), her bir hesaplamanın önceki yinelemenden kalanları en aza indirmek için özel olarak tasarlanması bakımından geleneksel Boosting algoritmalarından önemli bir sapma sergiler. Bu bir önyükleme yöntemine benzer. Her yeni karar ağacı, gradyan yönünde önceki model kalıntılarını azaltmak amacıyla oluşturulur²³⁵. GBT, hız ve insan tarafından yorumlanabilirlik ile ilgili sorunları en aza indirerek artırma kavramını genelleştirir. Gradyan Artırma Ağaçlarının (GBT) dört adımda nasıl çalıştığını aşağıda sunulmuştur²³⁶:

²³⁵ Chen, J., Chu, Z., Zhao, R., Luo, A. F., & Luo, K. H. (2022). Output prediction of alpha-type Stirling engines using gradient boosted regression trees and corresponding heat recovery system optimization based on improved NSGA-II. Energy Reports, 8(Supplement 5), 835-846.

²³⁶ https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/gradient_boosted_trees.html

Aşama 1: Bu operatör, H2O 3.30.0.1 kullanarak GBT algoritmasını çalıştırır. Tek düğümlü bir yerel H2O kümesini başlatır ve ayarlanan iş parçacığı sayısına dayalı olarak paralel yürütme ile algoritmayı bunun üzerinde çalıştırır. İlk olarak, Polinom veri kümesi alınır ve ardından Verileri Böl işleci kullanılarak iki parçaya bölünür. Birinci kısım eğitim seti, ikinci kısım ise puanlama veri seti olarak kullanılmaktadır.

Aşama 2: Giriş bağlantı noktası, eğitim seti görevi gören etiketli bir ExampleSet ekler. GBT algoritması, kayıp fonksiyonunu en aza indirmeyi amaçlayan bir dizi model üretmek için karar ağaçları gibi zayıf öğrencileri kullanan bir ileri öğrenme topluluk yöntemidir. Sonraki her model, önceki modellerin hatalarını iyileştirmek için eğitilir ve nihai tahmin, tüm modeller tarafından yapılan tahminlerin bir toplamıdır. Bu süreçte GBT operatörü "gamma" dağıtım parametresini kullanacak şekilde yapılandırılır.

Aşama 3: Çıkış bağlantı noktası, tahmin için yeni verilere uygulanabilen eğitilmiş Gradyan Artırma Ağaçları sınıflandırma veya regresyon modelini sağlar. Bu süreçte, Polinom veri kümesi üzerinde regresyon gerçekleştirmek için Gradyan Artırma Ağaçları (GBT) algoritması kullanılır. Amaç, girdi özelliklerine dayalı olarak gerçek değerli bir hedef özelliğin değerini tahmin etmektir.

Aşama 4: Niteliklerin etiket özniteliğine göre ağırlıkları da Öznitelik Ağırlıkları bağlantı noktası aracılığıyla iletilir. Puanlama veri kümesine GBT algoritmasını uyguladıktan sonra çıktı, eğitilmiş Gradyan Artırma Ağaçları Model'i ve etiketlenmiş verileri içermektedir.

GBDT modeli, bu adımları tekrarlayarak, kalan hataları azaltmaya odaklanan yinelemeli olarak yeni temel öğrenciler ekleyerek tahminlerini kademeli olarak geliştirir. Nihai tahmin, tüm temel öğrencilerin tahminlerinin ilgili öğrenme oranlarına göre ağırlıklandırılmasıyla elde edilir²³⁷.

²³⁷ Liu, Wanan, Hong Fan, and Meng Xia. "Credit scoring based on tree-enhanced gradient boosting decision trees." *Expert Systems with Applications* 189 (2022): 116034.

GBT algoritmasının sonucunun kullanılan veri sayısına bağlı olabileceğine ve farklı ayarların biraz farklı çıktılara yol açabileceğine dikkat edilmelidir. Bu nedenle, sistem için en uygun veri sayısını dikkatlice seçmek önemlidir.

Özetle GBT algoritması, gerçek değerli hedef niteliklerin değerlerini yüksek doğrulukla tahmin edebilen güçlü bir regresyon aracıdır. GBT, zayıf öğrencileri ve yinelemeli iyileştirmeleri kullanarak kayıp fonksiyonunu en aza indirmeyi amaçlayan bir dizi model üretebilir ve bu da son derece doğru bir nihai tahminle sonuçlanır.

4.3.3.5. Destek Vektör Makineleri Algoritması

Destek Vektör Makineleri (SVM) algoritması hem regresyon hem de sınıflandırma görevleri için kullanan bir operatördür. Destek Vektörü Makineleri (SVM) ailesindeki belirli bir tür olan Destek Vektörü Regresyonu (SVR), diğer regresyon metodolojilerine benzer bir tahmin işlevi geliştirmeyi amaçlar. SVR tarafından formüle edilen fonksiyon, SVM paradigması içinde tahmine dayalı analiz için sağlam bir araç olarak hizmet ederek, araştırılmakta olan bağımlı değişkenin davranışını aydınlatmaya çalışır²³⁸. Bu öğrenme yöntemi, hızlı algoritması ve çeşitli öğrenme görevlerinde iyi sonuçlarıyla bilinir. mySVM uygulaması, doğrusal veya ikinci dereceden ve hatta asimetrik kayıp fonksiyonlarına dayanır²³⁹. Özünde bir SVM modeli; sınıflandırma, regresyon veya diğer görevler için kullanılabilen yüksek boyutlu bir uzayda bir hiper düzlem veya hiper düzlemler kümesi oluşturur. Destek vektör makinelerinin çalışma prensibi üç adımda nasıl çalıştığını aşağıda sunulmuştur²⁴⁰.

Aşama 1: Hiperdüzlem ve marjı, yani hiperdüzlem ile her sınıfın en yakın veri noktaları arasındaki mesafeyi maksimize edecek şekilde seçilir. Bu yaklaşım, maksimal sınır hiper düzlemi (MMH) olarak bilinir ve iki sınıf arasında iyi bir ayrım sağlamayı amaçlar.

²³⁸ Valero-Carreras, D., Aparicio, J., & Guerrero, N. M. (2021). Support vector frontiers: A new approach for estimating production functions through support vector machines. Omega, 104, 102490.

²³⁹ https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/support_vector_machines/support_vector_machine.html

²⁴⁰ <https://docs.rapidminer.com>

Aşama 2: Verilerin orijinal özellik uzayında doğrusal olarak ayrılamadığı durumlarda, yüksek boyutlu uzayda özellik vektörleri arasındaki nokta çarpımı tanımlayan bir çekirdek işlevi kullanılarak veriler daha yüksek boyutlu bir uzaya eşlenebilir.

Aşama 3: DVM öğrencisinin çıktısı yeni veriler üzerinde tahmin için kullanılabilen SVM modelini, girdi olarak verilen örneklem seti ve modelin istatistiksel performansının tahminini sağlayan bir performans vektörünü içermektedir. Ek olarak öznitelik ağırlıkları, ağırlıklar bağlantı noktası aracılığıyla iletilebilir, ancak bu yalnızca nokta çekirdeği türü kullanıldığında mümkündür.

Bu adımları izleyerek DVM'den doğru ve genellenebilir sonuçlar elde etmek mümkündür.

4.3.3.6. ARIMA

ARIMA (Otoregresif Entegre Hareketli Ortalama), tarihsel gözlemlere dayalı olarak gelecekteki değerlerin analizini ve tahminini sağlayan, yaygın olarak benimsenen bir zaman serisi tahmin modelini temsil eder. Otoregresyon (AR), fark alma (I) ve hareketli ortalama (MA) olmak üzere üç temel bileşenden oluşan ARIMA modeli, bu bileşenlerin etkili bir birleşimini sergiler. Otoregresyon (AR) bileşeni, belirli bir gözlem ile belirli sayıda önceki gözlem arasındaki güvene karşılık gelir. Bir serinin gelecekteki değerlerinin kendi geçmiş değerlerine dayanarak tahmin edilebileceğini varsayar. Sonuç olarak, ARIMA'daki "AR" kısaltması bu özel yönü somutlaştırır. Bir zaman serisinde hakim olan trendleri veya mevsimselliği ortadan kaldırmak için fark (I) yönü kullanılır. Bu teknik, sabit ortalama ve varyans ile karakterize edilen durağan bir serinin elde edilmesini sağlamak için önceki değerlerin mevcut değerden çıkarılmasını kapsar. Buna göre, ARIMA içindeki "I", üstlenilen entegrasyon prosedürünü ifade eder. Hareketli ortalama (MA) bileşeni, bir gözlem ile gecikmeli gözlemlere uygulanan bir hareketli ortalama modelinden kaynaklanan artık hata arasındaki ilişkiyi araştırır. Bunu yaparak, bu bileşen, verilerin doğasında var olan geçici dalgalanmaları veya gürültüyü başarılı bir şekilde yakalar. Dolayısıyla, ARIMA'daki "MA" bileşeni bu temel özelliği kapsar.

Tipik olarak ARIMA (p, d, q) olarak temsil edilen ARIMA modeli, sırasıyla otoregresif, fark ve hareketli ortalama bileşenlerine atanan değerleri taşır²⁴¹.

ARIMA'nın güçlü ve yaygın olarak kullanılan bir modeli temsil etmesine rağmen, uygunluğunun zaman serisi verilerine özgü özelliklere bağlı olduğunu kabul etmek önemlidir. Söz konusu verilerin benzersiz özelliklerine bağlı olarak, SARIMA (mevsimsel ARIMA) gibi alternatif modeller veya durum uzayı modelleri veya makine öğrenimi algoritmaları gibi daha gelişmiş teknikler daha avantajlı olabilmektedir. Borsa tahmini için Otomatik Gerileyen (AR), Otomatik Gerileyen Hareketli Ortalama (ARMA) ve Otomatik Gerileyen Entegre Hareketli Ortalama (ARIMA) gibi doğrusal modeller kullanılmıştır. Bununla birlikte, bu modellerin önemli bir sınırlaması, bireysel zaman serisi verilerine özgü olmalarıdır. Bu, belirli bir şirket için uyarlanmış bir modelin diğerine uygulandığında tatmin edici sonuçlar vermeyebileceği anlamına gelir ve bu modellerin evrensel uygulanabilirliğinin olmadığını altını çizer²⁴².

Bir zaman serisini analiz etme süreci şu şekilde özetlenebilir²⁴³:

(1) Durağanlık Tespiti: Zaman serisinin durağanlığı, çizgi grafikler, saçılım grafikleri, otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafikleri incelenerek değerlendirilir. Augmented Dickey-Fuller (ADF) testi, birim kökleri test etmek ve varyans, trend ve mevsimsel değişimlerin varlığını belirlemek ve böylece durağanlığı belirlemek için yaygın olarak kullanılır.

(2) Sıra Tespiti: Zaman serisi durağan ise bir sonraki adıma geçilir. Aksi takdirde, durağan olmayan diziyi durağan diziye dönüştürmek için uygun dönüşümler (örneğin, fark alma, varyans durağanlığı, logaritma, karekök) uygulanır. Gerekli farkların sayısı, farkların sırasını temsil eder.

(3) ARMA Modelleme: Önceki adımdan dönüştürülen zaman serileri için otokorelasyon katsayıları (ACF) ve kısmi otokorelasyon katsayıları (PACF) hesaplanır.

²⁴¹ Polat, Coşkun, Mukaddes Sağlam, and S. A. R. I. Tuğba. "Atatürk üniversitesi iktisadi ve idari bilimler dergisi'nin bibliyometrik analizi." *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 27.2 (2013): 273-288. s143

²⁴² Hiransha, M., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2018). NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science*, 132, 1351-1362. s1352

²⁴³ Ma, L., et al. (2018). *IOP Conf. Ser.: Earth Environ. Sci.*, 208, 012017.

Bu değerler, ARMA modelinin otoregresif (AR) sırasını (p) ve hareketli ortalama (MA) sırasını (q) tahmin etmeye yardımcı olur.

(4) Parametre Tahmini: Otokorelasyon ve kısmi otokorelasyon grafikleri, önemli otokorelasyon ve kısmi otokorelasyon katsayılarının belirlenmesine yardımcı olur. Bu adım, zaman serileri için bir ön modelin seçilmesini içermektedir.

(5) Teşhis Testi ve Optimizasyon: Seçilen model, teşhis testi ve optimizasyonuna tabi tutulur. Modelin artıkları üzerinde beyaz gürültü testi yapılır. Artıklar beyaz gürültü özellikleri göstermiyorsa, süreç farklı bir model seçmek için Adım (4)'e geri döner. Artıklar beyaz gürültü testini geçerse, birden fazla model oluşturulur ve daha fazla test ve değerlendirmeye dayalı olarak takılan tüm modeller arasından en uygun model seçilir.

Özet olarak zaman serisi analizi, durağanlığın tanımlanmasını, fark alma sırasının belirlenmesini, ARMA model parametrelerinin tahmin edilmesini ve teşhis testi ve iyileştirme yoluyla seçilen modeli optimize etmeyi içermektedir.

4.3.3.7. Holt-Winters Modeli

Üçlü üstel yumuşatma modeli olarak da bilinen Holt-Winters modeli hem trendi hem de mevsimselliği barındıran zaman serisi verileri için saygın bir tahmin yaklaşımıdır. Bu model, geliştiricileri Charles C. Holt ve Peter E. Winters'ın adını almıştır. Model, üç bileşenle karakterize edilir: serideki ortalama değeri temsil eden seviye; dizideki artan veya azalan değeri ifade eden trend; ve seride tekrar eden kısa vadeli döngüyü ifade eden mevsimsellik. Model, üç bileşene de üstel yumuşatma uyguladığı için üçlü üstel yumuşatma olarak adlandırılır; bu, eski gözlemlere göre son gözlemlere daha fazla ağırlık veren bir süreçtir²⁴⁴.

²⁴⁴ Hyndman, Rob J., and George Athanasopoulos. *Forecasting: principles and practice*. OTexts, 2018.

"Zaman Serisi Tahmini", BigML'nin tahmin tekniklerinde kullanılan Üstel Düzleştirme modellerine kapsamlı bir genel bakış sağlar. Öne çıkan başlıca noktalar altta verilmiştir²⁴⁵:

Üstel Düzeltme: Bu yaklaşım, serinin geçmişini dikkate alırken yakındaki veri noktalarına ağırlık vererek bir zaman serisini yumuşatır. Geçerli veri noktası ile önceki düzeltilmiş değer arasında ağırlıklı bir ortalama hesaplar ve şimdiki zamana daha yakın noktalara daha yüksek ağırlıklar atanır.

Trend Modelleri: Trend bileşeni, bir zaman serisinin uzun vadeli yörüngesini yakalar. Toplamsal (ardışık düzeyler arasındaki fark) veya çarpımsal (ardışık düzeyler arasındaki oran) olabilir. Düz olmayan tahminler oluşturmak için trend bileşenine üstel düzeltme uygulanabilir.

Mevsimsel Modeller: Birçok zaman serisi, sabit uzunluktaki dönemlerde yinelenen varyasyonlarla karakterize edilen mevsimsel modeller sergiler. Mevsimsellik, bu kalıpları yakalamak için toplamsal veya çarpımsal olarak modellenabilir.

Üstel Düzeltme Modellerini Öğrenmek: Üstel yumuşatma modelleri için temel parametreler, yumuşatma katsayıları ve başlangıç durum değerleridir. Model uyumu ve gerçek eğitim değerleri arasındaki kare hatalarının toplamı kullanılarak değerlendirilir. Düzleştirme katsayıları ve başlangıç durum değerleri için en uygun değerleri belirlemek için sayısal optimizasyon teknikleri kullanılır.

Model Seçimi: Farklı modelleri karşılaştırmak ve sıralamak için Akaike Bilgi Kriteri (AIC) kullanılır. İdeal model, parametre sayısını en aza indirirken olasılığı en üst düzeye çıkarır. Ek olarak BigML, her model için iki ek ölçüm hesaplar: önyargı düzeltmeli AIC (AICc) ve Bayes Bilgi Kriteri (BIC). Bu ölçümler, tahmin amaçları için en uygun modelin seçilmesine yardımcı olur.

Holt-Winters modeli, geçmiş zaman serisi verileri üzerinde eğitilir ve daha sonra gelecek zaman dilimleri için tahminler yapmak için kullanılır. Tahminlerin

²⁴⁵ BigML Team. (2017, July 20). Behind the Scenes of BigML's Time Series Forecasting. The Official Blog of BigML.com. <https://blog.bigml.com/2017/07/20/behind-the-scenes-of-bigmls-time-series-forecasting/>

doğruluğu, Ortalama Mutlak Hata (MAE) ve Ortalama Hatanın Karekökü (RMSE) gibi çeşitli metrikler kullanılarak değerlendirilebilir. Model, tahminlerde bulunmak ve karar verme sürecini bilgilendirmek için finans ve ekonomi gibi sektörlerde yaygın olarak kullanılmaktadır. Model yapılandırıldıktan sonra modeli zaman serisi verileriniz üzerinde eğitebilir ve gelecek zaman dilimleri için tahminler oluşturabilirsiniz. Ayrıca modelin tahminlerinin doğruluğunu değerlendirmek için MAE (Mean Absolute Error) ve RMSE (Root Mean Squared Error) gibi çeşitli değerlendirme ölçümleri de sağlar.

4.3.4. Makine Öğrenme Algoritmaları Uygulamaları

Bu bölümde RapidMiner programı kullanılarak elde edilen makine öğrenme algoritması uygulamasının sonuçları paylaşıp yorumlanmıştır.

Altta sunulan tablo 4'te Derin Öğrenme, Karar Ağacı, Rastgele Orman, Gradyan Artırımlı Ağaçlar ve Destek Vektör Makineleri algoritmalarının 18 yıllık süreyi kapsayan dönemdeki 30 farklı hisse senedinin ertesi gün hisse senedi fiyatları tahmini için Görelî Hata performans kriteri açısından eğitim ve test sonuçlarını yüzdelik olarak göstermektedir. Kırmızı ile tabloda belirtilen sonuçlar en iyi yüzdelik görelî hata performansını veren algoritmayı göstermektedir.

Tablo 4: Makine Öğrenme Algoritmaları Günlük Görelî Hata Sonuçları

%

Hisse	Derin Öğrenme %	Karar Ağacı %	Rastgele Orman %	GBT %	DVM %
Akbank	2.1	2.1	2.0	2.0	1.9
Arcelik	2.4	1.9	2.9	2.2	1.7
Aselsan	3.0	1.9	3.2	2.0	2.6
Bımas	2.0	1.7	2.4	1.6	1.4
Ekgyo	1.6	1.7	1.7	1.7	1.6
Eregl	5.2	1.9	3.6	1.9	1.8
Froto	3.2	2.1	4.1	2.8	1.8
Garan	2.1	2.1	2.0	2.0	1.9
Gubrf	8.8	2.4	4.5	2.2	4.5
Halkb	2.1	2.0	1.9	2.0	1.9
Hekts	4.7	2.2	4.0	2.5	15.3
Isctr	2.2	1.9	1.9	1.9	1.8
Kcholl	2.1	1.9	2.2	1.7	1.7
Kozaa	3.8	2.7	3.3	2.7	2.5

Kozal	2.4	2.5	2.3	2.3	2.1
Krdmdl	3.4	2.3	3.8	2.3	2.9
Petkm	4.0	1.8	2.0	1.8	2.0
Pegasus	2.4	2.7	2.2	2.4	2.1
Sahol	1.7	1.9	1.8	1.8	2.0
Sasa	11.5	2.3	6.8	6.1	3.6
Sise	3.6	1.9	2.6	1.8	2.2
Tavhl	2.2	2.1	2.1	2.0	1.8
Tcell	1.6	1.8	1.8	1.7	1.6
Thyao	2.6	2.1	3.7	2.0	1.8
Tkfen	2.6	2.0	2.0	1.9	1.8
Toasol	2.4	2.1	3.0	2.0	2.6
Ttcom	1.7	1.7	1.6	1.6	1.5
Tuprs	2.2	1.9	2.3	2.0	1.7
Vestl	4.2	2.1	2.5	2.1	1.9
Ykbnk	1.9	2.0	1.9	1.9	1.9

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tahmin görelî hatası, tahmin edilen ve gerçek hisse senedi fiyatı arasındaki tutarsızlığın gerçek hisse senedi fiyatına bölünmesiyle hesaplanır. Böylelikle yüzde kaç hata ile sonucu bildiğini ortaya çıkarır. Daha düşük bir görelî hata değeri, hisse senedi fiyatının daha kesin bir tahminini yansıtır. Analizde kullanılan algoritmalar; Derin Öğrenme, Karar Ağacı, Rastgele Orman, Gradyan Artırmalı Ağaçlar ve Destek Vektör Makineleridir.

Tablo 4 incelendiğinde sonuçlar Destek Vektör Makinesinin 30 hisse senedinden 16'sı için en düşük tahmin bağıl hatasını elde ettiğini ve ona ek olarak dördünde en düşük görelî hata katsayısını paylaşmaktadır, Derin Öğrenmenin ise 4 hisse senedi için en düşük görelî hatayla takip ettiğini gösteriyor. Karar Ağacı 4, Rastgele Orman 2 ve Gradyan Artırmalı Ağaçlar algoritması 8, hisse senedi için en düşük bağıl hataya sahiptir. Her model için ortalama görelî hata değerleri: Derin Öğrenme: 3.19 Karar Ağacı: 2.06 Rastgele Orman: 2.74 GBT: 2.16 SVM: 2.53.

Derin Öğrenme: 'Sasa' (11.5) şirketi için en yüksek hatayı gösterir, bu da şirketin bu hisse senedini tahmin etmede en kötü performansı gösterdiği anlamına gelir. En iyi performansı 'Ekgyo' (1.6) gösterir.

Karar Ağacı: Model, 1,7- 2,1 civarında hata oranlarıyla çoğu şirkette tekdüze performans gösterir. 'Sasa' yine daha yüksek bir hataya (2.3) sahipken, en iyi performans birden çok şirket arasında 1.7 ile eşit.

Rastgele Orman: 'Sasa' ve 'Gubrf', 2.0 civarında gezinen diğerlerinden önemli ölçüde daha yüksek hata oranlarına (sırasıyla 6.8 ve 4.5) sahiptir.

Gradyan Artırımlı Ağaçlar algoritması benzer şekilde, 'Sasa' en yüksek hata oranına sahiptir (6.1). Model, yaklaşık 2.0 ortalama hata ile diğer şirketler arasında benzer performansa sahip görünüyor.

SVM: 'Hekts', SVM modelinde en yüksek hatayı (15.3) sunar. Bu, tüm şirketler ve modellerdeki en yüksek hatadır. Öte yandan, 'Ttcom' en düşük hata oranına sahiptir (1,5).

'Sasa', 'Hekts' ve 'Gubrf' gibi bazı şirketlerin tüm modellerde tutarlı bir şekilde daha yüksek hata oranları göstermesi dikkat çekicidir ve bu da onların tahmin edilmesinin daha zor olabileceğini düşündürmektedir. "Ekgyo" ve "Ttcom" genellikle daha düşük hata oranlarına sahiptir, bu da bu modellerde tahmin edilmelerinin daha kolay olabileceğini gösterir. Genel olarak, farklı şirketler ve modeller arasında hata oranlarında önemli farklılıklar vardır. Daha fazla araştırma, bu farklılıkların altında yatan nedenleri anlamaya yardımcı olabilmektedir. Bu bulgular, Destek Vektör Makinesi algoritmasının incelenen hisse senetlerinin ertesi gün hisse senedi fiyatlarını tahmin etmek için en doğru model olduğunu ve Karar Ağacı algoritmasının en iyi ortalama görelî hata (2.06) performansı sunduğunu göstermektedir. Bu tür içgörüler, yatırımcıların ve tacirlerin borsadaki yatırımları hakkında bilinçli kararlar vermeleri için faydalı olabilmektedir.

Altta sunulan tablo 5'te Derin Öğrenme, Karar Ağacı, Rastgele Orman, Gradyan Artırımlı Ağaçlar ve Destek Vektör Makineleri algoritmalarının 18 yıllık süreyi kapsayan dönemdeki 30 farklı hisse senedinin beş günlük (haftalık bazda) hisse senedi fiyatları tahmini için Görelî Hata performans kriteri açısından eğitim ve test sonuçlarını yüzdelik olarak göstermektedir. Kırmızı ile tabloda belirtilen sonuçlar en iyi yüzdelik görelî hata performansını veren algoritmayı göstermektedir.

Tablo 5: Makine Öğrenme Algoritmaları Haftalık Görelî Hata Sonuçları

%

Hisse	Derin Öğrenme %	Karar Ağacı %	Rastgele Orman %	GBT %	DVM %
Akbank	4.4	4.1	3.9	4.1	3.9
Arcelik	3.8	4.0	4.0	3.7	3.7
Aselsen	8.2	3.9	4.5	5.1	3.9
Bimas	3.3	3.4	3.9	3.3	3.2
Ekgyo	3.4	3.6	3.5	3.5	3.4
Eregl	7.0	4.0	4.2	3.9	3.9
Froto	5.8	4.0	4.0	4.4	3.8
Garan	4.3	4.1	4.0	4.0	3.9
Gubrf	5.6	4.9	5.6	5.3	5.0
Halkb	4.7	4.4	4.3	4.3	4.2
Hekts	15.2	3.8	8.8	3.9	8.0
Isctr	3.9	4.0	3.9	4.0	3.9
Kcholl	4.7	3.8	3.7	3.7	3.6
Kozaa	8.1	6.0	6.2	5.9	5.8
Kozal	4.8	4.8	4.7	err	4.9
Krdmdl	10.5	4.6	5.4	4.7	4.8
Petkm	4.5	3.7	12.7	3.6	3.5
Pegasus	5.7	5.4	5.2	5.4	5.1
Sahol	4.1	3.7	3.5	2.9	3.6
Sasa	4.9	2.1	7.6	4.8	11.8
Sise	4.2	2.7	3.9	3.1	3.8
Tavhl	4.5	2.1	3.8	3.2	3.9
Tcell	3.3	2.5	3.0	2.5	3.4
Thyao	13.0	2.1	5.0	3.4	4.2
Tkfen	4.0	3.3	3.8	3.0	3.9
Toasol	7.1	2.1	4.4	3.4	4.1
Ttcom	3.2	2.7	2.8	2.3	3.1
Tuprs	4.9	1.8	3.8	2.8	3.7
Vestl	5.3	2.1	4.6	4.3	4.3
Ykbnk	4.1	3.2	3.7	3.5	4.0

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Verilen tablo; çeşitli hisse senetleri için Derin Öğrenme, Karar Ağacı, Rastgele Orman, Gradyan Artırıcı Ağaçlar ve Destek Vektör Makinesi gibi farklı makine öğrenme algoritmaları kullanılarak beş günlük hisse senedi fiyat tahmini için görelî hata sonuçlarını sunar. Göreceli hata, beş günlük bir süre boyunca tahmin edilen hisse senedi

fiyatı ile fiili hisse senedi fiyatı arasındaki farkı ölçer. Göreceli hata ne kadar düşükse makine öğrenimi algoritmasının tahmini o kadar doğru olur.

Derin Öğrenme: Bu model, 'Hekts' (15.2) ve 'Thyao' (13.0) için en yüksek hatayı sunar ve bu hisse senetleri için daha düşük performans gösterir. En iyi performansı 'Tcell' (3.3) ve 'Bimas'ta (3.3) gösterir.

Karar Ağacı: Genel olarak hata oranları önceki tabloya göre biraz daha yüksektir. 'Tuprs' en düşük hataya (1.8) sahipken, 'Halkb' en yüksek hataya (4.4) sahiptir.

Rastgele Orman: En yüksek hata oranları 'Petkm' (12,7) ve 'Hekts' (8,8) için bulunurken, 'Tuprs' en düşük (3,8) değerine sahiptir.

GBT: Model, yaklaşık 4.0 ortalama hatasıyla birçok şirkette benzer performansa sahip görünüyor. En yüksek hata oranı 'Kozal' (5,9) ve en düşük 'Sahol' (2,9) için görülmektedir.

SVM: 'Hekts' (8.0) ve 'Sasa' (11.8) diğerlerinden önemli ölçüde daha yüksek hata oranlarına sahiptir. 'Ttcom' en düşük hata oranına sahiptir (3.1).

'Hekts', 'Sasa' ve 'Petkm' gibi bazı şirketlerin tüm modellerde sürekli olarak yüksek hata oranlarına sahip olduğunu belirtmekte fayda var, bu da bu hisse senetlerini doğru bir şekilde tahmin etmenin daha zor olabileceğini gösteriyor. Aynı zamanda, 'Tuprs', 'Tcell' ve 'Ttcom' gibi diğer bazı şirketler genellikle daha düşük hata oranlarına sahiptir, bu da bu modellerin tahmin etmesinin daha kolay olabileceğini gösterir.

Farklı makine öğrenimi algoritmaları kullanan beş günlük hisse senedi fiyatı tahmini için ortalama göreceli hata sonuçları aşağıdaki gibidir:

Derin Öğrenme: %5.68, Karar Ağacı: %3,56, Rastgele Orman: %4,75 , Gradyan Artırılmış Ağaçlar: %3.73 , Destek Vektör Makinesi: %4.41

Bu ortalamaların farklı hisse senetleri arasında değişiklik gösterdiğini ve tüm hisse senetleri için genellenemeyeceğini not etmek önemlidir. Örneğin Derin Öğrenme

algoritması Hekts hissesi için ortalama %15,2'lik bir göreceli hata üretirken, Tcell hissesi için ortalama %3,3'lük bir göreceli hata üretmiştir. Benzer şekilde Karar Ağacı algoritması Gubrf hissesi için ortalama %4,9 göreceli hata üretirken, Sise hissesi için ortalama %2,7 göreceli hata üretmiştir. Bu nedenle, her hisse senedi için her bir algoritmanın performansını ayrı ayrı değerlendirmek önemlidir.

Gün ertesi fiyat tahmini sonuçları ve beş günlük fiyat tahmini sonuçları, farklı makine öğrenimi algoritmalarının göreceli hata sonuçlarını etkileyebilecek farklı tahmin ufuklarını temsil eder. Genel olarak daha kısa tahmin aralığını tahmin etmek daha kolay olabilmektedir. Bu da daha düşük nispi hata sonuçlarıyla sonuçlanırken, daha uzun tahmin ufuklarının tahmin edilmesi daha zor olabilmektedir ve bu da daha yüksek nispi hata sonuçlarına yol açar. Önceki veri setine göre hata oranları genel olarak artmış olsa da modellerin göreceli performansı tutarlı görünmektedir. Verilerdeki bir değişiklikten, farklı değerlendirme dönemlerinden veya farklı değerlendirme dönemlerinde borsa davranışındaki değişikliklerden kaynaklanmaktadır. Sonuçlar ayrıca belirli bir görev için en doğru ve güvenilir algoritmayı belirlemek için farklı makine öğrenimi algoritmalarının göreceli hatasını değerlendirmenin önemini vurguluyor.

Analiz ayrıca bazı hisse senetlerinin belirli makine öğrenme algoritmaları için eksik verilere sahip olduğunu ortaya çıkardı ve bu algoritmaların bu hisse senetleri için uygun olmayabileceğini düşündürdü. Örneğin; Kozal hisse senedi, Gradyan Artırmalı Ağaçlar algoritması için eksik verilere sahipti ve bu, bu algoritma bu hisse senedi için doğru tahminler sağlayamayacağını gösteriyor.

4.3.5. ARIMA Modeli

Bu bölümde Eviews istatistik programı kullanılarak elde edilen Arima uygulamasının akademik çevrelerce kabul edilen performans kriteri sonuçları paylaşılıp tek tek yorumlanmıştır.

Tablo 6: Akbank Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.006338	Mean dependent var	0.001565
Adjusted R-squared	0.004849	S.D. dependent var	0.117727
S.E. of regression	0.117441	Akaike info criterion	-1.443441

Sum squared resid	64.41031	Schwarz criterion	-1.432409
Log likelihood	3384.207	Hannan-Quinn criter.	-1.439561
F-statistic	4.255309	Durbin-Watson stat	1.997601
Prob(F-statistic)	0.000107		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,006338): Model, bağımlı değişkendeki değişimin yaklaşık %0,006'sını açıklar. Bu çok düşük, bu da modelin iyi bir uyum olmayabileceğini düşündürüyor.

Ortalama bağımlı var (0,001565): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,001565'tir.

Düzeltilmiş R-kare (0,004849): Bu, modeldeki öngörücü sayısı için ayarlanmış R-karedir. Bu durumda, R-kareden biraz daha düşüktür, bu da bazı öngörücülerin modele fazla katkıda bulunmayabileceğini düşündürmektedir.

SD. bağımlı var (0.117727): Bağımlı değişkenin standart sapması yaklaşık 0.118'dir. Bu, bağımlı değişkenin değişkenliğinin bir ölçüsüdür.

S.E. regresyonun (0.117441): Regresyonun standart hatası, tahminin genel doğruluğunun bir ölçüsünü sağlar. Daha düşük bir değer, daha doğru bir modeli gösterir.

Akaike bilgi kriteri (-1.443441): Model seçiminde Akaike Bilgi Kriteri (AIC) kullanılmaktadır. AIC ne kadar düşükse, model o kadar iyidir.

Toplam kare kalıntı (64.41031): Bu, kare artıkların toplamıdır, veriler ile model tahmini arasındaki tutarsızlığın bir ölçüsüdür.

Schwarz kriteri (-1.432409): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir araçtır. AIC gibi, daha düşük değerler daha iyi bir model önerir.


Log-olabilirlik (3384.207): Bu, gözlemlenen verilerin model kapsamında olma olasılığının bir ölçüsüdür. Daha yüksek değerler, verilerin model altında olma olasılığının daha yüksek olduğu anlamına gelir.

Hannan-Quinn kriteri. (-1.439561): Bu, model seçimi için başka bir kriterdir. Düşük değerler daha iyi bir model önerir.

F istatistiği (4.255309): Bu, modelin genel önemini gösterir. Bu durumda, F istatistiği genel modelin anlamlı olduğunu öne sürer.

Durbin-Watson istatistiği (1.997601): Bu, istatistiksel bir regresyon analizinden elde edilen artıklardaki otokorelasyon testidir. Değer 2'ye yakındır ve otokorelasyon olmadığını gösterir.

Prob(F-istatistiği) (0,000107): Sıfır hipotezi doğruysa (tüm katsayılar sıfıra eşitse) gözlemlenen F-istatistiğini elde etme olasılığı. Çok düşük bir değer (0.000107 gibi) modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 1. Akbank Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 7: ARÇELİK Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.006973	Mean dependent var	0.000674
Adjusted R-squared	0.005059	S.D. dependent var	0.023086

S.E. of regression	0.023027	Akaike info criterion	-4.701011
Sum squared resid	2.475195	Schwarz criterion	-4.687222
Log likelihood	11005.66	Hannan-Quinn criter.	-4.696162
F-statistic	3.642196	Durbin-Watson stat	1.956311
Prob(F-statistic)	0.000151		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,006973): Model, bağımlı değişkendeki değişimin yaklaşık %0,007'sini açıklar. Bu oldukça düşük olup, modelin verilere tam olarak uymayabileceğini göstermektedir.

Ortalama bağımlı var (0,000674): Bu, verilerinizdeki bağımlı değişkenin ortalama değeridir, yaklaşık 0,000674'tür.

Düzeltilmiş R-kare (0,005059): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %0,5'tir. Bu değer de düşüktür ve modelin uyumunun güçlü olmayabileceğini düşündürmektedir.

SD. bağımlı var (0,023086): Bağımlı değişkenin standart sapması, verilerde nispeten küçük bir değişkenliği gösterir.

S.E. regresyon (0.023027): Uyumlu model etrafındaki verilerin yayılmasını ölçen regresyonun standart hatası. Bu değer ne kadar düşükse uyum o kadar iyidir.

Akaike bilgi kriteri (-4.701011): Model seçiminde Akaike Bilgi Kriteri (AIC) kullanılmaktadır. Daha düşük bir AIC daha iyidir ve bu değer nispeten iyi bir model uyumu önerir.

Toplam kare kalıntı (2,475195): Bu, gözlemlenen ve tahmin edilen değerler arasındaki tutarsızlığın bir ölçüsü olan artıkların karesinin toplamıdır.

Schwarz kriteri (-4.687222): Model seçimi için başka bir ölçü olan Bayes Bilgi Kriteri (BIC) olarak da bilinir. Daha düşük bir BIC ayrıca daha iyi bir model önerir.


Log-olabilirlik (11005.66): Bu, modelin verilere ne kadar iyi uyduğunun bir ölçüsüdür. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-4.696162): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer, daha iyi bir modeli gösterir.

F-istatistik (3.642196): Bu, modelin genel anlamlılığını test eder. Nispeten düşük değer, genel modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Durbin-Watson istatistiği (1.956311): Bu, bir regresyon analizinden elde edilen artıklardaki otokorelasyonu test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Probe(F-istatistik) (0.000151): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F-istatistiklerini elde etme olasılığıdır. Düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 2. Arçelik Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 8 ASELSAN Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.005893	Mean dependent var	0.001120
Adjusted R-squared	0.004827	S.D. dependent var	0.026539
S.E. of regression	0.026474	Akaike info criterion	-4.423984
Sum squared resid	3.266884	Schwarz criterion	-4.415694

Log likelihood	10329.37	Hannan-Quinn criter.	-4.421068
F-statistic	5.526219	Durbin-Watson stat	2.009818
Prob(F-statistic)	0.000044		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,005893): Model, bağımlı değişkendeki değişkenliğin yaklaşık %0,0059'unu açıklar. Bu çok düşük bir değerdir ve modelin bağımlı değişkeni tahmin etmede çok iyi olmayabileceğini düşündürmektedir.

Ortalama bağımlı var (0,001120): Bağımlı değişkeninizin ortalama değeri yaklaşık 0,00112'dir.

Düzeltilmiş R-kare (0,004827): Bu, modeldeki öngörücü sayısı için ayarlanmış R-kare değeridir. Aynı zamanda oldukça düşük, bu da bazı öngörücülerin modele önemli ölçüde katkıda bulunmayabileceğini ima etmektedir.

SD. bağımlı var (0,026539): Bağımlı değişkenin standart sapması 0,0265 civarındadır. Bu, bağımlı değişken değerlerinin değişkenliğinin veya dağılımının boyutunu gösterir.

S.E. regresyon (0.026474): Regresyon modelinin standart hatası. Bu, tahminlerin doğruluğunun bir tahminini sağlar. Bu değer ne kadar düşük olursa, modelin tahminleri o kadar kesin olur.

Akaike bilgi kriteri (-4.423984): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılan bir ölçüdür. Daha düşük bir AIC değeri, daha iyi uyan bir model önerir. Bu durumda, AIC oldukça düşüktür.

Toplam kare kalıntı (3.266884): Bu, veriler ile bir tahmin modeli arasındaki tutarsızlığı ölçen kare artıkların toplamıdır.

Schwarz kriteri (-4.415694): Modelleri karşılaştırmak için başka bir ölçüm olan Bayes Bilgi Kriteri (BIC) olarak da bilinir. AIC gibi, daha düşük bir değer daha iyi uyan bir modeli gösterir.

Log-olabilirlik (10329.37): Bu, modelin verilere ne kadar iyi uyduğunun bir ölçüsüdür. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-4.421068): Model karşılaştırması için kullanılan diğer bir kriterdir. Yine, düşük değerler daha iyi uyan bir modeli gösterir.

F istatistiği (5,526219): Bu değer, modelin genel anlamlılığını test eder. Bu durumda, F istatistiği oldukça küçüktür ve modelin istatistiksel olarak anlamlı olduğunu düşündürmektedir.

Durbin-Watson istatistiği (2.009818): Bu, regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın bir değer (bunun gibi), otokorelasyon olmadığını gösterir.

Prob(F-istatistik) (0.000044): Sıfır hipotezi altında F-istatistiğin şans eseri oluşabilme olasılığı. Buradaki küçük değer, modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Genel olarak bu sonuçlar, modelin istatistiksel olarak anlamlı olmasına rağmen açıklama gücünün sınırlı olduğunu ve değişkenler arasındaki ilişkiyi tam olarak anlamak için daha fazla analiz gerekebileceğini göstermektedir.



Grafik 3. ASELSAN Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 9: BIM Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.012532	Mean dependent var	0.001103
Adjusted R-squared	0.010448	S.D. dependent var	0.021633
S.E. of regression	0.021520	Akaike info criterion	-4.837302
Sum squared resid	1.974691	Schwarz criterion	-4.822421
Log likelihood	10347.32	Hannan-Quinn criter.	-4.832045
F-statistic	6.012868	Durbin-Watson stat	2.015988
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,012532): Model, bağımlı değişkendeki değişimin yaklaşık %0,125'ini açıklamaktadır. Bu düşük, modelin güçlü bir uyum olmayabileceğini düşündürüyor.

Ortalama bağımlı var (0,001103): Bu, verilerinizdeki bağımlı değişkenin ortalama değeridir, yaklaşık 0,0011.

Düzeltilmiş R-kare (0,010448): Bu, yordayıcı sayısı için ayarlanmış R-karedir. Aynı zamanda düşüktür, bu da bazı öngörücülerin modele önemli ölçüde katkıda bulunmayabileceğini ima eder.

SD. bağımlı var (0,021633): Bu, bağımlı değişkenin standart sapmasıdır ve verilerde orta düzeyde bir değişkenlik gösterir.

S.E. regresyonun (0.021520): Regresyonun standart hatası, artıkların yayılmasının bir ölçüsü. Ne kadar düşükse, modelin tahminleri o kadar doğru olur.

Akaike bilgi kriteri (-4.837302): Akaike Bilgi Kriteri (AIC), model seçimi için bir araçtır. Daha düşük bir AIC, daha iyi bir model önerir.

Toplam kare kalıntı (1.974691): Bu, veriler ile modelin tahminleri arasındaki tutarsızlığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-4.822421): Model seçimi için başka bir ölçü olan Bayes Bilgi Kriteri (BIC) olarak da bilinir. Daha düşük bir BIC aynı zamanda daha iyi bir modeli gösterir.

Log-olabilirlik (10347.32): Bu, modelin verilere ne kadar iyi uyduğunun bir ölçüsüdür. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.


Hannan-Quinn kriteri. (-4.832045): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F istatistiği (6.012868): Bu, modelin genel önemini gösterir. Nispeten yüksek değer, genel modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Durbin-Watson istatistiği (2.015988): Bu, regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Prob (F istatistiği) (0,000000): Bu, sıfır hipotezi (tüm katsayılar sıfırdır) doğruysa, F istatistiğinin gözlenen değerini alma olasılığıdır. Çok düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.

Genel olarak, modelin bir miktar öngörü gücü olabilir ancak performansını iyileştirmek için daha fazla araştırma ve potansiyel olarak ek değişkenler gerekebilir.



Grafik 4. BIM Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 10: EKGYO Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.006404	Mean dependent var	0.000574
Adjusted R-squared	0.004350	S.D. dependent var	0.044589
S.E. of regression	0.044492	Akaike info criterion	-3.384528
Sum squared resid	5.744517	Schwarz criterion	-3.370148
Log likelihood	4929.795	Hannan-Quinn criter.	-3.379347
F-statistic	3.117323	Durbin-Watson stat	1.996078
Prob(F-statistic)	0.004784		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,006404): Bu istatistik, bağımlı değişkendeki değişkenliğin yaklaşık %0,0064'ünü açıklar. Bu, modelin verilere pek uymadığını düşündüren çok düşük bir sayıdır.

Ortalama bağımlı var (0,000574): Veri kümenizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,000574'tür.

Düzeltilmiş R-kare (0.004350): R-kare ile benzer olan bu değer, modeldeki öngörücü sayısını açıklar. Yine düşük bir değer, modelin verilere iyi uymayabileceğini gösterir.

SD. bağımlı var (0,044589): Bağımlı değişkenin standart sapması yaklaşık 0,044589'dur. Bu, bağımlı değişkendeki dağılımın veya yayılmanın bir ölçüsüdür.

S.E. regresyonun (0.044492): Regresyonun standart hatası, tahminlerin doğruluğunu ölçer. Değer ne kadar küçük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (-3.384528): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modellerin karşılaştırılmasına yardımcı olur. Daha düşük bir AIC, daha iyi bir model önerir.

Toplam kare kalıntı (5.744517): Bu, kare artıkların toplamıdır. Tepki değerlerinin uyumdan yanıt değerlerine olan toplam sapmasını ölçer.

Schwarz kriteri (-3.370148): Bayes Bilgi Kriteri (BIC) olarak da bilinir ve modelleri karşılaştırmak için başka bir araçtır. Daha düşük bir değer daha iyi bir model önerir.


Log-olabilirlik (4929.795): Bu, modelin verilere ne kadar iyi uyduğunun bir ölçüsüdür. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-3.379347): Bu, model seçimi için başka bir kriterdir. Daha düşük bir değer daha iyi bir model önerir.

F-istatistik (3.117323): Bu, modelin genel önemini test eder. Değer nispeten düşüktür, bu da modelin istatistiksel olarak anlamlı olduğunu düşündürmektedir.

Durbin-Watson istatistiği (1.996078): Bu, regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. Değer 2'ye yakındır ve otokorelasyon olmadığını gösterir.

Prob (F istatistiği) (0,004784): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F istatistiğini elde etme olasılığıdır. Buradaki düşük değer, modelin istatistiksel olarak anlamlı olduğunu göstermektedir.



Grafik 5. EKGYO Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 11: EREGLİ Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.533030	Mean dependent var	7.27E-05

Adjusted R-squared	0.532128	S.D. dependent var	0.271599
S.E. of regression	0.185777	Akaike info criterion	-0.524609
Sum squared resid	160.9686	Schwarz criterion	-0.510810
Log likelihood	1236.012	Hannan-Quinn criter.	-0.519756
F-statistic	591.5316	Durbin-Watson stat	2.000221
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,533030): Model, bağımlı değişkendeki değişimin yaklaşık %53'ünü açıklar. Bu, verilere orta düzeyde bir uyum olduğunu göstermektedir.

Ortalama bağımlı var (7.27E-05): Veri kümenizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,0000727'dir.

Düzeltilmiş R-kare (0,532128): Bu, modeldeki öngörücü sayısı için ayarlanmış R-karedir. R-kareden biraz daha düşüktür, bu da bazı öngörücülerin modele önemli ölçüde katkıda bulunmayabileceğini düşündürmektedir.

SD. bağımlı var (0,271599): Bağımlı değişkenin standart sapması yaklaşık 0,272'dir. Bu, bağımlı değişkenin ortalamadan değişkenliğini veya dağılımını ölçer.

S.E. regresyonun (0.185777): Regresyonun standart hatası, tahminlerin doğruluğunu ölçer. Bu değer ne kadar düşük olursa, modelin tahminleri o kadar doğru olur.

Akaike bilgi kriteri (-0.524609): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılan bir ölçüdür. AIC'si en düşük olan model tercih edilir. Bu durumda, AIC oldukça düşüktür ve modelin iyi bir uyum olduğunu düşündürmektedir.

Toplam kare kalıntı (160.9686): Bu, veriler ile tahmin modeli arasındaki toplam tutarsızlığın bir ölçüsü olan artıkların karesinin toplamıdır.

Schwarz kriteri (-0.510810): Bayes Bilgi Kriteri (BIC) olarak da bilinen bu, farklı istatistiksel modelleri karşılaştırmak için kullanılan başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir model önerir.

Log olasılığı (1236.012): Bu, modelin uyum iyiliğinin bir ölçüsüdür. Daha yüksek değerler, verilerin model altında olma olasılığının daha yüksek olduğunu gösterir.


Hannan-Quinn kriteri. (-0.519756): Model karşılaştırması için kullanılan bir diğer kriterdir. Daha düşük bir değer, daha iyi bir modeli gösterir.

F istatistiği (591.5316): Bu, modelin genel önemini ölçer. Yüksek değer, en azından bazı regresyon katsayılarının sıfır olmadığını ve genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.000221): Bu, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer, otokorelasyon olmadığını gösterir.

Prob (F istatistiği) (0,000000): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) F istatistiğinin gözlemlenen değerini elde etme olasılığınızdır. Düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.

Akaike ve Schwarz kriterleri, modelin uyum ve karmaşıklık arasında iyi bir denge sağladığını göstermektedir. Genel olarak model verilere makul bir şekilde uyuyor gibi görünmektedir.



Grafik 6. EREGLİ Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 12: FROTO Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.010341	Mean dependent var	0.001081
Adjusted R-squared	0.008433	S.D. dependent var	0.024518
S.E. of regression	0.024414	Akaike info criterion	-4.584520
Sum squared resid	2.782359	Schwarz criterion	-4.570731
Log likelihood	10733.19	Hannan-Quinn criter.	-4.579671
F-statistic	5.419472	Durbin-Watson stat	1.999838
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,010341): Model, bağımlı değişkendeki değişkenliğin yaklaşık %0,01'ünü oluşturur. Bu, modelin çok güçlü bir uyum olmayabileceğini düşündüren çok düşük bir değerdir.

Ortalama bağımlı var (0,001081): Veri kümenizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,00108'dir.

Düzeltilmiş R-kare (0,008433): Bu, modeldeki öngörücü sayısı için ayarlanmış R-kare değeridir. Ayrıca oldukça düşüktür, bu da bazı öngörücülerin modele önemli ölçüde katkıda bulunmayabileceğini düşündürmektedir.

SD. bağımlı var (0,024518): Bu, bağımlı değişkenin standart sapmasıdır ve verilerde nispeten küçük bir değişkenliği gösterir.

S.E. regresyon (0,024414): Modelin tahminlerinin kesinliğinin bir ölçüsü olan regresyonun standart hatası. Bu sayı ne kadar düşük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (-4.584520): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir model önerir.

Toplam kare kalıntı (2.782359): Bu, gözlemlenen ve tahmin edilen değerler arasındaki toplam farklılığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-4.570731): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (10733.19): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-4.579671): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F-istatistik (5.419472): Bu, modelin genel önemini ölçer. Nispeten yüksek değer, genel modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Durbin-Watson istatistiği (1,999838): Bu, regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Prob (F istatistiği) (0.000000): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F istatistiğini elde etme olasılığıdır. Son derece düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 7. FROTO Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 13: GARAN Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.007491	Mean dependent var	0.003091

Adjusted R-squared	0.005791	S.D. dependent var	0.152022
S.E. of regression	0.151581	Akaike info criterion	-0.932992
Sum squared resid	107.2794	Schwarz criterion	-0.920581
Log likelihood	2191.267	Hannan-Quinn criter.	-0.928627
F-statistic	4.405160	Durbin-Watson stat	1.998915
Prob(F-statistic)	0.000025		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,007491): Model bağımlı değişkendeki değişimin yaklaşık %0,0075'ini açıklar. Bu, modelin verilere çok iyi uymadığını gösteren çok düşük bir değerdir.

Ortalama bağımlı var (0,003091): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,00309'dur.

Düzeltilmiş R-kare (0,005791): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %0,58'dir. Bu aynı zamanda çok düşük bir değerdir ve modelin verilere zayıf bir şekilde uyduğunu düşündürmektedir.

SD. bağımlı var (0.152022): Bu, bağımlı değişkenin standart sapmasıdır ve verilerdeki değişkenliği gösterir.

S.E. regresyonun (0.151581): Modelin tahminlerinin doğruluğunu gösteren regresyonun standart hatası. Bu değer ne kadar düşük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (-0.932992): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (107.2794): Gözlenen ve tahmin edilen değerler arasındaki toplam tutarsızlığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-0.920581): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (2191.267): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-0.928627): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F-istatistik (4.405160): Bu, modelin genel önemini ölçer. Değer nispeten düşüktür ancak yine de modelin istatistiksel olarak anlamlı olduğunu göstermektedir.

Durbin-Watson istatistiği (1.998915): Bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Probe(F-istatistik) (0.000025): Tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F-istatistiklerini elde etme olasılığıdır. Çok düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 8. GARAN Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 14: GUBRF Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.453084	Mean dependent var	0.000641
Adjusted R-squared	0.452146	S.D. dependent var	0.936862
S.E. of regression	0.693438	Akaike info criterion	2.109849
Sum squared resid	2244.638	Schwarz criterion	2.122262
Log likelihood	-4924.882	Hannan-Quinn criter.	2.114214
F-statistic	483.3908	Durbin-Watson stat	1.996918
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,453084): Model, bağımlı değişkendeki değişimin yaklaşık %45,31'ini açıklar. Bu oldukça iyi bir değerdir ve modelin verilere oldukça iyi uyduğunu düşündürmektedir.

Ortalama bağımlı var (0,000641): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,000641'dir.

Düzeltilmiş R-kare (0,452146): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %45,21'dir. Bu oldukça iyi bir değerdir ve modelin verilere makul bir şekilde uyduğunu düşündürmektedir.

SD. bağımlı var (0,936862): Bu, bağımlı değişkenin standart sapmasıdır ve verilerdeki değişkenliği gösterir.

S.E. regresyonun (0.693438): Modelin tahminlerinin doğruluğunu gösteren regresyonun standart hatası. Bu değer ne kadar düşük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (2.109849): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (2244.638): Bu, gözlenen ve tahmin edilen değerler arasındaki toplam tutarsızlığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (2.122262): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (-4924.882): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir. Ancak bu durumda log olasılığı negatiftir ve zayıf bir uyum olduğunu düşündürmektedir.

Hannan-Quinn kriteri. (2.114214): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F istatistiği (483.3908): Bu, modelin genel önemini ölçer. Değerin yüksek olması, modelin istatistiksel olarak anlamlı olduğunu düşündürmektedir.

Durbin-Watson istatistiği (1.996918): Bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Prob (F istatistiği) (0.000000): Tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F istatistiğini elde etme olasılığıdır. Çok düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 9. GUBRF Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 15: HALKB Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.004298	Mean dependent var	-7.27E-05
Adjusted R-squared	0.001939	S.D. dependent var	0.025995
S.E. of regression	0.025969	Akaike info criterion	-4.461126
Sum squared resid	2.562083	Schwarz criterion	-4.444730
Log likelihood	8506.214	Hannan-Quinn criter.	-4.455300
F-statistic	1.821937	Durbin-Watson stat	2.001357
Prob(F-statistic)	0.059410		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,004298): Model bağımlı değişkendeki değişimin yaklaşık %0,0043'ünü açıklar. Bu, modelin verilere çok iyi uymadığını gösteren çok düşük bir değerdir.

Ortalama bağımlı var (-7,27E-05): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık -0,0000727'dir.

Düzeltilmiş R-kare (0,001939): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %0,19'dur. Bu aynı zamanda çok düşük bir değerdir ve modelin verilere zayıf bir şekilde uyduğunu düşündürmektedir.

SD. bağımlı var (0.025995): Bu, bağımlı değişkenin standart sapmasıdır ve verilerdeki değişkenliği gösterir.

S.E. regresyonun (0.025969): Modelin tahminlerinin doğruluğunu gösteren regresyonun standart hatası. Bu değer ne kadar düşük olursa tahminler o kadar doğru olur.

Akaike bilgi kriteri (-4.461126): Akaike Bilgi Kriteri (AIC) farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (2.562083): Bu, gözlenen ve tahmin edilen değerler arasındaki toplam farklılığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-4.444730): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (8506.214): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-4.455300): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F istatistiği (1.821937): Modelin genel önemini ölçer. Nispeten düşük değer, modelin genel istatistiksel anlamlılığının sınırda olduğunu gösterir.

Durbin-Watson istatistiği (2.001357): Bir regresyon analizinden elde edilen artıklardaki otokorelasyonu test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Prob (F istatistiği) (0,059410): Bu tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F istatistiğini elde etme olasılığıdır. Değer 0,05'in üzerindedir ve bu, modelin sonuçlarının rasgele şansa bağlı olma olasılığının %5'ten fazla olduğunu gösterir.



Grafik 10. HALKB Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 16: HEKTS Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.651403	Mean dependent var	-4.19E-06
Adjusted R-squared	0.651104	S.D. dependent var	0.079297
S.E. of regression	0.046839	Akaike info criterion	-3.281027
Sum squared resid	10.23881	Schwarz criterion	-3.274125
Log likelihood	7669.478	Hannan-Quinn criter.	-3.278599
F-statistic	2180.235	Durbin-Watson stat	2.004406
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,651403): Model, bağımlı değişkendeki değişimin yaklaşık %65'ini açıklar. Bu, modelin verilere iyi uyduğunu gösteren oldukça yüksek bir değerdir.

Ortalama bağımlı var (-4.19E-06): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık -4, 19'dur.

Düzeltilmiş R-kare (0,651104): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %65,11'dir. Bu aynı zamanda yüksek bir değerdir ve modelin verilere iyi uyum sağladığını gösterir.

SD. bağımlı var (0,079297): Bu, bağımlı değişkenin standart sapmasıdır ve verilerdeki değişkenliği gösterir.

S.E. regresyonun (0.046839): Modelin tahminlerinin doğruluğunu gösteren regresyonun standart hatası. Bu değer ne kadar düşük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (-3.281027): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (10.23881): Bu, gözlenen ve tahmin edilen değerler arasındaki toplam tutarsızlığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-3.274125): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.

Log-olabilirlik (7669.478): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.


Hannan-Quinn kriteri. (-3.278599): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F istatistiği (2180.235): Bu, modelin genel önemini ölçer. Çok yüksek değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.004406): Bu, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Prob(F istatistiği) (0.000000): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F istatistiğini elde etme olasılığıdır. Çok düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.

Özetle, model yüksek bir R-kare değeri ile verilere iyi uyuyor gibi görünmektedir.



Grafik 11. HEKTS Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 17: İSCTR Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.003095	Mean dependent var	0.000517
Adjusted R-squared	0.001814	S.D. dependent var	0.024314
S.E. of regression	0.024292	Akaike info criterion	-4.595812
Sum squared resid	2.756332	Schwarz criterion	-4.586159
Log likelihood	10756.60	Hannan-Quinn criter.	-4.592417
F-statistic	2.416549	Durbin-Watson stat	1.999989
Prob(F-statistic)	0.024682		

R-kare (0,003095): Model, bağımlı değişkendeki değişimin yaklaşık %0,0031'ini açıklar. Bu, modelin verilere çok iyi uymadığını gösteren çok düşük bir değerdir.

Ortalama bağımlı var (0,000517): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,000517'dir.

Düzeltilmiş R-kare (0,001814): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %0,18'dir. Bu aynı zamanda çok düşük bir değerdir ve modelin verilere zayıf bir şekilde uyduğunu düşündürmektedir.

SD. bağımlı var (0,024314): Bu, bağımlı değişkenin standart sapmasıdır ve verilerdeki değişkenliği gösterir.

S.E. regresyonun (0.024292): Modelin tahminlerinin doğruluğunu gösteren regresyonun standart hatası. Bu değer ne kadar düşük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (-4.595812): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (2,756332): Bu, gözlenen ve tahmin edilen değerler arasındaki toplam farklılığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-4.586159): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.

Log-olabilirlik (10756.60): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.


Hannan-Quinn kriteri. (-4.592417): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F istatistiği (2,416549): Bu, modelin genel önemini ölçer. Nispeten düşük değer, modelin istatistiksel olarak anlamlı olmayabileceğini düşündürmektedir.

Durbin-Watson istatistiği (1.999989): Bu, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Prob(F istatistiği) (0,024682): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F istatistiğini elde etme olasılığıdır. Değer 0,05'ten küçüktür ve bu, modelin sonuçlarının rasgele şansa bağlı olma olasılığının %5'ten az olduğunu gösterir.

Genel olarak, model sınırlı öngörü gücüne sahip olabilir ancak istatistiksel olarak anlamlıdır.



Grafik 12. İSCTR Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 18: KCHOL Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.007424	Mean dependent var	0.000648
Adjusted R-squared	0.005509	S.D. dependent var	0.022113
S.E. of regression	0.022052	Akaike info criterion	-4.787946
Sum squared resid	2.268493	Schwarz criterion	-4.774149
Log likelihood	11201.82	Hannan-Quinn criter.	-4.783094
F-statistic	3.877057	Durbin-Watson stat	1.963085
Prob(F-statistic)	0.000065		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,007424): Model, bağımlı değişkendeki değişimin yaklaşık %0,0074'ünü açıklar. Bu oldukça düşük bir değerdir ve modelin verilerdeki değişkenliğin çoğunu yakalamadığını gösterir.

Ortalama bağımlı var (0,000648): Verilerinizdeki bağımlı değişkenin ortalama değeri yaklaşık 0,000648'dir.

Düzeltilmiş R-kare (0,005509): Modeldeki yordayıcı sayısı ayarlandıktan sonra, açıklanan varyasyon yaklaşık %0,55'tir. Bu aynı zamanda nispeten düşük bir değerdir ve modelin verilere zayıf bir şekilde uyduğunu düşündürmektedir.

SD. bağımlı var (0,022113): Bu, bağımlı değişkenin standart sapmasıdır ve verilerdeki değişkenlik düzeyini gösterir.

S.E. regresyon (0.022052): Modelin tahminlerinin doğruluğunu gösteren regresyonun standart hatası. Bu değer ne kadar düşük olursa, tahminler o kadar doğru olur.

Akaike bilgi kriteri (-4.787946): Akaike Bilgi Kriteri (AIC), farklı istatistiksel modelleri karşılaştırmak için kullanılır. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (2,268493): Bu, gözlenen ve tahmin edilen değerler arasındaki toplam farklılığı gösteren kare artıkların toplamıdır.

Schwarz kriteri (-4.774149): Bayes Bilgi Kriteri (BIC) olarak da bilinir, model seçimi için başka bir ölçüdür. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (11201.82): Modelin verilere ne kadar iyi uyduğunun bu ölçüsü. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri. (-4.783094): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer aynı zamanda daha iyi bir model önerir.

F-istatistik (3.877057): Bu, modelin genel önemini ölçer. Daha yüksek bir F istatistiği genellikle istatistiksel olarak daha anlamlı bir model önerir.

Durbin-Watson istatistiği (1.963085): Bu, bir regresyon analizinden elde edilen artıklardaki otokorelasyonu test eder. Bu durumda olduğu gibi 2'ye yakın bir değer otokorelasyon olmadığını gösterir.

Prob(F-istatistiği) (0.000065): Bu, tüm regresyon katsayıları sıfırsa (sıfır hipotezi) gözlenen F-istatistiklerini elde etme olasılığıdır. Düşük değer, modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 13. KCHOL Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 19: KOZAA Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.030781	Mean dependent var	0.005562
Adjusted R-squared	0.028912	S.D. dependent var	0.227535
S.E. of regression	0.224222	Akaike info criterion	-0.150141
Sum squared resid	234.5847	Schwarz criterion	-0.136347
Log likelihood	361.0294	Hannan-Quinn criter.	-0.145290
F-statistic	16.46520	Durbin-Watson stat	2.011796
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,030781): Model, bağımlı değişkendeki değişkenliğin yaklaşık %,0308'ini açıklar. Bu nispeten düşük bir değerdir ve modelin verilerin değişkenliğinin önemli bir bölümünü yakalamadığını düşündürmektedir.

Ortalama bağımlı var (0.005562): Veri setindeki bağımlı değişkenin ortalama değeri yaklaşık 0.005562'dir.

Düzeltilmiş R-kare (0,028912): Öngörücü sayısını hesaba kattıktan sonra model, bağımlı değişkendeki değişimin yaklaşık %2,89'unu açıklar. Bu değer de nispeten düşüktür ve verilere zayıf bir model uyumu olduğunu gösterir.

SD. bağımlı var (0,227535): Verilerdeki değişkenliği veya dağılımı gösteren bağımlı değişkenin standart sapması.

S.E. regresyonun (0,224222): Gözlenen değerlerin regresyon çizgisinden ortalama uzaklığını gösteren regresyonun standart hatası. Düşük değerler daha iyidir.

Akaike bilgi kriteri (-0.150141): Akaike Bilgi Kriteri (AIC), farklı modelleri karşılaştırmaya yardımcı olur. Düşük değerler daha iyi bir modeli gösterir.

Toplam kare kalıntı (234.5847): Bu, modelin toplam hatasını gösteren, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin toplamıdır.

Schwarz kriteri (-0.136347): Bayes Bilgi Kriteri (BIC) olarak da bilinen bu da bir diğer model karşılaştırma kriteridir. Düşük değerler daha iyi bir modeli gösterir.


Log-olabilirlik (361.0294): Bu, olabilirlik fonksiyonunun günlüğüdür ve daha yüksek bir değer genellikle daha iyi uyan bir modeli gösterir.

Hannan-Quinn kriteri. (-0.145290): Model seçiminde kullanılan diğer bir kriterdir. Daha düşük bir değer, daha iyi bir modeli gösterir.

F istatistiği (16.46520): Bu, modelin genel öneminin bir ölçüsüdür. Daha büyük bir F istatistiği, modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.011796): Bu istatistik, artıklardaki otokorelasyon için test eder. Bu durumda olduğu gibi 2'ye yakın bir değer otokorelasyon olmadığını gösterir.

Prob(F-istatistiği) (0.000000): Bu, tüm regresyon katsayıları sıfır (sıfır hipotezi) verilen F-istatistiğini gözlemleme olasılığıdır. Düşük değer (0,05'ten küçük), modelin istatistiksel olarak anlamlı olduğunu gösterir.



Grafik 14. KOZAA Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 20: KOZAL Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.000000	Mean dependent var	0.000884
Adjusted R-squared	0.000000	S.D. dependent var	0.029466
S.E. of regression	0.029466	Akaike info criterion	-4.210868
Sum squared resid	2.709714	Schwarz criterion	-4.208932
Log likelihood	6574.165	Hannan-Quinn criter.	-4.210173
Durbin-Watson stat	1.980197		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,000000): Model, sonuç değişkenindeki değişkenliğin hiçbirini açıklamaz. Bu, modelin bağımlı değişkeni tahmin etmede yararlı olmayabileceğini düşündürmektedir.

Ortalama bağımlı var (0.000884): Veri kümenizdeki bağımlı değişkenin ortalama değeri.

Düzeltilmiş R-kare (0,000000): R-kare değerine benzer şekilde, düzeltilmiş R-kare, modeldeki yordayıcı sayısını ayarladıktan sonra bile modelin bağımlı değişkendeki değişkenliğin hiçbirini açıklamadığını gösterir.

SD. bağımlı var (0.029466): Bağımlı değişkenin değişimini gösteren standart sapması.

S.E. regresyon (0.029466): Gözlenen değerlerin regresyon çizgisinden düştüğü ortalama mesafe veya esasen artıkların veya tahmin hatalarının standart sapması.

Akaike bilgi kriteri (-4.210868): Akaike Bilgi Kriteri (AIC), istatistiksel modelin uyum iyiliğini değerlendirir. Daha düşük bir AIC, daha iyi bir modeli gösterir.

Toplam kare kalıntı (2.709714): Bu, artıkların karelerinin toplamıdır (tahmin hataları). Model tahmininin toplam hatasını temsil eder.


Schwarz kriteri (-4.208932): Bayes Bilgi Kriteri (BIC) olarak da bilinen bu, model uyumunun başka bir ölçüsüdür. AIC'de olduğu gibi, daha düşük bir değer daha iyi bir modeli gösterir.

Log-olabilirlik (6574.165): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğüdür. Daha yüksek değerler daha iyidir.

Hannan-Quinn kriteri. (-4.210173): Hem AIC hem de BIC'ye benzer şekilde model seçiminde Hannan-Quinn kriteri kullanılmaktadır. Daha düşük bir değer, daha iyi bir modeli gösterir.

Durbin-Watson istatistiği (1.980197): Bu istatistik, bir regresyon analizinden elde edilen artıklarda otokorelasyon varlığını tespit eder. 2'ye yakın değer otokorelasyon olmadığını gösterir.

Sonuç olarak, R-kare ve düzeltilmiş R-kare değerlerinin sıfır olduğu göz önüne alındığında, makul bir model uyumu öneren diğer bazı uyum istatistiklerine rağmen, bu model bağımlı değişkeni tahmin etmek veya açıklamak için yararlı görünmemektedir.



Grafik 15. KOZAL Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 21: KRMD Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.052074	Mean dependent var	0.002279
Adjusted R-squared	0.050450	S.D. dependent var	0.093402
S.E. of regression	0.091016	Akaike info criterion	-1.953540
Sum squared resid	38.67718	Schwarz criterion	-1.941130
Log likelihood	4578.331	Hannan-Quinn criter.	-1.949176
F-statistic	32.06135	Durbin-Watson stat	1.999900
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,052074): Model, sonuç değişkenindeki değişkenliğin yaklaşık %0,052'sini açıklar. Yüksek bir yüzde olmasa da modelin bir miktar öngörü gücü vardır.

Ortalama bağımlı var (0,002279): Veri kümenizdeki bağımlı değişkenin ortalama değeri.

Düzeltilmiş R-kare (0.050450): Bu rakam, R-kare değerinden biraz daha azdır, aynı zamanda modeldeki öngörücü sayısını da açıklar. Bu durumda, yordayıcı sayısına göre ayarlandıktan sonra sonuç değişkenindeki değişkenliğin yaklaşık %5'ini açıklar.

SD. bağımlı var (0.093402): Bu, bağımlı değişkenin değişimini gösteren standart sapmasıdır.

S.E. regresyon (0.091016): Bu, gözlemlenen değerlerin regresyon çizgisinden düştüğü ortalama mesafe olan regresyonun standart hatasıdır. Esasen artıkların veya tahmin hatalarının standart sapmasıdır.

Akaike bilgi kriteri (-1.953540): Akaike Bilgi Kriteri (AIC), istatistiksel modelleri karşılaştırmak için kullanılan bir ölçüdür. Daha düşük değerler, daha iyi uyan modelleri gösterir.

Toplam kare kalıntı (38.67718): Bu, artıkların karelerinin toplamıdır (tahmin hataları). Modelin toplam tahmin hatasını temsil eder.

Schwarz kriteri (-1.941130): Bayes Bilgi Kriteri (BIC) olarak da bilinir, istatistiksel modelleri karşılaştırmak için kullanılan başka bir ölçüdür. Düşük değerler daha iyi modelleri gösterir.


Log-olabilirlik (4578.331): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğüdür. Daha yüksek değerler daha iyidir.

Hannan-Quinn kriteri. (-1.949176): Model seçiminde kullanılan diğer bir bilgi kriteridir. Düşük değerler daha iyi bir modeli gösterir.

Durbin-Watson istatistiği (1.999900): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. Bu durumda olduğu gibi 2'ye yakın bir değer otokorelasyon olmadığını gösterir.

F istatistiği (32.06135) ve Prob(F istatistiği) (0.000000): F istatistiği, model uyumunun ne kadar önemli olduğunun bir ölçüsüdür. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Sonuç olarak, sonuç değişkenindeki değişkenliğin yalnızca küçük bir kısmını açıklasa da bu model F-istatistik ve p-değerinin önerdiği gibi bir miktar öngörü gücüne sahiptir. AIC, BIC ve Durbin-Watson istatistiğine göre model oldukça uygun görünmektedir.



Grafik 16. KRMD Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 22: PETKİM Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.007516	Mean dependent var	0.000679
Adjusted R-squared	0.005599	S.D. dependent var	0.023412
S.E. of regression	0.023346	Akaike info criterion	-4.673529
Sum squared resid	2.539425	Schwarz criterion	-4.659718
Log likelihood	10920.35	Hannan-Quinn criter.	-4.668672
F-statistic	3.920117	Durbin-Watson stat	2.005661
Prob(F-statistic)	0.000056		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,007516): Bu istatistik bize bağımlı değişkenin varyansının yaklaşık %0,0075'inin model tarafından açıklandığını söyler. Bu, modelin sınırlı tahmin gücüne sahip olduğunu düşündüren yüksek bir yüzde değildir.

Ortalama bağımlı var (0.000679): Bu, veri kümenizdeki bağımlı değişkenin ortalama değeridir.

Düzeltilmiş R-kare (0,005599): Bu istatistik, modeldeki öngörücü sayısına göre ayarlanan R-karedir. Kullanılan yordayıcı sayısına bakıldığında bağımlı değişkendeki varyansın yaklaşık %0,56'sının model tarafından açıklandığını göstermektedir.

SD. bağımlı var (0,023412): Bağımlı değişkendeki değişim miktarını gösteren, bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0,023346): Bu, modeldeki açıklanamayan varyansın standart sapmasının bir tahmini olan regresyonun standart hatasıdır.

Akaike bilgi kriteri (-4.673529): Bu, istatistiksel modelleri karşılaştırmak için kullanılan bir ölçüdür. Daha düşük değerler, daha iyi uyan modelleri gösterir.

Toplam kare kalıntı (2.539425): Bu, artıkların karelerinin toplamı veya tahmin hatalarıdır. Modelin toplam tahmin hatasının bir ölçüsüdür.

Schwarz kriteri (-4.659718): Bayes Bilgi Kriteri (BIC) olarak da bilinir, istatistiksel modelleri karşılaştırmak için kullanılan başka bir ölçüdür. Düşük değerler daha iyi modelleri gösterir.


Log-olabilirlik (10920.35): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğüdür. Daha yüksek değerler daha iyidir.

Hannan-Quinn kriteri (-4.668672): Model seçiminde kullanılan bir diğer bilgi kriteridir. Düşük değerler daha iyi bir modeli gösterir.

F istatistiği (3,920117) ve Prob(F istatistiği) (0,000056): F istatistiği, model uyumunun ne kadar önemli olduğunun bir ölçüsüdür. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.005661): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. Bu durumda olduğu gibi 2'ye yakın bir değer otokorelasyon olmadığını gösterir.

Sonuç olarak, tüm model istatistiksel olarak anlamlı olsa ve otokorelasyon göstermese de, sonuç değişkenindeki değişkenliğin çok küçük bir bölümünü açıklayarak, sınırlı öngörü gücüne sahip olduğunu düşündürmektedir.



Grafik 17. PETKİM Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 23: PGSUS Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.018681	Mean dependent var	0.000961
Adjusted R-squared	0.015697	S.D. dependent var	0.029275
S.E. of regression	0.029044	Akaike info criterion	-4.236412
Sum squared resid	1.941862	Schwarz criterion	-4.216515
Log likelihood	4901.055	Hannan-Quinn criter.	-4.229159
F-statistic	6.260192	Durbin-Watson stat	1.988903
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,018681): Bu istatistik, bağımlı değişkenin varyansının yaklaşık %1,87'sinin model tarafından açıklanabileceğini göstermektedir. Bu, modelin güçlü bir tahmin gücüne sahip olmayabileceğini düşündüren yüksek bir yüzde değildir.

Ortalama bağımlı var (0.000961): Bu, veri kümenizdeki bağımlı değişkenin ortalama değeridir.

Düzeltilmiş R-kare (0,015697): Bu istatistik, modeldeki öngörücü sayısına göre ayarlanan R-kare değeridir. Kullanılan yordayıcı sayısı dikkate alındığında, bağımlı değişkendeki varyansın yaklaşık %1,57'sinin model tarafından açıklanabileceğini göstermektedir.

SD. bağımlı değişken (0,029275): Bu, bağımlı değişkendeki varyasyon miktarını temsil eden bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0.029044): Modeldeki açıklanamayan varyansın standart sapmasını tahmin eden regresyonun standart hatasıdır.

Akaike bilgi kriteri (-4.236412): Bu, istatistiksel modelleri karşılaştırmak için kullanılan bir ölçüdür. Daha düşük değerler daha uygun modeller önerir.

Toplam kare kalıntı (1.941862): Bu, artıkların veya tahmin hatalarının karelerinin toplamıdır. Modelin toplam tahmin hatasının bir ölçüsüdür.

Schwarz kriteri (-4.216515): Bayes Bilgi Kriteri (BIC) olarak da bilinir, istatistiksel modelleri karşılaştırmak için kullanılan başka bir ölçüdür. Düşük değerler daha iyi modeller önerir.


Log-olabilirlik (4901.055): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğüdür. Daha yüksek değerler daha iyidir.

Hannan-Quinn kriteri (-4.229159): Model seçiminde kullanılan bir diğer bilgi kriteridir. Düşük değerler daha iyi bir modeli gösterir.

F istatistiği (6.260192) ve Prob(F istatistiği) (0.000000): F istatistiği, model uyumunun ne kadar önemli olduğunun bir ölçüsüdür. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (1.988903): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. Bu durumda olduğu gibi 2'ye yakın bir değer otokorelasyon olmadığını gösterir.

Genel olarak modelin bir miktar istatistiksel önemi olabilir ancak bağımlı değişkendeki varyasyonun önemli bir oranını açıklamaz ve artıklarda otokorelasyonla ilgili bazı sorunlar olabilir.



Grafik 18. PGSUS Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 24: SAHOL Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.015375	Mean dependent var	0.003749
Adjusted R-squared	0.013477	S.D. dependent var	0.152802
S.E. of regression	0.151769	Akaike info criterion	-0.930463
Sum squared resid	107.5212	Schwarz criterion	-0.916674
Log likelihood	2186.353	Hannan-Quinn criter.	-0.925614
F-statistic	8.099185	Durbin-Watson stat	2.015790
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,015375): Bu istatistik, modelin bağımlı değişkendeki değişimin yaklaşık %0,154'ünü açıkladığını göstermektedir. Modelin bağımlı değişkeni tahmin etmede çok iyi olmayabileceğini ima eden düşük bir değerdir.

Ortalama bağımlı var (0,003749): Bu, veri kümenizdeki bağımlı değişkenin ortalama değeridir.

Düzeltilmiş R-kare (0,013477): Bu istatistik, R-karenin modeldeki öngörücü sayısına göre ayarlanmış değiştirilmiş bir versiyonudur. Bağımlı değişkendeki varyansın yaklaşık %1,35'inin bağımsız değişkenlerden tahmin edilebileceğini göstermektedir.

SD. bağımlı var (0.152802): Bu, bağımlı değişkenin dağılımının bir ölçüsünü sağlayan bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0,151769): Modeldeki açıklanamayan varyansın dağılımını ölçen regresyonun standart hatasıdır.

Akaike bilgi kriteri (-0.930463): Akaike Bilgi Kriteri (AIC), belirli bir veri seti için istatistiksel modellerin göreceli kalitesinin bir ölçüsüdür. Düşük değerler daha iyi uyan bir modeli gösterir.

Toplam kare kalıntı (107.5212): Bu, artıkların karelerinin toplamıdır. Modelin toplam tahmin hatasının bir ölçüsüdür.

Schwarz kriteri (-0.916674): Bayes Bilgi Kriteri (BIC) olarak da bilinen bu, istatistiksel modelleri karşılaştırmak için başka bir ölçüdür. Düşük değerler daha iyidir.


Log-olabilirlik (2186.353): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğüdür. Daha yüksek değerler daha iyidir.

Hannan-Quinn kriteri (-0.925614): Model seçiminde kullanılan bir diğer bilgi kriteridir. Düşük değerler daha iyi bir model önerir.

F istatistiği (8.099185) ve Prob(F istatistiği) (0.000000): F istatistiği, model uyumunun ne kadar önemli olduğunu bir ölçüsüdür. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.015790): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer artıklarda otokorelasyon olmadığını göstermektedir.

Özetle, genel model istatistiksel olarak anlamlı olsa ve otokorelasyon olmasa da, model sonuç değişkenindeki değişkenliğin çok küçük bir bölümünü açıklayarak, sınırlı öngörü gücüne sahip olduğunu düşündürmektedir. Bu model, eğer mevcutsa, ek ilgili öngörücülerin dahil edilmesinden potansiyel olarak yararlanabilir.



Grafik 19. SAHOL Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 25: SASA Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.601744	Mean dependent var	-3.59E-06
Adjusted R-squared	0.601061	S.D. dependent var	0.063394
S.E. of regression	0.040040	Akaike info criterion	-3.593912
Sum squared resid	7.483891	Schwarz criterion	-3.581500
Log likelihood	8413.364	Hannan-Quinn criter.	-3.589547
F-statistic	881.6374	Durbin-Watson stat	2.002950
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,601744): Bu istatistik bize, bağımlı değişkendeki değişimin yaklaşık %60,17'sinin bu ARIMA modeli tarafından açıklandığını söyler. Bu nispeten yüksek bir değer olup, modelin bağımlı değişkendeki değişimi iyi bir açıklama gücüne sahip olduğunu göstermektedir.

Ortalama bağımlı var (-3,59E-06): Veri setindeki bağımlı değişkenin ortalama değerinin sıfıra çok yakın olması model tahminlerinin ortalamaya yakın olduğunu düşündürmektedir.

Düzeltilmiş R-kare (0,601061): Düzeltilmiş R-kare, R-karenin modeldeki öngörücü sayısını ayarlayan değiştirilmiş bir versiyonudur. Burada, bağımlı değişkendeki değişimin yaklaşık %60,11'inin bu modeldeki yordayıcılardan tahmin edilebileceği anlamına gelmektedir.

SD. bağımlı var (0.063394): Bu, bağımlı değişkenin standart sapmasıdır. Bağımlı değişkeninizin dağılımının veya yayılmasının bir ölçüsüdür.

S.E. regresyonun (0.040040): Bu, regresyonun standart hatasıdır. Kalıntıların dağılımının bir ölçüsünü sağlar (gerçek değer ile tahmin edilen değer arasındaki fark).

Akaike bilgi kriteri (-3.593912): Bu kriter model seçiminde kullanılır. En düşük AIC'ye sahip model tercih edilir, bu nedenle daha düşük bir değer olan -3,593912 istenir.

Toplam kare kalıntı (7.483891): Bu, kare artıkların toplamıdır. Modelin toplam tahmin hatasının bir ölçüsüdür.

Schwarz kriteri (-3.581500): Model seçiminde kullanılan bir diğer kriterdir ve en düşük değer tercih edilir.


Log-olabilirlik (8413.364): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğünü ölçer. Daha yüksek değerler daha iyidir ve modelin daha uygun olduğunu gösterir.

Hannan-Quinn kriteri (-3.589547): Bu kriter, AIC ve Schwarz kriterleri gibi model seçiminde kullanılır. Düşük değerler daha iyi bir model uyumunu gösterir.

F istatistiği (881.6374) ve Prob(F istatistiği) (0.000000): F istatistiği, model uyumunun ne kadar önemli olduğunu bir ölçüsüdür. İlişkili p değeri çok düşüktür (0,05'ten az), genel modelin istatistiksel olarak anlamlı olduğunu düşündürmektedir.

Durbin-Watson istatistiği (2.002950): Bu istatistik, artıklardaki otokorelasyon için test eder. Yaklaşık 2 değeri otokorelasyon olmadığını gösterir; bu, artıkların bağımsız olduğu ve modelin varsayımlarının muhtemelen karşılandığı anlamına geldiği için iyi bir işarettir.

Özetle, bu model iyi bir uyum gibi görünüyor. Verilerdeki önemli miktarda varyasyonu açıklar (R-kareye göre %60,17), arzu edilir bir düşük AIC ve Schwarz kriterine sahiptir ve Durbin-Watson istatistiği artıkların bağımsız olduğunu öne sürer. Ancak, bu istatistikleri araştırma sorusu ve düşündüğünüz diğer modeller bağlamında her zaman dikkate almanız önemlidir.



Grafik 20. SASA Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 26: SİSE Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.548930	Mean dependent var	-4.28E-05
Adjusted R-squared	0.548060	S.D. dependent var	0.162467
S.E. of regression	0.109221	Akaike info criterion	-1.586909

Sum squared resid	55.67363	Schwarz criterion	-1.573117
Log likelihood	3720.986	Hannan-Quinn criter.	-1.582059
F-statistic	631.0556	Durbin-Watson stat	1.979198
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,548930): Bu istatistik, bağımlı değişkendeki değişimin yaklaşık %54,89'unun bu modeldeki yordayıcılar tarafından açıklandığını göstermektedir. Bu, modelin bir düzeyde açıklama gücüne sahip olduğunu gösteren makul bir R-kare değeridir.

Ortalama bağımlı var (-4.28E-05): Bağımlı değişkenin ortalaması sıfıra çok yakındır. Bu değer modelin tahminlerinin bu ortalama civarında olduğunu göstermektedir.

Düzeltilmiş R-kare (0,548060): Düzeltilmiş R-kare, modeldeki öngörücü sayısını ayarlar. Bu durumda bağımlı değişkendeki değişimin yaklaşık %54,81'inin yordayıcılar tarafından açıklandığı anlamına gelmektedir. Bu değer, R-kare değerine oldukça yakın olup, modelin gereksiz tahmin edicilerle aşırı karmaşık olmadığını gösterir.

SD. bağımlı var (0.162467): Bağımlı değişkenin standart sapmasıdır. Bağımlı değişken değerlerinin dağılımının veya dağılımının bir ölçüsüdür.

S.E. regresyonun (0.109221): Bu, regresyonun standart hatasıdır. Kalıntıların dağılımının bir ölçüsünü sağlar (gerçek değer ile tahmin edilen değer arasındaki fark).

Akaike bilgi kriteri (-1.586909): Akaike Bilgi Kriteri (AIC), istatistiksel modellerin görelî kalitesinin bir ölçüsünü sağlar. AIC ne kadar düşükse, model verilerdeki değişkenliği açıklamakta o kadar iyidir. Burada -1.586909 değerinin oldukça düşük olması modelin makul bir uyum olduğunu düşündürmektedir.

Toplam kare kalıntı (55.67363): Bu, kare artıkların toplamıdır. Modelin toplam tahmin hatasını temsil eder.

Schwarz kriteri (-1.573117): Bayes Bilgi Kriteri (BIC) olarak da bilinen istatistiksel modelleri karşılaştırmak için kullanılan bir diğer ölçüttür. AIC gibi, daha düşük değerler daha iyi modelleri gösterir.


Log-olabilirlik (3720.986): Bu değer, verilen modelin gözlemlenen verileri üretme olasılığının günlüğünü temsil eder. Daha yüksek değerler daha iyi uyumu gösterir.

Hannan-Quinn kriteri (-1.582059): Bu, model seçimi için bir başka bilgi kriteridir. AIC ve BIC'ye benzer şekilde daha düşük değerler daha iyidir.

F istatistiği (631.0556) ve Prob(F istatistiği) (0.000000): F istatistiği, modelin genel öneminin bir ölçüsüdür ve çok küçük bir Prob(F istatistiği) değeri, genel modelin istatistiksel olarak önemli.

Durbin-Watson istatistiği (1.979198): Bu, artıklar arasındaki otokorelasyonu saptamak için bir test istatistiğidir. 2'ye yakın bir değer, regresyon analizinde önemli bir varsayım olan otokorelasyon olmadığını gösterir.

Genel olarak, bu ARIMA modeli, R-kare ve düzeltilmiş R-kare'ye göre bağımlı değişkendeki varyasyonun önemli bir bölümünü açıklayan, verilere iyi bir uyum sağlıyor gibi görünmektedir. Düşük AIC ve BIC değerleri, yüksek log-olasılık ve F-istatistiklerinin tümü nispeten iyi bir uyuma işaret eder. 2'ye yakın Durbin-Watson istatistiği de artıklarda otokorelasyon olmadığını gösteren pozitif bir işarettir. Sonuçlar, modelin iyi bir uyuma sahip olduğunu ve bağımsız değişkenlerin bağımlı değişkeni tahmin etmede orta derecede etkili olduğunu göstermektedir.



Grafik 21. SİSE Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 27: TAVHL Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.548930	Mean dependent var	-4.28E-05
Adjusted R-squared	0.548060	S.D. dependent var	0.162467
S.E. of regression	0.109221	Akaike info criterion	-1.586909
Sum squared resid	55.67363	Schwarz criterion	-1.573117
Log likelihood	3720.986	Hannan-Quinn criter.	-1.582059
F-statistic	631.0556	Durbin-Watson stat	1.979198
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,006507): Bu istatistik, bağımlı değişkendeki değişimin yaklaşık %0,65'inin modeldeki yordayıcılar tarafından açıklanabileceğini ima eder. Bu çok düşük bir değerdir ve modelin bağımlı değişkendeki değişkenliği açıklamada iyi bir iş çıkarmadığını gösterir.

Ortalama bağımlı var (0.000625): Bağımlı değişkenin sıfıra oldukça yakın ortalama değeridir.

Düzeltilmiş R-kare (0,004962): Modeldeki yordayıcı sayısına göre ayarlanan model, bağımlı değişkendeki varyansın yaklaşık %0,50'sini açıklar. Bu da oldukça düşük olup, modelin bağımlı değişkeni tahmin etmede çok etkili olmadığını göstermektedir.

SD. bağımlı var (0,025748): Bu, değişkenin dağılımının veya varyansının bir ölçüsünü sağlayan bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0.025684): Regresyonun standart hatası, modelin artıklarının dağılımı (açıklanamayan varyans) hakkında bize bir fikir verir.

Akaike bilgi kriteri (-4.484027): Akaike Bilgi Kriteri, istatistiksel bir modelin göreceli uyum iyiliğinin bir ölçüsüdür. AIC değeri ne kadar düşükse, model o kadar iyidir. Bu değer oldukça düşüktür, bu da verilere göre modelin makul bir uyum olduğunu düşündürmektedir.

Toplam kare kalıntı (2,544437): Bu, modelin toplam tahmin hatasını temsil eden kare artıkların toplamıdır.

Schwarz kriteri (-4.472687) / Bayes Bilgi Kriteri (BIC): Bu, daha düşük bir değer için daha iyi bir modeli gösterdiği model seçimi için başka bir kriterdir. Modelin karmaşıklığını hesaba katar ve aşırı uyumdan kaçınmayı amaçlar.


Log-olabilirlik (8670.140): Bu değer, verilen veri kümesini gözleme olasılığını ölçen olasılık fonksiyonunun logaritmasını temsil eder. Daha yüksek bir değer daha iyidir, bu da modelimizin gözlemlenen verileri üretme olasılığının daha yüksek olduğunu düşündürmektedir.

Hannan-Quinn kriteri (-4.480000): Bu da model seçiminde kullanılan diğer bir kriterdir. AIC ve BIC'ye benzer şekilde, daha düşük bir değer daha iyidir.

F istatistiği (4.210402) ve Prob(F istatistiği) (0.000314): F istatistiği, modelin genel öneminin bir ölçüsüdür ve çok küçük bir Prob(F istatistiği) değeri, genel modelin istatistiksel olarak önemlidir.

Durbin-Watson istatistiği (2.000092): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. Değerin 2'ye çok yakın olması, model için olumlu bir özellik olan otokorelasyon olmadığını düşündürmektedir.

Genel olarak, düşük R-kare ve düzeltilmiş R-kare değerleri, bu modelin bağımlı değişkendeki varyansın çoğunu açıklamadığını göstermektedir. Bununla birlikte, düşük AIC ve BIC değerleri, yüksek log-olasılık ve istatistiksel olarak anlamlı F-istatistiği, kullanılan veriler göz önüne alındığında nispeten iyi bir uyuma işaret eder.



Grafik 22. TAVHL Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 28: TCELL Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.008457	Mean dependent var	0.000544
Adjusted R-squared	0.006544	S.D. dependent var	0.021366
S.E. of regression	0.021296	Akaike info criterion	-4.858433
Sum squared resid	2.114771	Schwarz criterion	-4.844631
Log likelihood	11361.73	Hannan-Quinn criter.	-4.853579
F-statistic	4.419206	Durbin-Watson stat	1.992838
Prob(F-statistic)	0.000009		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,008457): Bu istatistik, bağımlı değişkendeki değişimin yaklaşık %0,0085'inin modeldeki yordayıcılar tarafından açıklanabileceğini ima eder. Bu çok düşük bir değerdir ve modelin bağımlı değişkendeki değişkenliği önemli ölçüde açıklamadığını gösterir.

Ortalama bağımlı var (0.000544): Bağımlı değişkenin sifıra oldukça yakın ortalama değeridir.

Düzeltilmiş R-kare (0,006544): Modeldeki yordayıcı sayısına göre ayarlanan model, bağımlı değişkendeki varyansın yaklaşık %0,65'ini açıklar. Bu da oldukça düşük olup, modelin bağımlı değişkeni tahmin etmede çok etkili olmadığını göstermektedir.

SD. bağımlı var (0,021366): Bu, değişkenin dağılımının veya varyansının bir ölçüsünü sağlayan bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0.021296): Regresyonun standart hatası, modelin artıklarının dağılımı (açıklanamayan varyans) hakkında bize bir fikir verir.

Akaike bilgi kriteri (-4.858433): Akaike Bilgi Kriteri, istatistiksel bir modelin göreceli uyum iyiliğinin bir ölçüsüdür. AIC değeri ne kadar düşükse, model o kadar iyidir. Bu değer oldukça düşüktür, bu da verilere göre modelin makul bir uyum olduğunu düşündürmektedir.

Toplam kare kalıntı (2.114771): Bu, modelin toplam tahmin hatasını temsil eden kare artıkların toplamıdır.

Schwarz kriteri (-4.844631) / Bayes Bilgi Kriteri (BIC): Bu, daha düşük bir değer için daha iyi bir modeli gösterdiği model seçimi için başka bir kriterdir. Modelin karmaşıklığını hesaba katar ve aşırı uyumdan kaçınmayı amaçlar.


Log-olabilirlik (11361.73): Bu değer, verilen veri kümesini gözlemlenebilirlik olasılığını ölçen olasılık fonksiyonunun logaritmasını temsil eder. Daha yüksek bir değer daha iyidir, bu da modelimizin gözlemlenen verileri üretme olasılığının daha yüksek olduğunu düşündürmektedir.

Hannan-Quinn kriteri (-4.853579): Bu da model seçiminde kullanılan diğer bir kriterdir. AIC ve BIC'ye benzer şekilde, daha düşük bir değer daha iyidir.

F istatistiği (4,419206) ve Prob(F istatistiği) (0,000009): F istatistiği, modelin genel öneminin bir ölçüsüdür ve çok küçük bir Prob(F istatistiği) değeri, genel modelin istatistiksel olarak önemli.

Durbin-Watson istatistiği (1.992838): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. Değerin 2'ye çok yakın olması, model için olumlu bir özellik olan otokorelasyon olmadığını düşündürmektedir.

Genel olarak sonuçlar, regresyon modelinin istatistiksel olarak anlamlı olabilse de regresyonun düşük R-kare değeri ve yüksek standart hatası nedeniyle doğru tahminler yapmak için çok yararlı olmayabileceğini göstermektedir. Ek olarak kalıntılarda otokorelasyonun varlığı, modelin gözlemlerin bağımsızlığı varsayımını ihlal ettiğini gösterebilir.



Grafik 23. TCELL Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 29: THY Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.003968	Mean dependent var	0.000951
Adjusted R-squared	0.002482	S.D. dependent var	0.025097
S.E. of regression	0.025065	Akaike info criterion	-4.532936

Sum squared resid	2.948509	Schwarz criterion	-4.521950
Log likelihood	10662.67	Hannan-Quinn criter.	-4.529074
F-statistic	2.670722	Durbin-Watson stat	2.001284
Prob(F-statistic)	0.009294		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,003968): Bu metrik, modelin bağımlı değişkendeki değişimi ne kadar iyi açıkladığının bir ölçüsünü sağlar. Bu durumda bağımlı değişkendeki değişkenliğin sadece yaklaşık %0,004'ü model tarafından açıklanabilmektedir, bu da bu modelin açıklama gücünün düşük olduğunu düşündürmektedir.

Ortalama bağımlı var (0.000951): Veri setindeki bağımlı değişkenin sıfıra çok yakın ortalama değeridir.

Düzeltilmiş R-kare (0.002482): Bu, modeldeki öngörücü sayısını açıklayan R-kare istatistiğinin değiştirilmiş bir versiyonudur. Düzeltilmiş R-kare, R-kareden bile daha düşüktür; bu, öngörücü sayısı için düzeltme yapıldıktan sonra bağımlı değişkendeki değişkenliğin yalnızca yaklaşık %0,25'inin model tarafından açıklanabileceğini gösterir.

SD. bağımlı var (0,025097): Bu, bağımlı değişkendeki dağılımın veya değişkenliğin bir ölçüsünü sağlayan, bağımlı değişkenin standart sapmasıdır.

S.E. regresyon (0.025065): Bu, modelin artıklarındaki dağılımın (veya tahmin hatalarının) bir ölçüsünü sağlayan, regresyonun standart hatasıdır.

Akaike bilgi kriteri (-4.532936): Akaike Bilgi Kriteri (AIC), istatistiksel bir modelin göreceli kalitesinin bir ölçüsüdür. Daha düşük AIC değerleri, daha iyi uyan modelleri gösterir.

Toplam kare kalıntı (2.948509): Bu, artıkların karelerinin toplamıdır ve modelin toplam tahmin hatasını temsil eder.

Schwarz kriteri (-4.521950) / Bayes Bilgi Kriteri (BIC): Bu kriter, daha düşük değerlerin daha iyi modelleri gösterdiği model seçimi için kullanılır. AIC gibi, BIC de aşırı uyumu önlemek için model karmaşıklığını cezalandırır.


Log-olabilirlik (10662.67): Olabilirlik işlevinin günlüğü, verilen veri kümesini gözlemlene olasılığını ölçer. Daha yüksek değerler daha iyidir, bu da modelin gözlemlenen verileri üretme olasılığının daha yüksek olduğunu düşündürmektedir.

Hannan-Quinn kriteri (-4.529074): Bu, model seçimi için başka bir kriterdir. AIC ve BIC'ye benzer şekilde, daha düşük değerler daha iyi bir model önerir.

F-istatistiği (2,670722) ve Prob(F-istatistiği) (0,009294): F-istatistiği, modelin genel uyumunun bir ölçüsüdür ve 0,05'ten küçük bir Prob(F-istatistiği) genel modelin istatistiksel olarak önemli.

Durbin-Watson istatistiği (2.001284): Bu istatistik, artıklardaki otokorelasyon için test eder. 2'ye yakın bir değer, otokorelasyon olmadığını gösterir; bu, artıklarımızın rasgele olmasını ve ilişkili olmamasını istediğimiz için iyidir.

Genel olarak sonuçlar, regresyon modelinin bir miktar istatistiksel anlamlılığa sahip olabileceğini ancak açıklama gücünün düşük olduğunu ve doğru tahminler yapmak için yararlı olmayabileceğini göstermektedir. Regresyonun yüksek standart hatası, modelin bağımlı değişkenin değerlerini tahmin etmede güvenilir olmayabileceğini de gösterir.



Grafik 24. THY Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 30: TKFEN Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.015760	Mean dependent var	0.006041
Adjusted R-squared	0.013346	S.D. dependent var	0.268159
S.E. of regression	0.266364	Akaike info criterion	0.195057
Sum squared resid	260.3857	Schwarz criterion	0.211934
Log likelihood	-348.9051	Hannan-Quinn criter.	0.201065
F-statistic	6.529315	Durbin-Watson stat	1.993186
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,015760): Bu metrik, modelin bağımlı değişkendeki değişimin yaklaşık %0,058'ini açıkladığını gösterir. Bu nispeten düşük bir değerdir ve modelin bağımlı değişkendeki varyasyonun önemli bir bölümünü açıklamadığını düşündürmektedir.

Ortalama bağımlı var (0.006041): Bu, veri kümenizdeki bağımlı değişkenin ortalama değeridir.

Düzeltilmiş R-kare (0,013346): Bu, R-kare istatistiğinin modeldeki öngörücü sayısına göre ayarlanmış bir versiyonudur. Bağımlı değişkendeki değişkenliğin yalnızca yaklaşık %1,33'ünün model tarafından açıklandığını gösterir, bu da modelin aşırı basitleştirilmiş olabileceğini düşündürmektedir.

SD. bağımlı var (0,268159): Bu, bağımlı değişkenin değişkenliği veya dağılımının bir ölçüsünü sağlayan bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0,266364): Bu, modeldeki açıklanamayan varyansın standart sapmasının bir ölçüsünü sağlayan regresyonun standart hatasıdır.

Akaike bilgi kriteri (0.195057): Akaike Bilgi Kriteri (AIC), istatistiksel bir modelin görelî uyum iyiliğinin bir ölçüsüdür. Daha düşük bir AIC değeri genellikle daha iyi uyan bir modeli gösterir, ancak bu durumda AIC özellikle düşük değildir.

Toplam kare kalıntı (260.3857): Modelin toplam hatasını ölçen artıkların karelerinin toplamıdır.

Schwarz kriteri (0.211934) / Bayes Bilgi Kriteri (BIC): Bu kriter, sonlu bir model seti arasından model seçimi için kullanılır; BIC değeri en düşük olan model tercih edilir.


Log-olabilirlik (-348.9051): Model için olasılık fonksiyonunun günlüğü. Daha yüksek bir log olasılığı, verilere daha iyi uyum olduğunu gösterir.

Hannan-Quinn kriteri (0.201065): Bu, modelleri karşılaştırmak ve seçmek için kullanılan başka bir kriterdir. Düşük değerler daha iyi bir model önerir.

F istatistiği (6,529315) ve Prob(F istatistiği) (0,000000): F istatistiği, tüm regresyon katsayılarının sıfıra eşit olduğu boş hipotezini test eder. İlişkili p değerinin 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (1.993186): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın bir değer artıklarda otokorelasyon olmadığını gösterir.

İstatistikler, modelin istatistiksel olarak anlamlı olmasına rağmen, bağımlı değişkendeki varyansın çok küçük bir bölümünü açıkladığını göstermektedir.



Grafik 25. TKFEN Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 31: TOASA Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.004095	Mean dependent var	0.000942
Adjusted R-squared	0.003030	S.D. dependent var	0.025760
S.E. of regression	0.025721	Akaike info criterion	-4.481714
Sum squared resid	3.090904	Schwarz criterion	-4.473441
Log likelihood	10488.73	Hannan-Quinn criter.	-4.478805
F-statistic	3.842538	Durbin-Watson stat	1.981709
Prob(F-statistic)	0.001780		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,004095): Bu metrik, modelin bağımlı değişkendeki değişimin yaklaşık %0,0041'ini açıkladığını gösterir. Bu nispeten düşük bir değerdir ve modelin bağımlı değişkendeki önemli miktarda değişkenliği yakalamadığını düşündürmektedir.

Ortalama bağımlı var (0.000942): Bu, veri kümenizdeki bağımlı değişkenin ortalama değeridir.

Düzeltilmiş R-kare (0.003030): Bu, R-karenin modeldeki öngörücü sayısına göre ayarlanmış bir versiyonudur. Bağımlı değişkendeki değişkenliğin yalnızca yaklaşık

%0,30'unun model tarafından açıklandığını öne sürer. Bu oldukça düşüktür ve modelin aşırı basitleştirilebileceğini gösterir.

SD. bağımlı var (0,025760): Bu, bağımlı değişkenin dağılımını veya değişkenliğini gösteren standart sapmasıdır.

S.E. regresyonun (0,025721): Modeldeki açıklanamayan varyansın standart sapmasını veren regresyonun standart hatasıdır.

Akaike bilgi kriteri (-4.481714): Akaike Bilgi Kriteri (AIC), istatistiksel bir modelin görelî uyum iyiliğinin bir ölçüsüdür. Daha düşük AIC değerleri, daha iyi uyan modelleri gösterir.

Toplam kare kalıntı (3.090904): Modelin toplam tahmin hatasını veren artıkların karelerinin toplamıdır.

Schwarz kriteri (-4.473441): Bayes Bilgi Kriteri (BIC) olarak da bilinen bu, istatistiksel modelleri karşılaştırmak için başka bir ölçüdür. Düşük değerler daha iyidir.

Log-olabilirlik (10488.73): Model için olasılık fonksiyonunun günlüğü. Daha yüksek log-olasılık değerleri, verilere daha iyi uyum olduğunu gösterir.


Hannan-Quinn kriteri (-4.478805): Model seçiminde kullanılan diğer bir kriterdir. Düşük değerler daha iyi bir model önerir.

F istatistiği (3,842538) ve Prob(F istatistiği) (0,001780): F istatistiği, model uyumunun ne kadar önemli olduğunu bir ölçüsüdür. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (1.981709): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer artıklarda otokorelasyon olmadığını göstermektedir.

Genel olarak, sonuçlar, regresyon modelinin bir miktar istatistiksel anlamlılığa sahip olabileceğini ancak açıklama gücünün düşük olduğunu ve doğru tahminler yapmak için çok yararlı olmayabileceğini göstermektedir. Regresyonun yüksek standart hatası,

modelin bağımlı değişkenin değerlerini tahmin etmede güvenilir olmayabileceğini de gösterir.



Grafik 26. TOASA Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 32: TTKOM Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.014028	Mean dependent var	0.001984
Adjusted R-squared	0.012081	S.D. dependent var	0.106828
S.E. of regression	0.106180	Akaike info criterion	-1.644873
Sum squared resid	39.97853	Schwarz criterion	-1.630971
Log likelihood	2930.939	Hannan-Quinn criter.	-1.639916
F-statistic	7.207166	Durbin-Watson stat	2.002620
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,014028): Bu metrik, modelin bağımlı değişkendeki değişimin yaklaşık %01,4'ünü açıkladığını gösterir. Bu çok düşük bir değerdir, bu da modelin bağımlı değişkendeki değişkenliğin çoğunu yakalamadığı anlamına gelir.

Ortalama bağımlı var (0.001984): Bu, veri kümesindeki bağımlı değişkenin ortalama değeridir.

Düzeltilmiş R-kare (0.012081): Bu, R-kare'nin modeldeki öngörücü sayısına göre ayarlanmış versiyonudur. Bağımlı değişkendeki değişkenliğin yaklaşık %01,2'sinin model tarafından açıklandığını öne sürmektedir. Bu da oldukça düşük, bu da modelin çok etkili olmayabileceğini düşündürüyor.

SD. bağımlı var (0.106828): Bu, bağımlı değişkenin dağılımının bir ölçüsünü sağlayan bağımlı değişkenin standart sapmasıdır.

S.E. regresyonun (0.106180): Modeldeki açıklanamayan varyansın standart sapmasını ölçen regresyonun standart hatasıdır.

Akaike bilgi kriteri (-1.644873): Akaike Bilgi Kriteri (AIC), belirli bir veri seti için bir istatistiksel modelin görel kalitesinin bir ölçüsüdür. Düşük değerler daha iyi uyan bir modeli gösterir.

Toplam kare kalıntı (39.97853): Bu, modelin toplam tahmin hatasının bir ölçüsünü sağlayan artıkların karelerinin toplamıdır.

Schwarz kriteri (-1.630971): Bayes Bilgi Kriteri (BIC) olarak da bilinen bu, istatistiksel modelleri karşılaştırmak için başka bir ölçüdür. Düşük değerler daha iyidir.


Log-olabilirlik (2930.939): Bu, verilen modelin gözlemlenen verileri üretme olasılığının günlüğüdür. Daha yüksek değerler daha iyidir.

Hannan-Quinn kriteri (-1.639916): Model seçiminde kullanılan bir diğer bilgi kriteridir. Düşük değerler daha iyi bir model önerir.

F istatistiği (7.207166) ve Prob(F istatistiği) (0.000000): F istatistiği, model uyumunun ne kadar önemli olduğunu bir ölçüsüdür. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.002620): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer artıklarda otokorelasyon olmadığını göstermektedir.

Genel olarak sonuçlar, regresyon modelinin bir miktar istatistiksel anlamlılığa sahip olabileceğini ancak açıklama gücünün düşük olduğunu ve doğru tahminler yapmak için çok yararlı olmayabileceğini göstermektedir. Regresyonun yüksek standart hatası, modelin bağımlı değişkenin değerlerini tahmin etmede güvenilir olmayabileceğini de gösterir. Bununla birlikte, artıklarda önemli bir otokorelasyon olmaması modelin verilerdeki kalıpları iyi yakaladığını göstermektedir.



Grafik 27. TTKOM Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 33: TUPRS Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.007945	Mean dependent var	0.000953
Adjusted R-squared	0.006881	S.D. dependent var	0.022317
S.E. of regression	0.022240	Akaike info criterion	-4.772551
Sum squared resid	2.306913	Schwarz criterion	-4.764265
Log likelihood	11149.91	Hannan-Quinn criter.	-4.769636
F-statistic	7.470106	Durbin-Watson stat	2.015886
Prob(F-statistic)	0.000001		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,007945): Bu deęer, baęımlı deęiřkendeki toplam varyansın yaklaşık %0,0079'unun model tarafından açıklanabileceęi anlamına gelmektedir. Modelin baęımlı deęiřkendeki deęiřkenlięin çoęunu açıklamadıęını gösteren düşük bir deęerdir.

Ortalama baęımlı var (0.000953): Bu, veri kümenizdeki baęımlı deęiřkenin ortalama deęeridir.

Düzeltilmiř R-kare (0,006881): Bu, modeldeki öngörücü sayısına göre ayarlanan R-kare deęeridir. Serbestlik derecelerini açıklar ve modelin uyum iyilięine dair bir gösterge verir. Bu deęer de düşüktür, bu da modelin baęımlı deęiřkendeki küçük bir varyansı açıkladıęını daha da vurgulamaktadır.

SD. baęımlı var (0.022317): Bu, baęımlı deęiřkenin daęılımının bir ölçüsünü saęlayan baęımlı deęiřkenin standart sapmasıdır.

S.E. regresyonun (0.022240): Regresyonun standart hatası, regresyon analizinin kesinlięini gösterir. Daha düşük bir standart hata, yordayıcı deęiřkenlerin baęımlı deęiřken üzerindeki etkisinin daha kesin bir tahminini önerir.

Akaike bilgi kriteri (-4.772551): Model seçimi için kullanılır. AIC ne kadar düşükse model uyum iyilięi ve basitlik açısından o kadar iyi kabul edilmektedir.

Toplam kare kalıntı (2.306913): Bu, modelin toplam tahmin hatasının bir ölçüsünü saęlayan artıkların karelerinin toplamıdır.

Schwarz kriteri (-4.764265) veya BIC: AIC gibi model seçiminde de kullanılmaktadır. Daha fazla parametreye sahip modelleri daha ağır řekilde cezalandırır. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (11149,91): Bu deęer, modelin verilere ne kadar iyi uyduęunun bir ölçüsü olan olasılık fonksiyonunun logaritmasını temsil eder. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri (-4.769636): Model seçiminde kullanılan dięer bir kriterdir. Düşük deęerler daha iyi bir model önerir.

F istatistiği (7,470106) ve Prob(F istatistiği) (0,000001): F istatistiği, modelin genel anlamlılığını test eder ve p değerinin (olasılık F istatistiği) 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı.

Durbin-Watson istatistiği (2.015886): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer artıklarda otokorelasyon olmadığını göstermektedir.

Model istatistiksel olarak anlamlı olmakla birlikte, düşük R-kare ve Düzeltilmiş R-kare değerleri, veriler için güçlü bir uyum sağlamayabileceğini düşündürmektedir.



Grafik 28. TUPRS Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 34: VESTEL Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.022872	Mean dependent var	0.004440
Adjusted R-squared	0.020989	S.D. dependent var	0.230140
S.E. of regression	0.227712	Akaike info criterion	-0.119229
Sum squared resid	242.0492	Schwarz criterion	-0.105440
Log likelihood	288.8768	Hannan-Quinn criter.	-0.114380
F-statistic	12.14087	Durbin-Watson stat	2.000443
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0,022872): Bu deęer, baęımlı deęiřkendeki toplam varyansın yaklaşık %02,29'unun model tarafından açıklanabileceęini göstermektedir. Bu düşük bir deęerdir ve modelin baęımlı deęiřkendeki pek çok deęiřkenlięi açıklamadıęını düşündürmektedir.

Ortalama baęımlı var (0.004440): Bu, veri kümenizdeki baęımlı deęiřkenin ortalama deęeridir.

Düzeltilmiř R-kare (0,020989): Bu, modeldeki öngörücü sayısına göre ayarlanan R-kare deęeridir. Serbestlik derecelerini açıklar ve modelin uyum iyilięine dair bir gösterge verir. Bu deęer de düşüktür ve modelin baęımlı deęiřkendeki küçük bir varyansı açıkladıęını düşündürmektedir.

SD. baęımlı var (0.230140): Bu, baęımlı deęiřkenin daęılımının bir ölçüsünü saęlayan baęımlı deęiřkenin standart sapmasıdır.

S.E. regresyonun (0,227712): Regresyonun standart hatası, regresyon analizinin kesinlięini gösterir. Daha düşük bir standart hata, yordayıcı deęiřkenlerin baęımlı deęiřken üzerindeki etkisinin daha kesin bir tahminini önerir.

Akaike bilgi kriteri (-0.119229): Akaike Bilgi Kriteri (AIC), farklı modelleri karřılařtırmak için kullanılan bir ölçüdür. Daha düşük bir AIC deęeri daha iyi bir model önerir.

Toplam kare kalıntı (242.0492): Bu, artıkların karelerinin toplamıdır. Modelin toplam tahmin hatasının bir ölçüsünü saęlar.


Schwarz kriteri (-0.105440) veya Bayesian Information Criterion (BIC): AIC gibi, BIC de model seęiminde kullanılır. Ancak BIC, daha fazla parametreye sahip modelleri AIC'den daha ağır řekilde cezalandırır. Daha düşük bir BIC, daha iyi bir modeli gösterir.

Log-olabilirlik (288.8768): Bu deęer, modelin verilere ne kadar iyi uydununun bir ölçüsü olan olasılık fonksiyonunun logaritmasını temsil eder. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri (-0.114380): Model seçiminde kullanılan diğer bir kriterdir. Düşük değerler daha iyi bir model önerir.

F istatistiği (12.14087) ve Prob(F istatistiği) (0.000000): F istatistiği, modelin genel anlamlılığını test eder. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.000443): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer artıklarda otokorelasyon olmadığını göstermektedir.



Grafik 29. VESTEL Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 35: YKBNK Arima Sonuçları

Statistic	Value	Statistic	Value
R-squared	0.022872	Mean dependent var	0.004440
Adjusted R-squared	0.020989	S.D. dependent var	0.230140
S.E. of regression	0.227712	Akaike info criterion	-0.119229
Sum squared resid	242.0492	Schwarz criterion	-0.105440
Log likelihood	288.8768	Hannan-Quinn criter.	-0.114380
F-statistic	12.14087	Durbin-Watson stat	2.000443
Prob(F-statistic)	0.000000		

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

R-kare (0.022872): Bu deęer baęımlı deęiřkendeki toplam varyansın yaklaşık %0,02'si model tarafından açıklanabileceęini göstermektedir. Bu çok düşük bir deęerdir ve modelin baęımlı deęiřkendeki deęiřkenlięin çoęunu açıklamadıęını düşündürmektedir.

Ortalama baęımlı var (0.000440): Bu, veri kümenizdeki baęımlı deęiřkenin ortalama deęeridir.

Düzeltilmiř R-kare (0.020989): Bu, modeldeki öngörücü sayısına göre ayarlanan R-kare deęeridir. Serbestlik derecelerini açıklar ve modelin uyum iyilięine dair bir gösterge verir. Bu deęer de düşüktür ve modelin baęımlı deęiřkendeki küçük bir varyansı açıkladıęını düşündürmektedir.

SD. baęımlı var (0.230140): Bu, baęımlı deęiřkenin daęılımının bir ölçüsünü saęlayan baęımlı deęiřkenin standart sapmasıdır.

S.E. regresyon (0,227712): Regresyonun standart hatası, regresyon analizinin kesinlięini gösterir. Daha düşük bir standart hata, yordayıcı deęiřkenlerin baęımlı deęiřken üzerindeki etkisinin daha kesin bir tahminini önerir.

Akaike bilgi kriteri (-0.119229): Akaike Bilgi Kriteri (AIC), farklı modelleri karřılařtırmak için kullanılan bir ölçüdür. Daha düşük bir AIC deęeri daha iyi bir model önerir.

Toplam kare kalıntı (242.0492): Bu, artıkların karelerinin toplamıdır. Modelin toplam tahmin hatasının bir ölçüsünü saęlar.

Schwarz kriteri (-0.105440) veya Bayes Bilgi Kriteri (BIC): AIC gibi, BIC de model seçiminde kullanılır. Ancak BIC, daha fazla parametreye sahip modelleri AIC'den daha ağır řekilde cezalandırır. Daha düşük bir BIC, daha iyi bir modeli gösterir.


Log-olabilirlik (288.8768): Bu deęer, modelin verilere ne kadar iyi uyduęunun bir ölçüsü olan olasılık fonksiyonunun logaritmasını temsil eder. Daha yüksek bir log-olasılık, daha iyi bir uyumu gösterir.

Hannan-Quinn kriteri (-11.4380): Model seçiminde kullanılan diğer bir kriterdir. Düşük değerler daha iyi bir model önerir.

F istatistiği (12.14087) ve Prob(F istatistiği) (0,000000): F istatistiği, modelin genel anlamlılığını test eder. İlişkili p değerinin (olasılık F istatistiği) 0,05'ten küçük olması, genel modelin istatistiksel olarak anlamlı olduğunu gösterir.

Durbin-Watson istatistiği (2.000443): Bu istatistik, bir regresyon analizinden elde edilen artıklardaki otokorelasyon için test eder. 2'ye yakın değer artıklarda otokorelasyon olmadığını göstermektedir.

Özetle, model istatistiksel olarak anlamlı olmakla birlikte, R-kare ve Düzeltilmiş R-kare değerleri, veriler için güçlü bir uyum sağlamayabileceğini düşündürmektedir.



Grafik 30. YKBANK Arima Fiyat-Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Hisse senetleri için 30 ARIMA modelinin dikkatli analizi sonucunda, bu modellerin hisse senetlerindeki hareketleri öngörme derecesinde önemli farklılıklar bulduk. Model tarafından açıklanabilen bağımlı değişkenlerdeki (hisse senedi getirileri) varyansın oranını gösteren R-kare değerleri, bazı modellerin değişkenliğin %50'sinden fazlasını, diğerlerinin ise daha azını açıkladığı geniş bir aralığı kapsar %1. Bu bize, kendi özelinde hisse senetlerinin piyasadaki davranışının, genel piyasa trendlerinin yanı sıra her şirkete ve sektöre özgü faktörlerden etkilenecek oldukça kendine özgü

olabileceğini söyler. Ayrıca, arima analizlerin geneline baktığımızda 2 değerine yakın olan Durbin-Watson istatistikleri, kalıntılarda önemli bir otokorelasyon önermez; bu, modellerin, herhangi bir kalıcı eğilimi dışarıda bırakmadan verilerdeki temel kalıpları yeterince yakaladığı anlamına geldiği için arzu edilen bir durumdur.

F-istatistikleri ve ilişkili p-değerleri, hemen hemen tüm durumlarda, genel modellerin istatistiksel olarak anlamlı olduğunu ve modellerdeki öngörücülerin en azından bazılarının sıfır olmayan katsayılarla sahip olduğunu ima eder.

Bununla birlikte, modeller istatistiksel olarak anlamlı olmakla birlikte, birçoğunun düşük R-kare ve Düzeltilmiş R-kare değerlerine sahip olduğunu belirtmekte fayda var. Bu, parametrelerin istatistiksel önemine rağmen, modellerin çoğunun veriler için güçlü bir tahmin gücü sağlayamayacağını gösterir.

Bu nedenle, bu modeller hisse senedi getirilerinin dinamikleri hakkında bazı bilgiler sunarken, aynı zamanda borsa davranışını modelleme ve tahmin etmenin doğasında var olan zorlukları da vurgulamaktadır. Hisse senedi fiyatları, birçoğunun doğru bir şekilde ölçülmesi ve bir modele dahil edilmesi zor olan çok çeşitli faktörlerden etkilenir. Bu bulgular, borsada hiçbir garantinin olmadığı, yalnızca olasılıkların olduğu şeklindeki eski atasözünün altını çizmektedir.

4.3.6. Holt-Winters Modeli

Tablo AIC, AICc, BIC ve R-kare değerlerini içeren BigML kullanılarak eğitilen her bir zaman serisi modeli için eğitim puanlarını sağlar. Bu puanlar, her modelin performansını değerlendirmek ve birbirleriyle karşılaştırmak için kullanılabilir.

Tablo 36: Holt-Winters istatistiki Modeli Sonuçları

HİSSE	AIC	AIC s	BIC	R-SQUARED
Akbank	19374.6703	19374.6824	19407.2352	0.9971
Arcelik	24508.374	24508.3965	24553.9649	0.9988
Aselsen	9687.4272	9687.4393	9719.9921	0.9989
Bımas	23555.0163	23555.0221	23574.0002	0.9992
Ekgyo	4659.7854	4659.7941	4677.5695	0.9883
Eregl	8537.479	8537.5419	8615.6348	0.9988
Proto	28279.9836	28279.9957	28312.5485	0.9984
Garan	9981.8187	19982.5163	20248.8511	0.9979
Gubrf	14066.4097	14066.4218	14098.9747	0.9983

Halkb	18947.8323	18947.8487	18978.8775	0.9957
Hekts	3448.0351	3448.0223	3415.7809	0.9983
Isctr	7125.924	17125.9361	17158.489	0.9973
Kcholl	21455.1208	21455.1329	21487.6857	0.9989
Kozaa	15645.4568	15645.4746	15684.237	0.9983
Kozal	23250.198	23250.2182	23280.2065	0.9981
Krdmd	5288.2613	5289.1763	5594.3715	0.9986
Petkm	5017.7549	5017.7598	5037.2939	0.9988
Pegasus	16324.2713	16324.31	16358.3883	0.9962
Sahol	20869.6716	20869.6837	20902.2355	0.9977
Sasa	1807.1719	1807.1839	1839.7368	0.9981
Sise	8341.0666	8341.0891	8386.6575	0.9986
Tavhl	19935.1086	19935.1247	19966.2334	0.9977
Tcell	22035.188	22035.2	22067.7529	0.9983
Thyao	17446.8242	17446.8411	17485.9021	0.9985
Tkfen	15587.7324	15587.7392	15606.2506	0.9983
Toaso	20706.9907	20707.0027	20739.5556	0.9987
Ttcom	11741.5203	11741.5273	11759.9351	0.9949
Tuprs	34987.0579	34987.07	35019.6228	0.999
Vestl	19305.3902	19305.4068	19344.5875	0.9986
Ykbnk	11916.7207	11917.4875	12196.779	0.9965

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Akbank: AIC=19374,67, AIC s=19374,68, BIC=19407,24, R-kare=0,9971. Akbank'ın modelinin yüksek R-kare değeri, model ile veri arasında güçlü bir uyuma işaret etmektedir. AIC ve BIC değerleri de nispeten düşüktür, bu da modelin iyi bir açıklama gücüne sahip olduğunu ve aşırı derecede karmaşık olmadığını göstermektedir.

Arçelik: AIC=24508,37, AIC s=24508,40, BIC=24553,96, R-kare=0,9988. Arçelik'in modeli çok yüksek bir R-kare değerine sahip olup, bu da model ile veriler arasında mükemmel bir uyum olduğunu göstermektedir. AIC ve BIC değerleri nispeten düşüktür, bu da modelin aşırı derecede karmaşık olmadığını gösterir.

Aselsan: AIC=9687,43, AIC s=9687,44, BIC=9719,99, R-kare=0,9989. Aselsan'ın modeli çok yüksek bir R-kare değerine sahiptir ve bu da model ile veriler arasında mükemmel bir uyum olduğunu göstermektedir. AIC ve BIC değerleri nispeten düşüktür, bu da modelin iyi bir açıklama gücüne sahip olduğunu ve aşırı derecede karmaşık olmadığını düşündürmektedir.

BİMAS: AIC=23555.02, AIC s=23555.02, BIC=23574.00, R-kare=0.9992. BİMAS'ın modeli son derece yüksek bir R-kare değerine sahiptir ve bu, model ile veriler arasında mükemmel yakın bir uyumu gösterir. AIC ve BIC değerleri de nispeten düşüktür, bu da modelin mükemmel açıklama gücüne sahip olduğunu ve aşırı derecede karmaşık olmadığını düşündürmektedir.

EKGYO: AIC=4659.79, AIC s=4659.79, BIC=4677.57, R-kare=0.9883. EKGYO'nun modeli yüksek bir R-kare değerine sahiptir ve bu, model ile veriler arasında iyi bir uyum olduğunu gösterir. AIC ve BIC değerleri nispeten düşüktür, bu da modelin iyi bir açıklama gücüne sahip olduğunu ve aşırı derecede karmaşık olmadığını düşündürmektedir.

EREGL: AIC=8537.48, AIC s=8537.54, BIC=8615.63, R-kare=0.9988. EREGL'nin modelinin çok yüksek bir R-kare değeri vardır, bu da model ile veri arasında mükemmel bir uyum olduğunu gösterir. AIC ve BIC değerleri nispeten düşüktür, bu da modelin iyi bir açıklama gücüne sahip olduğunu ve aşırı derecede karmaşık olmadığını düşündürmektedir.

FROTO: AIC=28279.98, AIC s=28279.99, BIC=28312.55, R-kare=0.9984. FROTO'nun modeli, model ve veriler arasında iyi bir uyum olduğunu gösteren yüksek bir R-kare değerine sahiptir. AIC ve BIC değerleri nispeten düşüktür, bu da modelin iyi bir açıklama gücüne sahip olduğunu ve aşırı derecede karmaşık olmadığını düşündürmektedir.

GARAN: AIC=9981,82, AIC s=19982,52, BIC=20248,85, R-kare=0,9979. GARAN'ın modeli yüksek bir R-kare değerine sahiptir ve bu, model ile veriler arasında iyi bir uyuma işaret etmektedir. Bununla birlikte AIC ve BIC değerlerinin nispeten yüksek olması, modelin aşırı derecede karmaşık olabileceğini ve güçlü bir açıklama gücüne sahip olmayabileceğini düşündürmektedir.

Gubrf: AIC puanı 14066.4097, AICc puanı 14066.4218, BIC puanı 14098.9747 ve R-kare değeri 0.9983. Bu puanlar, nispeten düşük bir AIC ve BIC puanı ve yüksek bir R-kare değeri ile Gubrf hissesi için zaman serisi modelinin veriler için iyi bir uyum

olduğunu göstermektedir. Bu, modelin tahmin gücünün iyi bir göstergesi olan verilerdeki varyansın büyük bir bölümünü açıklayabildiğini göstermektedir.

Halkb: AIC puanı 18947.8323, AICc puanı 18947.8487, BIC puanı 18978.8775 ve R-kare değeri 0.9957'dir. Bu puanlar, nispeten düşük AIC ve BIC puanı ve yüksek R-kare değeri ile Halkb hissesi için zaman serisi modelinin verilere iyi uyduğunu göstermektedir. AICc puanı ayrıca bu modelin test edilen modeller arasında en uygunu olabileceğini düşündürmektedir.

Hekts: AIC=3448.0351, AIC s=3448.0223, BIC=3415.7809, R-kare=0.9983. AICc ve BIC'nin her ikisinin de AIC'den biraz daha iyi bir uyum gösteriyor, ancak üç değer de nispeten yakın. R kare değerinin çok yüksek olması, modelin verilerdeki varyansın neredeyse tamamını açıkladığını gösterir.

Isctr: AIC puanı 7125,924, AICc puanı 17125,9361, BIC puanı 17158,489 ve R-kare değeri 0,9973'tür. Bu puanlar Isctr'nin hisse senedi için zaman serisi modelinin, düşük AIC puanı ve yüksek R-kare değeri ile veriler için iyi bir uyum olduğunu göstermektedir. Bununla birlikte, AICc ve BIC puanları nispeten yüksektir ve bu, daha iyi uyum sağlayabilecek başka modeller olduğunu gösterebilir.

Kcholl: AIC puanı 21455.1208, AICc puanı 21455.1329, BIC puanı 21487.6857 ve R-kare değeri 0.9989. Bu puanlar nispeten düşük bir AIC ve BIC puanı ve yüksek bir R-kare değeri ile Kcholl hissesi için zaman serisi modelinin veriler için iyi bir uyum olduğunu göstermektedir.

Kozaa: AIC puanı 15645.4568, AICc puanı 15645.4746, BIC puanı 15684.237 ve R-kare değeri 0.9983. Bu puanlar Kozaa hisse senedi için zaman serisi modelinin, düşük AIC ve BIC puanı ve yüksek R-kare değeri ile verilere iyi bir uyum sağladığını göstermektedir.

Kozal: AIC puanı 23250,198, AICc puanı 23250,2182, BIC puanı 23280,2065, R-kare değeri 0,9981. Bu puanlar nispeten düşük bir AIC ve BIC puanı ve yüksek bir R-kare değeri ile Kozal hissesi için zaman serisi modelinin veriler için iyi bir uyum olduğunu göstermektedir.

Krdmd: AIC puanı 5288.2613, AICc puanı 5289.1763, BIC puanı 5594.3715 ve R-kare değeri 0.9986'dır. Bu puanlar nispeten düşük bir AIC ve BIC puanı ve yüksek bir R-kare değeri ile Krdmd hissesi için zaman serisi modelinin veriler için iyi bir uyum olduğunu göstermektedir.

Petkm: AIC puanı 5017.7549, AICc puanı 5017.7598, BIC puanı 5037.2939 ve R-kare değeri 0.9988'dir. Bu puanlar Petkm hissesi için kullanılan zaman serisi modelinin düşük AIC ve BIC puanı ve yüksek R-kare değeri ile verilere uygun olduğunu göstermektedir.

Pegasus: AIC puanı 16324.2713, AICc puanı 16324.31 ve BIC puanı 16358.3883. R-kare değeri 0,9962'dir. Bu puanlar, Pegasus hisse senedi için zaman serisi modelinin iyi bir uyuma sahip olduğunu ve doğru tahminler yapmak için kullanılabileceğini göstermektedir.

Sahol: AIC puanı 20869.6716, AICc puanı 20869.6837 ve BIC puanı 20902.2355. R-kare değeri 0,9977'dir. Bu puanlar, Sahol hissesi için zaman serisi modelinin iyi bir uyum olduğunu ve doğru tahminler için kullanılabileceğini göstermektedir.

Sasa: AIC puanı 1807.1719, AICc puanı 1807.1839 ve BIC puanı 1839.7368. R-kare değeri 0,9981'dir. Bu puanlar, Sasa hissesi için zaman serisi modelinin iyi bir uyum olduğunu ve doğru tahminler için kullanılabileceğini göstermektedir.

Sıse: AIC puanı 8341.0666, AICc puanı 8341.0891, BIC puanı 8386.6575. R-kare değeri 0,9986'dır. Bu puanlar, Sıse hissesi için zaman serisi modelinin iyi bir uyuma sahip olduğunu ve doğru tahminler yapmak için kullanılabileceğini göstermektedir.

Tavhl: AIC puanı 19935.1086, AICc puanı 19935.1247 ve BIC puanı 19966.2334. R-kare değeri 0,9977'dir. Bu puanlar, Tavhl hissesi için zaman serisi modelinin iyi bir uyum olduğunu ve doğru tahminler için kullanılabileceğini göstermektedir.

Tcell: AIC puanı 22035.188, AICc puanı 22035.2 ve BIC puanı 22067.7529'dur. R-kare değeri 0,9983'tür. Bu puanlar, Tcell hisse senedi için zaman serisi modelinin iyi bir uyuma sahip olduğunu ve doğru tahminler yapmak için kullanılabileceğini göstermektedir.

Thyao: AIC puanı 17446.8242, AIC puanı 17446.8411 ve BIC puanı 17485.9021. R-kare değeri 0,9985'tir. Bu puanlar, Thyao hissesi için zaman serisi modelinin iyi bir uyum olduğunu ve doğru tahminler için kullanılabileceğini göstermektedir.

Tkfen: AIC puanı 15587.7324, AIC puanı 15587.7392 ve BIC puanı 15606.2506'dır. R-kare değeri 0,9983'tür. Bu puanlar, Tkfen hissesi için zaman serisi modelinin iyi bir uyuma sahip olduğunu ve doğru tahminler yapmak için kullanılabileceğini göstermektedir.

Toaso: AIC puanı 20706.9907, AIC puanı 20707.0027 ve BIC puanı 20739.5556. R-kare değeri 0,9987'dir. Bu puanlar, Toaso hissesi için zaman serisi modelinin iyi bir uyum olduğunu ve doğru tahminler için kullanılabileceğini göstermektedir.

Ttcom: AIC puanı 11741.5203, AICc puanı 11741.5273, BIC puanı 11759.9351 ve R-kare değeri 0.9949'dur. Bu puanlar, modelin verilere iyi uyduğunu ve açıklama gücünün iyi olduğunu göstermektedir.

Tuprs: AIC puanı 34987.0579, AICc puanı 34987.07, BIC puanı 35019.6228 ve R-kare değeri 0.999'dur. Bu puanlar, modelin verilere çok iyi uyduğunu ve mükemmel açıklama gücüne sahip olduğunu göstermektedir.

Vestl: AIC puanı 19305.3902, AICc puanı 19305.4068, BIC puanı 19344.5875 ve R-kare değeri 0.9986. Bu puanlar, modelin verilere iyi uyduğunu ve açıklama gücünün iyi olduğunu göstermektedir.

Ykbank : 0.9965 gibi yüksek bir R-kare değeri ile güçlü model uyumunu gösterir. Bu da Holt-Winters yöntemine dayalı regresyon modelinin Ykbnk hisse senedi fiyatındaki değişkenliğin yaklaşık %99,65'ini açıkladığını göstermektedir.

4.4. Sonuç İncelemesi

30 hisse senedi için Holt-Winters tahminleri ilginç bulgular sunuyor. Akaike Bilgi Kriteri (AIC), Bayes Bilgi Kriteri (BIC) ve R-kare değerlerine dayanan sonuçlar, Holt-Winters yönteminin bu hisse senetleri için oldukça doğru tahmin modelleri sağladığını göstermektedir. Sonuçlarda görüldüğü gibi, R-kare değerleri son derece

yüksektir ve çoğu 1'e yaklaşmaktadır. Bu, modellerin hisse senedi getiri verilerindeki değişkenliğin büyük bir çoğunluğunu oluşturduğunu göstermektedir; modeller yüksek doğrulukta olduğunu göstermektedir.

AIC ve BIC'yi incelediğimizde, daha düşük bir değerin tipik olarak daha iyi bir model önerdiği model seçimi için kullanılan iki yöntem, bunların farklı hisse senetleri arasında oldukça önemli ölçüde değiştiğini görüyoruz. Bununla birlikte, bu metriklerin doğası, aynı modeli farklı hisse senetleri arasında karşılaştırmak yerine, aynı hisse senedinin farklı modellerini karşılaştırmak için en yararlı oldukları anlamına gelir.


AIC ve BIC değerleri, R-kare değerleriyle uyumlu olarak, Holt-Winters yönteminin bu hisse senetleri için öngörü gücünü göstermektedir. Bununla birlikte, bu modeller tarihsel verilere iyi uysa da tahminlerinin doğruluğunun, gelecekteki modellerin geçmiş modellere benzeyeceği varsayımına bağlı olduğunu unutmamalıyız. Borsa, çok sayıda faktörden etkilenen karmaşık, dinamik bir sistemdir ve bu nedenle herhangi bir tahmin, doğası gereği belirsiz olarak ele alınmalıdır.

4.5. ARIMA, SVM, Holt-Winters ve Karar Ağacı Karşılaştırmalı Uygulaması

Klasik istatistik yöntemleriyle makine öğrenimi yöntemleri karşılaştırmalı analizi bu bölümde sunulmuştur. Bu yöntemler, ARIMA, SVM, Holt-Winters ve Karar Ağacı olmak üzere dört farklı modelin BIST30 hisse senedi endeksinin gelecekteki değerlerini tahmin etme performansını değerlendirmektir. Analizimiz eğitim ve test setinden güncel bir örneklem dönem olan 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar ki beş günlük kesit bir dönemi kapsamaktadır.


4.5.1. Arima Modeli

ARIMA modeli, 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar uzanan, birbirini takip eden beş günlük bir süreyi kapsayan ve günlük tahmin grafiği oluşturulmuştur. Oluşturulmuş bu tahminler, karşılaştırma ve değerlendirme yapılırken kullanılmaktadır.




Grafik 31. 01 08 2022 Arima Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 32. 02 08 2022 Arima Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 33. 03 08 2022 Arima Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 34. 04 08 2022 Arima Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 35. 05 08 2022 Arima Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 38: ARIMA Tahmin Tablosu

	01 08 2022	02 08 2022	03 08 2022	04 08 2022	05 08 2022
ARIMA	2761,50	2838,20	2835,51	2879,40	2923,80

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Yukarıdaki grafikleri incelediğimizde ARIMA modelinin 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar verilen ardışık beş günlük dönem için tahmini şu şekildedir: 1 Ağustos'ta tahmin değeri 2761,50'dir. Bunu 2 Ağustos'ta 2838.20 tahmini değeri takip etmektedir. 3 Ağustos'ta tahmin edilen değer 2835,51'dir. 4 Ağustos için öngörülen değer 2879,40 ve son olarak 5 Ağustos'ta 2923,80 olarak tahmin ediliyor. Bu tahmin edilen değerler, ilgili her gün için beklenen eğilimler ve kalıplar hakkında bilgi sağlar.


4.5.2. Holt-Winters

Holt-Winters modeli, 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar uzanan, birbirini takip eden beş günlük bir süreyi kapsayan günlük tahmin grafiği oluşturulmuştur. Oluşturulmuş bu tahminler, karşılaştırma ve değerlendirme yapılırken kullanılmaktadır.




Grafik 36. 01 08 2022 Holt-Winters Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 37. 02 08 2022 Holt-Winters Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 38. 03 08 2022 Holt-Winters Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 39. 04 08 2022 Holt-Winters Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 40. 05 08 2022 Holt-Winters Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 39: Holt-Winters Tahmin Tablosu


	01 08 2022	02 08 2022	03 08 2022	04 08 2022	05 08 2022
HOLT-WINTERS	2761,3965	2833,6256	2835,8888	2877,7731	2922,1551

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Holt-Winters modeline göre, 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar belirtilen ardışık beş günlük dönem için tahmin edilen değerler aşağıdaki gibidir: 1 Ağustos'ta, model 2761.3965 değerini tahmin etmektedir. 2 Ağustos için tahmin edilen değer 2833.6256, ardından 3 Ağustos için 2835.8888. 4 Ağustos'ta model 2877.7731 değerini öngörüyor ve son olarak 5 Ağustos'ta 2922.1551 değerini tahmin etmektedir. Holt-Winters modelinden elde edilen bu tahmin edilen değerler, her bir gün için beklenen modeller ve eğilimler hakkında değerli bilgiler sağlar.


4.5.3. Karar Ağacı ve Destek Vektör Makineleri Modeli

Karar Ağacı ve DVM modeli, 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar uzanan, birbirini takip eden beş günlük bir süreyi kapsayan günlük tahmin grafiği oluşturulmuştur. Oluşturulmuş bu tahminler, karşılaştırma ve değerlendirme yapılırken kullanılmaktadır.




Grafik 41. 01 08 2022 DecisionTree

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 42. 01 08 2022 DVM

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 43. 02 08 2022 Karar Ağacı Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 44. 02 08 2022 DVM

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 45. 03 08 2022 DecisionTree Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 46. 03 08 2022 DVM Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 47. 04 08 2022 DecisionTree Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.




Grafik 48. 04 08 2022 DVM Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 49. 05 08 2022 Karar Ağacı Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.



Grafik 50. 05 08 2022 DVM Tahmin Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 40: Karar Ağacı ve DVM Tahmin Tablosu

	01 08 2022	02 08 2022	03 08 2022	04 08 2022	05 08 2022
DVM	2772,433	2830,612	2857,457	2848,043	2847,263
Karar Ağacı	2743,333	1497,008	2827,913	2877,657	2912,267

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Yukarıdaki grafikleri incelediğimizde DVM modelinin 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar verilen ardışık beş günlük dönem için tahmini şu şekildedir: 1 Ağustos'ta tahmin değeri 2772,433'tür. Bunu 2 Ağustos'ta 2830,612 tahmini değeri takip etmektedir. 3 Ağustos'ta tahmin edilen değer 2857,457'dir. 4 Ağustos için öngörülen değer 2848,043 ve son olarak 5 Ağustos'ta 2847,263 olarak tahmin ediliyor. Karar Ağacı modeline göre, 1 Ağustos 2022'den 5 Ağustos 2022'ye kadar belirtilen ardışık beş günlük dönem için tahmin edilen değerler aşağıdaki gibidir: 1 Ağustos'ta,

model 2743,333 değerini tahmin etmektedir. 2 Ağustos için tahmin edilen değer 1497,008 olup tahmin edilen değerler arasındaki en yanlış sonuçtur, ardından 3 Ağustos için 2827,913. 4 Ağustos'ta model 2877.657 değerini öngörüyor ve son olarak 5 Ağustos'ta 2912.267 değerini tahmin etmektedir. Bu tahmin edilen değerler, ilgili her gün için beklenen eğilimler ve kalıplar hakkında bilgi sağlar.

Tablo 41: BIST30 Endeks, ARIMA, DVM, Holt-Winters ve Karar Ağacı Endeks Tahmin Değerleri

	01 08 2022	02 08 2022	03 08 2022	04 08 2022	05 08 2022
BIST30	2834,09	2832,55	2877,4	2921,48	2956,24
HOLT-WINTERS	2761,3965	2833,6256	2835,8888	2877,7731	2922,1551
ARIMA	2761,50	2838,20	2835,51	2879,40	2923,80
DVM	2772,433	2830,612	2857,457	2848,043	2847,263
DECISION TREE	2743,333	1497,008	2827,913	2877,657	2912,267

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Tablo 42: ARIMA, DVM, Holt-Winters ve Karar Ağacı Modellerinin Bağlı Hata, Mutlak Hata ve Yüzde Hata % Sonuçları

Tarih	Model	Bağlı Hata	Mutlak Hata	Yüzde Hata %
Ağustos 1, 2022	Holt-Winters	72.6935	0.0256	2.56%
Ağustos 2, 2022	Holt-Winters	1.0756	0.000379	0.038%
Ağustos 3, 2022	Holt-Winters	41.5112	0.0144	1.44%
Ağustos 4, 2022	Holt-Winters	43.7069	0.0149	1.49%
Ağustos 5, 2022	Holt-Winters	34.0849	0.0115	1.15%
Ağustos 1, 2022	SVM	61.657	0.0217	2.17%
Ağustos 2, 2022	SVM	1.938	0.00068	0.068%
Ağustos 3, 2022	SVM	19.943	0.0069	0.69%
Ağustos 4, 2022	SVM	73.437	0.0251	2.51%
Ağustos 5, 2022	SVM	108.977	0.0369	3.69%
Ağustos 1, 2022	Karar Ağacı	90.757	0.032	3.2%
Ağustos 2, 2022	Karar Ağacı	1335.542	0.4713	47.13%
Ağustos 3, 2022	Karar Ağacı	49.487	0.0172	1.72%
Ağustos 4, 2022	Karar Ağacı	43.823	0.015	1.5%
Ağustos 5, 2022	Karar Ağacı	43.973	0.0149	1.49%

Ağustos 1, 2022	ARIMA	72.5900	0.0256	2.56%
Ağustos 2, 2022	ARIMA	5.6500	0.0020	0.2%
Ağustos 3, 2022	ARIMA	41.8900	0.0146	1.46%
Ağustos 4, 2022	ARIMA	42.0800	0.0144	1.44%
Ağustos 5, 2022	ARIMA	32.44	0.011	1.1%

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Bu çalışmanın temel amacı, ARIMA, DVM, Holt-Winters ve Karar Ağacı olmak üzere dört farklı modelin BIST30 hisse senedi endeksinin gelecekteki değerlerini tahmin etme performansını değerlendirmektir. Analizimiz eğitim ve test setinden güncel bir örneklem dönem olan 1 Ağustos 2022- 5 Ağustos 2022 arası beş günlük kesit bir dönemi kapsamaktadır. Bu bölümde bulgularımızın bir özetini sunuyoruz. Her modelin performansını değerlendirmek için her güne bağlı hata, mutlak hata ve yüzde hata hesapladık. DVM modeli, beş günün tamamında en düşük ortalama hata yüzdesine sahipti, onu Holt-Winters ve ARIMA modelleri ve Karar Ağacı modeli izledi. Karar Ağacı modeli beş günlük ortalama en yüksek ortalama hata yüzdesine sahipti. Bu bulgular, geçmiş verilere dayalı olarak BIST30 hisse senedi endeksinin gelecekteki değerlerini tahmin etmede test ettiğimiz modeller arasında kar etme potansiyelinin sırasıyla Holt-Winters, DVM ve ARIMA modelleri olduğunu göstermektedir.

4.6. SVM, Karar Ağacı, DVM, Rastgele Orman ve Derin Öğrenme Modellerinin Karşılaştırmalı Performans Analizi

İkinci uygulamada, Python programlama dili kullanılarak uygulama için Rastgele Orman (RF), Karar Ağacı (DT), Destek Vektör Makinesi (SVM), Derin Öğrenme (DL) ve Gradyan Artırma Ağaçları (GBT) dahil olmak üzere beş fiyat tahmin yöntemi/algoritması oluşturuldu. Bu çalışma çeşitli algoritma setini kullanarak karşılaştırmalı performanslarını keşfetmeyi ve verilen veri seti ve araştırma hedefleri için en uygun yöntemi belirlemeyi amaçlamaktadır.

4.6.1. Araştırmanın Amacı ve Yöntemi

Bu kapsamlı çalışma, farklı makine öğrenimi algoritmaları kullanarak gelecekteki endeks kapanış fiyatlarını doğru bir şekilde tahmin etmeği amaçlamaktadır. Python programlama dilinin popüleritesi ve kullanılabilirliği göz önüne alınarak çalışmamızda, en doğru tahmine dayalı modeli veren algoritmayı belirlemek için Python programlama dili ve makine öğrenme tekniklerinin kombinasyonu kullanılmıştır.

4.6.2. Veri Setinin Belirlenmesi

Borsa İstanbul 30 endeksi verilerinin kullanılmasına karar verilmiştir. Bireysel hisse senetleri yerine Borsa İstanbul 30 endeksi (BIST30 endeksi) verilerinin kullanılması, makine öğrenimi algoritmalarını test ederken çeşitli avantajlar sunar:

Çeşitlendirme: Bist30 endeksi, çeşitli sektörlerden 30 önde gelen ve yerleşik şirketten oluşmaktadır. Endeks verilerinin kullanılması, genel piyasa performansının yakalanmasına ve veri setinin çeşitlendirilmesine olanak tanır. Bu, piyasanın daha kapsamlı bir temsilini sağlayarak bireysel hisse senedi fiyat dalgalanmalarının etkisini azaltır.

İstikrar: Bireysel hisse senetleri, şirkete özgü haberler veya olaylar nedeniyle genellikle yüksek dalgalanma sergiler ve bu da ani fiyat hareketlerine yol açar. Bist30 endeksi verilerinin kullanılması, daha istikrarlı piyasa eğilimlerine odaklanmayı mümkün kılarak bireysel hisse senetleriyle ilişkili özel durumların etkisini en aza indirir.

Kıyaslama: Bist30 endeksi, genel pazar performansı için bir ölçüt olarak kabul edilmektedir. Bunu bir veri kümesi olarak dahil etmek, makine öğrenimi modellerinin performansını pazarın bir bütün olarak performansı ile karşılaştırmaya olanak tanır. Bu kıyaslama süreci kullanılan algoritmaların etkinliğine ilişkin değerli bilgiler sağlar.

4.6.3. Döneminin Belirlenmesi ve Veri Setinin Oluşturulması

Matriks terminalinden elde edilen veriler kullanılarak 2005'ten 2022'ye uzanan bir veri seti oluşturulmuştur. Matriks terminali, bu dönem için güvenilir ve kapsamlı bir finansal veri kaynağı sağlamıştır. Veri seti, belirli bir zaman diliminde düzenli

aralıklarla toplanan hisse senedi fiyatları, işlem hacimleri ve diğer ilgili göstergeler gibi çeşitli finansal değişkenleri kapsıyordu. Matriks terminali kullanılarak veri seti, seçilen yıllarda finansal piyasa eğilimlerinin, kalıplarının analizini ve değerlendirilmesini kolaylaştırmak için oluşturulmuştur.

4.6.4. Bağımlı ve Bağımsız Değişkenlerin Belirlenmesi

Bağımlı ve bağımsız değişkenlerin belirlenmesi, analiz için uygun değişkenlerin seçilmesini içermektedir. Seçilen bağımlı değişken, her işlem gününün sonunda genel piyasa performansını temsil eden günlük kapanış endeksi fiyatıydı. Bağımsız değişkenler; günlük açılış fiyatı, günlük yüksek fiyat ve günlük düşük fiyat olarak belirlendi. Bu bağımsız değişkenler, işlem seansı boyunca piyasanın fiyat hareketleri ve oynaklığı hakkında bilgi sağlar. Çalışma; bu değişkenleri göz önünde bulundurarak günlük kapanış endeks fiyatı üzerindeki günlük açılış, yüksek ve düşük fiyatlar arasındaki ilişkileri ve etkileri değerlendirmeyi ve doğru gün sonu kapanış fiyatı tahmini yapan makine öğrenimi algoritması veya algoritmalarını bulunmayı amaçlamaktadır.

4.6.5. Veri Setinin Hazırlanması

Veri seti hazırlama süreci, analiz için uygunluğunu sağlamak için birkaç adım içeriyordu. Öncelikle ilgili veri kaynakları tespit edilmiş ve erişim sağlanmıştır. Bu durumda veriler, kapsamlı finansal bilgiler sağlayan Matriks terminalinden alınmıştır.

Daha sonra bağımlı ve bağımsız değişkenler tanımlanarak veri seti yapılandırılmıştır. Seçilen bağımlı değişken, genel piyasa performansını temsil eden günlük kapanış endeks fiyatıydı. Bağımsız değişkenler; fiyat hareketleri ve volatilité hakkında bilgi sağlayan günlük açılış fiyatı, günlük en yüksek fiyatı ve günlük en düşük fiyatı içeriyordu. Değişkenler belirlendikten sonra Bist30 endeksinde yer alan şirketler belirlendi. Seçilen şirketler veya endeksler için finansal bilgiler, 2005'ten 2022'ye kadar değişen belirli bir süre için toplandı. Bu veriler günlük kapanış endeks fiyatlarının yanı sıra ilgili günlük açılış, en yüksek ve en düşük fiyatları içermektedir.

4.6.6. Korelasyon Analizi

Veri setindeki değişkenler arasındaki ilişkileri incelemek için korelasyon analizi yapılmıştır. Spesifik olarak bağımlı değişken, günlük kapanış endeks fiyatı ve bağımsız değişkenler yani günlük açık, yüksek ve düşük fiyatlar arasındaki doğrusal ilişkinin derecesini ve yönünü değerlendirmeyi amaçladı.

Pearson korelasyon katsayısı gibi istatistiksel teknikler kullanılarak değişken çiftleri arasındaki doğrusal ilişkinin gücü ve yönü belirlendi. Korelasyon katsayısı -1 ile +1 arasında değişir; burada -1 değer güçlü bir negatif korelasyonu, +1 değer güçlü bir pozitif korelasyonu gösterir ve 0 değer lineer bir korelasyon olmadığını gösterir.

Genel olarak korelasyon analizi, veri kümesindeki değişkenler arasındaki ilişkileri ve bağımlılıkları tanımlamaya yardımcı oldu, bağımsız değişkenlerdeki değişikliklerin bağımlı değişkeni nasıl etkilediğine ışık tuttu ve daha fazla analiz ve modelleme için değerli bilgiler sağladı.

4.6.6.1. Bağımlı Değişken ile Bağımsız Değişkenler Arasında Korelasyon İlişkisi

Bağımlı değişken ile bağımsız değişkenler arasında korelasyon ilişkisi aşağıdaki grafik 51 ve grafik 52 ile ortaya konmuştur.

Weights by Correlation

Attribute	Weight
Open	0.999
Low	0.999
High	0.999
Date:year	0.862
days_diff(Date, Today)	0.862
Date:half year = 2	0.060
Date:half year = 1	0.060
Date:month_of_year	0.051
Date:quarter = 3	0.050
Date:quarter = 1	0.040
Date:quarter = 2	0.029
Date:quarter = 4	0.020
Date:month_of_quarter = 2	0.018
Date:month_of_quarter = 1	0.017
Date:month_of_quarter = 3	0.001
Date:day_of_month	0.001

Grafik 51. Bağımlı Değişken ile Bağımsız Değişkenler Arasında Korelasyon Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Attributes	Close	Date:day_of_month	Date:hal...	Date:hal...	Date:m...	Date:m...	Date:m...	Date:m...	Date:qu...	Date:qu...	Date:qu...	Date:qu...	Date:year	days_diff(Dat...	High	Low	Open
Close	1	-0.001	0.060	-0.060	0.017	-0.018	0.001	-0.051	0.040	0.029	-0.050	-0.020	0.862	-0.862	0.999	0.999	0.999
Date:day_of_month	-0.001	1	0.006	-0.006	0.013	-0.019	0.006	-0.005	0.003	0.004	-0.006	-0.001	-0.005	-0.000	0.000	-0.000	-0.000
Date:half year = 1	0.060	0.006	1	-1	-0.009	-0.004	0.013	-0.866	0.570	0.582	-0.581	-0.577	0.069	-0.017	0.061	0.061	0.061
Date:half year = 2	-0.060	-0.006	-1	1	0.009	0.004	-0.013	0.866	-0.570	-0.582	0.581	0.577	-0.069	0.017	-0.061	-0.061	-0.061
Date:month_of_quarter = 1	0.017	0.013	-0.009	0.009	1	-0.494	-0.507	-0.207	0.000	-0.011	0.021	-0.010	0.017	-0.004	0.015	0.016	0.017
Date:month_of_quarter = 2	-0.018	-0.019	-0.004	0.004	-0.494	1	-0.499	0.007	-0.011	0.006	0.001	0.004	-0.015	0.015	-0.017	-0.017	-0.017
Date:month_of_quarter = 3	0.001	0.006	0.013	-0.013	-0.507	-0.499	1	0.200	0.011	0.004	-0.021	0.006	-0.002	-0.010	0.001	0.001	0.001
Date:month_of_year	-0.051	-0.005	-0.866	0.866	-0.207	0.007	0.200	1	-0.748	-0.251	0.248	0.755	-0.074	0.014	-0.052	-0.051	-0.051
Date:quarter = 1	0.040	0.003	0.570	-0.570	0.000	-0.011	0.011	-0.748	1	-0.337	-0.331	-0.329	0.071	-0.026	0.041	0.040	0.040
Date:quarter = 2	0.029	0.004	0.582	-0.582	-0.011	0.006	0.004	-0.251	-0.337	1	-0.338	-0.336	0.009	0.006	0.030	0.030	0.030
Date:quarter = 3	-0.050	-0.006	-0.581	0.581	0.021	0.001	-0.021	0.248	-0.331	-0.338	1	-0.330	-0.041	0.026	-0.051	-0.050	-0.050
Date:quarter = 4	-0.020	-0.001	-0.577	0.577	-0.010	0.004	0.006	0.755	-0.329	-0.336	-0.330	1	-0.039	-0.007	-0.020	-0.021	-0.020
Date:year	0.862	-0.005	0.069	-0.069	0.017	-0.015	-0.002	-0.074	0.071	0.009	-0.041	-0.039	1	-0.998	0.862	0.864	0.863
days_diff(Date, Today)	-0.862	-0.000	-0.017	0.017	-0.004	0.015	-0.010	0.014	-0.026	0.006	0.026	-0.007	-0.998	1	-0.861	-0.863	-0.862
High	0.999	0.000	0.061	-0.061	0.015	-0.017	0.001	-0.052	0.041	0.030	-0.051	-0.020	0.862	-0.861	1	1.000	0.999
Low	0.999	-0.000	0.061	-0.061	0.016	-0.017	0.001	-0.051	0.040	0.030	-0.050	-0.021	0.864	-0.863	1.000	1	1.000
Open	0.999	-0.000	0.061	-0.061	0.017	-0.017	0.001	-0.051	0.040	0.030	-0.050	-0.020	0.863	-0.862	0.999	1.000	1

Grafik 52. Bağımsız Değişken-Bağımlı Değişken Korelasyon Matrisi

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Korelasyon katsayılarını analiz ederek, bağımsız değişkenlerdeki değişikliklerin bağımlı değişkendeki değişikliklerle nasıl ilişkili olduğuna dair içgörüler elde edildi. Örneğin; günlük açılış fiyatı ile günlük kapanış endeks fiyatı arasındaki pozitif bir korelasyon katsayısı, daha yüksek açılış fiyatlarının daha yüksek kapanış endeks fiyatlarına karşılık gelme eğiliminde olduğunu ve potansiyel bir pozitif ilişkiye işaret ettiğini gösterir.

Benzer şekilde günlük en yüksek ve en düşük fiyatlar ile günlük kapanış endeks fiyatı arasındaki korelasyonun incelenmesi, piyasa oynaklığına ilişkin içgörü sağladı. Günlük en yüksek fiyat ile günlük kapanış endeks fiyatı arasındaki daha yüksek bir pozitif korelasyon; piyasadaki daha yüksek tepelerin daha yüksek kapanış endeks fiyatlarına karşılık gelme eğiliminde olduğunu gösterirken, günlük en düşük fiyat ile günlük kapanış endeks fiyatı arasındaki negatif bir korelasyon şunu gösterir: daha düşük dipler daha yüksek kapanış endeks fiyatlarına karşılık gelme eğilimindedir.

4.6.7. Verinin Eğitim Seti-Test Seti Olarak Bölünmesi

Veri seti, makine öğrenimi algoritmalarının performansını ve genellemesini değerlendirmek için bir eğitim seti ve bir test seti olarak bölünmüştür. Bu bölümlleme işlemi verilerin doğrusal iki alt kümeye bölünmesini içeriyordu: eğitim seti ve test seti.

Tipik olarak verilerin daha büyük bir bölümünü (%90) içeren eğitim seti, makine öğrenimi modellerini eğitmek için kullanıldı. Algoritmaların veriler içindeki kalıpları, ilişkileri ve eğilimleri öğrenmesi için girdi görevi gördü. Modeller, bu eğitim verilerine dayanarak parametrelerini ayarladı ve performanslarını optimize etti. Öte yandan, verilerin geri kalan kısmını (%10) oluşturan test seti, eğitim aşamasında ayrı ve dokunulmadan tutuldu. Bu test seti, eğitilmiş modellerin görünmeyen verilere ne kadar iyi genelleştirilebileceğini değerlendirmek için bağımsız bir değerlendirme veri seti olarak hizmet etti.

Verileri bu şekilde bölümlere ayırarak makine öğrenimi modellerinin yeni ve görünmeyen veriler üzerindeki performansını ölçmek mümkün oldu. Bu değerlendirme, modellerin gerçek dünya senaryolarında doğru tahminler veya sınıflandırmalar yapma becerisine ilişkin değerli bilgiler sağladı. Ayrıca aşırı uyum ile ilgili olası sorunların (bir


modelin eğitim verilerinde iyi, ancak yeni verilerde kötü performans göstermesi) tespit edilmesine ve modellerin genel sağlamlığının değerlendirilmesine yardımcı oldu.

4.6.8. Kullanılacak Yöntemlerin/Algoritmaların Belirlenmesi

Çalışma Python programlama dili kullanılarak uygulama için Rastgele Orman (RF), Karar Ağacı (DT), Destek Vektör Makinesi (SVM), Derin Öğrenme (DL) ve Gradyan Artırma Ağaçları (GBT) dahil olmak üzere beş yöntem/algoritma seçildi. Bu çeşitli algoritma setini kullanarak karşılaştırmalı performanslarını keşfetmeyi, verilen veri seti ve araştırma hedefleri için en uygun yöntemi belirlemeyi amaçladı.

4.6.9. Sonuç İncelemesi


Grafik 53 incelendiğinde; Rastgele Orman modeli yaklaşık 0,022'lik bir ortalama göreceli hata değeri görülmüştür. Karar Ağacı modelinin biraz üzerinde olmasına rağmen grafik temsili gerçek verilerle SVR veya Gradyan Artırma modelleri kadar uyumlu değildir. Karar Ağaçlarının bir topluluğu olan Rastgele Ormanlar, Karar Ağaçlarının bazı eksikliklerinin üstesinden gelebilmesine rağmen yine de gürültülü verilere aşırı uyum sorunu gözlenmektedir.



Grafik 53. Rastgele Orman Tahmin-Hata Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.


Grafik 54’ te görülen Derin Öğrenme modelinin yaklaşık 0,023’lük bir ortalama görelî hata skoru bulunmaktadır. Diğer modellere kıyasla daha az doğru olmasına rağmen grafik gösterimi, gerçek verilerle yine de önemli bir eşleşme sergilemektedir. Derin Öğrenmenin gücü, onu büyük ölçekli finansal veriler için güçlü bir araç haline getiren çok büyük miktarlarda karmaşık ve yüksek boyutlu verilerden öğrenme kapasitesinde yatmaktadır.



Grafik 54. Derin Öğrenme Tahmin-Hata Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Grafik 55’te Destek Vektörü Makineleri, modeli yaklaşık 0,016’lık ortalama bağıl hata skoruyla üstün performans göstermektedir. Bu model grafik 50’de tahmin edilen ve gerçek değerler arasında yakın bir uyum sunan tahminlerinde yüksek doğruluğu gösterir. Bu etkileyici performans, DVM’nin benzersiz yüksek boyutlu verilerle başa çıkma kabiliyetine ve aşırı uyuma karşı sağlamlığına bağlanabilir; bu da daha kesin ve güvenilir tahminler sağlamaktadır.



Grafik 55. Destek Vektör Makineleri Tahmin-Hata Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.


Grafik 56 için Gradyan Artırma Regresör modeli için ortalama bağıl hata yaklaşık 0,022'dir. DVM'den biraz daha düşük olmakla birlikte gerçek değerlerle Gradyan Artırma Regresör modelinin tahminlerini gösteren grafik önemli bir örtüşme göstermektedir ve bu da başarılı tahmin gücüne işaret etmektedir. Gradyan Artırma modelinin başarısı; her biri öncekilerin hatalarını öğrenen ve geliştiren, çeşitli veri kümeleri için iyi çalışma eğiliminde olan zayıf öğrencilerden oluşan bir topluluk oluşturma becerisinde yatmaktadır.



Grafik 56. GBT Tahmin-Hata Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Grafik 57 Karar Ağacı modeli için yaklaşık 0,025'lik bir ortalama bağıl hata skoru ile sonuçlanmıştır. Diğer modelleri takip etmesine rağmen karşılık gelen grafik yine de iyi bir tahmin doğruluğu seviyesi göstermektedir. Basit ve yorumlanabilir modeller olan Karar Ağaçları, veri modellerini anlamak için mükemmel bir temel sağlar. Bununla birlikte basit yaklaşımları, karmaşık ilişkileri diğer modeller kadar etkili bir şekilde yakalayamayabilir.



Grafik 57. Karar Ağacı Tahmin-Hata Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Sonuçlar; Destek Vektör Regresyonunun tüm modeller arasında en yüksek tahmin doğruluğunu elde ettiğini göstermektedir. SVR, genellikle baskın olan Derin Öğrenme modelini bile önemli ölçüde geride bırakarak güçlü tahmin yeteneği göstermektedir. Ancak bu sonuçların değerli içgörüler sağlasa da kesin olmadığını unutmamak önemlidir. Veri özellikleri, model parametreleri ve seçilen özellikler gibi çeşitli faktörler, bu algoritmaların tahmin gücünü etkileyebilmektedir. 'En iyi' model genellikle eldeki sorunun özelliklerine bağlı olabileceğinden, çeşitli model ve teknikleri keşfetmek her zaman ihtiyatlı bir davranıştır.

Ayrıca bu analiz yalnızca tarihsel verilere dayanmaktadır ve sonuçları gelişen piyasa dinamikleri veya görünmeyen gelecek verileri karşısında geçerli olmayabilir. Derin öğrenme modellerinin kaynak yoğun olmasına ve bazen daha basit modellere göre marjinal kazançlar sağlamasına rağmen genellikle daha karmaşık, çok boyutlu görevlerde üstün olduklarını belirtmekte fayda vardır.

Gelecekteki çalışmalarda, genellikle bireysel modellerden daha iyi performans gösteren daha gelişmiş özellik seçme yöntemlerinin, daha fazla hiperparametre ayarının ve topluluk yöntemlerinin araştırılmasının dahil edilmesini öneririz. Nihayetinde amaç modellerimizin tahmine dayalı doğruluğunu ve güvenilirliğini iyileştirmek, böylece gerçek dünyadaki finansal tahminlerde uygulanabilirliğini artırmaktır.

Sonuç olarak bu kapsamlı çalışma, farklı makine öğrenimi algoritmalarının tahmin potansiyeline ilişkin ilginç içgörüler ortaya koyuyor. XU030 endeksinin tarihsel fiyatlarını içeren, model eğitimi ve değerlendirmesi için özenle düzenlenmiş ve titizlikle işlenmiş kapsamlı bir veri seti kullandık. Amacımız çeşitli tahmine dayalı algoritmalar kullanarak gelecekteki endeks kapanış fiyatlarını doğru bir şekilde tahmin etmektir. Bu çalışmanın gelecekteki araştırma ve uygulamalar için bir temel oluşturmasını umuyoruz.


4.7. Backtest Uygulaması

Finanstaki istatistiksel modellerin gerçek gücü, gelecekteki fiyat hareketlerini güvenilir bir şekilde tahmin etme yeteneklerine yansır. Ticaret ve yatırım alanında en önemli zorluklardan biri, menkul kıymet alım satımı hakkında günlük kararlar vermektir. Geriye dönük test senaryomuzda, bu kararlar istatistiksel modellerimizin tahmin gücü tarafından yönlendirildi.

İlk olarak modelimizi eğitmek için tarihsel verilerden yararlanıldı, bu da modelin pazardaki geçmiş modellerden ve trendlerden 'öğrenmesine' olanak sağladı. Haftanın günü, ayın günü ve ayın kendisi gibi zamansal parametrelerin yanı sıra açılış, kapanış, önceki günlerin en yüksek ve en düşük fiyatları gibi özellikleri dahil ettik. Modelimiz eğitildikten sonra açılış fiyatına ve diğer ilgili faktörlere dayalı olarak bir sonraki işlem gününün kapanış fiyatını tahmin etmek için güçlü bir araç haline geldi. Bu tahminler aracılığıyla al-sat stratejimizi uygulayabiliriz. Her işlem gününde model kapanış fiyatını tahmin etmektedir. Öngörülen kapanış fiyatı açılış fiyatından yüksekse, modelimiz menkul kıymetin değerinin gün boyunca artacağını öne sürüyor. Yanıt olarak "uzun" pozisyon alınmaktadır, yani menkul kıymeti açılış fiyatından alır, daha sonra daha yüksek bir kapanış fiyatından satmayı planlar ve böylece fiyat artışından kar elde etmektedir.

Tersine işleyişte model kapanış fiyatının açılış fiyatından daha düşük olacağını tahmin ederse, menkul kıymetin değerinin gün boyunca düşeceğini sinyali verir. Bu gibi durumlarda esasen açılış fiyatından satış yaparak ve daha düşük bir kapanış fiyatından geri almayı planlayarak fiyat düşüşünden kâr elde ederek "kısa" pozisyon almaktadır.


Bu dinamik süreç, modelin sürekli olarak yeni verilerden öğrenmesi ve tahminlerini buna göre uyarlaması ile her işlem gününde gerçekleşti. Kümülatif portföy değeri grafiği test süresi boyunca bu stratejinin etkinliğini göstermektedir. Başlangıç portföy değeri 100.000 TL olarak belirlenmiştir. Bununla birlikte bu açıklama önemli bir uyarı ile birlikte gelmelidir: Bu geriye dönük test çalışmasının sonuçları umut verici olsa da gelecekteki başarıyı garanti etmez. Alım satım, doğası gereği risklidir ve tümü modellerle yakalanamayan sayısız faktörden etkilenir. İşlem maliyetleri, piyasa etkisi ve risk toleransı, bu tür stratejileri uygularken dikkate alınması gereken birçok gerçek dünya faktörü arasındadır. Sonuç olarak burada özetlenen metodoloji, ticarete sistematik ve veri odaklı bir yaklaşım oluşturmak için istatistiksel modellerin uygulanmasını göstermektedir.



Grafik 58. Derin Öğrenme Backtest Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.


Grafik 58, yapay sinir ağı olarak bilinen beynin yapısından ve işlevinden ilham alan bir algoritma sınıfı olan Derin Öğrenme modelidir. Modelin büyük miktarda karmaşık veriden öğrenme yeteneğini yansıtan 162.411,6 TL’lik bir portföy değeri ile sonuçlandığı gözlenmektedir. Derin Öğrenme modelinin performansı, finansal verilerin karmaşıklıklarının deşifre edilmesinde sahip olduğu analiz zaman dilimi özelinde gözlenmektedir.



Grafik 59. Rastgele Orman Backtest Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.


Grafik 59’da görüldüğü gibi diğer bir topluluk yöntemi olan Rastgele Orman modeli ise yaklaşık 79.377,82 TL portföy değeri ile sonuçlanmıştır. Bu modelin düşük performansı, gürültülü finansal verilere aşırı uyma eğiliminden veya modelin kendisindeki doğal rastgelelikten kaynaklı olabileceği akla gelmektedir. Rastgele Orman modelinin çok çeşitli sorunları etkili bir şekilde çözebilmesine rağmen analiz edilen dönem özelinde finansal piyasa tahmini için her zaman en iyi seçenek olmayabileceğini gözlenmektedir.



Grafik 60. Destek Vektör Makineleri Backtest Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.


Grafik 60'ta Destek Vektör Makineleri (SVM) modeli 228.522 TL gibi etkileyici bir portföy değeri topladığı görülmektedir. Bu üstün performans, modelin finansal verilerin karmaşık dinamiklerini ele alma konusundaki uzmanlığının altını çizerek, sağlamlığının ve uyarlanabilirliğinin bir kanıtıdır.



Grafik 61. Gradyan Artırma Ağaçları Backtest Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Grafik 61’de Gradyan Artırma Ağaçları modeli 157.132,9 TL’lik bir portföy değerine ulaştığı gözlenmektedir. Gradyan Artırma Ağaçları modeli performansı, karmaşık veri kalıplarını yakalama yeteneğini seçilen zaman dilimi özelinde %57,1 getiriyle ispatlamıştır.



Grafik 62. Karar Ağacı Backtest Grafiği

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Grafik 62’de basitliği ve yorumlanabilirliği ile tanınan algoritmik bir yaklaşım olan Karar Ağacı modeli sunulmaktadır. 73.917,58 TL’lik bir nihai portföy değeri gerilediği görülmektedir. Bu değer, analiz edilen diğer modellere kıyasla en kötü performanstır. Bu performans analiz edilen zaman özelinde fiyat tahmininin öncelikli olduğu senaryolar için en uygun seçim olmayacağı göstermektedir.

4.7.1. Sonuç İncelemesi

Makine öğrenimi ve finansal piyasaların büyüleyici kesişimini daha derinlemesine araştırdıkça bunların etkileşimine ilişkin anlayışımız daha net hale geliyor ve finansal tahmin araçlarımız giderek daha güçlü hale geliyor. Makine öğrenimi modelleri hızla finans sektöründe ayrılmaz bileşenler haline geliyor ve piyasaların doğasında var olan karmaşıklığın kodunu çözmemize ve değerli tahminler sağlamamıza yardımcı oluyor. Araştırmamızda Bist30 endeksi kullanılarak borsa ticaretindeki öngörü gücünü anlamak için birkaç makine öğrenimi modelini geriye dönük test ettik.

Çalışmamızda Karar Ağacı, Gradyan Artırıcı Ağaçlar (GBT), Destek Vektör Makineleri (SVM), Rastgele Orman ve Derin Öğrenme algoritmaları gibi modeller kullanılmıştır. Her model tarihsel verilerle beslendi ve tahminlerine göre günlük alım satım kararları vermekle görevlendirildi. 100.000 TL'lik bir başlangıç portföy değeri kabul edilen bu simülasyonda, Karar Ağacı modeli yaklaşık 73.917,58 TL'lik bir nihai portföy değeri verirken, Gradyan Artırıcı Ağaçlar modeli 157.132,9 TL'lik bir değer elde etti. Destek Vektör Makineleri modeli 228.522 TL'lik gibi önemli bir nihai portföy değeri toplayarak, test edilen modeller arasında en başarılısı olarak öne çıktı. Bunun yanında Rastgele Orman ve Derin Öğrenme modelleri sırasıyla yaklaşık 79.377,82 TL ve 162.411,6 TL nihai portföy değeri sonuçları sağladı.

Bu sonuçlar, finansal piyasaların akışkanlığı ve karmaşıklığı ile karşı karşıya kalındığında farklı makine öğrenimi modellerinin değişen tahmin gücünü canlı bir şekilde göstermektedir. Destek Vektör Makinelerinin çalışmamızdaki yüksek performansı, onu evrensel olarak üstün bir araç olarak göstermez. Finansal tahmin için model seçimi; veri setinin doğası, söz konusu finansal araç, geçerli piyasa koşulları ve yatırımcının risk toleransı gibi çok sayıda faktöre bağlıdır.

Geriye dönük test, strateji değerlendirmesi için güçlü bir yöntem olsa da modelin yorumlanabilirliği (finans gibi düzenlenmiş sektörlerde kilit bir faktör) ve seçilen modelin hesaplama gereksinimleri gibi hususları dikkate almak önemlidir. Sonuç olarak, araştırmamızın da gösterdiği gibi dinamik finans ortamı makine öğrenimi modellerinden büyük ölçüde yararlanabilir. Bununla birlikte kullanımları, modelin güçlü ve zayıf yanlarının ve kullanıldıkları bağlamın sağlam bir şekilde anlaşılmasıyla yumuşatılmalıdır. Ayrıca yatırımın ana kuralı unutulmamalıdır: geçmiş performans gelecekteki sonuçların göstergesi değildir. Bu nedenle yapay zeka odaklı ticaret stratejilerinin başarısı için sürekli değerlendirme ve iyileştirme esastır. Finansta yapay zeka çağı sadece ufukta değil, şimdiden önümüzde ve potansiyeli çok büyük ve kullanılmayı bekliyor.

4.7.2. Sonuç İncelemesi İki

Yapılan backtest uygulamasının makine öğrenme modellerine göre doğru karar sayısı, yanlış karar sayısı, doğru karar oranı ve yanlış karar oranı tablo 137 'de verilmiştir.

Tablo 37: Modellerin Doğru Karar, Yanlış Karar, Doğru Karar Oranı: % ve Yanlış Karar Oranı: % Tablosu

	Doğru Karar	Yanlış Karar	Doğru Karar Oranı: %	Yanlış Karar Oranı: %
Derin Öğrenme	137	114	54,57	45,43
Karar Ağacı	125	126	49,80	50,20
Rastgele Orman	132	119	52,60	47,40
DVM	137	114	54,57	45,43
GBT	145	106	57,78	42,22

Kaynak: Kendi ampirik çalışmamızın sonuçlarına dayanarak üretilmiştir, 2023.

Çoklu makine öğrenimi modellerinde yürütülen ampirik analize dayanarak Gradyan Artırıcı Ağaçların yaklaşık %57,78'lik bir doğruluk oranıyla sonuçları doğru bir şekilde sınıflandırma veya tahmin etmede üstün performans göstererek en yüksek doğruluğu sağladığı fark edilmektedir. Bu sonuç, bu modelin sağlanan veri setinden genelleme yapma ve bu özel bağlamda diğer modellere kıyasla doğru kararlar verme konusunda daha iyi bir yeteneğe sahip olduğunu göstermektedir. Karar Ağacı modeli yaklaşık %49,80 ile en düşük doğruluğu gösterdi. Bu, verilerin karmaşıklığıyla mücadele etmiş olabileceğini veya aşırı uyumdan meydana gelmiş olabileceğini düşündürüyor. Bu düşük doğruluk oranı, test edilen modeller arasında en fazla sayıda yanlış karar verdiğini ortaya koyuyor. Destek Vektörü Regresyonu (SVR), Derin Öğrenme modeli %54,57 ve Rastgele Orman modeli %52,60 doğruluklarla benzer performanslar sundu. Bu analiz sonuçları modellerin dengeli bir performans sağladığını başarılı olduğunu göstermektedir. Bununla birlikte, doğruluğun performansın yalnızca bir ölçüsü olduğunu ve özellikle verilerin dengesiz olduğu durumlarda tüm hikayeyi anlatmayabileceğini belirtmekte fayda var. Ayrıca her modelin, eldeki sorunun belirli

özelliklerine ve gereksinimlerine bağlı olarak az ya da çok ilgili hale gelebilecek güçlü ve zayıf yönleri vardır.

Gradyan Artırma Ağaçları bu analizde en iyi sonuçları gösterse de bu sonuçların verilen veri kümesine ve bağlama özel olduğuna dikkat etmek önemlidir. Belirli bir görev için en iyi modeli seçerken yorumlanabilirlik, hesaplama verimliliği, farklı veri türlerini ve karmaşık ilişkileri yönetme kapasitesi gibi diğer faktörler de dikkate alınmalıdır. Bu sonuçların nedenlerini daha iyi anlamak için daha fazla analiz önerilir, bu da potansiyel olarak model ayarlama ve veri kümesi ön işleme yoluyla daha iyi sonuçlara yol açar. Sonuç olarak bu metriklere dayanarak; sunduğunuz modeller arasında en yüksek doğruluğa Gradyan Artırma Ağaçları, en düşük doğruluğa ise Karar Ağacı modeli sahiptir.

4.8 Sonuçlara Genel Bakış

Bölüm 4'te çeşitli modellerin finansal piyasa tahminlerinin karmaşıklığını ve modeller arasındaki farklılıkları vurgulamaktadır. ARIMA modeli, çok yönlü sonuçlarıyla önemli bir noktanın altını çiziyor: Bazı modeller istatistiksel olarak geçmiş verilere iyi uyum gösterse de tahmin yetenekleri farklılık gösterebilir. Bu, bazı modellerin hisse senedi getirilerindeki değişkenliğin büyük çoğunluğunu açıkladığı, diğerlerinin ise yüzeyi zar zor açıkladığı, gözlemlediğimiz R-kare değerleri spektrumunda yankı buluyor. Bununla birlikte, Holt-Winters tahminleri, mükemmele yakın R-kare değerlerinin de gösterdiği gibi övgüye değer bir doğruluk sergileyerek farklı bir hikayeyi tasvir ediyor. AIC ve BIC'in R-kare değerleri ile iç içe değerlendirilmesi, söz konusu hisse senetleri için Holt-Winters yönteminin sağlamlığını desteklemektedir. Yine de bir uyarıda bulunmak gerekiyor: Bu modellerin öngörülebilirliği, geriye dönük bağlamda etkileyici olsa da geleceğe yönelik bir belirsizlik unsuru taşıyor. Piyasalar, çok iyi bildiğimiz gibi, dinamiktir ve hem ölçülebilir hem de soyut sayısız faktörden sürekli olarak etkilenir.

BIST30 hisse senedi endeksi için klasik istatistiksel yöntemlere karşı makine öğrenimi tekniklerinin kapsamlı bir analizi, bunların tahmin yeteneklerinin panoramik bir görünümünü sağlar. SVM, tahmin hassasiyeti açısından öne çıkarken, çok övülen Derin Öğrenme modelleri üzerindeki hakimiyeti, borsaların karmaşıklığının ve

doğasında var olan öngörülemezliğin bir kanıtıdır. Ek olarak, Karar Ağaçlarından Gradyan Arttırma Ağaçlarına kadar uzanan performans spektrumu, veri kümesinin doğasından geçerli piyasa koşullarına kadar çeşitli değişkenlere bağlı olarak akıllı model seçimi ihtiyacını vurgulamaktadır. Özellikle ampirik bulgularımız temel bir prensiple örtüşüyor: Geçmiş her ne kadar öğretici olsa da her zaman geleceğin göstergesi değildir. Gradyan Arttırma Ağaçlarının %57,78'lik doğru karar verme oranıyla kanıtlanan etkileyici performansı, uyarlanabilirliğini ve sağlamlığını vurguluyor. Bununla birlikte, niceliksel doğruluk ölçütü netlik sağlasa da kapsamlı bir ölçü değildir. Her modelin nüansları, doğasında var olan güçlü yönleri, hesaplamada kullandığı bilgi miktarı ve değişken piyasa ortamlarına uyum sağlama yeteneği dikkatli bir değerlendirme gerektirir.

Özetle, 4. Bölüm'de çeşitli modellerin öngörü yeteneklerine yönelik girişim aydınlatıcı görüşler sağlamaktadır. Makine öğrenimi umut vaat etmekte ve finansal piyasaların labirent dünyasını çözme konusunda etkinliğini gösteriyor olsa da bu tür modellere ılımlı bir iyimserlikle yaklaşmak hayati önem taşımaktadır. Piyasalar sürekli gelişen bir faktörler ağından etkilenir. Bu nedenle, SVM veya Gradyan Arttırma Ağaçları gibi modeller şu anda ilgi odağı olsa da finansal alanın sayıların, kalıpların ve öngörülemezliğin karmaşık bir dansı olmaya devam ettiğini hatırlamak çok önemlidir. Son olarak "Bilgi, gerçekleri biriktirme sürecidir; bilgelik ise onların basitleştirilmesinde yatar."

V. SONUÇ VE TARTIŞMA

Bu tez çalışmasında ortaya çıkan sonuca göre finansal teknoloji alanında çok önemli bir girişim olan günlük borsa kapanış fiyatlarının tahmininde makine öğrenimi modellerinin uygulanmasına ilişkin kapsamlı bir çalışma sunuldu. Bu araştırmayı yönlendiren dört ana hipotez vardır:

Birinci Hipotezin onaylandığını memnuniyetle bildirmekle birlikte makine öğrenim modellerimiz günlük borsa kapanış fiyatlarını tahmininde yüksek doğruluk göstermektedir. Gradyan Artırma Ağaçları (GBT) modeli, %57,78'lik bir doğru karar oranı sergileyerek dikkate değer bir yeterlilik göstermiştir. Bu sonuç yalnızca sayısal bir başarı değil, aynı zamanda makine öğrenimi algoritmik model kapasitesi ile yapay zeka finansal anlayışının karmaşık birleşiminin bir kanıtı olarak hizmet etmektedir. Her ikisi de %54,57'lik doğru karar oranı sergileyen Derin Öğrenme ve Destek Vektör Makinesi (SVM) modelleri, önermelerimizin doğrulandığının altını çizmektedir. Performansları; hesaplama tekniklerindeki ilerlemelerin ve finansal analitik ile simbiyotik ilişkilerinin simgesidir. Rastgele Orman ve Karar Ağacı modelleri, sırasıyla %52,60 ve %49,80 oranlarıyla biraz geride kalsa da yine de akademik varsayımlarımızın kapsamlı bir şekilde doğrulanmasına katkıda bulunmaktadır. Bu bulguları borsa dinamiklerinin geniş dokusu içinde bağlamsallaştırmamız gerekmektedir. Borsa oynaklığının çok yüksek olduğu Bist30 endeksinde böylesine övgüye değer doğruluk oranlarına ulaşmak, metodolojik çerçevemizin sağlamlığı ve hipotezimizin uygulanabilirliğinin bir başarısıdır. Sonuçta burada ortaya konan hipotezi onaylamakla kalmamakta, aynı zamanda makine öğrenimi ve finansal tahmin arasındaki simbiyotik ilişkiyi çevreleyen literatür birikimini de arttırmaktadır.

Makine öğrenimi ile kesişen finansal tahminin akademik ortamında, standartlaştırılmış çözümler ile özel modeller arasındaki tartışma çok eskidir. Çalışmamızın ikinci hipotezi, Python ortamında özel olarak geliştirilen bir modelin geleneksel paket programlarda kapsüllenmiş mevcut modellere kıyasla üstün tahmin becerisi sergileyebileceğini ikinci hipotezimizde belirtmekteyiz. Bu önermeyi

sorgulamak için, görelî hata ölçütlerinin doğrudan incelenmesi belirleyici olmaktadır. Yerleşik paket algoritmalar şu görelî hataları sunmaktadır: 3.19'da Derin Öğrenme, 2.06'da Karar Ağacı, 2.74'te Rastgele Orman, 2.16'da GBT ve 2.53'te SVM. Aksine, Python'daki özel olarak tasarlanmış SVM modelimiz, 1,60 gibi düşük bir görelî hata kaydetti; bu, istatistiksel olarak önemli ölçüde bir performans artışıdır. Akademik bir bakış açısıyla yaptığımız bu çalışma, iki önemli içgörünün altını çiziyor. İlk olarak, kullanıma hazır çözümlerin avantajları olsa da özel olarak oluşturulmuş modellerde kullanılmayan potansiyel optimizasyon vardır. İkincisi, Python gibi bir yazım dilinin sağladığı esneklik ve uyarlanabilirlik, finansal tahmin gibi özel alanlarda daha uyumlu ve rafine tahmine dayalı sonuçlar elde etmek için kullanılabilir. Özünde, bu çalışmanın bulguları, ikinci hipotezimizin paket programların kolay kullanımına karşın özel çözümlerin ayırt edici özellikleri olan finansal tahmin, kesinlik ve özgüllük alanında gerçekten de üstün tahmin doğruluğu sağlayabileceğini öne sürmektedir.

Beş günlük hisse senedi fiyat tahminlerini birden fazla modelde inceledikten sonra üçüncü hipotezimiz güçlü bir şekilde doğrulanmış olup bazı modellerin diğerlerini başarı performansı olarak geride bırakacağını belirtmektedir. Çeşitli modeller için ortalama görelî hata önemli ölçüde farklılık gösterir: Derin Öğrenme %5,68, Karar Ağacı %3,56, Rastgele Orman %4,75, Gradyan Artırma Ağaçları %3,73 ve Destek Vektör Makinesi %4,41. Bu rakamlar, tahmin kapasitelerindeki içsel heterojenlikleri vurgulayarak, her bir algoritmik yaklaşımın farklı etkinlik ve hassasiyetlerinin altını çizmektedir. Günlük ortalama görelî hata değerleri daha fazla ayrıntı sağlamaktadır. Burada yine modeller arasında dikkate değer farklılıklar görüyoruz: Derin Öğrenme (3.19), Karar Ağacı (2.06), Rastgele Orman (2.74), GBT (2.16) ve DVM (2.53). Özellikle Karar Ağacı modeli, belirli tahmin bağlamlarındaki iyi başarısının bir kanıtı olan minimum hata oranıyla öne çıkmaktadır. Bu bulguları destekleyen Bist30 endeksi üzerinde uyguladığımız analizimizin doğru karar oranları da benzer bir eğilimi açıklamaktadır. Gradyan Artırma Ağaçları modeli, %57,78'lik doğru karar oranıyla emsallerinden daha iyi performans gösterirken, Karar Ağacı modeli diğer analizlerde daha düşük görelî hatasına rağmen %49,80'lik doğru karar oranı sergilemektedir. Bu da belirli piyasa koşullarına potansiyel aşırı uyum veya duyarlılığı göstermektedir. Burada derlenen sayısız sonuç üçüncü hipotezimizin doğruluğuna tanıklık ediyor. Sayıların

karmaşık ilişkisi – ister göreceli hata oranları veya doğru karar yüzdeleri şeklinde olsun – hisse senedi fiyat tahmini alanındaki makine öğrenimi modellerinin farklı performans kapasitelerine açık bir şekilde işaret etmektedir. Sonuç olarak bu araştırma sadece belirli finansal tahmin görevleri için doğru makine öğrenme modelini seçmenin önemini yeniden teyit etmekle kalmaz, aynı zamanda bu tür seçimlere rehberlik etmede titiz ampirik incelemenin değerini de vurgulamaktadır.

Makine öğrenimi ve finansal tahminin birleşmesi, yıllar içinde zengin bir akademik iştigal dokusuna dönüştü. Araştırmanın bu karmaşık matrisi içinde yer alan ve diğer üç hipotezine ek olarak dördüncü hipoteziyle ifade edilen çalışmamız, makine öğrenimi tekniklerinin hisse senedi fiyatı tahminleri alanındaki pratik sonuçlarına ışık tutarak literatürü zenginleştirmeye çalışmaktadır. Ayrıca teorik varsayımlar ile bunların finansal yatırımdaki pragmatik faydaları arasındaki mesafeyi kapatmayı amaçlamaktadır. Zengin bir literatür taraması sonucu ortaya çıkan çalışmamız; Karar Ağacı, Gradyan Artırıcı Ağaçları (GBT), Destek Vektör Makineleri (SVM), Rastgele Orman ve Derin Öğrenme algoritmalarını kapsayan makine öğrenimi modellerinin yanı sıra klasik yöntemlerden Arima ve Holt-Winters yöntemlerini de kapsamaktadır. Mevcut literatürde yaygın olarak bulunan geleneksel değerlendirme ölçütlerine ek olarak araştırmamız daha uygulamalı bir simülasyon üstlendi. Her bir modele 100.000 TL'lik bir başlangıç portföy değeri mevduat vererek modellerin tahminlerine göre hisse senedi alım satımına olanak sağladı. Bu bilimsel çabanın sonuçları hem işlevsel hem de aydınlatıcıdır. Karar Ağacı modeli, yorumlanabilirliği nedeniyle birçok akademik çalışmada övgüyle karşılanırken, yaklaşık 73.917,58 TL'lik bir nihai portföy değeri ile sonuçlandı. Bunun yanında Gradyan Artırıcı Ağaçları modeli önceki araştırmalardaki övgü dolu sözlerini tekrarlayarak 157.132,9 TL gibi güçlü bir değer ortaya koydu. Ancak finansal literatürde sık sık alıntılanan sağlamlılığının bir kanıtı olan SVM modeli, 228.522 TL'lik benzersiz bir portföy değerine ulaştı. Çalışmaya derinlik katan Rastgele Orman ve Derin Öğrenme modelleri sırasıyla 79.377,82 TL ve 162.411,6 TL getiri kaydetti. Bu bulguların ağırlığı yalnızca ampirik değerlerinde değil, aynı zamanda mevcut akademik literatürün ufku genişletme potansiyelinde yatmaktadır. İlk olarak; her bir modeldeki karmaşık güçlü ve zayıf yönler örgüsünün altını çizerek araştırmacıları daha nüanslı, bağlama duyarlı bir yaklaşımı benimsemeye teşvik

ediyorlar. İkinci olarak; simülasyondan tahmin edilen somut mali sonuçlar teorik yapılar ile bunların gerçek dünyadaki sonuçları arasındaki simbiyotik ilişkiyi vurgulayarak yatırımcı topluluğa açık bir kılavuz görevi görür. Özetle bu araştırma; ampirik analize dayanmakla birlikte makine öğrenimini yalnızca hesaplamalı bir araç olarak değil, aynı zamanda borsaların karmaşık dinamiklerinin ayırt edilebileceği ve incelenebileceği bilimsel bir mercek olarak öne sürerek büyüyen finansal literatür özetine önemli ölçüde katkıda bulunmaktadır. Buradaki bulguların yalnızca akademik diyalogları zenginleştirmekle kalmayıp aynı zamanda makine öğrenimi ve finansal literatürün bağlantı noktasında gelecekteki araştırmaların önünü açması en büyük temennimizdir. İnanıyoruz ki çeşitli makine öğrenimi modellerinin performansının karşılaştırılmasından elde edilen bilgiler ile bunların farklı güçlü ve zayıf yönlerinde elde edilen anlayış, kaçınılmaz olarak mevcut bilgi havuzuna katkıda bulunacaktır.

Dikkatli değerlendirme ve analiz yoluyla sonuçlarımız hipotezleri doğrulamıştır. Sonuç olarak bulgularımız, bilinçli kararlar almak için tahmine dayalı modellere güvenen finansal analistler ve yatırımcılar için önemli çıkarımlara sahiptir. Ancak bu çalışmanın sonuçlarının kullanılan teknolojik imkanlar, veri seti ve zaman dilimine özgü olduğuna dikkat etmek önemlidir. Örneğin Bank of Amerika'nın 2023 yılı ilk üç aylık uluslararası piyasalarda hisse Al-Sat getirisi 1.6 milyar dolardır²⁴⁶. Bu rakam yıllık bazda Türkiye'nin 2022 yılı net karı en yüksek şirketten (Koç Holding 69 milyar TL) daha fazla bir getiri işaret etmektedir. Bu çalışma, makine öğrenimi modellerinin borsa kapanış fiyatlarını tahmin etmedeki potansiyel ve değişken etkililiğinin altını çiziyor. Bulgularımız bu alanda makine öğreniminin vaadini gösterirken, aynı zamanda model seçimi ile geliştirmede devam eden iyileştirmenin ve model performansını etkileyebilecek faktörlere yönelik daha fazla araştırmanın önemini vurguluyor. Bu nedenle bu araştırma hem akademik alana hem de pratik finansal yatırım uygulamalarına katkıda bulunarak finansal teknolojide gelecekteki stratejiler ve karar verme süreçleri hakkında bilgi verme potansiyeline sahiptir.

²⁴⁶<https://investor.bankofamerica.com/quarterly-earnings>

KAYNAKLAR

A. Ceylan, T. Korkmaz, Sermaye Piyasası ve Menkul Değerler Analizi, Ekin Kitapevi, Bursa, Nisan2004

Abdioglu, Z., & Degirmenci, N. (2013). Istanbul Menkul Kiymetler Borsasinda Mevsimsel Anomaliler/seasonal anomalies in Istanbul stock exchange. *Business and Economics Research Journal*, 4(3), 55.

Fettahoğlu, A. (2003). *Menkul Değerler Yönetimi*. Abdurrahman Fettahoğlu.

ACHELIS, Steven B. Technical Analysis from A to Z. 2001.

Aggarwal, R., & Rivoli, P. (1989). Seasonal and day-of-the-week effects in four emerging stock markets. *Financial review*, 24(4), 541-550.

Ahmed, Nesreen K., et al. "An empirical comparison of machine learning models for time series forecasting." *Econometric reviews* 29.5-6 (2010): 594-621.

Ahmet Bayraktar, "Etkin piyasalar hipotezi." Aksaray Üniversitesi İİBF Dergisi, Cilt: 4, Sayı: 1 Ocak 2012, ss 37-47

Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6), 716-723.

AKSOY, A., TANRIÖVEN, C., (2013), "Sermaye Piyasası Yatırım Araçları ve Analizi", Detay Yayıncılık, 4. Baskı, Ankara

Alex Edmans. "The Link between Job Satisfaction and Firm Value, with Implications for Corporate Social Responsibility." *Academy of Management Perspectives*, vol. 26, no. 4, 2012, pp. 1-19.

Alexander, C. (2008). Moving average models for volatility and correlation, and covariance matrices. *Handbook of finance*, 3(5), 62.

Al-Rjoub, S. A. M., Alwaked, A. (2010), "January Effect During Financial Crisis: Evidence from the U.S", *European Journal of Economics, Finance and Administrative Sciences*, 24, 29-35.

Altaş, D., & Gülpınar, V. (2012). Karar Ağaçları ve Yapay Sinir Ağlarının Sınıflandırma Performanslarının Karşılaştırılması. *Trakya Üniversitesi Sosyal Bilimler Dergisi*.

Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609.

Ana Rita Dos Anjos Batista, Ualison Maia, and Andrea Romero. "Stock Market under the 2016 Brazilian Presidential Impeachment: A Test in the Semi-Strong Form of the Efficient Market Hypothesis." *Revista Contabilidade & Finanças*, vol. 29, 2018, pp. 405-417.

Anastasios Siganos. "The Daylight Saving Time Anomaly in Relation to Firms Targeted for Mergers." *Journal of Banking & Finance*, vol. 105, 2019, pp. 36-43.

Andrea Frazzini. "The Disposition Effect and Underreaction to News." *The Journal of Finance*, vol. 61, no. 4, 2006, pp. 2017-2046.

Appel, G. (1985). *The Moving Average Convergence Divergence Trading Method*. Dow Jones-Irwin.

Appel, Gerald (1979), *The Moving Average Convergence-Divergence Trading Method-Advanced Version*, Publisher: Traders Pr, BookType: Paperback , ISBN-13: 9789991453576, ISBN-10: 9991453571.

Asadi S, Hadavandi E, Mehmanpazir F, Nakhostin MM. Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction. *Knowledge-Based Systems*. 2012 Nov 1;35:245-58.

Asadi, Shahrokh, et al. "Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction." *Knowledge-Based Systems* 35 (2012): 245-258.

Ashoka Mody and Mark P. Taylor. "The High-Yield Spread as a Predictor of Real Economic Activity: Evidence of a Financial Accelerator for the United States." *IMF Staff Papers*, vol. 50, no. 3, 2003, pp. 373-402.

Aslı Demirgüç-Kunt and Ross Levine. "Stock Market Development and Financial Intermediaries: Stylized Facts." *The World Bank Economic Review*, vol. 10, no. 2, 1996, pp. 291-321.

Atack, Jeremy, and Larry Neal, eds. *The origins and development of financial markets and institutions: from the seventeenth century to the present*. Cambridge University Press, 2009.

Atsalakis, George S., and Kimon P. Valavanis. "Surveying stock market forecasting techniques—Part II: Soft computing methods." *Expert Systems with applications* 36.3 (2009): 5932-5941.

Aybar, C.B. (1993), 'Day of the Week Anomaly: A Contrary Evidence from Istanbul Stock Exchange', *İ.Ü. İşletme Fakültesi Dergisi*, Cilt 22, Sayı 1, Nisan, 157-168.

AYCEL, Üzeyir, and Yunus SANTUR. "A new algorithmic trading approach based on ensemble learning and candlestick pattern recognition in financial assets." *Turkish Journal of Science and Technology* 17.2 (2022): 167-184.

Baker, Malcolm P., Ryan Taliaferro, and Jeffrey Wurgler. "Pseudo Market Timing and Predictive Regressions." *NBER Working Paper No. w10823*. October 2004. s 1

Balaban, E. (1995a) *Informationa lEfficiency Of TheIstanbulSecurities Exchange And Some Rationale For Public Regulation*, The Central Bank Of TheRepublic Of Turkey Research Department Discussion Paper No:9502.

Balaban, E. (1995b) Some Empirics of The Turkish Stock Market, The Central Bank of The Republic of Turkey Research Department Discussion Paper no:9508.

Bansal, M., Goyal, A., & Choudhary, A. (2022). A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, 3, 100071.

Barberis, N., & Thaler, R. (2002). A Survey Of Behavioral Finance "A Survey Of Behavioral Finance", *The Handbook of the Economics Of Finance*. b.18.

Barone, E. (1989), 'The Italian Stock Market: Efficiency and Calendar Anomalies', SSRN Electronic Library ID-512503.

BASSAL, O. (2011) *Swing Trading for Dummies*, USA: Wiley Publishing, s.111.

Baumeister, C., & Kilian, L. (2012). Real-time forecasts of the real price of oil. *Journal of business & economic statistics*, 30(2), 326-336.

Beneish, M. D. (2013). The beneish M-score for detecting manipulation of financial statements: A new forensic accounting tool. *Journal of Forensic and Investigative Accounting*, 5(1), 17-34.

Beneish, Messod D., and David Craig Nichols. "Identifying overvalued equity." *Review of Financial Economics* (2009).

Benjamin Graham, David Le Fevre Dodd. *Security Analysis: The Classic* 1934 Edition. McGraw Hill Professional, 1934.

Benjamin Graham. *The Intelligent Investor*. HarperCollins Publishers, 2003. ss1-640

Benjamin Graham. *The Intelligent Investor: A Book of Practical Counsel*. 1. Baskı. Harper Business Essentials, 2006

BERK, N. (1995). Finansal Yönetim. İstanbul: Türkmen Kitapevi.

Bethge, M. (2006). Factorial coding of natural images: how effective are linear models in removing higher-order dependencies?. JOSA A, 23(6), 1253-1268.

BigML Team. (2017, July 20). Behind the Scenes of BigML's Time Series Forecasting. The Official Blog of BigML.com. <https://blog.bigml.com/2017/07/20/behind-the-scenes-of-bigmls-time-series-forecasting/>

BİLDİK, R. (2000), Hisse Senedi Piyasalarında Dönemsellikler ve İMKB üzerine Ampirik bir Çalışma, İMKB yayını, İstanbul.

Birgili, E. ve Esen, S. (2013). Teknik analiz yönteminin bulanık mantık yaklaşımı ile uygulanması: İMKB 30 banka hisseleri örneği. Finans, Politik ve Ekonomik Yorumlar, 50(575), 95-113.

Bloemer, M. M. J., Brijs, T., Vanhoof, K. ve Swinnen, G. (2003); "Comparing Complete AndPartialClassificationForIdentifyingCustomers At Risk", International Journal Of ResearchIn Marketing, Vol:20, Issue:2, s. 117-131.

Boginski, Vladimir, Sergiy Butenko, and Panos M. Pardalos. "Mining market data: A network approach." Computers & Operations Research 33.11 (2006): 3171-3184.

Boginski, Vladimir, Sergiy Butenko, and Panos M. Pardalos. "Mining market data: A network approach." Computers & Operations Research 33.11 (2006): 3171-3184.

BOLAK, M. (2001). Sermaye Piyasası Menkul Kıymetler ve Portföy Analizi. İstanbul: Beta Basım A.Ş.

Bollen, Johan, Huina Mao, and Xiaojun Zeng. "Twitter mood predicts the stock market." Journal of computational science 2.1 (2011): 1-8.

Bollinger, J. (2001). Bollinger on BollingerBands. McGraw-Hill Education.

Bounsaythip, C. ve Esa, R. R. (2001). "Overview of Data MiningForCustomerBehaviorModeling", VTT Information TechnologyResearch Report, Version:1, s. 1-53.

Box, G. E. P., Jenkins, G. M., &Reinsel, G. C. (2008). Time seriesanalysis: Forecastingandcontrol (4th ed.). John Wiley&Sons.

Box, G. E. P., Jenkins, G. M., Reinsel, G. C., &Ljung, G. M. (2015). Time seriesanalysis: forecastingandcontrol (5th ed.). Wiley.

Brockwell, P. J., & Davis, R. A. (2016). Introductionto time seriesandforecasting (3rd ed.). Springer.

Burman, P. (1989). A comparative study of ordinary cross-validation, v-fold cross-validation and the repeated learning-testing methods. *Biometrika*, 76(3), 503-514.

BÜKER, S., Aşıkoğlu, R. ve Sevil, G. (1997). Finansal Yönetim. 2. Baskı, Eskişehir: Anadolu Üniversitesi Yayınları.

CANBAY, P. (2021). Sağlıkta Yapay Zeka: MakineÖğrenmesiYöntemleri Ve Uygulamaları.

Cavalcante, Rodolfo C., et al. "Computational intelligence and financial markets: A survey and future directions." *Expert Systems with Applications* 55 (2016): 194-211.

Cavalcante, Rodolfo C., Rodrigo C. Brasileiro, Victor LF Souza, Jarley P. Nobrega, and Adriano LI Oliveira. "Computational intelligence and financial markets: A survey and future directions." *Expert Systems with Applications* 55 (2016): 194-211.

CEYLAN, A. ve Korkmaz, T. (2004). Sermaye Piyasası ve Menkul Değer Analizi, 2.Basım, İstanbul: Ekin Kitapevi, 2004, s.290

Chan, R. H. F., Wong, A. W. K., & Lee, S. T. H. (2014). Technical analysis and financial asset forecasting: From simple tools to advanced techniques. World Scientific Publishing Company.

Chapelle, O., Scholkopf, B., & Zien, A. (2009). Semi-supervised learning (Chapelle, O. et al., eds.; 2006)[book reviews]. IEEE Transactions on Neural Networks, 20(3), 542-542.

Chen, J., Chu, Z., Zhao, R., Luo, A. F., & Luo, K. H. (2022). Output prediction of alpha-type Stirling engines using gradient boosted regression trees and corresponding heat recovery system optimization based on improved NSGA-II. Energy Reports, 8(Supplement 5), 835-846.

Chen, Shi, Si Bao, and Yu Zhou. "The predictive power of Japanese candlestick charting in Chinese stock market." Physica A: Statistical Mechanics and its Applications 457 (2016): 148-165. s150

Chen, Wun-Hua, Jen-Ying Shih, and Soushan Wu. "Comparison of support-vector machines and back propagation neural networks in forecasting the six major Asian stock markets." International Journal of Electronic Finance 1.1 (2006): 49-67.

Chong, Eunsuk, Chulwoo Han, and Frank C. Park. "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies." Expert Systems with Applications 83 (2017): 187-205.

Clark, John Maurice. "Economics and modern psychology: I." Journal of Political Economy 26.1 (1918): 1-30. s4

Conneau, A., Kiela, D., Schwenk, H., Barrault, L., & Bordes, A. (2017). Supervised learning of universal sentence representations from natural language inference data. arXiv preprint arXiv:1705.02364.

Çondur, Funda, and Arş Gör Umut EVLİMOĞLU. "İMKB'NİN İŞLEVSELLİĞİNİ ARTTIRMAYA YÖNELİK ALTERNATİF POLİTİKA ÖNERİLERİ." (2007). s 3

Dağlı, H. (2000). Hisse Senedi Piyasa Endeksleri ve Türkiye. Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 191.

Daniel Kahneman and Amos Tversky. "Prospect Theory: An Analysis of Decision Under Risk." *Econometrica*, vol. 47, no. 2, 1979, pp. 263-291.

Dash, R., & Dash, P. K. (2016). A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science*, 2(1), 42-57.

Dash, Rajashree, and Pradipta Kishore Dash. "A hybrid stock trading framework integrating technical analysis with machine learning techniques." *The Journal of Finance and Data Science* 2.1 (2016): 42-57.

David Dreman. "Contrarian Investment Strategies: The Next Generation." Simon & Schuster, 1998..

David Genesove and Christopher Mayer. "Loss Aversion and Seller Behavior: Evidence from the Housing Market." *The Quarterly Journal of Economics*, vol. 116, no. 4, 2001, pp. 1233-1260.

Diehl, P. U., & Cook, M. (2015). Unsupervised learning of digit recognition using spike-timing-dependent plasticity. *Frontiers in computational neuroscience*, 9, 99.

DİMA, B., MİLOS, L. R. (2009), "TestingTheEfficiency Market HypothesisForTheRomanianStock Market", *AnnalesUniversitatisApulensis Series Oeconomica*, 11(1), 402-415.

Ding, Z., & Granger, C. W. (1996). Modelingvolatilitypersistence of speculativereturns: a newapproach. *Journal of econometrics*, 73(1), 185-215.

Doherty, K. A., Adams, R. G., & Davey, N. (2007). Unsupervised learning with normalised data and non-Euclidean norms. *Applied Soft Computing*, 7(1), 203-210.

Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55(10), 78-87.

Donaldson, R. Glen, and Mark Kamstra. "An artificial neural network-GARCH model for international stock return volatility." *Journal of Empirical Finance* 4.1 (1997): 17-46.

Dong Huang, Di Mu, Lin Yang, and Xiongcai Cai. "CoDetect: Financial Fraud Detection with Anomaly Feature Detection." *IEEE Access*, vol. 6, 2018, pp. 19161-19174.

EBERL, Ulrich. (2019). Akıllı Makineler, Yapay Zekâ Hayatımızı Nasıl Değiştiriyor, . çev." *Levent Tayla*. Poloma Yayınları: İstanbul.

Elliott, R. N. (1938). *TheWavePrinciple*. Financial World.

EMEL, Gül GÖKAY; TAŞKIN, Çağatan. (2005). Araç Rotalama Problemlerinin İki Aşamalı Çözümünde Genetik Algoritma Kullanımı. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7.1: 1-17.

Enver Sümer and Şakir Aybar. "Etkin Piyasalar Hipotezinin, Finansal Piyasalardaki Yetersizliği ve Davranışsal Finans." *Erzincan Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* , vol. IX, no. II, 2016, pp. 75-84.

ERCAN, M.K., BAN, Ü. (2008). Değere dayalı işletme finansı finansal yönetim. 4. bs. Ankara: Gazi Kitabevi.

ERDOĞAN, M., ELMAS, B. (2010), "Hisse Senedi Piyasalarında Görülen Anomaliler ve Bireysel Yatırımcı Üzerine Bir Araştırma", *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14(2), 1-22.

Erkan, Hüsnü. Sosyal piyasa ekonomisi: ekonomik sistem ve piyasa ekonomisine işlerlik kazandırması. Konrad Adenauer Vakfı, 2001.

Eugene F. Fama and Kenneth R. French. "Business Conditions and Expected Returns on Stocks and Bonds." *Journal of Financial Economics*, vol. 25, no. 1, 1989, pp. 23-49.

Eugene F. Fama, Kenneth R. French. "The Cross-Section of Expected Stock Returns." *The Journal of Finance*, vol. 47, no. 2, June 1992, pp. 427-465. s452

Eugene F. Fama. "Efficient Capital Markets II." *The Journal of Finance*, vol. 46, no. 5, 1991, pp. 1575-1617.

Eugene F. Fama. "Efficient Capital Markets: A Review of Theory and Empirical Work." *The Journal of Finance*, vol. 25, no. 2, May 1970, pp. 383-417.

Eugene F. Fama. "The Behavior of Stock-Market Prices." *The Journal of Business*, vol. 38, no. 1, 1965, pp. 34-105.

Fabozzi, F. (1989), *Portfolio and Investment Management*, USA: Probus Publishing.

Fahad, A., Alshatri, N., Tari, Z., Alamri, A., Khalil, I., Zomaya, A. Y., ... & Bouras, A. (2014). A survey of clustering algorithms for big data: Taxonomy and empirical analysis. *IEEE transactions on emerging topics in computing*, 2(3), 267-279.

Fan, Alan, and Marimuthu Palaniswami. "Stock selection using support vector machines." *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No. 01CH37222)*. Vol. 3. IEEE, 2001.

Farmer, J. D., Patelli, P., & Zovko, I. I. (2005). The predictive power of zero intelligence in financial markets. *Proceedings of the National Academy of Sciences*, 102(6), 2254-2259.

Fausett, L. (1994). "Fundamentals Of Neural Networks: Architectures, Algorithms and Applications", Usa, Prentice Hall.

Fernández, Alberto, and Sergio Gómez. "Portfolio selection using neural networks." *Computers & operations research* 34.4 (2007): 1177-1191.

Fertekligil, A. (2000). *Türkiye’de Borsanın Tarihçesi*. İstanbul.

Fischer Black and Myron Scholes. "The Pricing of Options and Corporate Liabilities." *Journal of Political Economy*, vol. 81, no. 3, May - June 1973, pp. 637-654. The University of Chicago Press.

Fischer, Thomas, and Christopher Krauss. "Deep learning with long short-term memory networks for financial market predictions." *European journal of operational research* 270.2 (2018): 654-669.

Flach, P. (2012). *Machine learning: the art and science of algorithms that make sense of data*. Cambridge university press.

Foote, K. D. (2019). A brief history of machine learning. Dataversity webpage, March, 26.

Foote, K. D. (2019). A brief history of machine learning. dataversity web page, Homepage, Data education, Smart Data News, Articles, & Education.

French, K. (1980), 'Stock Returns And The Weekend Effect', *Journal Of Financial Economics*, 8, Sayfa: 55-69.

Freund, Y., & Haussler, D. (1991). Unsupervised learning of distributions on binary vectors using two layer networks. *Advances in neural information processing systems*, 4.

Gardner, H. (1983). *Frames of mind: The theory of multiple intelligences*. Basic Books.

Gary B. Gorton and Guillermo Ordoñez. "The Supply and Demand for Safe Assets." *National Bureau of Economic Research Working Paper No. w18732*, 2013. s37

Gerald L. Musgrave. "Reviewed Work: A Random Walk Down Wall Street by Burton G. Malkiel." *Business Economics*, vol. 32, no. 2, April 1997, pp. 74-75.

Glaser, Markus -Nöth, Markus - Weber, Martin, (2003), "Behavioral Finance", Sonderforschungsbereich 504 Universität Mannheim.

Godoy, V. A., Napa-García, G. F., & Gómez-Hernández, J. J. (2022). Ensemble random forest filter: An alternative to the ensemble Kalman filter for inverse modeling. *Journal of Hydrology*, 615(Part B), 128642.s5

Goldberg D.E. (1983): “Computer-Aided Gas Pipeline Operation Using Genetic Algorithms and Rule Learning”, PhD Dissertation University of Michigan, Ann Arbor.

Graham, B., & Dodd, D. L. (2008). *Security analysis: Principles and technique*. McGraw-Hill.

Gu, Shihao, Bryan Kelly, and Dacheng Xiu. "Empirical asset pricing via machine learning." *The Review of Financial Studies* 33, no. 5 (2020): 2223-2273.

Gunstone, R.F., & Mitchell, I.J. (1998). *Metacognition and Conceptual Change*. In J.J. Mintzes, J.H. Wandersee & J.D. Novak (Editörler) *Teaching Science for Understanding: A Human Constructivist View* (133-163). San Diego: Academic Press

Güdelek, Mehmet Uğur. Zaman serisi analiz ve tahmini: Derin öğrenme yaklaşımı. MS thesis. TOBB University of Economics and Technology, Graduate School of Engineering and Science, 2019.

Güler, Fazıl (2005), *İstatistik Metodları ve Uygulamaları*, 1. Baskı –Kasım, Sayfa:

Gülsoy, Ufuk. *İstanbul Ticaret Borsası 1924-2014*. İstanbul Ticaret Borsası, 2014.s1

Günak, N. (2018). *İleri Teknik Analiz Uygulamaları*. İstanbul: Literatür Yayıncılık .

Hadavandi, Esmaeil, Hassan Shavandi, and Arash Ghanbari. "Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting." *Knowledge-Based Systems* 23.8 (2010): 800-808.

Hagenau, Michael, Michael Liebmann, and Dirk Neumann. "Automated news reading: Stock price prediction based on financial news using context-capturing features." *Decision support systems* 55.3 (2013): 685-697.

Hair, J.F., Black, W.C., Babin, B.J., Anderson, R.E. (2009), *Multivariate Data Analysis*, 7th Ed., PrenticeHall, London, UK

Halevy, A., Norvig, P., & Pereira, F. (2009). The unreasonable effectiveness of data. *IEEE Intelligent Systems*, 24(2), 8-12. doi: 10.1109/MIS.2009.36

Harry Markowitz. "Portfolio Selection." *The Journal of Finance*, vol. 7, no. 1, March 1952, pp. 77-91. s77 89

Hasan Eken and Sait Adalı. "Piyasa Etkinliği ve İMKB: Zayıf Formda Etkinliğe İlişkin Ekonometrik Bir Analiz." *Muhasebe ve Finansman Dergisi*, vol. 37, 2008.

Haykırı S. (1999). *Neural Networks: A Comprehensive Foundation* [Elektronik Sürüm], PrenticeHall Inc, New Jersey.

Hersh Shefrin and Meir Statman. "The Disposition to Sell Winners Too Early and Ride Losers Too Long: Theory and Evidence." *The Journal of Finance*, vol. 40, no. 3, 1985, pp. 777-790.

Hiransha, M., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2018). NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science*, 132, 1351-1362. s1352

Hoffmann, A. O., & Shefrin, H. (2014). Technical analysis and individual investors. *Journal of Economic Behavior & Organization*, 107, 487-511.

Hofmann, T. (2001). Unsupervised learning by probabilistic latent semantic analysis. *Machine learning*, 42, 177-196.

<https://docs.rapidminer.com>

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/neural_nets/deep_learning.html

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/parallel_random_forest.html

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/parallel_decision_tree.html

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/gradient_boosted_trees.html

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/support_vector_machines/support_vector_machine.html

<https://investor.bankofamerica.com/quarterly-earnings>

<https://www.mevzuat.gov.tr/MevzuatMetin/1.5.6102-20130328.pdf>

Huang, Chenn-Jung, Dian-Xiu Yang, and Yi-Ta Chuang. "Application of wrapper approach and composite classifier to the stock trend prediction." *Expert Systems with Applications* 34.4 (2008): 2870-2878.

Huang, Wei, Yoshiteru Nakamori, and Shou-Yang Wang. "Forecasting stock market movement direction with support vector machine." *Computers & operations research* 32.10 (2005): 2513-2522.

Hyndman, Rob J., and George Athanasopoulos. *Forecasting: principles and practice*. OTexts, 2018.

International Organization for Standardization. ISO 31000:2018 Risk management - Guidelines. 2nd edition. February 15, 2018.

Jaffe, J., R.Westerfield (1985a), 'TheWeekendEffect in CommonStockReturns: The International Evidence', Journal Of Finance, 40, 433-454.

Jaffe, J., R.Westerfield (1985b), 'Patterns in JapaneseCommonStockReturns: Day of theWeekandTurn of theYearEffects', Journal of Financial andQuantitative Analysis, 20, 261-272.

Jan Mossin. "Equilibrium in a Capital Asset Market." *Econometrica*, vol. 34, no. 4, October 1966, pp. 768-783. The Econometric Society.

Jegadeesh, N. & Titman, S. (1993), "Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency", *Journal of Finance* 48, 65-91.s 90

Jensen, M. C. (1968). The performance of mutual funds in the period 1945-1964. *The Journal of finance*, 23(2), 389-416.

Jiang, Yuchen, et al. "Quo vadis artificial intelligence?." *Discover Artificial Intelligence* 2.1 (2022): 4.

John Burr Williams. *The Theory of Investment Value*. Harvard University Press, 1938.

John F. Muth. "Rational Expectations and the Theory of Price Movements." *Econometrica*, vol. 29, no. 3, 1961, pp. 315-335.

John Lintner. "The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets." *The Review of Economics and Statistics*, vol. 47, no. 1, February 1965, pp. 13-37. The MIT Press.

John R. Graham, Campbell R. Harvey, and Shiva Rajgopal. "The Economic Implications of Corporate Financial Reporting." *Journal of Accounting and Economics*, vol. 40, no. 1-3, 2005, pp. 3-73.

John Y. Campbell, Robert J. Shiller, and Luis M. Viceira. "Understanding Inflation-Indexed Bond Markets." *Brookings Papers on Economic Activity*, vol. 40, no. 1 (Spring 2009), pp. 79-138.

John Y. Campbell. "Asset Pricing at the Millennium." *The Journal of Finance*, vol. 55, no. 4, Aug. 2000, pp. 1515-1567. Wiley.

Johnson, K. W., Soto, J. T., Glicksberg, B. S., Shameer, K., Miotto, R., Ali, M., ... & Dudley, J. T., Artificialintelligence in cardiology. *Journal of theAmericanCollege of Cardiology*, Vol. 71, Issue23 ,Pages 2668- 2679, 2018.

Jordan, M. I. (2019). Artificial intelligence—the revolution hasn’t happened yet. *Harvard Data Science Review*, 1(1), 1-9.

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.

Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4, 237-285.

Kahraman, D. & Erkan, M. (2005). İstanbul menkul kıymetler borsasında tesadüfî yürüyüş testi. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12 (1), 11-24.

Kamstra, M. J., Kramer, L. A. and Levi, M. D. (2000): “LoosingSleep at the Market: TheDaylightSavingAnomaly”, *TheAmericanEconomicReview*, 90(4): 1005-1011.

Kaouthar Lajili. "Corporate Risk Disclosure and Corporate Governance." *Journal of Risk and Financial Management*, vol. 2, no. 1, 2009, pp. 94-117.

Karan, M. B. (2020). *Yatırım Analizi ve Portföy Yönetimi*. Ankara: Gazi Kitabevi.

Karan, M.B. (2002), ‘İstanbul Menkul Kıymet Borsası Sektör Endeksleri’nde Haftanın Günleri Ve Ocak Ayı Etkilerinin Test Edilmesi’, İşletme Ve Finans Dergisi, Yıl 17, Sayı 90, 51-59.

Kavajecz, K. A., & Odders-White, E. R. (2004). Technical analysis and liquidity provision. *Review of Financial Studies*, 17(4), 1043-1071.

Kenneth R. French and Eugene F. Fama. "Common Risk Factors in the Returns on Stocks and Bonds." *Journal of Financial Economics*, vol. 33, no. 1, 1993, pp. 3-56.

KESKINTÜRK, Timur. Diferansiyel gelişim algoritması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 2006, 5.9: 85-99.

Kılınç, K. (1991). 200 Soruda A’dan Z’ye Borsa,. İstanbul.

Kitapçı, İ. (2017). Rasyonaliteden İrrasyonaliteye: Davranışsal İktisat Yaklaşımı ve Bilişsel Önyargılar. *Maliye Araştırmaları Dergisi* 3(1), 85-102.

Kohonen, T. (1987). “Int. Conf. On Aı”, State Of The Art İn Neural Computing, Pp. 1-79, 1-90.

Konuralp, G. (2005). Sermaye Piyasaları: Analizler, Kuramlar ve Portföy Yönetimi. İstanbul: Alfa Yayınları.

Kumar, Deepak, Pradeepta Kumar Sarangi, and Rajit Verma. "A systematic review of stock market prediction using machine learning and statistical techniques." *Materials Today: Proceedings* 49 (2022): 3187-3191.

KUMAWAT, S. K. .; BANSAL, A. .; SAINI, S. S. . Design Analysis and Implementation of Stock Market Forecasting System using Improved Soft Computing Technique. *International Journal on Future Revolution in Computer Science & Communication Engineering*, [S. l.], v. 8, n. 4, p. 09–16, 2022. DOI: 10.17762/ijfrcsce.v8i4.2110. Disponível em: <https://www.ijfrcsce.org/index.php/ijfrcsce/article/view/2110>. Acesso em: 7 jul. 2023.

Lakshini Kengatharan and Niranjana Kengatharan. "The Influence of Behavioral Factors in Making Investment Decisions and Performance: Study on Investors of Colombo Stock Exchange, Sri Lanka." *Asian Journal of Finance & Accounting*, vol. 6, no. 1, 2014, pp. 1-16.

Lane, G. (1957). *The Stochastic Oscillator*. *Technical Analysis of Stocks and Commodities*, 24(3), 75-79.

LARSON, Mark L; (2001), *Technical Charting for Profits*, Wiley, New York.

LAVRENTCHENKO, DMYTRO. "Application of fundamental analysis." Brno 2022

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

LIM, Mark Andrew. (2015), *The Handbook of Technical Analysis+ Test Bank: The Practitioner's Comprehensive Guide to Technical Analysis*, John Wiley & Sons.

Li, Xiaodong, et al. "News impact on stock price return via sentiment analysis." *Knowledge-Based Systems* 69 (2014): 14-23.

Liu, Wanan, Hong Fan, and Meng Xia. "Credit scoring based on tree-enhanced gradient boosting decision trees." *Expert Systems with Applications* 189 (2022): 116034.

Lo, A. W., Mamaysky, H., & Wang, J. (2000). Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation. *The journal of finance*, 55(4), 1705-1765.

Lockard, Craig. *Societies, Networks, and Transitions: A Global History*, Volume I. 4th edition. Cengage Learning, February 13, 2020. s 340 367

Long, Wen, Zhichen Lu, and Lingxiao Cui. "Deep learning-based feature engineering for stock price movement prediction." *Knowledge-Based Systems* 164 (2019): 163-173.

M. Ayhan Kose, Eswar Prasad, Kenneth Rogoff, and Shang-Jin Wei. "Financial Globalization: A Reappraisal." *IMF Staff Papers*, vol. 56, no. 1, 2009, pp. 8-62.

Ma, L., et al. (2018). *IOP Conf. Ser.: Earth Environ. Sci.*, 208, 012017.

Malkiel, Burton G. *A Random Walk Down Wall Street: The Time-Tested Strategy for Successful Investing*. 12th edition. New York: W. W. Norton & Company, 2019.

Maria Alessandra Bertella, Fernando Roberto Pires, Ling Feng, and H. Eugene Stanley. "Confidence and the Stock Market: An Agent-Based Approach." *PLoS One*, vol. 9, no. 1, 2014, e83488.ss. 1-8

Mark P. Sharfman and Chitru S. Fernando. "Environmental Risk Management and the Cost of Capital." *Strategic Management Journal*, vol. 29, no. 6, 2008, pp. 569-592.

Markus Glaser and Martin Weber. "Overconfidence and Trading Volume." *The Geneva Risk and Insurance Review*, vol. 32, 2007, pp. 1-36.

Marlon Dumas, Marcello La Rosa, Jan Mendling, Hajo A. Reijers, Marlon Dumas, Marcello La Rosa, ... & Hajo A. Reijers. "Introduction to business process management." *Fundamentals of business process management*, vol. 1, 2018, pp. 1-33.

Mary Gbemi Ajao and Regina Osayuwu. "Testing the Weak Form of Efficient Market Hypothesis in Nigerian Capital Market." *Accounting and Finance Research*, vol. 1, no. 1, 2012, pp. 169-179.

MASOVER, Hal; (2001), *Value Investing in Commodity Futures: How to Profit with Scale Trading*, Wiley, New York.

Matthew Chau and Dimitri Vayanos. "Strong-Form Efficiency with Monopolistic Insiders." *The Review of Financial Studies*, vol. 21, no. 5, 2008, pp. 2275-2306.

McCarthy, J. (1956). Proposal for the Dartmouth Summer Research Project on Artificial Intelligence.

McGroarty, Frank, et al. "High frequency trading strategies, market fragility and price spikes: an agent based model perspective." *Annals of Operations Research* 282 (2019): 217-244.

Md. Lutfur Rahman. "Stock Market Anomaly: Day of the Week Effect in Dhaka Stock Exchange." *International Journal of Business and Management*, vol. 4, no. 5, 2009, pp. 193-206.

Mehta, Pooja, Sharnil Pandya, and Ketan Kotecha. "Harvesting social media sentiment analysis to enhance stock market prediction using deep learning." *PeerJ Computer Science* 7 (2021): e476.

Metin Kamil Ercan and Ünsal Ban. "Değere Dayalı İşletme Finansı" *Finansal Yönetim*. 4. baskı. Ankara: Gazi Kitabevi, 2016.

MILLER, E.M. (1988), 'Why A Weekend Effect?', *Journal Of Portfolio Management*, 14, Sayfa: 43-48.

Michael E. Porter. "Competitive Strategy: Techniques for Analyzing Industries and Competitors." Free Press, 1980.

Miguel R. Borges. "Efficient Market Hypothesis in European Stock Markets." *The European Journal of Finance*, vol. 16, no. 7, 2010, pp. 711-726.

Mitchell, T. M. (1997). *Machine learning*. McGraw Hill.

Mockenhaupt, A. (2021). *Maschinelles Lernen.* Digitalisierung und Künstliche Intelligenz in der Produktion. Wiesbaden: Springer Vieweg.

Monica Billio, Mila Getmansky, Andrew W. Lo, and Lorian Pelizzon. "Econometric Measures of Connectedness and Systemic Risk in the Finance and Insurance Sectors." *Journal of Financial Economics*, vol. 104, no. 3, 2012, pp. 535-559.

Montserrat Guillen, Jens Perch Nielsen, and Ana María Pérez-Marín. "The Need to Monitor Customer Loyalty and Business Risk in the European Insurance Industry." *The Geneva Papers on Risk and Insurance - Issues and Practice*, vol. 33, 2008, pp. 207-218.

Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.

Mutasa, S., Sun, S., & Ha, R. (2020). Understanding artificial intelligence based radiology studies: What is overfitting?. *Clinical imaging*, 65, 96-99.

Müller, K-R., et al. "Predicting time series with support vector machines." *International conference on artificial neural networks*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1997.

MÜNYAS, Turgay ve ATASOY, Ferhat, "Sermaye Piyasası Temel ve Teknik Analiz Yöntemleri, 3.Basım, Bursa: Ekin Basın Yayın Dağıtım,2021.

Neely, C. J., & Weller, P. A. (2012). Technical analysis in the foreign exchange market. *Handbook of exchange rates*, 343-373.

Nicholas Barberis and Richard H. Thaler. "A Survey of Behavioral Finance." *Handbook of the Economics of Finance*, vol. 1, 2003, pp. 1053-1128.

Nicholas Barberis, Ming Huang, and Tano Santos. "Prospect Theory and Asset Prices." *The Quarterly Journal of Economics*, vol. 116, no. 1, 2001, pp. 1-53.

Nurul Muhammad and Norazlina Mohamad Nor Azman Rahman. "Efficient Market Hypothesis and Market Anomaly: Evidence from Day-of-the-Week Effect of Malaysian Exchange." *International Journal of Economics and Finance*, vol. 2, no. 2, 2010, pp. 35-42.

NUSRET, Ç. N., & TÜREMİŞ, H. E. (12 2008). Menkul Kıymetler Borsalarında Alım Satım Aracılık Faaliyet Kapsamında Aracı Kurumlarla Yatırımcılar Arasındaki İlişkinin Hukuki Niteliği. *Gazi Üniversitesi Hukuk Fakültesi Dergisi*, 79.

Okan Acar and Aslı Beyhan Acar. "Modern Risk Management Techniques in Banking Sector." In *Banking, Finance, and Accounting: Concepts, Methodologies, Tools, and Applications*, edited by Information Resources Management Association, IGI Global, 2015, pp. 886-906.

Öndeş, T. (2014). Sermaye Piyasası Araçları: Hisse senetleri, B. Güngör. (Ed.), *Sermaye ve para Piyasaları içinde* (114-133). Erzurum: Atatürk Üniversitesi Yayını.

Önkal, D., Goodwin, P., Thomson, M., Gönül, S., & Pollock, A. (2009). The relative influence of advice from human experts and statistical methods on forecast adjustments. *Journal of Behavioral Decision Making*, 22(4), 390-409.

ÖZGÜR, S. B. Algoritmalar, Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme ve Uygulamaları: Beşeri Fayda Üretiminin Yazılımlar Tarafından Karşılanması. *Ekonomi ve Yönetim Araştırmaları Dergisi*, 10(1), 1-29.

ÖZHAN, Tarkan (2016), Borsaya Teknik Bakış Açıklamalı Terimler ve Diyagramlarla, E kitap Projesi, <http://www.ekitaprojesi.com/books/borsaya-teknik-bakis>

ÖZMEN, T. (1997). Dünya Borsalarında Gözlemlenen Anomaliler ve İstanbul Menkul Kıymetler Borsası Üzerine Bir Deneme. *Sermaye Piyasası Kurulu Yayını*, s. no61.

ÖZTEMEL, E. (2003). *Yapay Sinir Ağları*, Papatya Yayınları, İstanbul.

Paolo Di Corte, Steven J. Riddiough, and Lucio Sarno. "Currency Premia and Global Imbalances." *The Review of Financial Studies*, vol. 29, no. 8, 2016, pp. 2161-2193.

Papaioannou, M. G. (2006). Exchange rate risk measurement and management: Issues and approaches for firms. *South-Eastern Europe Journal of Economics*, 2, 129-146.

Park, C. H., & Irwin, S. H. (2004). The profitability of technical analysis: A review.

Patel, Jigar, et al. "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques." *Expert systems with applications* 42.1 (2015): 259-268.

Patel, Jigar, Sahil Shah, Priyank Thakkar, and Ketan Kotecha. "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques." *Expert systems with applications* 42, no. 1 (2015): 259-268.

Patrick Bolton, Hui Chen, and Neng Wang. "A Unified Theory of Tobin's q, Corporate Investment, Financing, and Risk Management." *The Journal of Finance*, vol. LXVI, no. 5, October 2011..s1545 1546

Pearson, K. (1900). On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. *Philosophical Magazine Series 5*, 50(302), 157-175. doi: 10.1080/14786440009463897

Pearson, K., 1900. X. On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 50(302), 157-175.

PERŞEMBE, Ali (2001). *Teknik Analiz mi Dedin Hadi Canım Sen de*, Skala Yayıncılık, C.I, İstanbul

Pieroni, M. P., McAloone, T. C., & Pigosso, D. C. (2019). Business model innovation for circular economy and sustainability: A review of approaches. *Journal of cleaner production*, 215, 198-216.

Piotroski, J.D., 2000. Value investing: The use of historical financial statement information to separate winners from losers. *Journal of Accounting Research*, pp.1-41.

Polat, Coşkun, Mukaddes Sağlam, and S. A. R. I. Tuğba. "Atatürk üniversitesi iktisadi ve idari bilimler dergisi'nin bibliyometrik analizi." *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 27.2 (2013): 273-288. s143

Price, W. N., & Cohen, I. G. (2019). Privacy in the age of medical big data. *Nature medicine*, 25(1), 37-43.

Rasekhschaffe, Keywan Christian, and Robert C. Jones. "Machine learning for stock selection." *Financial Analysts Journal* 75.3 (2019): 70-88.

Ravì, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2016). Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.

Richard H. Thaler. "Anomalies: The January Effect." *Journal of Economic Perspectives*, vol. 1, no. 1, 1987, pp. 197-201.

Richard H. Thaler. "Mental Accounting and Consumer Choice." *Marketing Science*, vol. 4, no. 3, 1985, pp. 199-214.

Robert J. Shiller. "Irrational Exuberance." 2nd ed., Princeton University Press, 2005. s. 344

ROGALSKI, R. (1984), 'New Findings Regarding Day of Week Returns Over Trading and Non-trading Periods', *Journal of Finance*, December, 1603-1614.

Rui Albuquerque, Yrjö Koskinen, and Chendi Zhang. "Corporate Social Responsibility and Firm Risk: Theory and Empirical Evidence." *Management Science*, vol. 65, no. 10, October 2019, pp. 4451-4469.

Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210-229. doi: 10.1147/rd.33.0210

SARICAOĞLU, C. (2019). Sözcüksel Analiz Kullanarak Kötü Niyetli Url'leri Derin Öğrenme Teknikleri İle Tespit Etme. Gazi Üniversitesi Yüksek Lisans Tezi.

Sathya, R., & Abraham, A. (2013). Comparison of supervised and unsupervised learning algorithms for pattern classification. *International Journal of Advanced Research in Artificial Intelligence*, 2(2), 34-38.

SAYILGAN, G. (2003). Soru ve Yanıtlarla İşletme Finansmanı. Ankara: Turhan Kitapevi.

Schumaker, Robert P., and Hsinchun Chen. "Textual analysis of stock market prediction using breaking financial news: The AZFin text system." *ACM Transactions on Information Systems (TOIS)* 27.2 (2009): 1-19.

Schumaker, Robert P., and Hsinchun Chen. "Textual analysis of stock market prediction using breaking financial news: The AZFin text system." *ACM Transactions on Information Systems (TOIS)* 27.2 (2009): 1-19.

SERTKAYA, Cengiz, and K. Ö. S. E. Zekeriya. "Yapay Zeka ile Tasarruf Finansmanı Sektörü Firmalarının Sosyal Medya Etkinliklerinin Tahmin Edilmesi." *International Journal of Advanced Natural Sciences and Engineering Researches* 7.3 (2023): 109-114.

Shiller, Robert J. *Irrational Exuberance*. 2nd edition. Princeton University Press, 2005.

Solnik, B., L. Bousquet (1990), ‘Day of the Week Effect on the Paris Bourse’, *Journal of Banking & Finance*, 14, 461-468.

Song, O., Hu, W. Ve Xie, W. (2002). “Robust Support Vector Machine With Bullet Hole Image Classification” [Kurşun Deliklerini Destek Vektör Makineleri İle Sınıflandırma], *Ieee Transactions On Systems, Man And Cybernetics – Part C: Applications And Reviews*, 32(4): 440

Stefano Della Vigna. "Psychology and Economics: Evidence from the Field." *Journal of Economic Literature*, vol. 47, no. 2, 2009, pp. 315-372.

Stephen A. Ross. "The Arbitrage Theory of Capital Asset Pricing." *Journal of Economic Theory*, vol. 13, no. 3, 1976, pp. 341-360. s353

Stewart C. Myers. "The Capital Structure Puzzle." *The Journal of Finance*, vol. 39, no. 3, July 1984.

Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*, Su Vakfı Yayınları, İstanbul.

Şimşek, Mehmet Ali, and Zeynep Orman. "A Study on Deep Learning Methods in the Concept of Digital Industry 4.0." *Handbook of Research on Management and Strategies for Digital Enterprise Transformation*. IGI Global, 2021. 318-339.

Tabachnick, B.G. & Fidell, L.S. (2007). *Using Multivariate Statistics* (5th ed.). Pearson Education, Inc. / Allyn and Bacon.

TANER, B., & AKKAYA, G. c. (2009). *Sermaye Piyasası Faaliyet Alanı ve Menkul Kıymetler*. Ankara: Detay Yayıncılık.

Tanrıöver, Banu, and Duygu Arslantürk Çöllü. "Türkiye'de Yatırımcıların Öngörü Performanslarının Rastgele Yürüyüş Modeli Çerçevesinde Analizi/Analysis of Forecasting Performance of Investors in Turkey Within Framework of the Random Walk Model." *Business and Economics Research Journal* 6.2 (2015): 127.

Tarca, A. L., Carey, V. J., Chen, X. W., Romero, R., & Drăghici, S. (2007). Machine learning and its applications to biology. *PLoS computational biology*, 3(6), e116.

Taylor, M. P., & Allen, H. (1992). The use of technical analysis in the foreign exchange market. *Journal of international Money and Finance*, 11(3), 304-314.

TDK. (12 Mart 2022). Türk Dil Kurumu Sözlükleri: <https://sozluk.gov.tr/> adresinden alındı

Temin, Peter. "The Economy of the Early Roman Empire." *The Journal of Economic Perspectives*, vol. 20, no. 1, Winter 2006, pp. 133-151. American Economic Association.s143

Thomas H. Naylor, Terry G. Seaks ve D. W. W i chern, 11Box Jenkins Methods: An AlternativetoEconometricModels 11 • International Statistical Review, C. 40, No~ 2, (1972), s. 125.

Thomas Ilin and Liz Varga. "The Uncertainty of Systemic Risk." *Risk Management*, vol. 17, 2015, pp. 240-275.

Time Series Analysis andIts Applications: With R Examples 3rd ed. 2011 Edition by Robert H. Shumway (Author), David S. Stoffer

TMAER, T., & KAYALIDERE, K. (2002). 1995 - 2000 Döneminde İMKB'de Anomali Araştırması. *Yönetim Ve Ekonomi Dergisi*, c9 s1-2.

TOPALOĞLU, Emre Esat, and Turhan KORKMAZ. "POLİTİK RİSKİN DOĞRUDAN YABANCI YATIRIMLAR ve PAY PİYASASI ENDEKS GETİRİLERİNE ETKİSİ: G7 ÜLKELERİ ÜZERİNE BİR UYGULAMA." *Verimlilik Dergisi* 1 (2021): 97-115.

Tufan, Cenk, and Reyhan SARIÇİÇEK. "Davranışsal Finans Modelleri, Etkin Piyasa Hipotezi ve Anomalilerine İlişkin Bir Değerlendirme." *Trakya Üniversitesi Sosyal Bilimler Dergisi* 15.2 (2013): 159-182. s174

Usta, Öcal : İşletme Finansı ve Finansal Yönetim, Ankara, Detay Yayıncılık, 5. Baskı, 2012.s 253

ÜLKÜ, N. (2001). Finansta Davranış Teorileri ve İMKB'nin Dezenflasyon Programının Başlangıcında Fiyat Davranışı. İMKB Dergisi cilt 5 sayı 17, 101-132.

ÜSTÜNEL, İ. E. (2000). Durağan Portföy Analizi ve İMKB Verilerine Uygulanması, Ankara: İstanbul Menkul Kıymetler Borsası Yayınları.

Vaishya, R., Javaid, M., Khan, I. H., & Haleem, A. (2020). Artificial Intelligence (AI) applications for COVID-19 pandemic. Diabetes & Metabolic Syndrome: Clinical Research & Reviews, 14(4), 337-339.

Valero-Carreras, D., Aparicio, J., & Guerrero, N. M. (2021). Support vector frontiers: A new approach for estimating production functions through support vector machines. Omega, 104, 102490.

Van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. Machine learning, 109(2), 373-440.

Vogel, R., Bellet, A., & Cléménçon, S. (2018, July). A probabilistic theory of supervised similarity learning for pointwise ROC curve optimization. In International Conference on Machine Learning (pp. 5065-5074). PMLR.

WACHTEL, Sidney B., (1942), "Certain Observations on Seasonal Movement in Stock Prices, Journal of Business, No. 15, pp. 184-193.

Wang, W. C., Chau, K. W., Cheng, C. T., & Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. Journal of hydrology, 374(3-4), 294-306.

Welch, I., & Goyal, A. (2008). A comprehensive look at the empirical performance of equity premium prediction. The Review of Financial Studies, 21(4), 1455-1508.

Wilder, J. W. (1978). New Concepts in Technical Trading Systems: Relative Strength Index. *Journal of Commodity Trading*, 1(1), 49-53.

William F. Sharpe. "Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk." *The Journal of Finance*, vol. XIX, no. 3, September 1964. ss431-432

Williams, A., Nangia, N., & Bowman, S. R. (2017). A broad-coverage challenge corpus for sentence understanding through inference. *arXiv preprint arXiv:1704.05426*.

Williams, R. J. (1992). Simple statistical gradient-following algorithms for connectionist reinforcement learning. *Reinforcement learning*, 5-32.

Wing-Keung Wong, Aigbe Akhigbe, and Nee-Tat Wong. "The Disappearing Calendar Anomalies in the Singapore Stock Market." *The Lahore Journal of Economics*, vol. 11, no. 2, 2006, pp. 123-139.

Zofío, J., Condeço-Melhorado, A., Maroto-Sánchez, A., & Gutiérrez, J. "Generalized transport costs and index numbers: A geographical analysis of economic and infrastructure fundamentals." *Transportation Research Part A: Policy and Practice*, 67(C), 2014. ss141-157.