

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ
YÖNTEMLERİYLE BORSA ALIM SATIM
DAVRANIŞLARININ MODELLENMESİ

Afan HASAN

DOKTORA TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Prof. Dr. Oya KALIPSIZ

Ağustos, 2020

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME VE MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE
BORSA ALIM SATIM DAVRANIŞLARININ MODELLENMESİ

Afan HASAN tarafından hazırlanan tez çalışması 06.08.2020 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Oya KALIPSIZ
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Oya KALIPSIZ, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Songül VARLI, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Selim AKYOKUŞ, Üye
İstanbul Medipol Üniversitesi

Doç. Dr. Mehmet Sıddık AKTAŞ, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üye. Faruk BULUT, Üye
İstanbul Rumeli Üniversitesi

Danışmanım Prof. Dr. Oya KALIPSIZ sorumluluğunda tarafımda hazırlanan Derin Öğrenme ve Makine Öğrenmesi Yöntemleriyle Borsa Alım Satım Davranışlarının Modellenmesi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Afan HASAN

İmza

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu tarafından desteklenmiştir (TÜBİTAK, Proje No: 115K179).

aileme adanmıřtır...

TEŞEKKÜR

Doktora sürecindeki çalışmalarım vesilesiyle, Türkiye'nin en köklü üniversitelerinden Yıldız Teknik Üniversitesi, Özyeğin Üniversitesi ve Sabancı Üniversitesi'nde, sıra dışı bilim insanlarıyla beraber çalışma fırsatım olduğu için çok şanslıyım.

Her şeyden önce, danışmanım Prof. Dr. Oya Kalıpsız'a ve tez izleme komitesi üyesi Prof. Dr. Selim Akyokuş'a, geniş bilgi ve deneyimlerini paylaştıkları ve araştırmalarda mükemmel birer örnek oluşturdıkları için teşekkür ediyorum. Ayrıca bu uzun soluklu süreçte her zaman destek olan Prof. Dr. Songül Varlı'ya teşekkür ediyorum.

Sabancı Üniversitesi'ndeki TÜBİTAK projesine beni dâhil edip çok farklı deneyimler kazanmama vesile olan Profesör Aziz Şimşir'e ve Profesör Koray Şimşek'e bu harika fırsatı sundukları için minnettarım.

Doktora süresince işlerimi hafifletip doktora çalışmalarına odaklanabilmemi sağlayan çalışma arkadaşlarıma, dualarını hiçbir zaman eksik etmeyen annem ve nineme, maddi manevi desteğini her zaman hissettiren babama sonsuz teşekkürler.

Son olarak, bu zorlu süreçte doktorayı tamamlayabilmem adına katlandıkları tüm zorluklar için eşim ve oğluma teşekkür ederim.

Afan HASAN

İÇİNDEKİLER

SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	3
1.3 Orjinal Katkı	5
1.4 Tezin İçeriği	6
2 ÖN BİLGİ	8
2.1 AI, ML ve DL'nin Sınıflandırılması ve Tarihsel Özeti	10
2.2 Yapay Zeka Endüstrisinin Küresel Büyüklüğü	15
2.3 AI Finansal Hizmetler Endüstrisini Nasıl Değiştiriyor	16
2.3.1 Sohbet Robotu ve Robo-danışmanlık Hizmetleri	16
2.3.2 Elektronik AI/Sat İşlemleri - Algoritmik Ticaret	19
2.3.3 AI'nın Diğer Uygulamaları	23
2.4 Ekonometri ve ML	24
2.4.1 Denetimsiz Makine Öğrenmesi Modelleri	26
2.4.2 Denetimli Makine Öğrenmesi Modelleri	28
3 PİYASA YÖNÜNÜN TAHMİN EDİLMESİ	31
3.1 Piyasadaki Rastgelelik	32
3.2 Etkin Olmayan Piyasa	33
3.3 Tahmin Metotları	33
3.3.1 Temel Analiz	33

3.3.2	Teknik Analiz	34
3.3.3	Teknik Analizde Nicelik	35
4	METODOLOJİ VE VERİ YAPISI	36
4.1	Sınıflandırma Yöntemleri	38
4.1.1	DNN Sınıflandırıcı	38
4.1.2	Lojistik Regresyon	40
4.1.3	Rastgele Orman (Random Forest)	42
4.1.4	Destek Vektör Makinesi (Support Vector Machines)	43
4.2	Verilerde Önışlem Süreci	44
4.2.1	Kötü İşlem Verisi ve Gürültü	45
4.2.2	Sermaye Piyasasının İşlem Yoğunluğu	46
4.2.3	Veri Normalizasyonu	47
4.3	Veri Seti	48
4.4	Öznitelik Vektörlerinin Oluşturulması	50
4.5	Getiri Oranının Hesaplanması	51
4.6	Sınıf Etiketleme Kuralları	52
4.7	Modelin Kârlılığı	52
4.8	Tahmin Modellerinin Performans Ölçüm Metrikleri	55
4.8.1	Karışıklık Matrisi (Confusion Matrix)	55
4.8.2	Bileşik Getiri (Compound Return)	57
4.8.3	Maximum Düşüm (Maximum Drawdown)	58
5	DENEYSEL SONUÇLAR	59
5.1	Deneyisel Sonuçlardan Çıkarımlar	71
6	SONUÇ VE ÖNERİLER	73
	KAYNAKÇA	75
	TEZDEN ÜRETİLMİŞ YAYINLAR	91

SİMGE LİSTESİ

p_i	Dönemin kapanış fiyatını
y_i^F	Düşüş yönündeki i-inci dönemin sınıf etiketi
θ	Eşik değeri
r_i	Getiri
ℓ	Lojistik regresyondaki cezalandırma parametresi
y_i^R	Yükseliş yönündeki i-inci dönemin sınıf etiketi

KISALTMA LİSTESİ

AI	Yapay Zeka (Artificial Intelligence)
ANN	Yapay Sinir Ağları
AT	Algoritmik Ticaret
BIST	Borsa İstanbul
CNN	Konvolüsyonel Sinir Ağları
DJIA	Dow Jones Endüstri Ortalaması
DNN	Derin Sinir Ağları
FAIS	FinCEN Yapay Zeka Sistemi
FCA	Finansal Davranış Otoritesi(Financial Conduct Authority)
HFT	Yüksek Frekanslı Ticaret
LR	Lojistik Regresyon
MDA	Çoklu Diskriminant Analizi
MDD	Maximum Drawdown
ML	Makine Öğrenmesi (Machine Learning)
MLP	Çok Katmanlı Algılayıcı
NN	Sinir Ağları
OHLC	Açılış, En Yüksek, En Düşük ve Kapanış Fiyatları
PFPS	Kişisel Finansal Planlama Sistemi
RF	Rastgele Orman
SVM	Destek Vektör Makinesi

ŞEKİL LİSTESİ

Şekil 2.1	Makine öğrenmesi yöntemlerinin kategorizasyonu.	26
Şekil 3.1	Bollinger bandı	35
Şekil 4.1	Tensorflow kullanım senaryosunun uygulanmasına ilişkin adımlar .	37
Şekil 4.2	Zaman serisinin çapraz doğrulama gösterimi	38
Şekil 4.3	Sermaye piyasasında kötü işlem verisine bir örnek.	45
Şekil 4.4	Borsa işlem verilerinin zaman içindeki dağılımı	46
Şekil 4.5	On saniyelik zaman periyodunun saatlik OHLC'ye dönüştürülmesi .	49
Şekil 4.6	Varsayımsal örneğimiz için olası yönlü fiyat hareketleri - yukarı, aşağı veya değişiklik yok	53
Şekil 4.7	Sermaye piyasalarında algoritmik ticaret süreci	54
Şekil 4.8	Maksimum düşüş yapısının grafiksel gösterimi	58
Şekil 5.1	BIST 100 endeksinin en kârlı dönemlerinden birinin 30 dakikalık DNN getirisiyle karşılaştırılması.	68
Şekil 5.2	BIST 100 endeksinin en kötü dönemlerinden birinin 30 dakikalık DNN getirisiyle karşılaştırılması.	68
Şekil 5.3	Druckenmiller'den alıntı.	71

TABLO LİSTESİ

Tablo 4.1	DNN randomized-search-cv girdi parametreleri	39
Tablo 4.2	DNN randomized-search-cv sonuç parametreleri	40
Tablo 4.3	DNN grid-search-cv girdi parametreleri	40
Tablo 4.4	DNN grid-search-cv sonuç parametreleri	40
Tablo 4.5	Rastgele orman grid-search-cv sonuç parametreleri	43
Tablo 4.6	BIST 100 işlem verisi	44
Tablo 4.7	BIST 100 saatlik OHLC veri yapısı	49
Tablo 4.8	Teknik gösterge listesi	51
Tablo 4.9	Yükseliş yönündeki karışıklık matrisi	56
Tablo 4.10	Düşüş yönündeki karışıklık matrisi	56
Tablo 5.1	Yukarı yönlü işlemlerin tahmin sonuçları - 30 dakikalık zaman periyodu	61
Tablo 5.2	Yukarı yönlü işlemlerin tahmin sonuçları - saatlik zaman periyodu .	62
Tablo 5.3	Yukarı yönlü işlemlerin tahmin sonuçları - iki saatlik zaman periyodu	63
Tablo 5.4	Aşağı yönlü işlemlerin tahmin sonuçları - 30 dakikalık zaman periyodu	64
Tablo 5.5	Aşağı yönlü işlemlerin tahmin sonuçları - saatlik zaman periyodu . .	65
Tablo 5.6	Aşağı yönlü işlemlerin tahmin sonuçları - iki saatlik zaman periyodu	66
Tablo 5.7	Yukarı yönlü işlemlerin tahmin sonuçları	69
Tablo 5.8	Aşağı yönlü işlemlerin tahmin sonuçları	69

Derin Öğrenme ve Makine Öğrenmesi Yöntemleriyle Borsa Alım Satım Davranışlarının Modellenmesi

Afan HASAN

Bilgisayar Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Prof. Dr. Oya KALIPSIZ

Finansal piyasa tahmini her zaman büyük ilgi gören bir konu olmuştur ve gelecekteki hareketi tahmin etmede kârlılık olduğu sürece cazip bir araştırma konusu olmaya devam edeceği görülmektedir. Borsa tahmininin çekiciliği, yatırımcıların kısa sürede büyük kârlar elde etmeleri için büyük bir potansiyel sunmasıdır. Büyük kazanç sağlama potansiyeli sunarken aynı zamanda büyük kayıplara da neden olabilir. Çift taraflı bir kılıç gibi, doğru kullanıldığında çok kârlıdır ve yanlış kullanıldığında çok zararlı olabilir. Ancak insanlar genellikle kazançlı tarafa odaklanır ve zararlı tarafı görmezden gelir.

Temel analistlerin büyük çoğunluğu teknik analistlerin tahminlerinin ve bu analizlerde kullanılan teknik göstergelerinin anlamsız olduğuna inanırlar da, son araştırmalar hem profesyonellerin hem de bireysel tüccarların teknik göstergeleri kullandığını ortaya koymaktadır.

Finansal piyasa yönünün doğru bir tahmini, öncelikle finansal zaman serilerinin doğrusal olmayan doğasından dolayı çok zorlayıcı bir faaliyettir. Derin öğrenme ve makine öğrenmesi yöntemleri ise insanların zorlandığı birçok alanda çok başarılı sonuçlar elde etmiştir.

Bu çalışmada, derin öğrenme ve makine öğrenmesi yöntemlerine teknik göstergeler entegre edilip finansal piyasa yönünü tahmin etme başarısını artırmak için borsa simsarlarının davranışları modellenmiştir. Borsa İstanbul ulusal 100 endeksinin (BIST100) yakın gelecekteki (bir dönem sonraki) yönünü tahmin etmek için girdi

özellikleri olarak teknik analizdeki uygulamaları temel alınarak bir dizi teknik gösterge incelenmiştir.

Endeksin yönünü tahmin etmek için Derin Sinir Ağlar (DNN), Destek Vektör Makinesi (SVM), Rastgele Orman (RF) ve Lojistik Regresyon (LR) sınıflandırma teknikleri kullanılır.

Bu modellerin performansı, karışıklık matrisi, bileşik getiri ve maksimum düşüm gibi çeşitli performans metriklerine göre değerlendirilmiştir.

Anahtar Kelimeler: Bist100 endeksi, derin öğrenme, finans, makine öğrenmesi, zaman serisi sınıflandırması

ABSTRACT

Modeling Trading Behaviours with Deep Learning and Machine Learning Methods in Stock Exchange Markets

Afan HASAN

Department of Computer Engineering

Doctor of Philosophy Thesis

Advisor: Prof. Dr. Oya KALIPSIZ

The financial market prediction has always been a topic of great interest, and it seems that it will continue to be an attractive research subject as long as there is profitability in predicting future movement. The attractiveness of the stock market prediction is that it offers great potential for investors to make huge profits in a short time. While offering the potential to generate huge profits, it can also cause huge losses at the same time. Like a double-sided sword, it is very profitable when used correctly and can be very harmful when used incorrectly. But people generally focus on the lucrative side and ignore the harmful side.

Although the vast majority of fundamental analysts believe that technical analysts' estimates and technical indicators used in these analyses are unresponsive, recent research has revealed that both professionals and individual traders are using technical indicators.

A correct estimate of the direction of the financial market is a very challenging activity, primarily due to the nonlinear nature of the financial time series. Deep learning and machine learning methods on the other hand have achieved very successful results in many different areas where human beings are challenged.

In this study, technical indicators were integrated into the methods of deep learning and machine learning, and the behavior of the traders was modeled in order to increase the accuracy of forecasting of the financial market direction. A set of technical indicators has been examined based on their application in technical analysis as

input features to predict the oncoming (one-period-ahead) direction of Istanbul Stock Exchange (BIST100) national index.

To predict the direction of the index, Deep Neural Network (DNN), Support Vector Machine (SVM), Random Forest (RF), and Logistic Regression (LR) classification techniques are used.

The performance of these models is evaluated on the basis of various performance metrics such as confusion matrix, compound return and max drawdown.

Keywords: Bist100 index, deep learning, finance, machine learning, time series classification

1.1 Literatür Özeti

Araştırmacıların, zaman serisini ve makine öğrenmesi metodolojilerini kullanarak, çeşitli finansal araçların hareket yönünün tahmini ile ilgili çalışmalara yoğunlaştıkları görülmektedir. Hem akademik araştırmacılar hem de uygulayıcılar sermaye piyasası enstrümanlarının gelecekteki hareketleri hakkında tahminler yapmak ve tahminleri kâra dönüştürmek için finansal ticaret stratejileri geliştirmektedirler. Bu bölüm, teknik göstergeleri öznitelik olarak kullanan yöntemleri, geleneksel makine öğrenmesi algoritmalarını, Borsa İstanbul (BIST) için yapılan çalışmaları ve finansta derin öğrenme algoritmalarını kullanan mevcut yöntemleri kapsayan hisse senedi tahmini hakkındaki araştırmanın bir özetini içermektedir.

Makine öğrenmesi algoritmaları ile borsa tahminine dayanan çalışmaların çoğunda, eğitim veri kümesinin bir parçası olarak teknik göstergeler kullanılmaktadır. Yapay Sinir Ağları (NN) [1, 2] ve Destek Vektör Makineleri (SVM) en çok kullanılan makine öğrenmesi yöntemlerindendir. Karar Ağaçları (DT) [3], Rastgele Ormanlar (RF) [4], Lojistik Regresyon (LR) [5] ve Naive Bayes (NB) [6] gibi sınıflandırma yöntemlerini kullanan çalışmalar da çok fazladır. Patel ve diğ. Destek Vektör Regresyonu (SVR), Yapay Sinir Ağı (YSA) ve Rastgele Orman (RF) kullanarak Hindistan borsa endekslerinin gelecekteki değerlerini tahmin etmeye odaklandı [7]. En iyi genel tahmin performansı SVR – ANN hibrid modeli ile elde edilmiştir. Khaidem'in araştırmasında öngörücü bir model oluşturarak rastgele orman sınıflandırıcısı kullanan AAPL, MSFT ve Samsung gibi hisse senetlerinde uzun vadeli tahmin için % 85-95 aralığında bir doğruluk elde edilmiştir [8]. Satın alma, bekletme veya satma kararı tahmini Boonpeng ve Jeatrakul tarafından Tayland Borsası'nda (SET) gerçekleştirilmiştir, geleneksel sinir ağının performansı Bire Tüm (OAA) ve Bire Bir (OAO) sinir ağı (NN) ile karşılaştırılır [9]. Ortalama % 72,50 doğrulukla OAA-NN, OAO-NN ve geleneksel NN modellerinden daha iyi performans sağladığı gösterilmiştir.

Booth, mevsimsellik olaylarını içeren, ticaretin kârlılığını ve istikrarını artırmak

için, rastgele ormanların performans ağırlıklı topluluklarına dayanan otomatik bir ticaret sistemi geliştirmiştir [10]. Testler DAX'tan büyük bir stok örneği üzerinde yapılır ve rastgele ormanların yenilik ağırlıklı topluluklarının üstün sonuçlar verdiğini bulmuşlardır. Araştırma, dört borsa öğrenme tahmin modelini karşılaştırarak Hint borsaları için hisse senedi ve hisse senedi fiyat endeksinin hareket yönünü tahmin etme yöntemlerinden Yapay Sinir Ağı (YSA), Destek Vektör Makinesi (SVM), Rastgele Orman ve Naif- Bayes araştırılmıştır [7]. Random Forest'ın diğer üç tahmin modelinin genel performansına göre daha iyi performans gösterdiği tespit edilmiştir. Benzer şekilde, Hindistan borsa endekslerinin tahmini için K-En Yakın Komşu yaklaşımına sahip bir Destek Vektör Makinesi'nin (SVM) melezleştirilmiş bir çerçevesi önerilmektedir [11]. Bu makale, 1 gün, 1 hafta ve 1 ay gibi gelecekteki hisse senedi değerlerini tahmin etmek için çeşitli tekniklerin nasıl birleştirileceğini araştırılmıştır. Önerilen hibridize modelin, yüksek boyutlu verilerin ölçeklendirilmesine ve daha iyi tahmin kabiliyetine ihtiyaç duyulduğu yerlerde kullanılabileceği belirtilmektedir.

Kara ve diğ. yapay sinir ağları (YSA) ve destek vektör makineleri (SVM) olmak üzere iki sınıflandırma tekniğine dayalı iki verimli model geliştirmiş ve günlük İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi'nde hareket yönünü tahmin etme performanslarını karşılaştırmıştır [11]. Önerilen modellerin girdisi olarak on teknik gösterge seçilmiştir. YSA modelinin SVM modelinden önemli ölçüde daha iyi performans gösterdiği savunulmuştur.

Pekkaya'nın çalışmasında, Doğrusal Regresyon ve NN modelinin sonuçları girdi verileri olarak makro değişkenler kullanılarak YTL/USD para birimini tahmin etmekle karşılaştırılmıştır [12]. NN'nin daha iyi sonuçlar verdiği gösterilmiştir. Pehlivanlı ve diğ. ertesi günün hisse senedi fiyat yönünü tahmin etme performansını artırmak için bir grup öznitelik seçim yaklaşımı ile optimum alt küme göstergeleri seçilmiştir [13]. İstanbul Menkul Kıymetler Borsası'ndan (İMKB) gerçek bir veri kümesi elde edilir ve alt küme teknik ve makroekonomik göstergeler kullanılarak oluşturulur. Bu çalışmanın sonuçlarından, azaltılmış veri kümesinin ertesi günün yön tahmininde bir iyileşme gösterdiği bulunmuştur. Türkiye hisse senedi piyasasında kapanış fiyatı, momentum gibi basit hareketli ortalamaların teknik göstergelerin kullanılmasının etkinliği Göçken'in çalışmasında değerlendirilmiştir [14]. Teknik göstergeler ve borsa arasındaki ilişkiyi yakalamada en uygun teknik göstergeleri seçmek için Harmony Arama (HS) ve Genetik Algoritma (GA) gibi Hibrid Yapay Sinir Ağı (YSA) modelleri kullanılmaktadır. Bu çalışmanın sonucunda HS bazlı YSA modelinin borsa tahmininde daha iyi performans gösterdiği bulunmuştur.

Görsel görüntüleri analiz etmek için en sık kullanılan DNN yöntemlerinden biri olan Konvolüsyonel Sinir Ağları (CNN) [15] ile stok hareket yönünün tahmini ilk olarak

Gündüz ve ark. tarafından Borsa İstanbul BIST 100 hisselerinin gün içi yönünün tahmin edilmesinde uygulanmıştır [16]. Öznitelik kümesi farklı göstergelerden oluşur. Sınıflandırıcıların kapanış fiyatı, geçici bilgiler ve alım satım verileri saatlik kapanış fiyatları kullanılarak etiketlenir. Yedi katmanlı önerilen sınıflandırıcı, rastgele sıralı özellikleri kullanan Lojistik Regresyon ve CNN'den daha iyi performans gösterir. Chong, Han ve Park, Güney Kore'deki en büyük borsa olan KOSPI sermaye piyasasının hisse senedi getirilerini kullanan bir vaka çalışması olarak derin öğrenme tabanlı borsa tahmin modeli önerdi. Derin öğrenme ağının yüksek frekanslarda piyasa tahmini üzerindeki performansını değerlendirmek için beş dakikalık bir süre kullanılır. Amaç, borsa analizi ve tahmini için derin öğrenme algoritmalarının avantaj ve dezavantajlarının kapsamlı ve objektif bir değerlendirmesini sağlamaktır. Önerilen model, kovaryans temelli piyasa yapısı analizi ile test edilmiştir ve önerilen modelin kovaryans tahminini etkili bir şekilde iyileştirdiği bulunmuştur. Deneysel sonuçlardan, derin öğrenme ağlarının nasıl kullanılacağına dair daha fazla araştırma için pratik ve potansiyel olarak faydalı talimatlar önerilmektedir.

Popüler kelime yerleştirme temsili ve derin öğrenme tekniklerini kullanarak hisse senedi hareketlerini tahmin etmek için finansal haberlerden yararlanan basit bir yöntem önerilmiştir [17]. Çeşitli özniteliklere dayalı stokun fiyat hareketini tahmin etmek için her katmanda 4 gizli katman ve 1024 gizli düğümden oluşan DNN kullanılmıştır. Finansal haberlerden türetilen öznitelikler eklenerek hata oranı önemli ölçüde azaltılmıştır.

1.2 Tezin Amacı

Market yönünü tahmin etmek için kullanılan en eski enstrümanlardan biri olan teknik analizlerin etkinliği uzun süredir tartışılmakta ve tartışılmaya devam edecek gibi görünmektedir. Tartışmanın temel nedeni, teknik analizin klasik piyasa verimliliği teorisini ihlal eden gelecekteki piyasa trendlerini tahmin etmek için geçmiş fiyat ve geçmiş hacim gibi temel analizlere dayanmayan bilgileri kullanmasıdır [18].

Yatırımcıların belli teknik analiz değerlerine verdikleri tepkiye bağlı olarak gerçekleşen alışveriş işlemlerinin hisse senedi fiyatlarındaki oynaklığın en önemli itici güçlerinden biri olduğu fikrini ortaya koymaktadır. Bu, hisse senedi fiyatlarının teknik analizin temelini oluşturan eğilimleri takip ettiği fikrine yol açmaktadır [19]. Her ne kadar desenli ticaret davranışı bazılarında mantıklı görünmese de, yatırımcıların piyasa eğilimlerini tahmin edebildikleri ve gelecekteki fiyat hareketlerini etkin bir şekilde tahmin edebildikleri bilinmektedir.

Teknik analistlerin kullandığı temel bilgiler *hacim* ve *fiyattır*. Teknik analiz

çalışmalarında, günlük piyasa faaliyetlerinden kaynaklanan tarihsel borsa serilerindeki modeller, gelecekteki piyasa hareketlerini tahmin etmeye çalışacak şekilde incelenmektedir.

Teknik analizin etkinliği konusundaki süregelen tartışmalara rağmen, bu konudaki çalışmalar, teknik analizin finansal tahmin uygulamalarındaki popüleritesi ile daha da motive olabilir [20–24]. Örneğin, 692 fon yöneticisine yapılan anket, fon yöneticilerinin % 87'si yatırım kararları verirken teknik analize önem verdiklerini göstermektedir [25].

Borsa alış veriş işlemlerinde, teknik ve kantitatif analiz yöntemleri matematiksel ve istatistiksel araçları kullanarak yatırımcıların işleme giriş ve işlemten çıkış emirleri için en uygun zamanın belirlenmesinde destek olmaktadır. Bu da ticarete alım satım talimatlarının modellenmesi anlamına gelir. Bu geleneksel yaklaşımlar bir ölçüde amaçlarına hizmet ederken, hesaplamalı zekâlarda makine öğrenmesi ve veri madenciliği gibi ortaya çıkan yeni teknikler de finansal bilgileri analiz etmek için kullanımı her geçen gün artmaktadır.

Yararlı kalıplar, yeni veriler üzerinde kayda değer tahminler yapmamızı sağlarken Makine Öğrenmesi yöntemlerinin ana hedeflerinden biri de otomatik veya yarı otomatik yöntemler kullanarak veri içindeki gizli kalıpları bulmaktır [26]. Özellikle gerçek hayatta, zaman serileri analizi [27], iletişim [28], internet trafik analizi [29], tıbbi görüntüleme [30], astronomi [31], belge analizi [32] ve biyoloji [33] gibi birçok alanda makine öğrenmesi teknikleri *sınıflandırma* problemlerini çözmede etkileyici bir performans göstermiştir. Finansal mühendislik araştırmalarının büyük çoğunluğu, Neural Networks [2, 34–36] ve Support Vector Machines [37, 38] gibi karmaşık hesaplama modellerine odaklanırken, finansal olmayan uygulamalarda daha iyi sonuçlar veren Derin Öğrenme modelleri üzerine de araştırmalar hız kazanmaktadır [39, 40].

Diğer yandan derin öğrenme, modelleri eğitmek için geçmiş verileri kullanıp yeni gelen verilerden tahminlerde bulunmayı sağlayan makine öğrenmesi formlarından biridir. Derin öğrenmeyle ilgili son gelişmeler, bilgisayarların, görüntüleri tanımasını ve etiketlemesini, konuşmayı tanımasını ve çevirmesini ve beceri gerektiren oyunlarda çok başarılı olmasını ve tüm bu durumlarda insan performansından daha iyi bir performans sergileyebilmesine olanak sağladı [41]. Derin öğrenmenin göze çarpan bu uygulamalarında amaç, genellikle, insanoğlunun iyi yapabildiği görevleri en az insan kadar iyi yapabilecek bir bilgisayar yetiştirmektir - örneğin bir görüntünün içeriğini tanımak gibi. Derin öğrenme yöntemleri, görevin insan katılımı olmaksızın yapılmasına olanak tanır; belki de bir insan tarafından farklı şekilde yapılabilen

görev, verilen kısıtlı zaman içinde insan gücüyle tamamlanması pek mümkün olmayan görevlerdir veya insanüstü performansa ihtiyaç duyulan görevlerde faydanın çok fazla olması - tıbbi teşhislerde olduğu gibi [42].

Finansal piyasalardaki sorunlar, birçok bakımdan tipik derin öğrenme uygulamalarından farklı olabilir, ancak en dikkat çekici hususlardan biri, finansal piyasalardaki problemlerin insanların zaten iyi yapabildiği görevlerden olmamasıdır. Bir görüntüyü tanımaktan veya sözlü isteklere uygun şekilde yanıt vermekten farklı olarak, insanlar, örneğin, gelecekteki bazı dönemlerde iyi performans gösterecek bir hisse senedi seçmek gibi doğuştan gelen bir kabiliyete sahip değildir. Buna rağmen, derin öğrenme teknikleri, bu tür seçim problemlerinde faydalı olabilir, zira derin öğrenme teknikleri özünde, herhangi bir fonksiyon haritalama verisini (ki bunlar farklı getiriler, ekonomik veriler, muhasebe tarihleri, demografik verileri, hukuk rejimi verileri vb. olabilir) dönüş değerine dönüştürür. En azından teorik olarak, derin bir öğrenen, ne kadar karmaşık ve doğrusal-olmayan olursa olsun, bir dönüş ilişkisini bulabilir. Bu, hem geleneksel finansal ekonominin basit doğrusal faktör modellerinden hem de nispeten kaba geçici istatistiksel arbitraj yöntemlerden ve diğer kantitatif varlık yönetim tekniklerinden çok uzaktır [43].

Bu çalışmada, Derin Sinir Ağları (DNN), Destek Vektör Makinesi (SVM), Rastgele Orman (RF) ve Lojistik Regresyon (LR) gibi sınıflandırıcılarının BIST 100 endeksinin yönüne karar vermede faydalarını araştırılmıştır. Özellikle, bu sınıflandırma yaklaşımlarının borsadaki işlemleri uzun süre tutarlı ve kârlı hale getirip getiremeyeceği incelenmiştir.

1.3 Orjinal Katkı

Çalışmanın ana katkısı OHLC fiyatları ve işlem maliyetleri dikkate alınarak derin öğrenme modellerinin geliştirilmesidir. Ayrıca geliştirilen modellerin sınıflandırma performansı, borsa endeks yönünü tahmin etmek için en sık kullanılan makine öğrenmesi yöntemleriyle karşılaştırılmasıdır. Derin öğrenme ve makine öğrenmesi yöntemlerinin başarısı piyasa verimliliğine göre değişiklik gösterebilmektedir [44]. Bu çalışmada, Borsa İstanbul ve gelişmekte olan piyasalar incelemiştir. Bu çalışmanın bir diğer katkısı, finansal tahminlerde işlem maliyetlerini kontrol etmek için eşik değerlerin kullanılmasıdır. Bazı çalışmalarda, tahminler kârlı görünse de, işlem maliyetleri karşılanmaz. İşlem maliyetleri dâhil edildiğinde kârlılığın ortadan kalkabileceği bilinmektedir [39]. Bu problemten kaçınmak için eşik seviyesi, kâr dağıtımının standart sapmasına göre dinamik olarak ayarlanır ve işlem başına getiriye (yatırım kârı) artırmak için işlem sayısını azaltmak üzere optimal değerler seçilir.

Buna göre amaç, eğitim seti boyutunun doğru parametre değerleri ve özellik seçimi kombinasyonu ile uzun vadede kârlı işlemleri seçebilmektir.

Yong Hu'nun ortaya koyduğu çalışmada 650 makale taranıp bu konularla ilgili olan 51 i detaylı incelenmiş [45]. Bu çalışmada elde edilen çıktı bizim elde ettiğimiz sonuçları desteklemektedir. Bir sürü makalede de benzer çıkarımlar olmasına rağmen burada güzel bir şekilde derlenmiştir. Burada özellikle iki konu üzerinde durulmuştur. Birinci çıkarımda vurgulanan konu, bir sürü çalışmada elde edilen sonuçlar market kötü iken başarılı sonuçlar verirken market iyi olduğunda pek de başarılı sonuçlar vermemesidir. Gözlemledikleri ikinci problem de yapılan çalışmalarda işlem maliyetinin göz ardı edildiği bildiriliyor.

Çalışmalarda elde ettiğimiz sonuçlarda, market iyi olduğundan da kötü olduğunda da BIST100 den daha iyi getiri sağlıyor. İkinci problem için de standart sapmaya göre eşik değerini tanımlayıp girilecek işlemler belirlenmektedir, buna göre getirinin işlem maliyetinden fazla olduğu durumları seçilebilmektedir. Bu önerilen yapı da ikinci soruna çözüm oluyor.

1.4 Tezin İçeriği

Bu bölümde tezin içeriğinin nelerden oluştuğu özetlenmiştir.

- Bölüm 2 - Ön Bilgi.

Bu bölümde finans alanında makine öğrenmesi ve yapay zeka üzerine yapılmış çalışmalar ve FinTech çözümleri hakkında güncel bilgiler paylaşılmaktadır.

- Bölüm 3 - Piyasa Yönünün Tahmin Edilmesi Mümkün Mü?.

Bu bölümde sermaye piyasasındaki enstrümanların tahmin edilip edilemeyeceği ile ilgili varsayımlar değerlendirilip literatür taraması yapılmıştır.

- Bölüm 4 - Metodoloji ve Veri Yapısı.

Bu bölümde kullanılan metodolojiyi, genel deney düzeneğini, veri setlerini, modelleri eğitmek için kullanılan öznitelik seçimini, deneylerde kullanılan Derin Öğrenme ve diğer Makine Öğrenmesi algoritmaları için kapsamlı bilgi sağlanmıştır. Bu yöntemlerin eğitilmesinde kullanılan hyper-parametre seçimleri ve optimizasyonu hakkında bilgi verilmiştir.

- Bölüm 5 - Deneysel Sonuçlar.

Bu bölümde uygulanan yöntemler ile elde edilen sonuçlar detaylı bir şekilde açıklanmıştır.

- Bölüm 6 - Sonuç ve Öneriler.

Bu bölümde elde edilen sonuçlar yorumlanıp gelecekte yapılabilecek çalışmalar hakkında bilgi verilmiştir.

2 ÖN BİLGİ

Alan Turing'in "Makineler düşünebilir mi?" sorusunu sorduğundan bu yana 70 yıl geçti ve o zamandan beri yapay zeka (bundan sonra AI olarak anılacaktır) uygulamaları çok farklı alanlarda başarılı sonuçlarla karşımıza çıkmaktadır [46]. Ancak son yıllarda ilgi yeniden canlandı ve AI küresel finansal hizmetler sektöründe yenilikçi uygulamalarla kendine yer buldu. AI'deki en son yenilik dalgasının temel itici güçleri büyük verilerin kullanılabilirliği, gelişmiş teknoloji, bulut bilişim ve daha hızlı özel amaçlı donanımlar olmuştur. Son yıllarda Fintech¹ pazarının büyümesinin ana nedeni yapay zeka ve makine öğrenimi (ML) becerilerinin çok fazla artmasıdır. "Fintech" deyimi, finans dünyasındaki hizmetlere teknoloji ekleyerek veya teknolojiyi kullanarak ve sağladıkları hizmetler için süreçleri geliştiren şirketler için kullanılır. Bugün Fintech deyimi, kripto paralar, akıllı sözleşmeler, blok-zinciri², robot danışmanlık, kitlesel fonlama, AI platformları ve mobil ödemeler gibi tabirleri içermektedir. Bunların dışında farklı uygulama alanlarının da olduğunun vurgulanması gerekmektedir. 2017'de AI, finansal hizmetler ve Fintech'te ana trend olarak listenin başında yer aldı [47].

"Yapay Zeka" sözcüğü ilk olarak 1950'lerin ortalarında McCarthy tarafından ortaya atıldı. Diğer taraftan IBM'den Arthur Samuel "Makine öğrenmesi" deyimini ise 1960'lı yıllarda kullanmaya başladı. Önceden öğretildiği eylemleri herhangi bir dış müdahale olmadan tekrarlayabilen AI perspektifine karşılık, AI'nin özel bir alt perspektifi olarak ortaya çıkan ML, veri ve algoritmaları girdi olarak alıp, problem için doğrudan programlanmadan yeni senaryolara ve kalıplara uygulayabilmektedir. ML'nin bir alt kümesi olarak da Derin öğrenme (DL) karşımıza çıkmaktadır. Derin öğrenme sistemlerinin hiyerarşik işlevi, verileri doğrusal olmayan bir yaklaşımla işlemesini sağlarken, geleneksel programlar verilerle doğrusal bir analiz oluşturur. Sıradan insanların büyük miktarda yapılandırılmamış veriyi anlamaları ve işlemeleri onlarca yıl alacakken, derin öğrenme bunu birkaç saniye içinde başarabilir. Finansal hizmetler

¹Financial technology (FinTech)

²Blockchain, bir finansal aracı olmadan elektronik ödemelerin yapılmasına izin veren dağıtılmış bir defter teknolojisine bir örnektir.

sektöründe, kullanılan yüksek hızlı iletişim, süper bilgisayarlar ve bu bilgisayarlarda paralel çalışabilecek bilgisayar programları kullanımındaki artışının en büyük sebebi yüksek frekanslı ticaret (HFT) ve algoritmik ticaretindeki kullanım artışıdır [48]. Ayrıca kredi kartı sahtekârlığını tespitinde bankalar on yılı aşkın bir süredir AI ve ML yöntemlerini kullanmaktadırlar [49].

İngiltere’de vatandaşların banka hesaplarını yönetmelerine yardımcı olmak için ML yöntemlerinin kullanılmasını Finansal Davranış Otoritesi (FCA) tarafından desteklemektedir. Finans alanında ML kullanım alanlarında biri de hedge fonlardır³. İstatistiksel modellerin oluşturulmasında ML nin kullanım oranı yaklaşık % 10 olduğu bilinmektedir. Buna bağlı olarak önemli hedge fonlardan biri olan Aidya, hisse senedi alım satımlarını yapmak için AI hedge’i 2016 yılından bu yana kullanmayı ve geliştirmeyi sürdürmektedir. Aidya’nın baş bilim adamı Ben Goertzel cesurca, “Hepimiz ölse de, AI ticarete devam edecektir.” diyor [50]. Ödemelerin hesaplanmasında IBM’in Watson Explorer AI’sini kullanan şirketlerden biri Fukoku Hayat Sigortası’dır. AI ve DL sistemleri, sermaye piyasalarındaki işlemlerinin bir parçası olarak ve yatırım araçlarını desteklemek için Sentient Investment Technologies tarafından kullanılmaktadır. Sahte bankacılık işlemlerin ML ile tespiti Feedzai tarafından gerçekleştirilmiştir. Şirketlerin iş yükünü kolaylaştırmak için kurumsal dosyalardan anlamlı verileri otomatik olarak tanımlamak, ayıklamak ve yönetmek için AI tekniklerini kullanan start-up sayısı gün geçtikçe artmaktadır. Bunlardan biri olan Birleşik Krallık PropTech⁴ şirketi Leverton, kiralamada kullanılan belgeleri uygulama alanı olarak belirlemiştir. Borsa yatırım fonları, 2017 yılının son aylarında uzun vadeli hisse senedi varlıklarının seçiminde AI algoritmalarını kullanmaya başladıklarını açıkladı. AI’nın bu alandaki etkisi her geçen gün artmaktadır [46].

AI’nın finans sektörüne getirdiği risklere dikkat çekmek isteyen Nobel ödüllü ekonomist Robert Shiller’in 2018 Davos Forumunda "AI yıkıcı bir teknoloji olarak büyük bir belirsizlik sunuyor" ifadesini kullanmıştır [51]. AI bir sürü fırsat sunarken bunun yanında çok farklı riskleri de beraberinde getirmektedir, farklı Fintech çözümlerinin sunduğu gibi. Daha önce finansal piyasalara erişimi olmayan birçok kurum ve kişi için, AI teknolojisinin sermaye piyasalarındaki artan uygulamaları sayesinde dahil olmak daha kolay olacaktır. Tesla, Apple, Amazon, Alibaba gibi dünyanın en değerli teknoloji şirketleri AI araştırmalarına devlet bütçeleri kadar yatırım yapıp rakiplerinden fark yaratmaya çalışmaktadırlar. Farklı sektörlerde elde edilen tecrübeleri finans alanında fark yaratmak için de kullanabilirler.

GIS-Liquid Strategies şirketi, tüm dünyaya AI sayesinde 12 kişiyle 13 milyar dolar

³Riskten korunma amaçlı yatırım fonları

⁴Emlak piyasası ve teknolojiyi birleştiren yeni bir Fintech sektörü.

yönetebileceğini gösterdi. 2017 yılında Standard & Poor, Kensho'yu 550 milyon dolara satın aldı. Bu o güne kadar, bir AI şirketinin satın alınması için yapılan en büyük ödemeydi. Kensho, 2013 yılında tahvil ve hisse senedi analistlerini değiştirmek amacıyla kuruldu. Geliştirilen algoritma (Warren Buffet'dan sonra) "Warren" olarak adlandırılır ve ekonomik raporlar, ilaç onayları, para politikası değişiklikleri ve siyasi olaylar ve bunların finansal varlıklar üzerindeki etkisi gibi 90.000'den fazla olayı tarayarak 65 milyon soru kombinasyonunu işleyebilir. AI şirketlerini satın almanın önemli eşiklerinden biri, Google'ın DeepMind Technologies'i satın almasıdır. Benzer şekilde, Intel'in Nervana Systems'ı satın alması da çok yankı buldu. AI'nın finans alanında yapacağı en büyük tahribatlardan biri, farklı sektörlerde olduğu gibi büyük işten çıkarmalar olacaktır. Opimas LLC'ye göre, finans sektöründeki yaklaşık 230.000 kişinin 2025 yılına kadar mevcut pozisyonlarda iş bulamayacağı tahmin etmektedir [52].

ML yaklaşımlarından denetimsiz öğrenme ve denetimli öğrenmenin uygulama alanları incelendiğinde, banka hesaplarında düşük bakiye uyarılarının yayınlanmasında uygulanabilecek çözümler denetimsiz öğrenmenin uygulama alanlarına biridir. Ayrıca, bireysel müşterilere neler olduğunu ve durumun nedenlerinin ne olabileceğini tespit etmeye yardımcı olmak için banka kredili mevduat ücretlerine de uygulanabilir. Bunu gerçekleştirmek için kümeleme algoritmaları kullanılabilir. Kümeleme algoritmaları, yasal incelemelerden önce, ticareti daha iyi anlamak ve bankaların iş modellerini düzenleyiciler tarafından kategorilere ayrılması için de kullanılabilir.

Konu modelleri, denetimsiz ML teknikleri arasında yer alan metin madenciliği ve doğal dil işlemede yaygın olarak kullanılmaktadır. Her iki teknik de tahmine dayalı analitiklerin öncüleri olarak kabul edilir. ABD'de, doğal dil işlemedeki konu modelleri SEC⁵ tarafından muhasebe sahtekarlığını tespit etmek için yardımcı bir ML aracı olarak kullanılır. Farklı piyasa katılımcılarının davranışlarının altında yatan nedenler, konu modelleri yardımıyla anlaşılmaya çalışılmaktadır. Denetimli ML teknikleri kullanılarak algoritmanın geçmiş ihlallerle eğitildiği ve yeni ihlalleri, içeriden öğrenenlerin ticaretini ve kartelleri tahmin edebilen sistemler üzerinde çalışmalar yapıldığı bilinmektedir [53].

2.1 AI, ML ve DL'nin Sınıflandırılması ve Tarihsel Özeti

"Yapay zeka" terimi 1956 yılında John McCarthy tarafından deyim bulup "akıllı makineler yapma bilimi ve mühendisliği" olarak tanımladı [54]. Sözlükler incelendiğinde yapay zeka terimi "insan zekası gerektiren görüntü algılama, konuşma,

⁵Securities and Exchange Commission - Menkul Kıymetler ve Borsa Komisyonu

tanıma, karar verme ve diller arasında çeviri gibi görevleri yerine getirebilen bilgisayar sistemlerinin geliştirilmesi ve bu gelişim sürecindeki teorik bilgi”⁶ olarak karımıza çıkmaktadır. FSB ye göre AI, “Normalde çözümü için insan zekasına ihtiyaç duyulan problemlere çözüm üretilecek bilgisayar sistemlerinin teorisi ve gelişimi.” olarak tanımlamaktadır [55].

Bunlar oldukça geniş tanımlar olsa da “Sınırlı verilere dayanarak, zamanında uygun genellemeler yapabilme yeteneği, aslında gerçek zekanın özü olan yapay zekanın hedefidir. Uygulama alanı mümkün olduğunca geniş tutulmasıyla davranışlar mümkün olduğunca akıllı ve sonuçlar minimum bilgi ile hızlı bir şekilde üretilmesine olanak sağlamaktadır.” Kaplan’ın AI’yi tanımıdır [56].

Yapay zekanın ilk yıllarında, mantık tabanlı algoritmaları içeren kurallara odaklanan çalışmalar dikkat çekiyor. Bu tarihsel süreçte açık bir şekilde görünüyor. Bu dönemde gerçekleştirilen akıllı davranışların gerçekten de akıllı olup olmadığının test edilmesine Turing tarafından Turing Testi adı verildi [57]. Seming çalışmasında Turing, gelecekte yapay zeka çalışması için dil, akıl yürütme, bilgi, öğrenme ve anlayışla temel bileşenleri sağladı. Turing, makine öğrenmesi, genetik algoritmalar ve takviyeli öğrenimi için gerekli olan altyapıyı Turing Testi ile sağladı. Bu dönemde ortaya çıkan ve sembollerin işlenmesiyle insanın mantıksal karar alma süreçlerinin kopyalanması için yapılan çalışmalar “sembol işlem hipotezi” olarak biliniyor olup bu alanda çok fazla çalışma mevcuttur [58–60].

1950’lerde ve 1960’larda AI’nin çalışmalarının çoğu finans uygulamalarına uzaktı. 1960’larda, daha sonra ML’de kullanılacak, Bayes istatistikleri üzerine önemli çalışmalar gerçekleştirildi. Aynı şekilde derin öğrenmenin temellerini oluşturan sinir ağları, 1960’larda çok fazla ilgi gördü. Ancak bu dönemde elektronik veri yetersizliği ve bilgi işlem gücü eksikliği nedeniyle yapay zeka çalışmalarında umulan başarı yakalanamadığı için “AI Winter” olarak bilinen, yapay zekada kış dönemine girilir [55, 56]. Yapay zekaya olan ilginin azaldığı ve yatırımlardaki büyük kesintilerin olduğu dönem “AI Kış” olarak tanımlandı. Bu açıklamalardan biri, İngiltere’de AI araştırmalarına devlet desteğinin sona erdirildiğini belirten 1973’te yayınlanan İngiltere Lighthill Raporu’nda yer almaktadır [61].

1980’lerde yeni fonlar ve teknikler nedeniyle AI yeniden canlandı. Bu yıllarda, ABD, İngiltere ve Japonya gibi gelişmiş ülkeler teknolojik yeniliklerin öncüleriydi ve fırsatlardan yararlanmak için AI’ya büyük yatırımlar yaptılar. Bu dönemde ABD’deki Stratejik Bilgi İşlem Girişimi için 1 milyar doların üzerinde finansman DARPA tarafından sağlamıştır. Japon Beşinci Nesil Bilgisayar Projesi, Japonya hükümetinden

⁶https://en.oxforddictionaries.com/definition/artificial_intelligence

400 milyon dolarlık yatırım almıştır. İngiliz hükümeti Alvey Programına 350 milyon poundluk yatırımla destek olmuştur [62]. Örüntü tanımada kullanılan finansal sinyal işleme teknikleri ile bilinen Renaissance, Simons tarafından kantitatif yatırım şirketi olarak 1982’de kurulmuş olup AI nin finansal hizmetler endüstrisinde kullanılmasının önünü açmıştır [55].

Uzman sistemlerin kişisel finansal planlamada kullanılması ilk olarak 1990 yıllarda Brown, Nielson ve Phillips tarafından ortaya atılmıştır. Uzman sistemler, belirli bir bağlamda sorunları çözen ve sorulan sorulara cevaplayan ve bunları gerçekleştirmek için AI tekniklerini kullanan sistemlerdir. Sezgisel ve bilgi ile kontrolün ayrılmasını kullanan uzman sistemleri vurgular ve o sırada yaygın olan uzman sistemlere örnekler verir. Finansal hizmetlerde uzman sistemlerin kullanımına örnek olabilecek bir uygulama, geliri belirli bir seviyenin üzerinde olan kişilere özel finansal planlar sağlamak olabilir [63].

Finans dünyası bireylere gelecekleri hakkında değerlendirebilecekleri yatırım planlaması, borç planlaması, emeklilik planlaması, eğitim planlaması, hayat sigortası planlaması, bütçe teklifleri ve gelir vergisi planlaması gibi birçok farklı yatırım planı sunar. Sıradan bireylerin bir uzmanın desteği olmadan bu tür kararlar vermeleri çok zordur. Bunu önlemek için Bireysel Finans Planlama Sistemi geliştirilmiştir. Bunu ilk kullananlar arasında Arthur D. Little Inc ve Chase Lincoln First Bankasıdır [64].

Borsada “program ticareti” olarak bilinen uzman sistemler de kullanılmıştır. Zamanında, kurumsal yatırımcılar piyasadaki fiyat eşitsizliklerinden yararlanmak için program ticaretini kullandılar. Hisse senedi endeksi vadeli işlemleri ile temel hisse senedi endeksi arasındaki tutarsızlıklar, Finnerty ve Park tarafından sağlanan ampirik bir program ticareti çalışmasıyla belirlenmiştir [65]. Program ticaret stratejisinin, basit yürütme ve süre sonu stratejisine göre daha iyi performans gösterdiğini düşünüyorlar.

Bununla birlikte, program ticareti, 1980’lerin sonlarındaki vahşi pazar dalgalanmalarına atfedildi ve 1987’de Dow Jones Endüstri Ortalaması (DJIA) 508 puanlık düşüşle sonuçlandı. Chen ve Liang (1989), piyasa koşullarına bağlı olarak çeşitli kritik parametre ayarlamasına dayanan öğrenme mekanizması PROTRADER’ı (program ticareti için uzman bir sistem prototipi) sunmaktadırlar [66]. Chen ve Liang 1986’da DJIA’nın 87 puan düşüşünü başarılı bir şekilde tahmin edebildiklerini iddia etmektedirler.

FICO Blaze Advisor iş kuralları yönetim sistemi yıllara meydan okuyup varlığını sürdürebilen nadir uzman sistemlerden biridir. Çoğu uzman sistem kattığı faydayı ortaya koyamadığından varlığını sürdürememiştir [56, 67]. 1980’lerin sonu IBM ve Apple masaüstü bilgisayarların yükselişine tanık oldu. Özel uzman sistemlerin bakımı

daha pahalı hale geldikçe, ikinci bir AI kışı başladı. Bunun önemli nedenlerinden biri de abartılı vaatlerde bulunan şirketlerin vadettiklerinden çok uzak kalmalarıdır. Bu sefer AI kışı 1990'ların ortalarına kadar sürdü. Buna rağmen 1988'de David Shaw trading için AI tekniklerini erken benimseyen bir hedge fonu (D.E. Shaw & Co.) kurdu.

Cheeseman ve Pearl'in farklı zaman aralıklarında gerçekleştirdikleri çalışmalarından sonra Bayes analizi, AI araştırmalarındaki belirsizliği ele almada daha fazla kabul görmüştür [68, 69]. 1960'larda ve 1970'lerde olasılıklı akıl yürütme modelleri baskındı, ancak Bayes ağları klasik AI ve sinir ağlarını birleştirdi ve deneyimden öğrenmenin önünü açtı.

Yapay zeka kullanarak sahtekarlığın tespiti 1990'larda daha fazla dikkat çekmeye başladı. 1990'ların ortalarında yapay zeka kullanarak kara para aklama olaylarını zamanında tanımak ve değerlendirmek için FAIS⁷ sistemi devreye alındı. Devreye alındıktan sonra, haftada yaklaşık 400 potansiyel kara para aklama olayının tespitini, 200.000'den fazla işlemi gözden geçirerek gerçekleştirilecektir. İlk iki yıl içinde yaklaşık 1 milyar dolar değerinde kara para aklama tespit edecektir [70].

İkinci AI kışı sona erdikten sonra, yapay zekâ daha çok makine öğrenmesi, veri madenciliği, sanal gerçeklik ve vaka temelli akıl yürütme gibi yeni alanlara ilerledi. Sınırlı insan müdahalesi olan veya hiç olmayan bir deneyimle çözümleri otomatik olarak geliştirmek için algoritmalar kullanan makine öğrenmesi, yapay zekanın bir alt kümesi olarak bilinir. Deneyim, uygulama, eğitim ve akıl yürütme makine öğrenmesinin başlıca kaynaklarıdır. Önceden analitik bir çözümün bulunmadığı durumlara, makine öğrenmesi, verilerdeki ilişkilerin evrensel yaklaşımlarını ve örüntü tanımayı kullanıp bir çözüm bulmaya çalışmaktadır [71].

Makine öğreniminin McCulloch ve Pitts'in 1940'lardaki çalışmalarıyla hayat bulduğu kabul edilmektedir [72]. Beyin sinyallerinin doğada dijital olduğunu, daha doğrusu ikili sinyaller olduğunu tanımladılar. Boole devrelerinin beyin sinyallerini modellemek için kullanılabileceğini ilk olarak ortaya koyan da bu iki araştırmacı olmuştur. Chakraborty ve Joseph'e göre (1) problem, (2) veri kaynağı, (3) model, (4) optimizasyon algoritması ve (5) doğrulama ve test her makine öğrenmesi sisteminin olmazsa olmaz beş bileşenidir [73].

ML, gürültülü verilerden veya duyuşsal algılardan desen çıkarılmasını gerektiren durumlar için en uygundur. Önceden fiziksel olarak saklanan verilerin artık elektronik ortamda saklanıyor olması, bilgisayarların hesaplama hızındaki ve bellek kapasitelerindeki önemli artış, bilgiye ulaşmada internetin sağladığı sınırsız imkân,

⁷ABD Hazine Bakanlığı tarafından desteklenmektedir.

yüksek çözünürlüklü dijital sensörler maliyetlerinin ciddi şekilde düşmesi gibi faktörler makine öğrenmesindeki başarının ve buna bağlı olarak kullanımının artmasındaki ana faktörlerdir.

2011 yılına gelindiğinde, bilgisayar işlem gücü ve depolaması hızla artmakta ve süper bilgisayarlar yapay zekâ alanı için yeni olanaklar sunmaktadır. Katmanlar arasında ve katmanların içinde çalışan algoritmaları kullanan makine öğrenmesi yöntemlerinden biri olan Derin Öğrenme (DL) insan beynin yapısı ve işlevinden esinlenmiştir. Derin öğrenme, büyük miktardaki verilerden kalıpları bulmak için kullanılabilir istatistiksel tekniklerden biridir. Yapısı yapay sinir ağlarından oluşan DL algoritmaları, denetimli, denetimsiz veya takviyeli öğrenimi için kullanılabilir [55]. Beynin nöronlarının çoklu katmanlarının çalışma şeklini taklit eden sinir ağlarını replike etmeye çalıştığından “derin” terimi kullanılır.

Yapay sinir ağları ilk olarak 1940’ların ortalarında insan beyninin çalışma şeklini simüle etmek için McCulloch ve Pitts tarafından tasarlanan bir mimari olarak tanıtıldı [72]. DL’in iki temel avantajı: (1) aşırı uygunluğa (overfitting) karşı ML’den daha dayanıklıdır ve (2) DL, piyasa niceliği gibi genellikle standart nicel modellerde manuel olarak ayarlanması gereken doğrusal olmayan olayları ele alabilir. 2012 yılında bu alanda çalışmaya başlayan Google’ın bugünlerde 1000’den fazla DL projesi devam etmektedir. [74].

Yapay zekâda doğrulamanın ne kadar önemli olduğu son birkaç yıl içinde ortaya çıkmıştır. 6 Mayıs 2010’daki "Flash Crash" ın nedeni tam olarak bilinmemekle birlikte, doğrulanmamış yazılımdan kaynaklandığı düşünülmektedir [75]. P&G, bir kuruş ile 100.000 dolar arasında fiyatta değişti, sorun doğrulamadan kaçınan hatalardan veya bilgisayar arızalarından kaynaklanmadı. Birçok şirket, otomatik ticaret programları için varsayımlarının doğrulanmadığı, kendilerini beklemedikleri bir ticaretin içinde bulmuşlardır. Bu, beklentilerin ihlal edilmesinden kaynaklandı. 2012 yılının ortalarında, Knight Capital’in tüm senaryoların yeterince test edilmeden devreye aldığı ticaret yazılımı nedeniyle yaklaşık yarım milyar dolara zarar etmesi 1 saatten az sürdü [76].

2013 yılında, 17 dakikalık bir bilgisayar aksaklığı sırasında, Goldman Sachs ABD piyasasına, hisse senetleri ve ETF’lere bağlı 800.000 sözleşme satın alma emriyle çok büyük sorunlara neden oldu. Aynı hafta içinde, Çin aracılık şirketi Everbright Securities, Şangay pazarında yaklaşık 4 milyar dolarlık hisse satın almasına neden olan bir arıza yaşadı. Piyasadaki oynaklığa tepki olarak, Haziran 2016’daki Brexit referandumundan sonra, Betterment LLC müşterilerine daha yüksek işlem maliyetleri sağlamak için ticareti erteledi. Düzenleyiciler, Betterment LLC’nin

algoritmik ticareti büyük ölçüde kullandığından, alım satım işlemlerini doğru şekilde kısıtlayabileceğinden emin olamıyorlardı [77].

2.2 Yapay Zeka Endüstrisinin Küresel Büyüklüğü

Yapay zeka alanındaki başarı öykülerinin sayısı son yıllarda oldukça yüksek olmasına rağmen, son 60 yıl değerlendirildiğinde çok sayıda başarısızlık hikayesi mevcuttur. Dünyanın dört bir yanındaki hükümetler, AI'yi bir kaldıraç olarak görülüp, AI sayesinde ekonomik güç ve etki sağlamak için çok gelişmiş tesisler kurup bu tesislerde çalışacak araştırmacılara çok fazla imkân sunulmakta birbiriyle yarış içindedirler. 2012-2016 yılları arasında ABD Yapay Zeka'ya 18,2 milyar dolar yatırım yaptı, bunu takip eden diğer ülkelerden Çin'de 2,6 milyar dolar ve İngiltere'de 850 milyon dolar yatırım yaptı. Japon Hükümeti Emeklilik Yatırım Fonu için (dünyanın en büyük emeklilik tasarrufu yöneticisi) AI'nin insan fonu yöneticilerinin yerini alacağını düşünüyor. 2018'in başında, BlackRock, Palo Alto'da bir AI laboratuvarı kuracağını açıkladı. Yaklaşık 6 buçuk trilyon doları yöneten şirket şu anda metin analizlerini ve kurumsal web sitesi trafiğini ve akıllı telefon coğrafi konum verilerini ML tekniklerini kullanarak analiz ediyor. Şirket şimdi ML'deki bu deneyimi varlık yönetimine aktarmayı hedefliyor [78].

Son dönemdeki AI alanındaki hızlı büyüme birçok raporda gözükmektedir. 2018 yılında yayınlanan China AI Development Raporu'na göre, son beş yıl içinde dünya genelinde yaklaşık 5 bin AI şirketi kurulmuş ve bu da önceki 10 yıla göre neredeyse % 200'lük bir artış anlamına geliyor. Bu etkileyici büyümenin iki önemli nedeni vardır. Bunlardan ilki veri işleme ve veri depolama maliyetlerinin, bilgi işlem gücündeki muazzam gelişmeler sayesinde çok ucuza mal olmaya başlaması. İkinci de, internet sayesinde bilgiye ulaşmanın çok kolaylaşması sonucunda, AI modellerinin ihtiyaç duyduğu büyük veriler daha kolay kullanılmaya başlandı, bu da modellerin performansına çok olumlu yansıdı [79].

Tarihsel olarak, ABD bugüne kadar AI endüstrisine hâkim olmuş görünüyor. 2000 ile 2016 yılları arasında, ABD'de dünya toplamının yaklaşık % 40'ına karşılık gelen 3 binden fazla yapay zekâ girişimi hayat buldu [80]. Ancak, oran azalmakta ve 2016 yılında ilk kez % 30'un altına düşmüştür. Aynı dönemde ABD, dünya toplam fonunun % 71,78'ini oluşturan 20,7 milyar dolarlık fona sahiptir [79].

2017'de Çin, AI startup finansmanı açısından ABD'yi ilk kez geçti [81]. 2012 yılında, küresel AI girişimlerinin finansmanının neredeyse % 50'si Çin tarafından desteklendi ve 2017'de toplam küresel AI finansmanı 15 milyar doların üzerindeydi. AI hisse senedi anlaşmaları bir önceki yıla göre % 141 arttı ve 2016'dan bu yana 1.100'den

fazla yeni AI şirketi ilk sermaye finansmanı turunu artırdı. Bununla birlikte, ABD son beş yıl içinde küresel AI hisse senedi anlaşma payını kaybediyor ve son beş yılda hisse senedi anlaşma payı % 77'den % 50'ye düştü [81].

Çin, Asya pazarında AI büyümesine şuan için egemen durumda. Son beş yılda, Çin Asya AI girişimlerinin finansmanının yaklaşık % 60'ına sahipken, AI girişimleri Asya toplamının yaklaşık % 70'ini oluşturdu. Birçok Çin şehri ve eyaleti diğer Asya ülkelerinin toplamından fazla şirkete sahip durumda. AI şirket sayısı açısından Çin şehri ve eyaletleri incelendiğinde Pekin'de 450 üzeri, Guangdong'da 300 üzeri ve Şanghay'da 200 üzeri iken buna karşılık diğer ülkelerden Singapur'da 60 ve Hindistan'da yaklaşık 300 şirket bulunmaktadır [79].

2.3 AI Finansal Hizmetler Endüstrisini Nasıl Değiştiriyor

Teknoloji sektörü dışında, finansal hizmetler endüstrisi yapay zeka hizmetleri için yatırım yapan en büyük sektörlerden olduğundan çok hızlı bir büyüme yaşamaktadır [82]. Yakın zamana kadar fonları ve HFT firmaları finans alanında yapay zekanın ana kullanıcılarıydı, ancak uygulamalar şimdi bankalar, düzenleyiciler, Fintech, sigorta şirketleri de dahil olmak üzere diğer alanlara yayıldı.

Finansal hizmetler endüstrisinde AI uygulamaları algoritmik ticaret, portföy kompozisyonu ve optimizasyonu, model doğrulaması, geri test(back-test), robotik danışmanlık, sanal müşteri asistanları, pazar etki analizi, mevzuata uyum ve stres testini içerir. Bu bölümde, AI'nın şu anda finansal hizmetler endüstrisini değiştirdiği iki belirli alanı ele alacağım; (1) bankacılık sohbet botları ve robotik danışmanlık hizmetleri; ve (2) algoritmik ticaret.

2.3.1 Sohbet Robotu ve Robo-danışmanlık Hizmetleri

2008 mali krizinden sonra, Avrupa ve ABD'deki finansal aracılık maliyeti bir miktar azalmış olsa da, ABD'de 100 yıldan fazladır finansal aracılık birim maliyeti yaklaşık % 2 olmuştur [83–85]. Finansal kriz sonrası yanıtın bir parçası olarak, finansal hizmetler sektöründe robo-danışmanlar ve chatbotlar ortaya çıkmakta ve tüketicilerin yatırımları, bankacılık ürünlerini ve sigorta poliçelerini seçmelerine yardımcı olmaktadır. “Bot”, AI teknolojisini kullanarak belirli görevleri otomatikleştirmek için oluşturulan bir yazılım uygulamasıdır [47]. Robo-danışman, otomatik finansal danışmanlık veya yatırım yönetimi hizmetleri sunan algoritma tabanlı bir dijital platformdur.

“Robo-danışman” terimi aslında on yıl önce duyulmamıştı, ancak şimdi finansal

ortamda nispeten yaygındır. Robot terimi otomatik işlemlere atıfta bulunmak için kullanılmıştır ve aslında bu şekilde kalmamıştır, aslında bilinen robotları içermez. Bunun yerine, robo-danışmanlar, bir finansal portföyü kullanıcının hedeflerine ve risk toleransına göre kalibre etmek için oluşturulmuş algoritmalarıdır. Doğal dil işleme (NLP) ve ML algoritmaları tarafından desteklenen sohbet botları ve robo danışmanları, farklı alanlardaki kullanıcılara kişiselleştirilmiş, konuşma ve doğal bir deneyim sağlamak için güçlü araçlar haline gelmiştir.

Chatbotlar ve robo-danışmanlar, güvende hissedip rahatça yatırım yapmak için fiziksel bir danışmana ihtiyaç duymayan ve insan danışmanlara ödenen ücretleri tasvip etmeyen genç tüketicilerle önemli ölçüde yaygın hale geldi.

AI chatbot'ların bankacılık endüstrisini geliştirebilmeleri için, kullanıcıların paralarını ve tasarruflarını yönetmelerine yardımcı olmak gibi çeşitli yolları vardır. Örneğin, Plum, Facebook Messenger üzerinden erişilebilen ve müşterinin küçük artışlarla tasarruf etmesine yardımcı olan bir sohbet botudur. Plum'ın hedefi, müşterilerin ne kadar tasarruf edebileceğini tahmin etmektir. Plum'ın AI motoru, müşterinin banka hesabına bağlandıktan sonra müşteri gelirini ve harcama geçmişini analiz eder. Bunun etkinleştirilebilmesi için, öncelikle müşterilerin Plum sistemine kaydolmaları gerekir. Hesapları kaydettikten ve bağladıktan sonra, Plum tasarruf hesabında küçük miktarlarda yatırımlar başlar. Bu süreçte müşterilere periyodik raporlar gönderilir [86].

Bankalar ayrıca self-servis arayüzlerini geliştirmek için chatbotlarla uğraşıyorlar. Bank of America, AI sohbet botu Erica'yı başlattı ve bankanın mobil uygulamasında sesli veya mesajla sohbet yoluyla kullanılabilir. Kişisel finans yönetimine destek olmak için Erica'nın AI motoru veri analitiğini de kullanmaktadır. Bunun dışında dosyaları insan becerileri ile yapılamayacak kadar kısa sürelerde ve daha az hata ile inceleyip anlamlı veriler çıkarabilen AI teknolojisi COiN'e JP Morgan tarafından yatırım yapıldı. İnsanın 12.000 dokümanı incelemesi ve anlaması 360.000 saatten fazla zaman alırken, aynı işlem COiN sayesinde saniyeler içinde tamamlanabilir [77].

Chatbot'lar ve konuşma arayüzleri için girişim yatırımları ve müşteri hizmetleri bütçeleri hızla artmaktadır. Bu tür sohbet botları, finansa özgü müşteri etkileşimleri dikkate alınıp sağlam doğal dil işleme motorları kullanılarak geliştirilmelidir. Gelişmiş doğal dil işleme tekniklerinin başarısı öyle bir hal aldı ki, banka müşterileri bir AI arayüzüyle mi yoksa bir insanla mı konuştuklarını fark etmeleri çok zor hale geldi. Japonya'daki en büyük bankalar, müşteri sorularını uygun başlıklar altında toplamak ve anlamlı cevaplar üretmek için yapay zekâ ve sohbet robotları kullanıyor. Bu alandaki en başarılı uygulamalardan biri, dokümanların derlenmesine ve varlık

yönetimi ile ilgili soruların cevaplanmasına yardımcı olabilecek Mizuho Group robotudur [87].

Yapay zekâ destekli Amelia adlı sohbet robotu Allstate Insurance çalışanlarına yardım ediyor. 2017'nin sonuna doğru görevlendirilen Amelia, çağrı merkezi temsilcilerine 3 milyondan fazla müşteri toplantısında yardımcı oldu. Amelia, sigorta ile ilgili 40 konuda eğitilmiştir ve kullanıcının metninin amacını anlamak ve kesin yanıtlar sunmak için DL ve doğal dil işlemenin yanı sıra veri analitiğini kullanır [88].

Mülkiyet ve afet sigortası sunan B2C platformlarından biri olan "Lemonade", ev sahipleri ve kiracılar için tasarlanmıştır ve müşterilerine sunduğu hizmetlerde ML ve chatbot'ları kullanır. Platform sayesinde hak talebinde bulunmak üç dakika sürüyor ve ortalama 90 saniye içinde sigortalı olmak mümkün. Çin'de, diyalog robotları şu anda eşler arası (P2P) endüstrisinde kullanılan bir AI teknolojisidir [89].

Çin P2P endüstrisinde tahmini 200 milyar dolarlık bir borç dağılımı oluştu ve 2017'nin ortalarından bu yana, borç verme kontrolleri uygulandıkça ve ek lisanslar gerektiğinden, birçok borç verenler kapandı [90].

Vadesi geçmiş kredilerin tahsilatını destekleyebilecek AI tabanlı yazılımlar üzerinde de çok fazla çalışma var. Bunun en iyi örneği 2016 yılında başlatılan Ziyitong uygulamasıdır [90]. Ziyitong'un amacı ödenmemiş kredilerin tahsil edilmesine yardımcı olmaktır. Bunun için borçlu ve arkadaş ilişkileri ağı hakkında bilgi kullanarak bunu başarmaya çalışan bir diyalog robotu olarak da ifade edilir. Ziyitong Çin Post Tasarruf Bankası ve Alibaba gibi Çin'de 200'den fazla kredi sağlayan şirket ile 600'den fazla borç tahsildarı tarafından kullanılmaktadır. Diyalog robotu bilgiyi, borçluya krediyi geri ödemeye zorlama olasılığı en yüksek olan ifadeyi belirlemek için kullanır. Ziyitong borçlunun arkadaşlarını arayarak onları tedirgin edip kredinin geri ödenmesinde borçluya baskı yapmalarına teşvik etmektedir. Ziyitong, büyük müşteriler için bir haftada ödenmemiş kredileri toparlanma oranının % 41 olduğunu iddia ediyor. Bu geleneksel borç tahsilat yöntemlerinin iki katı bir orandır.

ABD ve Çin'den sonra, AI'ye çok fazla yatırım Avrupa'dan geliyor. İngiltere ve Almanya, Avrupa'da robotik danışmanlık sektörünün gelişiminde lokomotiflerdir. Bununla birlikte, ABD hala robo-danışma sektörünün önemli bir merkezi olarak kabul edilmektedir. Avrupa'da 98 ile 126 arasında robo-danışma hizmeti bulunurken bu oran ABD'de yaklaşık 200'dür. Düşük faiz oranlı bir ortam, ETF'lerin Robo-danışmanlar tarafından portföy oluşturmak için hisse senetlerinde veya tahvillerde yaygınlaşmasının ana nedeni olmuştur. Banka mevduatlarının ilgisi daha ihmal edilebilir hale geldiğinden, yatırım danışmanları ucuz ve uygun bir platform sağladığı için yatırım hizmetleri için talep artmıştır [91].

Maliyetleri büyük ölçüde düşürmek ve tüketiciler için finansal tavsiyelerin başarısını ve nedenselliğini arttırmak, Robo danışmanları kullanılarak elde edilebilecek iki temel faydadır. Etkin olmayan kural tabanlı yatırım stratejilerinin otomatik olarak yeniden dengelenmesi, daha düşük maliyetlerle çeşitlendirilmiş varlık dağılımı sağlanması ve insan davranış eğilimlerinin sınırlandırılması, Rohner ve Uhl tarafından robo-danışmanlık hizmetleri için yapılan tanımlardır. Robo-danışmanları, geleneksel yatırım tavsiyesine kıyasla % 4.4'e kadar maliyet tasarrufu sağlayabilir, ancak aynı zamanda geleneksel yatırım tavsiyesinde olmayan birçok yenilik sunar [92].

2.3.2 Elektronik Al/Sat İşlemleri - Algoritmik Ticaret

Finansal dünyada algoritmik ticaret (AT) olarak bilinen elektronik alım / satım işlemleri, küresel finansal piyasalarda vazgeçilmez hale gelmiştir. “Otomatik Ticaret Sistemleri” olarak da adlandırılan AT'nin kökenleri 1970'lere dayanmaktadır. Algoritmik trading alanının gelişme süreci ile ilgili güzel bir çalışma Kirilenko ve Lo tarafında sunulmuştur. Buna ek olarak, Chakravorty sadece Algoritmik ticareti değil, aynı zamanda AI ticaretini de tanıttı. Algoritmik ticaret ve AI ticareti arasındaki fark göz önüne alındığında, algoritmik ticaret, ticaret kurallarını programa uygulamak ve programı kuralların net olduğu alım / satım işlemleri için kullanmaktır. Öte yandan AI ticareti, bir yaklaşım olarak verilerin yapısını öğrenen makine öğrenimi yaklaşımıdır ve verilerle eğitilen makine öğrenmesi modeli, gerçek hesaplarda önceden tanımlı herhangi bir kurala bağlı kalmadan alım satım işlemleri hakkında tahminlerde bulunur [93].

Finans alanında karmaşık AI sistemlerinin çok kısa sürelerde sonuç üretmesi ihtiyacı her geçen gün artmaktadır, bunun en büyük nedeni de algoritmik ticaret yeteri kadar hızlı olmaması durumunda ticaretin kar değil zarara neden olacağındandır. Yadav ve Brummer 2017 yılında yayınladıkları çalışmada hisse senedi piyasası işlemlerinin yaklaşık % 70'i, vadeli işlemlerinin % 60'ını ve hazine işlemlerinin yaklaşık % 50'si otomatik elektronik ticaret ile gerçekleştiğini ortaya koymaktadırlar [77]. Aldridge ve Krawciw AT pazar payının % 40'a yakın olduğunu tahmin etmektedirler [94].

AT'nin faydaları arasında (1) işlemlerin mümkün olan en iyi fiyatlarla gerçekleştirilebilmesi, (2) artan doğruluk ve azalmış hata olasılığı, (3) birden fazla piyasa koşulunu otomatik olarak ve eşzamanlı olarak kontrol etme yeteneği ve (4) psikolojik veya duygusal koşullardan kaynaklanan insan hatalarının azalması muhtemeldir [46].

İkinci avantajla ilgili olarak, Avrupa Uzay Ajansı'nın Mozaik Akıllı Veri algoritmaları artık "şişman parmak (fat finger)" işlemlerini hafifletmek için kullanılıyor. Şişman

parmak ticareti, tüccarın yanlışlıkla yanlış tuşa bastığı durumu ifade etmek için kullanılmaktadır. Finansal hizmetler endüstrisinde sahtekârlığı tespit etmek için de Mozaik Akıllı Veri algoritmaları kullanılmaktadır. Milyonlarca finansal ticaret veri noktası Mosaic Smart Data'ya uygulanarak analiz edilebilmektedir. Bunu uygulayan Samsung ve Deutsche Bank yüksek profilli vakalar elde ettiler [95].

Bankaların şahsi işlem masaları, prop trading firmaları, finansal riskten korunma fonları, yeni nesil piyasa yapıcılar ve şirketler algoritmik ticaretin hedef kitlesidir. İşleme girmek için en doğru anı beklemek, işleme giriş kararı vermek, işleme girmek, işleme girdikten sonra süreci takip edip en doğru çıkış kararını vermeye çalışmak ve işlemenden çıkmak algoritmik ticaretin sürecinin temel adımlarıdır. Biais ve Martinez'nin çalışmalarında, algoritmik ticaret hızının sermaye piyasasındaki enstrümanların doğru fiyatlandırılması üzerinde olumlu bir etkiye sahip olduğu doğrulanmaktadır [96]. Benzer savunmayı Martinez ve Rosu da yapmaktadır [97]. Hendershott ve diğ. (2013) AT'nin likiditeyi iyileştirdiğini ve tekliflerin bilgi içeriğini geliştirdiğini bulmuşlardır. Öte yandan AT, yavaş işlemlere daha yüksek olumsuz seçim maliyetleri de getirebilir.

Sermaye piyasasının açık olduğu her gün algoritmik sistemler aracılığıyla onbinlerce veya milyonlarca işlem yapılır. Bu karada çok işlemin bu kadar kısa sürede gerçekleştirilmesine olanak sağlayan sistemler HFT olarak adlandırılmaktadır. HFT'nin kullanımına olanak sunulduğu finansal piyasalarda işlemlerin gerçekleştirilmesinde yüksek hızlı iletişim altyapısı ve çok iyi optimize edilmiş algoritmalar kullanılmaktadır. HFT'nin destekçileri olduğu kadar karşıtları da vardır. 2013'ten bu yana, HFT'ler hakkında alıntı yapılan ilk 30 makalenin üçte ikisi HFT'lerden olumlu pazar etkileri göstermektedir [98]. HFT'de genelde geçici fiyatlandırma hatalarının tersi yönde veya kalıcı fiyat değişimleri doğrultusunda işlem yapılmaktadır. Bu tür işlemlerin de fiyat keşfi ve fiyat verimliliğine yardımcı olduğuna dair destekleyici çalışmalar ortaya konmuştur [99]. Bu ticaret türleri piyasa likiditesini artırır. Hendershott ve Riordan HFT'nin pazar istikrarı sağlayabileceğini ve Menkveld HFT'nin ticaret maliyetlerini düşürdüğünü bulmuştur [100, 101]. HFT kullanıldığında piyasa kalitesinin arttığını ve teklif-talep marjlarının daraldığını gösteren kanıtlar Hasbrouck ve Saar çalışmalarında ortaya konmuştur [102].

Şirketler tescil nedenlerden ötürü, finansal riskten korunma fonlarının ve finans kurumlarının çoğu al-sat işlemlerinde yapay zekâ tekniklerini nasıl uyguladıklarını net bir şekilde açıklamamaktadırlar. Kesin olarak bilinen şey ise gerçek zamanlı al-sat işlemlerinde doğru anın belirlenmesindeki ince ayarlarında yoğun olarak ML ve DL'nin uygulandığıdır. Bunun dışında örüntü tanıma, sinir ağları ve bulanık mantık kullanımı da yaygındır. Yaygın olarak kullanılan dört AT stratejilerini kısaca açıklayacak olursak. Bunlardan ilki, teknik analizin matematiksel bir uzantısı olup

gürültüyü ortadan kaldırmak için filtreleme sanatına ve ayırt edici ticaret kalıplarına dayanan Sinyal İşleme'dir. Market Sentiment stratejisi piyasa duyarlılığı olarak bilinen ikinci yöntemdir. Bu yöntemde model, piyasa veri akışlarıyla beslendikten sonra algoritma piyasa dalgalanması ve katılımcı faaliyetlerinin farkına varır. Bu zamana kadar algoritma piyasa faaliyetlerinden habersizdir. Sermaye piyasasında arz ve talep psikolojisinin piyasa duyarlılığından sağlanan algoritma ile analiz edilmesi ve öğrenilmesi hedeflenmektedir. Üçüncüsü, haber başlıklarının yapay olarak nasıl okunacağı öğretilmediği sürece, haber okuyucu olarak bilinen bir AT stratejisi vardır. Son olarak, AT yöntemlerinden, makine öğrenmesi yöntemlerinin al-sat işlemlerinden kar elde etme fırsatlarını öğrenmesini, uyarlamasını ve tepki vermesini sağlayan örüntü tanıma stratejisidir.

AI teknolojilerini kullanarak riskten korunma fonları işleten şirketlerden biri ABD'de bulunan Sentient Technologies'dir. Ticaret modellerini ve tahmin eğilimlerini bulmak için milyonlarca veri noktasını işleyen bir algoritma Sentient tarafından geliştirilmiştir. Başarılı ticaret modellerini ortaya koymak ve bu modelleri harmanlayarak yeni stratejiler belirlemek için Sentient'in algoritmaları trilyonlarca taklit ticaret senaryosu kullanır [103]. Bu teknikleri kullanarak Sentient Technologies, önceden nerdeyse 2000 gün süren işlemleri dakikalar içinde tamamlayabilmesine olanak sağladı. Daha sonra canlı bir ticaret ortamında test edilen başarılı ticaret stratejilerine Sentient'te "genler" denir. "Gen" stratejileri canlı ticaret ortamında deneyim kazandıkça, otomatik olarak gelişmelerine olanak sağlanmaktadır. Yatırım fırsatlarını ve veriler arasındaki korelasyonları ortaya koymak için milyonlarca piyasa veri noktası Kensho'nun algoritmasıyla işlenmektedir [82].

AT'nin ticaret kararları vermesi için en iyi algoritmaları oluşturmak için yarışan binlerce isimsiz veri bilimcisi var. Ayrıca bazı şirketler için dış kaynak olarak da çalışabilirler. Buna karşılık, veri bilimciler çabaları için kripto para kazanırlar. AT algoritmalarının geliştirilmesinde dış kaynak kullanan şirketlerden biri de Numerai'dir [104]. Numerai'nin ticaret verilerini bilim adamları ile paylaşma şekli, daha iyi işlemler için modeller oluştururken bilim adamlarının fonun işlemlerini kopyalamasını kısıtlıyor. 2017 sonunda Katana, ING'de AI tahvil ticareti aracı olarak lanse edildi [105]. Katana, gelişmekte olan piyasa masasındaki insan trader'lara tahvil fiyatlarının nasıl daha hızlı toplanacağını gösteriyor. Maliyetleri % 25 oranında düşürmek ve fiyatlandırma kararlarını % 90 oranında daha hızlı almak, Katana'nın altı aylık deneme sürecinde gösterdiği performanstır. UBS ve JP Morgan, yapay zekayı ticaret araçlarına zaten tanıttı. Hisse senedi alım satımlarını gerçekleştirmek için AI algoritmaları ve volatilité ticaretine yönelik AI teknikleri sırasıyla JP Morgan ve UBS tarafından kullanılmaktadır. Risk sermayesi yatırımlarına da AI algoritmaları yön göstermektedir [106].

Uygulamada hala birçok tedirgin yatırımcı var. Özellikle yapay zeka algoritmalarının şeffaflığı ve “kara kutu”⁸ doğası konusunda şüpheli olan geleneksel tüccarlar [107]. Yadav piyasalarda kullanılan algoritmaların “model risk” ya da algoritmik programlamanın dünyayı olduğu gibi doğru bir şekilde temsil etmeme riskine sahip olduğunu belirtmektedir [108]. Pasquale’e göre, hisse senedi ticareti yapılan şirketin temel değerini keşfetmeden diğer hisse senedi brokerlerinin yaptıklarını taklit edip işleme girmek yüksek frekanslı ticaretin dezavantajlarından biridir. AT risklerinden biri de ticaret stratejileri öngörülemeyen şekillerde etkileşime girdiğinde, piyasaları dondurma ve istikrarsızlık yaratma potansiyeline sahip olmasıdır [49].

Örneğin HFT, 6 Mayıs 2010 tarihli “Flash Crash”⁹ için suçlandı, Kirilenko, Lo ve Lewis çalışmalarında bu durumu açıklamaya çalıştı [75, 93, 109]. 6 Mayıs 2010’da S&P500 hızla geri dönmeden önce % 8’den fazla düştü. Yeni çağ algoritmik ticaretinin ilk sermaye piyasası çöküşü "Flash Crash" olarak kabul edildi. Ayrıca, 2016’daki Brexit referandumu sırasında, pound iki dakika içinde ABD dolarına karşı yaklaşık % 6 gibi çok büyük bir değer kaybı yaşadı [110]. 2015 yılını ortalarındaki piyasa çalkantılarının ana nedeni nicel stratejilerine dayanan algoritmalar idi. Bunla bağlantılı olarak aynı gün içinde sermaye piyasası açıldıktan sonra S&P500 yaklaşık 1300 kez devre kesiciyi tetikledi [111].

Birçok deneysel araştırmada, insan tahminlerinin kanıta dayalı algoritmalarından daha az doğru olduğu gösterilmiştir. “Algoritmalarından çekinmeye ne olacak?”. Bu, bir insanın yaptığı tahmin ile istatistiksel bir algoritma arasında seçim yaparken, bireyler genellikle insanın yaptığı tahminleri seçmektedir. Algoritmaların insan tahminlerinden daha iyi performans gösterdiğini görünce, yatırımcıların çekincelerinin arttığını Dietvorst ve diğ. yaptıkları çalışmalarla ortaya koymuşlardır [112, 113]. Çünkü insanlar aynı hatayı yaptıklarını gördükten sonra algoritmik tahmincilere olan güvenini insanlara kıyasla çok daha kısa sürede yitirirler.

Deney yoluyla Dietvorst ve ark. katılımcıların değiştirilebilir algoritmalar için tercihlerinin, tahmin sonucu üzerinde daha fazla kontrol arzusu için değil, tahmin sonucu üzerinde bir miktar kontrol arzusunun göstergesi olduğunu belirlemiştir. Bu nedenle, deneyimler, değiştirilebilen algoritmaların, işlemin ana aktörleri tarafından statik algoritmalarından daha çok tercih edildiğini göstermiştir [112].

⁸Black-box

⁹Flash Crash, bir işlem sırasında yarım saat sürdü. 6 Mayıs’ta DJIA, tarihindeki en büyük günlük puan düşüşünü (gün içi bazında) yaşadı. Bu dönemde, bazı hisse senetleri anlaşılabilir fiyatlarla işlem gördü. Bunların dünyanın en büyük şirketlerinin hisse senetleri olduğu göz ardı edilmemelidir. Beklenmedik bir şekilde 1 cent ile 100 bin dolar arasındaki fiyatlardan oluşan işlemler ortaya çıkmıştır (2013, Kirilenko ve Lo).

O'Neill AT'deki potansiyel önyargıları ele almaktadır [114]. Kirilenko ve Lo küresel finans piyasalarının birbirine bağlı olduğunu ve beraberinde getirdiği zorlukları ve istenmeyen sonuçları kabul etmektedir [93]. Flaş çökmeleri, yıkıcı ticaret hataları, dikkatsiz halka arzlar, yangın satışları (fire sales) ve siber güvenlik ihlalleri AT'nin istenmeyen sonuçlarından bazılarıdır. Endüstrinin teknolojik ilerlemelerinin ele alındığı ve teknolojik olarak ileri düzeyde olmayanları koruyan AT'nin düzenlenmesine daha uyumlu ve sistematik bir yaklaşım çağrısında bulunuyorlar. Nisan 2018'deki bir İngiltere Lordlar Kamarası raporu, AI sektörünün tam potansiyelinin ancak algoritmik önyargı ve "kara kutu" sistemlerinin opaklığı gibi potansiyel risklerin ortadan kaldırılabilmesi durumunda gerçekleşeceğini gösteriyor [115].

2.3.3 AI'nın Diğer Uygulamaları

Günümüzde ML, kredileri onaylamaktan varlıkların yönetimine, risklerin değerlendirilmesine kadar finansal ekosistemin pek çok alanında önemli bir rol oynamaya başlamıştır. 2016 yılındaki çalışmalarında Barnes, yeni teknolojilerin değeri 200 trilyon doları aşan küresel gayrimenkul endüstrisini önemli ölçüde dönüştürdüğünü belirtti. AI, yeni teknoloji olarak, emlak sektöründe yeni iş modellerini destekleyen bir araç olarak kullanılmaktadır. Buna bağlı olarak gayrimenkul piyasalarına kötü yönde etki eden yeni ve gelişmekte olan teknolojilere PropTech adı verilmektedir [116].

Almanya'daki önemli girişimlerden biri olan Leventon tarafından geliştirilen AI destekli veri çıkarma platformunda, kira sözleşmeleri, kesme seçenekleri ve genel hükümler gibi belgelerden önemli bilgileri DL algoritmaları kullanarak işlenebilir verilere otomatik olarak dönüştürülebilmesine olanak sunmaktadır. 20 dilde anlaşılabilir olan platform, yapılandırılmış verilere kolay erişim sağlar. Ayrıca, temel dokümantasyon ve yapılandırılmış veri çıktısı arasında, platformun sağladığı izlenebilir bir denetim vardır [117]. Singapur'da proptech'ler, manuel değerlendirme yerine karşılaştırmalı piyasa analizi ve algoritmalarını kullanarak bir mülkün değerini hesaplayan formüller elde etmek için AI kullanır [118].

Kurumsal yönetim içeriklerinin yapay zeka algoritmalarıyla optimize edilebileceğini gösteren çalışmalar mevcuttur. ML algoritmaları, geçmişte yöneticilerin seçilme yöntemlerinden öğrenebileceğinden Erel ve arkadaşları yaptıkları çalışmada performansa göre şirket yöneticilerinin seçiminde ML algoritmalarını kullanmışlardır [119]. ML'nin kurumsal yönetim uygulamalarını iyileştirme potansiyeli olduğunu, çünkü algoritmalarla kötü performans göstermesi beklenen yöneticilerin iyi performans göstereceği tahmin edilenden çok daha kötü performans gösterdiklerini düşünüyorlar. Routledge ve diğ., birleşme ve devralmalarla (M&A) ile

ilgili etki ve son performansa ilişkin ifadeleri araştırmıştır [120]. Kurum kültürü ve birleşme ve satın alma faaliyetlerindeki MA rolü Li ve arkadaşlarının 2018 yılındaki çalışmalarında ortaya konmuştur [121].

Kredi ve sigorta taahhüt işleri finans alanında ML için ideal bir ortamdır. Büyük bankalarda ve halka açık sigorta şirketlerinde ML algoritmaları milyonlarca tüketici veri ögesi (yaş, iş, medeni durum, vb.) ve finansal borç verme veya sigorta sonuçları (kişi temerrüde düşmüş, krediyi zamanında geri ödemiş, trafik kazası vb.) kullanılarak eğitilebilir. Bjorkegren ve Grissen, kredi geri ödemelerini tahmin etmek için 2015 yılındaki çalışmalarında cep telefonu verilerine ML yöntemlerini uygulamışlardır [122].

Algoritmalar ile değerlendirilebilen ve gelecekteki borç vermeyi ve sigortalamayı etkileyebilecek eğilimleri tespit etmek için sürekli analiz edilen temel eğilimler için de ML yaygın olarak kullanılmaktadır. Örneğin belirli bir bölgede giderek daha fazla genç araba kazalarına maruz kalıyor mu? gibi sorulara cevap bulmak için uygulanabilmektedir. Sigorta endüstrisinde Cytora, müşterileri hakkında daha iyi risk değerlendirmeleri yapmak için yapay zekayı kullanıyor ve bu da daha doğru fiyatlandırmaya ve iddiaları en aza indirmeye olanak sağlıyor [123].

2.4 Ekonometri ve ML

Frame ve diğ. vurguladığı gibi hem istatistik hem de ML yöntemlerinin amacı verilerden öğrenmektir. Bununla birlikte, asimtotik istatistiksel süreçler ekonomik teori tarafından yönlendirilirken, ML yöntemleri daha çok algoritmalar hakkındadır. ML yöntemleri tahmin performansını maksimize etmeye çalışırken, geleneksel istatistik ise hipotez testlerini ve çıkarımları ön planda tutmaktadır. Maksimum olasılık tahmininden farklı olarak, ML'nin çerçevesi daha az birleşik olma eğilimindedir. Bugüne kadar, finans literatüründe ML ve DL'nin veri yoğunluğu nispeten sınırlı uygulamaları olmuştur. Ancak, 2008 mali krizinden sonra işleme gücünün artması, büyük verilerin ortaya çıkması, daha iyi algoritmalar ve Fintech'te büyüme ML ve DL teknik ve uygulamalarında artışa neden oldu [124].

Verilere uygun eğri uydurma probleminde finans dâhil olmak üzere birçok alanda kullanılan doğrusal regresyon gibi geleneksel modeller vardır. Bu problemlerde genellikle uydurmaya çalışılan eğrinin düz bir çizgi olduğu görülmektedir [125]. Ancak, çoğu problemde, veriler doğrusal olmama eğiliminde olduğundan doğru bir çözüm elde edilemez. Bazı ML yöntemleri doğrusal olmayan ilişkileri ortaya çıkarabilir. ML ve konvansiyonel ekonometrik analiz arasındaki temel fark, tahmin ve nedensel çıkarımlara kıyasla öngörüye daha fazla odaklanmasıdır [126]. ML “yüksek boyutlu


tahmin problemini” vurgularken, geleneksel istatistiksel modeller “düşük boyutlu problemlerde resmi istatistiksel çıkarımı (güven aralıkları, hipotez testleri, optimal tahmin ediciler) vurgulamaktadır [127]. Bu nedenle, ML modelleri istatistiksel testlere göre değil, örnek dışı tahmin performanslarına göre değerlendirilir.

Daha önce görülmeyen ve ilk defa ortaya çıkabilecek durumların açıklanmasında ML modelleri ile başarılı sonuçlar alınması muhtemeldir. Güçlü bir örnek dışı tahmin modeli oluştururken, en güçlü tahmin değişkenleri ve veri alt örneklerindeki ile model tanımlanır. Tahmin performansını artırmak ve verilerden öğrenmek için, farklı veri alt örneklerinde, modele binlerce kez test uygulanır [128]. Örneğin, örnek dışı tahminlerin oluşturulmasında ML yöntemlerinin kullanıldığı çalışmalar vardır. Bunlardan biri Khandani ve ark. 2010 yılında ML yöntemlerinin tüketici kredi riski modellerine uygulandığı çalışmadır. Geliştirilen örneklem dışı tahminler modelinde, kredi kartı sahibi temerrüt ve temerrütlerin sınıflandırma oranlarını önemli ölçüde iyileştirmiştir. Toplam kayıpların % 6 ila % 25'i arasında maliyet tasarrufun sağlandığı tahmin ediliyor [129].

ML ve DL yöntemlerinin bazı dezavantajları vardır. ML'nin dezavantajlarından biri, modelin neden neyi yaptığını açıklamada zorlanmasıdır, bu da literatürde yaygın olarak "kara kutu" eleştirisi olarak bilinir. Ayrıca, DL tekniklerinin karar vermede attığı adımlar belirsizdir. Derin Öğrenme teknikleri tahmin sağlar, ancak değişkenlerin bu tahminlere ulaşmak için nasıl kullanıldığına dair bir fikir vermez [127]. Bu, ayrımcılığı önleyen borç verme modellerinde özellikle önemlidir. Bu konu, eşler arası ödünç verme literatüründe geniş çapta incelenmektedir.

Birçok ML tekniğine genel bakış sağlayan hatırı sayılır çalışmalar mevcuttur [126, 130–132]. Ayrıca, çeşitli ML yöntemleri için daha teknik tartışmaların yapıldığı çalışmalar da vardır [133]. Denetimsiz öğrenme, denetimli öğrenme ve takviyeli öğrenme ML yöntemlerinin temel kategorileridir. ML yöntemlerinin birleştiren genel kategoriler denetimsiz öğrenme, denetimli öğrenme ve takviyeli öğrenmedir.

Denetimli öğrenmenin amacı, etiketli verilerden örüntüler öğrenerek tahminler yapmak, denetimsiz öğrenmede ise veriler hakkında daha fazla bilgi edinmek için temel yapı veya veri dağılımını modellemektir. Kümeleme, sınıflandırma ve regresyon, ML'nin uygulanabileceği istatistiksel sorunlardan bazılarıdır. İstatistiksel problemlerden kümeleme yöntemleri denetimsiz ML e balı olup regresyon ve sınıflandırma da denetimli ML nin alt kümelerini oluşturur. Şekil 2.1'de denetimsiz ve denetimli öğrenme yöntemlerinin kategorizasyonu göstermektedir.



Şekil 2.1 Makine öğrenmesi yöntemlerinin kategorizasyonu.

2.4.1 Denetimsiz Makine Öğrenmesi Modelleri

Denetimsiz ML, insan yardımına ve “etiketlenmiş” veriye ihtiyaç duymadan öğrenen bir sistem olarak tanımlanır. Algoritma, genellikle gözlemleri veya kümeleri gruplayarak verilerdeki yapıyı bulmayı amaçlar. Denetimsiz ML yöntemlerini içeren tipik örnekler kümeleme algoritmaları, boyut küçültme işlemleri, özellik çıkarma, doğal dil işleme ve metin madenciliği modelleri olabilir. Finansal piyasaların belirli bölümlerinin mekanizmalarını kavramak için, kümeleme algoritmaları genellikle tanımlayıcı teknikler olarak kullanılır. Metin ve görüntüler de dahil olmak üzere yüksek boyutlu verilerin temel endişe kaynağı olduğu finansal sorunlara gözetimsiz öğrenme tekniklerini uygulayarak süreç optimizasyonuna büyük bir potansiyel sunar [134].

2.4.1.1 Kümeleme Yöntemleri

Tüketicilerin ve borsacıların davranışlarının modellenmesinde kümeleme yöntemleri kullanılabilir. Buna örnek olarak, bankacılar kredi limitini aşan müşterilerine neler olduğunu ve bu durumun nedenleri hakkında daha iyi bir anlayış kazanmaları için kullanılmaktadır. Düzenleyiciler, yatırımcıları daha iyi anlamak (içeriden

öğrenenlerin ticareti dahil) ¹⁰ için kümeleme algoritmalarını kullanabilir ve düzenleyici ziyaretlerinden önce firmaların iş modellerini kategorize edebilir.

2.4.1.2 Konu Modelleri

Finansal piyasada, piyasa katılımcı davranışlarının arkasındaki farklı itici güçleri analiz etmek için konu modelleri kullanılabilir. Doğal dil işleme ve metin analizi de konu modellerinin alt kategorileridir. ABD’de SEC kurumu tarafından işleme alınan ilk metin madenciligi ve doğal dil işleme uygulamalarında temel olarak amaç muhasebe sahtekarlıklarını tespit etmektir [135]. Medya ve hisse senedi fiyat etkileşimlerini ortaya koymak adına Wall Street Journal’ın popüler günlük köşe yazılarını Tetlock tarafından incelenmiştir. Temel analistlerin öngördüğü doğrultuda, piyasa fiyatları üzerindeki aşağı yönlü baskının, yüksek medya karamsarlığından tahmin edilebileceğini buldu. çalışmalarında ayrıca, yüksek piyasa işlem hacminin alışılmadık derecede yüksek veya düşük karamsarlıktan tahmin edilebileceğinden bahsediyor. [136].

Tetlock ve diğ. sözlüğe dayalı bir yaklaşım kullanmış ve bireysel ölçütlerin muhasebe kazançlarını ve hisse senedi getirilerini tahmin etmek için dil önlemlerinin kullanılıp kullanılamayacağını incelemiştir [137]. Medya içeriğinin, firmaların temel unsurlarını belirlemek için başka türlü zor yakalandığını ve yatırımcıların bunu hızlı bir şekilde hisse senedi fiyatlarına dahil ettiğini farketmişlerdir. 2010 yılındaki çalışmalarında, Sinha hisse senetleri ile ilgili internet mesajlarına ML yöntemleri uygulandığında, piyasanın birçok haber makalesine yeterince yanıt vermediğini iddia ediyor [138].

Li, naïve Bayes algoritması kullanarak firma özellikleri ile ilişkisini gösteren ileriye dönük ifadelerin tonunu sınıflandırır [139]. Manela ve Moreira (2017), 1890’da WSJ ön sayfa makaleleriyle başlayan metne dayalı belirsizlik ölçüsü oluşturuyor. Borsa çöküşleri, politikaya bağlı belirsizlik zamanları, dünya savaşları ve finansal krizler sırasında ima edilen volatilité (NVIX) zirvelerini ölçüyorlar. 1890 ve 2009 yılları arasında yüksek bir NVIX, normal zamanlarda yüksek gelecek getirileri tahmin eder ve ekonomik felaketlere geçmeden hemen önce yükselir [140].

Guo ve ark., Kearney ve Liu, Loughran ve McDonald muhasebe ve finans literatüründe metinsel analiz uygulamaları üzerine bir araştırma sunmaktadır [141–143]. Sosyal medyada sürekli değişen kelime haznesinin ton farkını anlamak ve buna göre sınıflandırmak çok zor olabilir. Emojiler, argo ve alay sözcükleri dahil edildiğinde problem katlanarak artar. Bao ve Datta, Form 10-Ks’deki risklerle ilgili konuları

¹⁰İçeriden Öğrenenlerin Ticareti (Insider Trading) - Sermaye Piyasası araçlarının değerini etkileyebilecek, henüz kamuya açıklanmamış bilgileri kendisine veya üçüncü kişilere menfaat sağlamak amacıyla kullanmak.

araştırmak için gelişmiş metin analizi kullanır (10-Ks, SEC tarafından istenen yıllık raporlardır) [144]. Analist raporlarının içeriğini ölçmede bilgi keşfi ve yorumlamanın etkisini değerlendirmek için Huang'ın yaklaşımı uygulanabilir [145].

Antweiler ve Frank, internet stok mesaj panolarının DJIA ve Dow Jones İnternet Endeksindeki şirketler hakkında Yahoo Finance ve Raging Bull mesajlarını inceleyerek sermaye piyasasını hareket ettirip ettiremeyeceğini incelemişlerdir [146]. Hisse senedi mesajlarının piyasadaki oynaklığı tahmin etmeye yardımcı olduğunu ortaya koymuşlardır. Bununla birlikte, hisse senedi getirileri üzerindeki etki istatistiksel olarak anlamlı olmakla birlikte, ekonomik önemi azdır. Renault mikroblog platformu StockTwits'i inceliyor ve çevrimiçi yatırımcı hissesinin gün içi hisse senedi endeksi getirilerini tahmin etmeye yardımcı olduğuna dair ampirik kanıtlar sunuyor [147].

2.4.2 Denetimli Makine Öğrenmesi Modelleri

Denetimli öğrenme, seçilen algoritmanın verilen giriş özniteliklerini kullanarak hedefe uymaya çalıştığı durumdur. Algoritmaya gözlemlerle ilgili etiketler içeren bir “eğitim veri” seti verilir. Örneğin, etiketler yukarı yönlü / aşağı yönlü olabilir. Devasa bir veri kümesine dayanarak, algoritma, örnek dışı gözlemlerin etiketlerini tahmin etmek için kullanacağı bir sınıflandırma kuralını “öğrenir”. Birçok makine öğrenmesi yönteminde olduğu gibi, denetimli öğrenme yöntemlerindeki test örneği de genellikle gözlemlerin yüzde onunu oluşturur [134].

Denetimli ve Denetimsiz ML arasındaki fark, ikincisinin etiketlenmiş eğitim verisinden yoksun olması ve korelasyonları kendi başına belirlemesi gerektiğidir. Rastgele ormanlar, sinir ağları ve LASSO teknikleri, tahmini analitik ve denetimli öğrenmeye örnek olabilecek yöntemlerden bazılarıdır. Tibshirani tarafından tanıtilen LASSO, en az mutlak büzülme ve seçim operatörü anlamına gelir [148]. Belloni ve diğ., LASSO tekniklerinin yüksek boyutlu verilere nasıl uygulanabileceği konusunda çok ayrıntılı bir tartışma sunmaktadır [149].

Destekli öğrenmenin kökleri, Bellman'ın optimal kontrol üzerindeki öncü çalışmalarındadır ve denetimsiz ve denetimli makine öğrenmesi arasındadır [55, 150]. Destekli öğrenmede, eylemler ve ödülleri arasındaki bağlantı bilinmemektedir ve acentenin çevre ile etkileşimlerinden anlaşılmalıdır. Her veri noktası için uygulanabilecek eylemlerin seçimi, algoritmaya girdi olarak etiketlenmemiş veri kümesi kullanılarak algoritmadan beklenir. Daha sonra, denetimli öğrenmenin bir parçası olarak, insan algoritmanın öğrenme hızını artırmak için geri bildirim sağlayabilir. Corazza ve Ritter, farklı çalışmalarda dinamik ticaret stratejilerine destekli öğrenmeyi uygulamaktadırlar [151, 152].

2.4.2.1 Öngörü Analitiği

Denetimli bir makine öğrenimi biçimi olan tahmine dayalı analitik, genel olarak kümeleme algoritmalarından ve konu modellerinden türetilmiştir. Bu yöntemlerde, regülasyondaki yeni ihlallerin tespiti, algoritmanın geçmişteki düzenleme ihlallerine göre eğitilmesiyle sağlanır. Öngörü analitiği yöntemleri, içeriden öğrenenlerin ticareti ve kartel algılama sorunlarını iyileştirme potansiyeline sahiptir.

2.4.2.2 Rasgele Ormanlar

Breiman, 2000'lerin başında rastgele ormanlar kavramını tanıttı [153]. Rasgele orman modeli, karar ağacı modelleri olarak bilinen genel sınıflandırma ve regresyon ağaçlarından (CART) türetilmiştir. Rastgele orman metodolojisine 2000'lerin başlarında Breiman'dan başlayarak ayrıntılı bir teknik bakış 2014 yılında Booth ve ark. ve 2018 yılında Bagherpour tarafından sağlanmıştır [10, 153, 154]. Bootstrap toplama tekniği rastgele orman modelinde ağaç öğrenenlerine uygulanır. Rastgele orman algoritması tahmin için son derece yararlıdır ve karar ağacını oluştururken bir değişkenin az ya da çok önemli olup olmadığının sınıflandırılmasına izin verir.

Yeh ve diğ. rastgele orman tekniklerinin çok gürbüz olduğunu ve eğitim setinde aykırı değerlerden ve gürültüden çok fazla etkilenmediğini ortaya koymuşlardır [155]. JPMorgan araştırmacıları, rastgele ormanın 10 yıllık ABD Hazine piyasası araçlarının alım satımı için umut verici olduğu düşünüyor [156]. Medeiros ve diğ. doğrusal olmayan özelliği enflasyon dinamikleriyle tanımlamış ve 16 ML yöntemlerini standart istatistiksel modellerle karşılaştırmıştır. Genel olarak, çok sayıda ortak değişken içeren ML yöntemleri, tek değişkenli ölçütlere ve faktör modellerine kıyasla üstün sonuçlar sağladığını ortaya koymuşlardır. Medeiros ve arkadaşlarına göre, enflasyon dinamiğindeki doğrusal olmama durumunun en iyi gösterimi rastgele orman yöntemleri ile elde edilebilir [157]. İflas tahmininde ML uygulamalarını kullanan Barboza ve ark. rastgele orman tekniklerinin diğer yöntemlerden daha iyi performans gösterdiğini bulmuşlardır [158].

2.4.2.3 Sinir Ağları

DL metodolojisinin bir biçimi olan sinir ağları (NN) uygulamaları ilk olarak 2010 yılından sonra finans alanında daha fazla ilgi görmeye başladı. Das, DL'nin standart lineer ekonometrik modeller kullanılarak keşfedilemeyen verilerdeki ince doğrusal olmayanlıkları ortaya çıkardığını kanıtlamıştır [159]. Her katman birden fazla üniteden oluşmakla birlikte giriş katmanı, gizli katman ve çıkış katmanı genel NN'nin üç temel katmanını oluşturmaktadır. Kurumsal finans sağlığını değerlendirmek için

Lacher ve diğ. çalışmalarında NN'i kullanmışlardır. Bu çalışmada Çoklu Diskriminant Analizi (MDA) sınırlamalarının üstesinden gelmede ve üstün sonuçlar elde etmede NN'nin çok değişkenli normallik, doğrusal tekrarlanabilirlik ve öngörücü değişkenlerin bağımsızlığı sayesinde sağlanabileceği ortaya konmuştur [160].

Logit analizi ve diskriminant analizi dâhil olmak üzere geleneksel istatistiksel metodolojileri, 1990'ların başında Altman ve diğerleri tarafından yapay sinir ağı (YSA) ile karşılaştırılmıştır. Ayrıca 80'li yıllardan 90'lı yıllara kadar on yıllık bir süreçte bin İtalyan sanayi firmasının mali durumu incelenmiş ve NN'nin kalıcı örneklem ve sınıflandırma doğruluğu konusunda iyi performans gösterdiği ortaya çıkmıştır [161]. Endişe verebilecek bir sorunun olup olmadığına ilişkin görüş alan firmaların belirlenmesinde ve finansal sıkıntının erken tespitinde Coats ve Fant tarafından 70'li yıllardan başlayarak 20 yıllık S&P verilerini kullanarak yaptıkları çalışmada NN'nin MDA'dan daha etkili olduğunu tespit etmişlerdir [162].

Black and Scholes opsiyon fiyatlandırma formülünün yeniden üretilmesinde, Culkin ve Das 2017 yılında yaptıkları çalışma ile tamamen bağlı DL NN kullanmışlardır. İlk olarak, Culkin ve Das (2017), Black-Scholes opsiyon fiyatlama modelini simüle edilmiş verilerden öğrenme uygulamasıyla başlar. Tahmine dayalı doğruluk, uyarlanabilirlik ve sağlamlık açısından daha iyi performans göstermesi için opsiyon fiyatlandırma modelini eğitmek bir sonraki adımdı ve gerçekten de ana sonuç buydu. Bu sayede yüksek derecede doğrulukla elde edilmiştir [159]. Kazanç çağrılar ve şirketler için kültürel değerleri otomatik olarak işlerken, YSA katmanlarını kullanan DL yöntemi Li ve diğerleri tarafından yaptıkları çalışmalarında geliştirilmiştir. Geniş bir metinsel veri koleksiyonuna ölçeklenebilen ve aynı zamanda kurumsal kültürü ölçmek için yararlı olan ML yaklaşımı, yüksek kaliteli bir kültür sözlüğü sağlar [141].

2.4.2.4 Destek Vektör Makinesi (SVM)

Destek vektör makineleri, ML, NN ve parametrik olmayan uygulanan istatistiklerin unsurlarıyla ilgilidir ve bunları içerir. Bagherpour, SVM metodolojisi hakkında mükemmel ve ayrıntılı bir teknik tartışma sunmaktadır [154]. Cecchini ve diğ. finansal verileri kullanarak kurumsal yönetim sahtekarlığını tespit etmek için SVM'leri kullanmaktadır [163]. Fransız bankası Société Générale, destek-vektör makinelerinin zaman içinde uzun / kısa öz sermaye yatırım kararları almak için daha iyi olduğunu söylüyor. Hardle ve diğ. (2008), firma temerrüt riskini tahmin etmek için sorunsuz SVM'ler kullanmaktadır. Hardle, Moro ve Hoffmann (2011) SVM'lerin finansal bilançolardan gerekli bilgileri alabileceklerini ve daha sonra şirketin gelecekteki ödeme gücü veya iflas tahminlerini yapabildiklerini bulmuşlardır [164].

3 PİYASA YÖNÜNÜN TAHMİN EDİLMESİ

Finans teorisindeki ana akım, geleneksel olarak finansal fiyatların etkin olduğunu ve rassal yürüyüş teorisine göre hareket ettiğini bu nedenle öngörülemez olduğunu varsaymaktadır. Finansal kuramlardan biri olan rassal yürüyüş tanımı, bir zaman periyodundan diğerine olan değişikliklerin birbirinden bağımsız olduğu ve aynı şekilde dağıldığı bir süreci ifade etmektedir. Etkin piyasa açıklaması, zamanın herhangi bir noktasında hisse senedi fiyatlarının, fiili içsel değeri en iyi nasıl temsil ettiğini ve fiyatların anlık olarak bilgi güncellemesi tanımı 1960'ların ortalarında Fama tarafından yapılmıştır [165]. Etkin piyasa, trendsiz ve öngörülemeyen bir finansal piyasa olarak ifade edilmektedir.

Rassal yürüyüşler ve piyasa etkinliği teorisine göre, bir hisse senedinin gelecekteki yönü kümülatif rastgele sayıların serisinden daha fazla tahmin edilemez. İstatistiksel olarak, her ardışık fiyatın geçmişten bağımsız olduğu söylenebilir; Her fiyat değişim serisinin hafızası yoktur. Piyasa bağımsızlığı testi yapılırsa, t zamanında piyasa yönlü hareket olasılığı $t - 1$ ile karşılaştırılır. Aynı verilere daha fazla ön bilgi eklendikçe eklenmelidir, çünkü piyasa verimliliğine göre geçmiş geleceği tahmin etmek için kullanılamaz [165].

Rassal yürüyüşler ve piyasa fiyatlarının etkinliği teorisi 1970'lerde Fama tarafından [166]'de Etkin Pazar Hipotezine (EMH) genişletildi. Teori, mevcut piyasa fiyatının doğru olduğunu ve herhangi bir geçmiş bilginin fiyata yansıtıldığını belirtmektedir. EMH'ye göre, hiçbir piyasa katılımcısı tüm market hakkında bilgisi olmasa da, tüm katılımcılar dâhil olduğunda tüm market bilgisi oluşuyor ve bu da piyasayı oluşturuyor. Bu bireyler, pazarın yönüne dair inançlarını sürekli olarak güncelliyorlar ve hisse senedinin yönü üzerinde hemfikir olmayacaklarsa da, Fama'nın da belirttiği gibi, bu, gerçek fiyat ile içsel arasındaki bir uyumsuzluğa yol açacaktır. Bu da fiyatın, rakip piyasa katılımcıları ile hisse senedinin kendi içsel değeri etrafında rasgele dolaşmasına neden olmaktadır [166].

Eğer piyasalar gerçekten etkin ise, o zaman piyasalar işlem günü boyunca hiçbir

zaman aşırı ya da az tepki göstermez. Ortalama bir yatırımcının menkul kıymetleri analiz etme ve alım satımına karar vermek için çaba harcamaz, çünkü sürekli olarak doğru tahminde bulunmayı umut edemez. Gelecekteki fiyatları tahmin etmeye yönelik herhangi bir girişim, her ne kadar, yüksek getiri oranları elde edilebilirse de, ortalama olarak riskle orantılıdır. Ayrıca, yüksek risk yüksek getiri oranlarına ulaşabilir, ancak aynı zamanda yüksek oranda kayıp oranı da sağlayabilir. Örneğin, adil bir madeni parayı çevirirken, kabaca % 50’lik bir şans elde etme olasılığı beklenir; bununla birlikte, tura (resimli yüzü) on kez art arda beklemek yüksek riskle gelirdi. Etkin bir piyasa kavramı, piyasayı tutarlı bir şekilde tahmin etmenin yüksek bir risk derecesi taşıdığını ima eder.

Yapılan borsa tahmini çalışmalarının büyük bölümünde öznitelik olarak hisse fiyatları ve teknik göstergeler kullanılmıştır. Son yıllarda yapılan çalışmalarda ise finansal haber metinlerinin kullanıldığı çalışmalarda bulunmaktadır.

3.1 Piyasadaki Rastgelelik

Etkin Piyasa hipotezi, piyasa kriterlerinin getirilerini sürekli olarak doğru yönde tahmin etmek yüksek bir risk derecesiyle karşı karşıya olduğunu ima eder. Her ne kadar piyasadan iyi performans gösterme ihtimali son derece küçük olsa da, bunu yapmaya çalışan yeteri kadar kişi olsa da, sonunda birisi saf rastgelelikle bunu başaracaktır. Bu argüman, başarılı yatırımcıları veya dünyanın en büyük yatırımcılarından biri olarak kabul edilen Warren Buffett’in (53.3 milyar \$) büyük zenginliklerini açıklamak için kullanılabilir.

William Sharpe, [156]’da alıntılandığı gibi Warren Buffett’i bir anormallik olarak tanımlamaktadır - bir “3 sigma olayı”. [158] makalesinde Burton Malkiel şöyle yazıyor: “Çok sayıda insanın dâhil olduğu herhangi bir faaliyette, ortalama büyük olasılıkla baskın olmasına rağmen, beklenmedik bir şey gerçekleşecektir. Yatırım yönetimi sektöründe bulduğumuz çok az sayıda iyi performans gösteren oyuncu, aslında tesadüf kanunları ile tutarsız değildir.”

Yatırım ve trade yaklaşımları arasında bir ayrım yapılmalıdır. Buffet yatırım yaparak para kazanmaktadır. Yatırım, kârlı şirketlerin hisse senetlerini satın alıp uzun süre boyunca elinde tutarak zenginlik oluşturma sürecidir. Trading ise genellikle fiyattaki usulsüzlükleri inceleyerek stokları daha sık satın alma ve satma işlemidir. Trading işlemleri daha sık yapıldığı için, hisse başına birkaç kuruşluk küçük karlar zamanla toplamda önemli getiriler sağlayabilir. Buradaki önemli nokta, yatırım ve trading etkin olmayan piyasa varsayımına dayanmasıdır; yani piyasa tahmini mümkündür ve piyasa tamamen rastgele değildir. Bu tez, model karlılığı ile ilgili iddialarda bulunmamakla

birlikte, tüm stokların her zaman veya her zaman aralıklarla öngörülebilir olması ile ilgili de bir varsayımda bulunmaz. Bu çalışmada kısa vadede gelecekteki pazar yönüyle ilgili bir fikir sahibi olmak (örneğin birkaç dakika içinde), önemli.

3.2 Etkin Olmayan Piyasa

Andrew Lo derslerinde anlattığı hikâyede bir ekonomist, arkadaşıyla birlikte caddede dolaşırken yerde yatan 100 dolarlık banknotun fark ederler. Arkadaşı 100 doları almak için uzandığında ekonomist, "Zahmet etme, gerçek bir 100 dolarlık banknot olsaydı, birileri onu çoktan almıştı." der.

Bu, bir akıl yürütmenin abartılması olsa da, Verimli Piyasa Hipotezinin takipçilerinin birçoğu, pazarın tersine kanıtlar ne olursa olsun etkili olduğunu düşünmektedir. Bu, finans ve ekonomi alanında hala tartışmalı bir konu olup, pazarın tahmin edilemeyen anlara karşı inanmayanlar arasında bölünmüş olanlar arasında bölünmüştür. Bu, bu tez için önemli bir konudur çünkü verim, stok tahminini boşa çıkarır ve araştırmamız burada sona erer.

3.3 Tahmin Metotları

Bir önceki bölümde, piyasanın etkinliğine ilişkin şüpheler dile getirdik ve belirli piyasa hareketleri sırasında yüksek seviyede piyasa tahmin mümkün olduğunu gösterdik. Piyasaların öngörülebilir olduğuna inananlar için, hisse senedi fiyatlarını ve dolayısıyla stok yönünü tahmin etmek için iki yaklaşım vardır; bunlar “temel” ve “teknik” yaklaşımlardır. Bunları uygulayanlar genellikle temel analistler ve teknik analistler olarak adlandırılır. Temel analistler, fiyat değişimini belirlemek için dış ve ekonomik faktörlere bakar. Genel inanç, hisse senedinin ait olduğu şirketin kâr, satış, borç seviyeleri ve temettüler gibi temel göstergelerin incelenmesi, fiyatın gelecekteki yönüne bir bakış açısı getirecektir. Teknik analistler, hisse senedi geçmiş performansının gelecekteki fiyat hareketlerini tahmin etmesine yardımcı olabileceğine inanıyor. Diğer piyasa katılımcılarının (kalabalıkların) psikolojisini anlamaya çalışmak için tarihsel fiyatları inceler. Teknik analist, fiyat veya hacim bilgilerinin zaman serilerindeki düzenliliklerini tanımlamaya çalışır; beklenti, fiyat biçimlerinin eğilimler içinde hareket etmesi ve bu örüntülerin sıklıkla kendilerini tekrar etmesidir [6, 158].

3.3.1 Temel Analiz

Daha önce açıklandığı gibi, temel yaklaşım, şirketin fiyatını yönlendiren ekonomik faktörleri, şirketin içsel (temel) değerini ortaya çıkarmak amacıyla inceler [229].

3.3.2 Teknik Analiz

Teknik analistler (teknik analizi takip edenler), diğerlerinin hisse senedi fiyatına ve hacmine göre ne düşündüklerini tahmin etmeye çalışırlar. Göstergeler, fiyatların ve hacimlerin geçmiş değerlerinden hesaplanır ve fiyatların gelecekteki değişikliklerini öngörmek için sinyal olarak kullanılır. Teknik analizin arkasındaki temel kavram trendin devam edip etmeyeceğinin öngörüsünde bulunmak, gelecekteki fiyatların mevcut eğilim yönünden mi yoksa ters yönde mi devam etmesinin daha muhtemel olduğunun tahmin edilmesidir. Teknik analistler, trendin arz ve talep arasındaki stok dengesizliğinden kaynaklandığını savunuyorlar, stok talebi hisse senedi fiyatında artışa neden olmaktadır [25]. Bir haber hikâyesinin temel analize göre yorumlamak yerine teknik analistler, piyasanın haberlere nasıl tepki verdiğini inceler. Hisse senedi fiyatı haberlere tepki göstermezse, haber yanlış olabilir veya temel arz ve talebi doğru olarak yansıtmıyor olabilir [5].

Teknik analizin neden işe yaradığına dair bir öngörü, takipçilerin genellikle kendini gerçekleştiren bir argüman oluşturmalarıdır; traderler, fiyat artışını kaçırmak istememekte, göstergenin beklentisiyle satın almakta, böylece hisse senedine olan hevesin artmasına ve daha yüksek seviyelere itilmesine yardımcı olmaktadır [158]. Bu, diğer yönde de çalışabilir, tüccarlar, fiyat düşüşünü gözden kaçırmak istemez, göstergenin beklentisiyle satar, böylece stok için kötümserliğin artmasına katkı sağlayarak azalmasına ve daha düşük seviyelere itilmesine yardımcı olur.

Herhangi bir nedenden ziyade, kendi kendini gerçekleştiren bir kavramdan daha çok olduğu anlaşılan popüler bir göstergenin örneği, Şekil 2.11’de görülen omuz-baş-omuz göstergesidir. Bu modelin [227]’de tarif edildiği gibi karakteristiği: 1. “Baş”, “omuz” dan çok daha uzun olmalıdır. 2. Omuzların üst ve alt kısmı kabaca eşit yükseklikte olmalıdır. 3. Omuzlar ve baş arasındaki boşluk kabaca simetrik olmalıdır.

Fiyat, sol ve sağ omuzların tabanını bağlayan düz bir çizgi olan “boyun çizgisi” ile kesiştiğinde, trader açığa satış yapmalıdır. 1999’dan 2005’e kadar S&P 100 endeksindeki tüm hisse senetleri için gün içi tik verileri kullanarak Weller [227] tarafından yapılan araştırmada, tahminlerle tutarlı istatistiksel olarak anlamlı büyük hareketler saptanmıştır.

Teknik analizin kullanımı önemini yitirmeden devam etmektedir, profesyonellerin ve bireysel yatırımcıların bağlılığı % 80 ila % 90 arasında olduğunu gösteren çalışmalar mevcuttur [157, 162, 163, 213]. Daha önce de açıklandığı gibi, teknik analize doğru eğimin olmasının en büyük nedeni temel analizdeki “finansal gelir tablosu” gibi parametrelerin işlem günü boyunca tüm fiyat hareketlerini açıklayamamasından kaynaklanmaktadır. Teknik analizdeki popüler kitaplar arasında [1, 64, 167, 168]


bulunur.

3.3.3 Teknik Analizde Nicelik

Teknik analizin amacı, gürültülü verilerden sisteme uygun olabilecek kalıpları belirlemektir. Uygulayıcılara göre, belirli kalıpların piyasada yukarı ya da aşağı doğru hareketlerin ataları olduğu görülmüştür. Bilgisayarların yaygın kullanılmasından önce, bu modeller görsel olarak ortaya çıkarıldı. Teknoloji ve algoritmalarındaki son atılımlarla, teknik analiz daha kantitatif ve istatistiksel bir yaklaşıma dönüşmüştür [154]. Teknik analizleri birbirinden ayrılıp bu tür analizler kantitatif teknik analiz olarak adlandırılmıştır. Geleneksel teknik analiz görsel ve çoğu zaman “belirsiz kurallar” ile doluyken, kantitatif teknik analiz sayısaldır. Bu, kuralları bir bilgisayara kolayca programlayabilmemizi sağlar.

Kantitatif teknik göstergenin bir örneği, onu popülerleştiren ve John Bollinger’in adını taşıyan Bollinger Band’tır. Orta, üst ve alt banttandır. Orta bant, en yüksek, en düşük ve kapanış işlem fiyatlarının n birimlik hareketli ortalamasıdır. Üst bant, orta bantın üzerinde standart sapmalardır (genellikle iki) ve alt bant da d standart sapmalar altındadır. Aşağıda formüle edilmiştir, t değişkeni zamanı ifade etmektedir:

Bollinger Band aşırı satım (ör: ucuz, bu nedenle hisse senedi satın almak) ve aşırı alım (ör: pahalı, bu nedenle hisse senedi satmak) koşullarının bir göstergesidir. Fiyat üst veya alt bantlara yakın olduğunda, geri dönüşün yakın olduğunu gösterir. Aşırı alım ve aşırı satımı belirleyen örnek Bollinger Band Şekil 3.1’te gösterilmiştir.




Şekil 3.1 Bollinger bandı

4 METODOLOJİ VE VERİ YAPISI


Bu çalışmada amacımız, piyasa yönünü tahmin edebilmemiz için yatırımcıların davranışlarını modellemede en uygun öznitelikleri seçip en iyi performans sağlayan makine öğrenme yöntemlerini kullanmaktır. Yatırım bankaları, finansal riskten korunma fonları ve aracı kurumlar dâhil olmak üzere sermaye piyasalarındaki büyük paydaşlar, hisse senedi ticareti için tescilli ticaret yazılımlarını oluştururlar. Bu firmalar tarafından kullanılan yöntemler, gizli ve ticari sır olarak tutulur, bu da karşılaştırmalarını nerdeyse imkânsız kılar. En iyi yöntem ve stratejileri araştırmamızda, birçok alanda başarılı olmaları nedeniyle geleneksel makine öğrenmesi algoritmalarına ek olarak zengin bir dizi öznitelik vektörü ve derin öğrenme yöntemleri kullanılmıştır. Derin öğrenme frameworku olarak, birçok farklı yapay zeka görevine hizmet etmek için Google Brain ekibi tarafından geliştirilen güçlü ve açık kaynaklı bir yazılım olan TensorFlow’u kullanıyoruz [167]. Veri setimizin öznitelikleri, etiketleri ve diğer parametreleri Tensorflow veri yapısına uygun olarak düzenlenmiştir.

Şekil 4.1, TensorFlow frameworku kullanarak pazar yönünü tahmin etmek için gerçekleştirilen adımları göstermektedir. Öznitelikleri belirleyen ve normalizasyon uygulayan bir ön işleme adımıyla başlar. Veri kümesini okurken, bir dizi öznitelikleri ve etiket tanımlanır. Dize değişkenleri varsa, bunlar kodlanır. Bu adımdan sonra, veri kümesi eğitim ve test veri setleri olarak iki kısma ayrılır. Değerlendirme için zaman serisi k katlamalı çapraz doğrulama yöntemi kullanılmıştır. Bu çalışmada k katlama değeri on’a ayarlanmıştır. Finansal zaman serisi verileri, Şekil 4.2’de gösterildiği gibi iki kısma ayrılmıştır. Her çapraz doğrulama adımında, eğitim verileri büyür ve test verisinden önceki tüm verileri içerirken test verilerinin boyutu aynı kalır. Çapraz doğrulamanın son döngüsünde, eğitim veri kümesinin boyutu test veri kümesinden dokuz kat daha büyüktür. Her adımda eğitim veri setiyle bir model oluşturulduktan sonra, model test veri seti ile test edilir ve doğruluk, kümülatif getiri, maksimum düşüm ve yatırım getirisi hesaplanır. Burada nihai hedef, en yüksek hassasiyet, doğruluk, kümülatif getiri ve en düşük maksimum düşümü elde etmektir. Böylece, doğruluk ve kümülatif getiri arasındaki değişime bağlı olarak optimal parametreler



Şekil 4.1 Tensorflow kullanım senaryosunun uygulanmasına ilişkin adımlar

elde edilir.



Şekil 4.2 Zaman serisinin çapraz doğrulama gösterimi

4.1 Sınıflandırma Yöntemleri

Bu çalışmada modellerin finansal tahmin yeteneklerini karşılaştırmak için dört farklı veri madenciliği algoritması kullanılmıştır. Bu bölümde kullandığımız sınıflandırma yaklaşımlarının yapısını ve hyperparametrelerin seçilme süreci ile ilgili bilgi vermektedir.

4.1.1 DNN Sınıflandırıcı

Çok Katmanlı Algılayıcı (MLP) bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Çıkış katmanı dışındaki her katman bir sapma nöronu içerir ve bir sonraki katmana tamamen bağlanır. Bir YSA'nın iki veya daha fazla gizli katmanı varsa, buna derin sinir ağı (DNN) denir [168]. Tamamen bağlı sinir ağı katmanları ¹ oluşturmak için TensorFlow frameworkunun gelişmiş işlevleri kullanılır. DNNClassifier, Tensorflow Python API'sından *tf.estimator.DNNClassifier* ögesini çağırır [167]. Bu komut, benzer, etiketlenmemiş veriler üzerinde sınıflandırma

¹fully connected neural network layers

Tablo 4.1 DNN randomized-search-cv girdi parametreleri

Parametre : [Değer]
"n-neurons":[64, 128, 256, 512, 1024, 2048]
"n-hidden-layers":[3, 4, 5, 6, 7, 8]
"batch-size":[10, 50, 100, 200]
"learning-rate":[0.01, 0.02, 0.05, 0.1]
"activation":[tf.nn.relu, tf.nn.elu, leaky-rela(alpha=0.01), leaky-relb(alpha=0.1)]
"optimizer-class":[tf.train.AdamOptimizer, (tf.train.MomentumOptimizer, momentum=0.95)]
"dropout-rate":[0.2, 0.3, 0.4, 0.5, 0.6]

yapmak için bir dizi etiketli veri ile eğitilmiş bir ileri beslemeli çok katmanlı sinir ağı² oluşturur. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır, ayrıca düzenleme (regularization) ve normalleştirme (normalization) hiperparametreleri optimize edilmiştir.

Sinir ağlarının esnekliği aslında ana dezavantajlarından biridir, çünkü ayarlanması gereken birçok hiperparametre vardır. Akla gelebilecek herhangi bir topolojide kullanmanın yanı sıra, katman sayısının, katman başına nöronların, her katmanda kullanılan aktivasyon fonksiyonunun tipinin, ağırlık başlatma mantığının ve diğer birçok parametrenin olabileceği basit bir MLP’de bile kullanılabileceği gibi hiperparametreleri de değiştirilebilir. Bu nedenle, DNN modeli için en iyi hiperparametreler kombinasyonunu seçerken, hem ızgara arama hem de rastgele arama kullanılır. GridSearchCV tüm kombinasyonları değerlendirdiğinden, en iyi hiperparametreleri bulmak uzun sürebilir. Bu nedenle, DNN için hiperparametre ayarlama işlemi iki adımda gerçekleştirilir. İlk olarak, her hiperparametre için aralığı daraltmak için RandomizedSearchCV kullanılır. Daha sonra GridSearchCV, RandomizedSearchCV tarafından sağlanan en iyi değerlere dayanan bir ızgara kullanılarak uygulanır. RandomizedSearchCV için kullanılan girdi parametreleri Tablo 4.1 deki gibidir.

RandomizeSearchCV kullanılarak her kombinasyon test edilmese bile, çok çeşitli değerler rastgele test edilir. Zamanla performans arasındaki dengeleme ana endişe konusu olduğundan, RandomizedSearchCV test parametrelerini tanımlarken performansı sınırlı bir sürede artırmaya çalıştık. Bunun için n-katman - örneklenen parametre ayarlarının sayısı 80 olarak ayarlanmıştır. Ayrıca cv - çapraz doğrulama için kullanılacak kat sayısı 4’e ayarlanmıştır. Bu parametrelerin artırılması performansı artırabilir, ancak çalışma süresini de artıracaktır. RandomizedSearchCV’nin eğitilmesiyle elde edilen en iyi hiperparametreler Tablo 4.2 de gösterilmiştir.

²feedforward multilayer neural network

Tablo 4.2 DNN randomized-search-cv sonuç parametreleri

Parametre : [Değer]
"hidden-units"=[1024, 512, 256]
"n-hidden-layers": 3
"batch-size": 50
"learning-rate": 0.05
"activation": tf.nn.relu
"optimizer-class": tf.train.AdamOptimizer
"dropout-rate": 0.5

Tablo 4.3 DNN grid-search-cv girdi parametreleri

Parametre : [Değer]
"n-neurons":[128, 256, 512, 1024]
"n-hidden-layers":[3, 4, 5]
"batch-size":[40, 50, 60]
"learning-rate":[0.04, 0.05, 0.06]
"activation":[tf.nn.relu, tf.nn.elu]
"optimizer-class":[tf.train.AdamOptimizer, partial(tf.train.MomentumOptimizer, momentum=0.95)]
"dropout-rate": [0.4, 0.5, 0.6]

DNN performansını artırmak için GridSearchCV, RandomizedSearchCV'den elde edilen en iyi hiperparametrelere odaklanarak kullanılır. GridSearchCV için kullanılan eğitim parametreleri Tablo 4.3 de gösterilmiştir.

GridSearchCV eğitildikten sonra DNN modeli için en iyi hiperparametreler elde edilir. Elde edilen hiperparametreler Tablo 4.4 de gösterilmiştir.

4.1.2 Lojistik Regresyon

Borsadaki herhangi bir enstrümanın yönünü tahmin ederken, Lojistik Regresyon genellikle belirli bir sınıfa ait örneğin olasılığını tahmin etmek için kullanılır. İkili bir sınıflandırıcı yapmak için, model, tahmini olasılık % 50'den büyükse, örneğin bu

Tablo 4.4 DNN grid-search-cv sonuç parametreleri

Parametre : [Değer]
"n-neurons":[1024, 512, 512, 128]
"batch-size":[60]
"learning-rate":[0.06]
"activation":[tf.nn.relu]
"optimizer-class":[tf.train.AdamOptimizer]
"dropout-rate": [0.4]

sınıfa ait olduğunu tahmin eder, aksi takdirde değildir.

Lojistik Regresyon modelinin tahmini olasılık vektörü formu denklem (4.1)'de gösterilmiştir. Lojistik Regresyon modeli, lojistik özelliklerin ağırlıklı toplamına önyargı terimi eklenerek hesaplanır ve lojistik çıktılar elde edilir. Denklem (4.2)'de gösterildiği gibi, logit olarak da adlandırılan lojistik, 0 ile 1 arasında bir sayı veren bir sigmoid işlevdir.

$$\hat{p} = h_{\theta}(x) = \sigma(\theta^T \cdot x) \quad (4.1)$$

$$\sigma(t) = \frac{1}{1 + \exp(-t)} \quad (4.2)$$

Olasılık $\hat{p} = h_{\theta}(x)$ Lojistik Regresyon modeli ile hesaplandıktan sonra, y tahmini, Denklem (4.3) kullanılarak kolayca hesaplanabilir. $\theta^T \cdot x$ pozitif olduğunda, model 1 (yükselme) olarak, aksi halde 0 (düşme) olarak tahmin eder.

$$\hat{y} = \begin{cases} 0, & \text{if } \hat{p} < 0.5 \\ 1, & \text{if } \hat{p} \geq 0.5 \end{cases} \quad (4.3)$$

Eğitimin amacı, model vektörü maksimize edilecek şekilde parametre vektör θ 'yı ayarlamaktır. Bu amaçla bir maliyet fonksiyonu kullanılır. Tüm eğitim seti üzerindeki maliyet fonksiyonu basitçe ortalama maliyet genel eğitim örnekleridir. Maliyet fonksiyonu dışbükey olduğundan, Gradient Descent kullanmak küresel minimumun bulunmasını garanti eder [168].

LR'yi uygulamak için Scikit-Learn's Lojistik Regresyon modeli kullanılmıştır. Model düzenlenmesi için ℓ_1 and ℓ_2 cezalandırma parametreleri uygulanır. Scikit-Learn'da ℓ_2 ceza parametresi varsayılan olarak eklenir [169].

Hiperparametreler LR'de çok kritik olmasa da, veri setimiz için en iyi hiperparametreleri kullandığımızdan emin olmak istedik, bu nedenle hiperparametreler ayarlanır. En iyi model, modelde test edilmesi istenen parametrelerin ızgarası tanımlanarak GridSearchCV kullanılarak seçilmiştir. Farklı çözücülerle performans veya yakınsamada faydalı farklılıklar görülebilir. Bu nedenle test edilecek ızgaraya 'newton-cg', 'lbfgs' ve 'liblinear' çözücüler eklenmiştir. Ceza (normalleştirme) olarak "l1" ve "l2" parametreleri kullanılır. Son olarak, regülasyon kuvvetini kontrol eden girdiye C parametresi eklenir. C parametreleri olarak 100, 10,

1.0, 0.1 ve 0.01 değerleri kullanılır. GridSearchCV çalıştırıldıktan sonra LR için elde edilen en iyi parametreler $C = 0.01$, $\text{penalty} = 'l2'$ ve $\text{solver} = 'liblinear'$ ’dır.

4.1.3 Rastgele Orman (Random Forest)

Karar ağaçları, borsa yönünü tahmin etmek için yaygın olarak kullanılan makine öğrenmesi yöntemlerinden biridir. Son derece düzensiz desenler olduğundan, bu desenleri öğrenmek için ağaçların çok derinleşmesi gerekir. Bu da ağaçların eğitim setlerini aşırı öğrenmesine (overfitting e) neden olabilir. Verilerdeki hafif bir gürültü, ağacın tamamen farklı bir şekilde büyümesine neden olabilir. Bunun nedeni, karar ağaçlarının çok düşük eğilim (bias) ve yüksek varyansa sahip olmasıdır. Rastgele Orman, biraz daha fazla önyargı pahasına özellik alanının farklı alt alanında birden fazla karar ağacı eğiterek bu sorunun üstesinden gelir [8]. Rastgele Orman algoritması, ağaç yetiştirirken ekstra bir rastgelelik sunar; Bir düğümü bölerken en iyi özelliği aramak yerine, rastgele bir özellik alt kümesi arasında en iyi özelliği arar [168]. Bu, ormandaki ağaçların hiçbirinin tüm eğitim verilerini görmediği anlamına gelir. Veriler özyinelemeli olarak bölümlere ayrılır. Belirli bir düğümde, bölünme bir öznitelik hakkında bir soru sorarak yapılır. Bölme kriteri için seçim, Shannon Entropi veya Gini safsızlığı gibi bazı safsızlık önlemlerine dayanmaktadır. Bu, daha düşük bir varyans için daha yüksek bir sapma sağlayan daha büyük bir ağaç çeşitliliği ile sonuçlanıp genel olarak daha iyi bir model elde edilir.

RF uygulamasında Scikit-Learn RandomForestClassifier Python kütüphanesi kullanılır [169]. Breiman Random Forest sınıflandırıcısının önerdiği gibi, her biri maksimum 16 düğümle sınırlı 500 ağaçla eğitilir [153]. Rasgele Orman Sınıflandırıcılarının performansını artırmak için hiperparametreler bir ızgara araması kullanılarak ayarlanır.

Ayarlanabilen on beşten fazla parametre var. Bu parametrelerin en önemli beşine odaklandık. Izgara üzerine yerleştirilen parametreler ormandaki ağaç sayısı $n\text{-estimators}$: [100, 200, 300, 400]; ağacın maksimum derinliği max-depth : [50, 60, 70, 80, 90]; bir iç düğümü bölmek için gereken minimum numune sayısı min-samples-split : [8, 10, 12]; bir yaprak düğümünde olması gereken minimum numune sayısı min-samples-leaf : [3, 4, 5]; en iyi bölünmeyi ararken dikkate alınması gereken özellik sayısı max-features : [2, 3]. Izgara araması verilere uygulandıktan sonra en iyi parametreler elde edilir. Bu araştırmada Rastgele Orman için kullanılan en iyi parametreler Tablo 4.5 de gösterilmiştir.

Tablo 4.5 Rastgele orman grid-search-cv sonuç parametreleri

Parametre : [Değer]
"n-estimators" : 200
"max-depth" : 60
"min-samples-split" : 12
"min-samples-leaf" : 5
"max-features" : 3

4.1.4 Destek Vektör Makinesi (Support Vector Machines)

Bir modeli eğiterek görünmeyen yeni nesneleri belirli bir kategoriye atamak için SVM en çok kullanılan ikili sınıflandırıcılardan biridir. SVM'nin ana fikri, yükselen ve düşen örneklerin doğru ayrılmasının en üst düzeye çıkarıldığı bir karar sınırı (hyperplane-hiper düzlem) oluşturmaktır [51]. N boyutlu özellik vektörleri $x=x_1, \dots, x_n$ hiper düzlemi, denklem (4.4) 'te olduğu gibi tanımlanabilir, burada elemanların toplamı bir tarafta 0'dan büyük iken diğer tarafta 0'dan az olacaktır.

$$\beta_0 + \beta_1 X_1 + \dots + \beta_n X_n = \beta_0 + \sum_{i=1}^n \beta_i X_i = 0 \quad (4.4)$$

The class of each point x_i can be denoted by $y_i \in \{1, -1\}$ where $y = \beta_0 + \sum_{i=1}^n \beta_i X_i$. By maximizing the distance between the boundary and any point we can get an optimal hyperplane. The best data splitting boundary is called maximum margin hyperplane. Data points close to the hyperplane are known as a Support Vector Classifier (SVC) and only these points are relevant to hyperplane selection. SVC cannot be applied to non-linear functions. For solving this issue in SVM, a more general kernel function is applied as in Eq. (4.5), which is a Quadratic programming (QP) optimization problem with linear constraints, and can be solved by using standard QP solver.

$$f(x) = \text{sgn}(\beta_0 + \sum_{i=1}^n \alpha_i y_i K(x, x_i)) \quad (4.5)$$

SVM için Pedregosa ve ark. Scikit-learn Python kütüphanesinin LinearSVC paketi kullanılmıştır [169]. LinearSVC de “bire-karşı-geri (one-vs-the-rest)” çok-sınıf stratejisini uygulanır. Bu çalışmada sadece iki sınıfımız olduğundan bir modelin eğitilmesi yeterli olmuştur.

SVM'nin performansını artırmak için, üç ana hiper parametrenin ayarlanmasına odaklandık. Kernels, Regularisation ve Gamma performansı etkileyen en önemli parametrelerdir. Bu parametreler, GridSearchCV tarafından ızgara

araması için kullanılmak üzere ızgaraya yerleştirilir. Model, ızgarada belirtilen algoritma parametrelerinin her kombinasyonu için değerlendirilir. Kullanılan hiper-parametreler aşağıdaki gibidir: C: [0.1,1, 10, 100], Gamma: [1,0.1,0.01,0.001], kernels: [rbf, poli, sigmoid]. GridSearchCV'yi eğitim verilerine yerleştirdikten sonra, en iyi tahminçiler elde edilir. Bu çalışmada kullanılan en iyi hiper parametreler C = 10; Gamma = 0.1; ve kernel = rbf.

4.2 Verilerde Önışlem Süreci

Tahmin modelinin performansını artırmak ve olası sorunları en aza indirmek için sınıflandırma algoritmalarında girdi olarak kullanılan verilere uygulanan adımlar, veri önışleme süreci olarak kabul edilir. Elektronik ticaret geçmişten gelen ticaret verilerinin güvenilirliğini arttırdı, eskiden ticaret bilgisayar kullanılmadan yürütölmekteydi ve kâtipler işlemleri fiyatını ve hacim miktarını manuel olarak girmektedirler. Geliştirilen modellerin, stok hareketlerini analiz etmede güvenilir olduğundan emin olmak için veri önışleme gerekli olan önemli bir adımdır. Verileri temizleme, az ya da çok veri ihtiyacını belirleme, verileri belirli bir sınıflandırıcıda kullanmak üzere dönıştürme, eğilimi giderme gibi adımlar veri önışlemede kullanılan yöntemlerden bazılarıdır [170].

Borsa İstanbul Nasdaq ile yapılan işbirliğinden sonra yüksek hızlı veri setleri sunmaya başladı. Sunulmakta olan veri setlerinde yapılan her işlemin zamanı milisaniye hassasiyetindedir. Ancak BIST 100 veri seti inceleme yapılan dönemde Borsa İstanbul tarafından 10 saniyelik periyotlar ile sunulmuştur. Nasdaq ile yapılan anlaşmadan sonra da her saniyede sunulmaya başlandı. Bu çalışmada Borsa İstanbulda temin edilen veri seti örneğı Tablo 4.6 de gösterilmiştir.

Tablo 4.6 BIST 100 işlem verisi

Id	Tarih	Sembol	Fiyat	Volum
1	2/1/2008 09:45:00	XU100	55160.2	1696787
2	2/1/2008 09:45:10	XU100	55157.1	1187785
3	2/1/2008 09:45:20	XU100	55128.96	88521
4	2/1/2008 09:45:30	XU100	55171.04	138561
5	2/1/2008 09:45:40	XU100	55134.99	75664
6	2/1/2008 09:45:50	XU100	55087.88	821015
7	2/1/2008 09:46:00	XU100	55105.16	115548
8	2/1/2008 09:46:10	XU100	55094.05	121227
9	2/1/2008 09:46:20	XU100	55090.96	63070
10	2/1/2008 09:46:30	XU100	55035.34	100684


Matriks, Bloomberg ve Reuters gibi farklı veri sağlayıcıları da hisse senedi fiyat

verilerini 1 saniye, 1 dakika, 5 dakika, günlük, haftalık, vb. zaman periyotlarında hizmet olarak sunmaktadır.

Bu bölümde veri ön işleme gerekliliğinin üzerinde durulmuştur. Gürültü ve kötü ticaret verilerinin belirlenmesi ve düzeltilmesi, çok fazla ve çok az veri probleminin ele alınması, verilerini standartlaştırmak için normalleştirme adımlarının uygulanması, veri önışlemedeki temel problemlerdir.

4.2.1 Kötü İşlem Verisi ve Gürültü

Veri ön işlemenin önemi Şekil 4.3'de görülmekte olup, bu da IBM'in hisse senedi için 3 Ocak 2005 tarihinde saat 12:14'den 12:21'e kadar olan tüm işlemlerini göstermektedir. Fiyatlar, önceki işlemde 0,58 dolar daha düşük fiyattan görülebileceği yaklaşık 12:17'ye kadar küçük bir aralıkta hareket eder. Sermaye piyasasındaki koşullu birleşik alım-satımın bir örneği bu aykırı değerdir. Bu durum, bir trader in birkaç küçük siparişi bir araya getirmesiyle sonuçlanır, bu da mevcut işlem fiyatından uzak bir fiyatla sonuçlanır (bu örnekte, grup ticareti önceki işlem fiyatından 0.58 \$ uzağa gerçekleşir). Pek çok araştırmacı [171–174] koşullu işlemlerin, geç işlemlerin, sıra dışı olarak bildirilen işlemlerin veya özel anlaşma koşullarına sahip işlemlerin kaldırılmasını önermektedir. Bu işlemlerin kaldırılmaması (Şekil 4.3'deki gibi), birçoğu daha sonra bu makalede ele alınacak olan gürültü ve yanlış hesaplanmış sinyallerle sonuçlanır. Böylelikle sadece model performansını geliştirmek için değil, aynı zamanda (ve belki de daha da önemlisi) otomatik bir ticaretin bir yanlış sinyale bağlı olarak aktifleşmesini engellemek için de son derece önemlidir.



Şekil 4.3 Sermaye piyasasında kötü işlem verisine bir örnek.


Kalan verileri bozabilecek değişken piyasa koşullarını ortadan kaldırmazken gürültüyü

azaltmak çok büyük sorunlara neden olabileceği öngören çalışmalar mevcuttur. Çoğu araştırmada daha fazla öngörülebilirlik ve öğrenme kabiliyetinin artırılması için modellerden gürültünün giderilmesi gerektiği savunulsa da zaman zaman oldukça değişken ve kaotik olabilecek gerçek piyasa koşullarını ortadan kaldırmamaya dikkat edilmesinin gerekliliğini Falkenberry vurgulamaktadır [172].

Örnekleme aralığının düzensiz tik verilerinin 5, 10, 30 dakika ya da 1, 2, 4 saat gibi daha uzun aralıklara yükseltilmesi [175] veya daha uzun zaman aralıklarında hacim ağırlıklı ortalamasının kullanılması gürültüyü azaltmak için kullanılabilecek ek yöntemlerdir [174, 176]. Bu çalışmada tick-by-tick verisi 30, 60 ve 120 dakika aralıklara OHLC ye göre grupladığımızdan gürültü çıkarılmadan bizim sonuçlarımıza da olumsuz etki etmesinin önüne geçmiş olduk.

4.2.2 Sermaye Piyasasının İşlem Yoğunluğu

Sermaye piyasasındaki işlem verileri düzenli aralıklarla gelmediğinden, genellikle sınıflandırma modelleri oluşturmakta zorluklarla karşılaşılmasına sebebiyet vermektedir. Borsa işlem verilerinin zaman içindeki dağılımı Şekil 4.4'de gösterilmektedir. Borsa işlem verilerinin çokluğu, gelen veri hızı makine öğrenmesi modelinin verimli bir şekilde sonuç üretmesinden daha yüksek olduğunda (örneğin, çevrimiçi uyarlamalı modellerde) ve veri boyutu depolama kaynakları üzerinde bir kısıtlama olduğunda endişe verici hale gelebilmektedir. Aynı şekilde işlemler, ara sıra meydana gelebilir ve çok az veri, zayıf genellenebilirliğe sahip bir model ile sonuçlanabilir. Çok fazla veriye sahip olmak veya yeterli veriye sahip olmamak farklı sorunlara neden olabileceğinden, ihtiyaca göre doğru çözümler üretilmelidir.



Şekil 4.4 Borsa işlem verilerinin zaman içindeki dağılımı

Çok fazla veri ile karşılaşıldığında çözümlerden biri örnekleme yöntemlerini kullanmak bir diğeri de düzensiz aralıklı tick-by-tick gözlemlerini, 1 saniye, 1 dakika, vs. gibi düzenli aralıklara dönüştürmektir [172, 177]. Araştırdığımız literatürde daha yaygın olarak kullanıldığından ve bizim çalışmamıza daha uygun olduğundan, bu çalışmada gözlemler düzenli aralıklara dönüştürülmüştür. Bu dönüşüm ile veri örneklerinin sayısını azaltırken olabildiğince fazla bilgi sahibi olmak için, hem ticaret hacimlerini (yani işlem gören hisse sayısı) hem de açılış, en yüksek, en düşük ve kapanış fiyatlarının aralık boyunca tutulması Şekil 4.5'de görüldüğü gibi yaygındır.

Örneklemenin diğer avantajları arasında, gürültünün azaltılması ve Brownlees ve Gallo [172, 177]'e göre, yüksek frekanslı verilerden aykırı değerler, veriler 1, 5, 10 dakika gibi daha uzun aralıklarla örneklendiğinde veya ortalaması alındığında daha az problemli olabilir [175]. Genellemenin artmasına katkı sağlayabileceğinden öznitelik alt kümesinde boyut azaltma için çalışmaların yapılarak, etkisi olmayan veriler çıkartılacağından aynı zamanda veri setinde de küçülme olacaktır. Bu problemi ele almak için, ticaret verilerinin aşırı yüklenmesi (değiştirilerek) ve sentetik olarak üretilen örneklerle aşırı örnekleme gibi çeşitli stratejiler kullanılmıştır ([178]'te SMOTE algoritmasına bakınız). Farklı çalışmalarda, Maimon ve Garcia verilerdeki dengesizliği ele alıp ve uygulanabilecek çözümleri değerlendirmişlerdir [179, 180]. Verilerin aralıklı olması problemine farklı çözümler uygulanmaya çalışılabilir. Uygulanabilecek çözümler arasında ek veri kaynakları kullanılarak eksik verilerden kaynaklanan boşlukların doldurulması veya seyrek değişkenlerin azaltılması olabilir. Bununla birlikte, veri eksikliği, zayıf genellenebilirliğe veya gelecekteki fiyatların tahmin edilememesine neden olan bir modele yol açabileceğinden, zor ve önemli bir sorun olmaya devam etmektedir.

4.2.3 Veri Normalizasyonu

Genellikle makine öğrenmesinde standartlaştırma ile eşanlamlı olan veri normalizasyonu, bir eğitim modelinde kullanılmak üzere verilerin dönüştürülmesi sürecini ifade eder. En yaygın teknik denklem (4.6)'dır ancak aynı zamanda denklem (4.7) ve (4.8) de kullanılır. Sınıflandırıcıda hisse senedi ticaret hacmi gibi büyük sayılar kullanıldığında, denklem (4.8) yaygın olarak kullanılır [170, 181].

$$x_t = \frac{x_t - \min(x)}{\max(x) - \min(x)} \quad (4.6)$$

$$x_t = \frac{x_t}{\max(x)} \quad (4.7)$$

$$x_t = \frac{x_t - \mu}{\sigma} \quad (4.8)$$

$$x_t = \log(x_t) \quad (4.9)$$

Veri normalizasyonun yapılmasının iki ana sebebi vardır. Bunlardan ilki, aykırı değerlerden çok fazla etkilenen yapay sinir ağları gibi bazı modellerin bu tür

problemlerini ortadan kaldırmak ve performansının iyileşmesine katkı sağlamak için veri normalizasyonun uygulayıp verilerin dönüştürülmesi önemlidir. İkincisi de, zaman serilerindeki eğilimler durağan-olmama ³ olarak ifade edilmektedir. Zaman serilerindeki eğilimlerin varlığı sınıflandırıcıların başarısına kötü yönde etki ettiğini gösteren çok fazla çalışma mevcuttur. Bu yüzden dönüşümler kullanılıp zaman serilerindeki eğilimler ortadan kaldırılmalıdır [182]. Denklemler (4.6)-(4.9)'deki yöntemlere ek olarak, t zamanından itibaren t oranındaki yüzde değişimleri veya farkları bulmak için, n , herhangi bir sayı olabilir, aynı zamanda yaygın olarak kullanılır [183, 184].

Hisse senedi fiyatının yüzde değişimini kullanmanın doğrudan stoklar arası karşılaştırmalara izin verdiğinden dolayı ideal olduğu bilinmektedir. Fiyat farkı kullanımının sadece baştan fiyat farkı alınan iki stok arası karşılaştırmaya izin verdiğinden dolayı çok fazla tercih edilmemektedir. Örneğin, 200 TL'lik bir hisse senedi için 20 TL'lik bir hareket olması, 50 TL'lik bir stoktaki 20 TL'lik hareket olması ihtimalinden daha fazladır.


Veri normalizasyonu, çevrimiçi öğrenmede daha zordur çünkü verinin gelecekteki dağılımının geçmişle aynı kalacağı düşünülemez; Tüm veriler mevcut olana kadar minimum ve maksimum değerler bilinemeyecektir. Gaber ve diğ., çevrimiçi öğrenmede bu sorunu ortadan kaldırmak için verileri ayırmayı veya ikilileştirmeyi önermektedir [185]. Sarıcı öğrenmede sınıflandırıcılar tüm eğitim setini içeren parçalar ile oluşturulduğundan, bu sorun sarıcı öğrenmede mevcut değildir. Buna rağmen minimum ve maksimum değerler hala saklanmalıdır. Bunun nedeni de yakın gelecekte benzer karşılaştırmalara ihtiyaç olabilmesidir.

4.3 Veri Seti

Bu çalışmada kullanılan Ocak 2008 ile Aralık 2016 arasındaki 9 yıllık BIST 100 endeks verisi Borsa İstanbul Veri Mağazası'ndan elde edilmiştir [186]. Her ne kadar son birkaç yıldaki BIST 100 verileri bir saniyelik zaman periyodunda yayınlansa da, elde ettiğimiz verilerdeki yayınlanma süre on saniyedir. Veri kümesini on saniyeden farklı zaman aralıklarına dönüştürmek için açılış, en yüksek, en düşük ve kapanış (OHLC) fiyatları kullanıldı. Dönüştürme işlemi Şekil 4.5'de gösterilmiştir. Veri kümesi daha düşük bir zaman diliminden daha yüksek zaman periyotlarına dönüştürüldüğünden, dönüştürülen zaman periyotlarında eksik veri olmadığı anlamına gelmektedir.

Örneğin, saatlik veri kümesine dönüştürme sürecinde, saatin başındaki fiyat *Açılış* fiyatı, o saatteki maksimum fiyat *En Yüksek* fiyat, minimum fiyat *En Düşük* fiyat ve

³Nonstationarity



Şekil 4.5 On saniyelik zaman periyodunun saatlik OHLC'ye dönüştürülmesi

saatin sonundaki son fiyat da *Kapanış* fiyatı olarak kullanılır. Aynı şekilde, o saatteki tüm hacimler toplanıp saatin toplam hacmi elde edilir. İki saatlik, saatlik ve 30 dakikalık periyotlarda endeksin açılış, en yüksek, en düşük, ve kapanış fiyatlarını ve o periyottaki toplam hacmi kullanılmıştır. İki saatlik, saatlik ve 30 dakikalık veri setleri sırasıyla 9157, 18314 ve 33673 satırdan oluşur. Saatlik veri kümesi örneği Tablo 4.7'de gösterilmiştir. Her Katlamalı Çarpaz Doğrulamada k katlama değeri için (k-fold cross validation), örnekleme dönemi eğitim için, örnekleme dışı dönem ise tahmin performansını değerlendirmek için kullanılmıştır.

Tablo 4.7 BIST 100 saatlik OHLC veri yapısı

Tarih	Açılış	En Yüksek	En Düşük	Kapanış	Volum
2008010209	55160.2	55171.04	54889.51	54951.62	180514
2008010210	54891.5	55281.66	54821.49	54854.45	132182
2008010211	54853.8	54951.23	54481.52	54638.57	76451
2008010212	54527.59	54527.59	54527.59	54527.59	25427
2008010214	54741.95	54939.83	54584.49	54618.13	136968

4.4 Öznitelik Vektörlerinin Oluşturulması

Hisse senedi tahminleri ile ilgili yayınlar incelendiğinde, teknik analizde kullanılan teknik göstergelerin genellikle tahmin modellerinin özellik kümelerini oluşturmak için kullanıldığı görülmektedir [187]. Teknik göstergeler finansal araçların fiyatlarını analiz etmek için kullanılan matematiksel hesaplama yöntemleridir. Zaman serisi verileriyle ilgili bazı spesifik hesaplamalardan sonra, göstergelerin çoğu yatırımcıların gelecekte fiyat hareketi eğilimlerini tahmin etmelerine yardımcı olur. Bazı göstergeler ise trendin devam edip etmeyeceğini göstermeye çalışmaktadır. Göstergeler, yatırımcıları aydınlatmak için belirli bir an ve süre için hesaplanır. Yatırımcılar gösterge değerlerini yorumlayıp hisse / enstrüman fiyatlarının düşme yada yükselme eğilimde olup olmadığını tespit etmeye çalışır.

Literatürde tahmin için kullanılabilecek yüzlerce teknik gösterge vardır. Bu göstergelerin bazıları benzer bilgilere çıkarır ve benzer sinyaller üretir. Kullanılan teknik göstergelerin seçiminde göstergelerin işaret ettiği bilgi türleri göz önünde bulundurulmalıdır. Bunun nedeni ise aynı disiplinden seçilen göstergelerin çalışma mantıkları da aynı olacağından aynı yerlerde sinyal üretecek olmalarıdır.

Bu kadar çok göstergeden başarıya etkisi olabilecek çeşitlendirilmiş göstergelerin doğru parametre varyasyonlarına göre seçilmiş olması çok önemlidir. Araştırmada kullanılan seçilmiş teknik göstergelerin adları ve tanımları Tablo 4.8’te verilmiştir. Kumar [188]’ın ve Gündüz [16]’ün çalışmalarındaki göstergelerin tanımlanmasında da benzer kısaltmalar kullanılmıştır. Bu çalışmada da aynı adlandırma kurallarını kullanıyoruz.

Kullanılacak teknik göstergeler belirlendikten sonra bu göstergelerin hangi zaman periyotları ve hangi tür fiyat verisi ile hesaplanacağına karar verilmiştir. Örneğin, SMA, EMA, ROCP ve MOM göstergeleri hisselerin kapanış fiyatları kullanılarak ve 5, 10, 15, ve 20 günlük zaman periyotları için hesaplanmıştır. WILLR, CCI, UO ve ATR göstergeleri hisselerin günlük en yüksek, en düşük ve kapanış fiyatları kullanılarak bulunmuştur. Bu göstergelerden WILLR için 4 farklı zaman periyodu kullanılarak değer bulunurken, CCI, UO ve ATR için bir zaman periyodu kullanılarak hesaplama yapılmıştır. Farklı zaman dilimleri için farklı göstergelerin hesaplanmasıyla BIST 100 endeksinin her bir dönemi için 97 özellik elde ettik. Hesaplanan tüm öznitelikler en küçük-en büyük normleştirilmesi (Min-max normalization) uygulanmıştır.

Özellikler oluşturulduktan sonra, denklem (4.6)’deki gibi her bir özelliğe min-maks normleştirme uygulanır; burada $x = x_1, \dots, x_n$, özellik vektörlerini ifade eder ve z , x ’in normleştirilmiş değeridir. Elde edilen veri seti her model için kullanıldı; veri setinde modellere göre değişiklik yoktur.

Tablo 4.8 Teknik gösterge listesi

Gösterge İsmi	Tanım
OP	Açılış fiyatı
HI	En yüksek fiyat
LO	En düşük fiyat
CL	Kapanış fiyatı
ROC(x)	Değişim oranı
ROCP(x)	Değişim oranı yüzdesi
%K	Stokastik %K
%D	%K 'nın hareketli ortalaması
BIAS	x-günlük sapma
MA(x)	x-günlük hareketli ortalama
EMA(x)	x-günlük üssel hareketli ortalama
MOM(x)	MOM(x) Momentum
MACD(x,y)	x-günlük hareketli ortalama yakınsama ve ıraksama
TEMA(x)	Üçlü üssel hareketli ortalama
PPO(x,y)	Yüzdesel fiyat osilaörü
CCI(x)	CCI(x) Emtia kanal indeksi
WILLR(x)	WILLR(x) Larry William 's %R
RSI(x)	RSI(x) Görece güç indeksi
ULTOSC(x,y,z)	ULTOSC(x,y,z) Esas osilatör
RSI(x)	Görece güç indeksi
ULTOSC(x,y,z)	Esas osilatör
ATR(x)	Ortalama gerçek aralık
MEDPRICE(x)	x-günlük ortanca fiyat
MIDPRICE(x)	günlük ortalama fiyat
signL(x,y)	Tetikleme çizgisi
HH(x)	x-günlük en yüksek fiyat
LL(x)	x-günlük en düşük fiyat

4.5 Getiri Oranının Hesaplanması

Elinizde tuttuğunuz bir hisse senedi fiyatının 100 TL den 105 TL ye yükseldiğini var sayarsak bu %5 lik bir getiri olarak ifade edilmektedir.

Getiri tanımını yapacak olursak: Getiriyi r_i olarak ifade edecek olursak, p_i . günün/saatin/30 dakikanın kapanış fiyatını göstermektedir 4.10.

$$r_{(i+1)} = \frac{p_{(i+1)} - p_i}{p_i} \quad (4.10)$$

4.6 Sınıf Etiketleme Kuralları

Bu çalışmada sınıf etiketlemesi, BIST 100 endeksinin işlem dönemlerinin kapanış fiyatlarına göre hesaplanan getirilere göre belirlenmiştir. r_i i-inci işlem döneminin getirisini ve $r_{(i+1)}$ bir sonraki işlem döneminin getirisini sembolize eder. İşlem dönemleri sırasıyla otuz dakika, bir saat ve iki saat olarak tanımlanmıştır. Ayrıca p_i i-inci işlem döneminin kapanış fiyatını ve $p_{(i+1)}$, denklem (4.10)'de kullanıldığı gibi bir sonraki işlem döneminin kapanış fiyatını belirtir.

Yükseliş yönündeki i-inci dönemin sınıf etiketi y_i^R denklem (4.11) ' de, düşüş yönündeki i-inci dönemin sınıf etiketi y_i^F de denklem (4.12) ' de gösterilmiştir.


$$y_i^R = \begin{cases} 1, & \text{If } r_{(i+1)} > r_{(i)} + \theta \\ 0, & \text{otherwise} \end{cases} \quad (4.11)$$

$$y_i^F = \begin{cases} 1, & \text{If } r_{(i+1)} < r_{(i)} - \theta \\ 0, & \text{otherwise} \end{cases} \quad (4.12)$$

Sınıf etiketleme denklemlerinde işlem maliyetlerini düzenlemek ve hedeflenen getirileri tanımlamak için θ eşik değeri kullanılır. İşlem maliyetleri ve borsa riski nedeniyle, yatırımcılar çok fazla işleme girmek istemiyorlar, en azından işlem maliyetlerinin karşılanması hedefleniyor. Getirinin işlem maliyetinden düşük olduğu işlemlerden kaçınabilmek ve sistemin başarısını tahmin performansına ve bileşik getiriye göre değerlendirebilmek için farklı eşik değerleri kullanılmaktadır. Eşik değerleri, getirilerin standart sapmasının önceden belirlenmiş değerlerle çarpılmasıyla elde edilmiştir. Önceden belirlenmiş değerler 0'dan başlar ve 0,5'e ulaşana kadar 0,1 oranında artar. Bu şekilde altı farklı eşik değeri kullanılmıştır.

4.7 Modelin Kârlılığı

Hisse senedi fiyatı yönünü tahmin etmenin nihai sonucu kârlılığı arttırmak olsa da, şu ana kadar tartışılan performans ölçütleri (maliyet tabanlı metrik hariç), bir ticaret sisteminin genel kârlılığına göre doğru sınıflandırmaya ve sınıflandırmaya dayanmayan sınıflandırıcıları değerlendirmektedir. Örnek olarak, bir sınıflandırıcı çok yüksek doğruluk, kappa, AUC vb. olabilir, ancak bu, kârlı bir ticaret stratejisine denk gelmeyebilir, çünkü bireysel işlemlerin kârlılığı çoğu zaman "doğru" olmaktan daha önemli olabilir; Örneğin 100 işlemin her biri için 0,50 TL kazanmak, 95 kez 0.05 TL kaybetmek ve daha sonra her 5 işlemde 12 şer TL kazanır kadar kârlı değildir.



Şekil 4.6 Varsayımsal örneğimiz için olası yönlü fiyat hareketleri - yukarı, aşağı veya değişiklik yok


Aynı şekilde modelin karlılığını değerlendirirken maliyetlerin de göz ardı edilmemesi gerekmektedir [180, 189, 190]. Örneğin, stokta iyi bir kazanç elde edilebilecek işleme girmekte geç kalınması fırsat maliyeti ile ilişkilendirilebilir. Bu yanlış bir ticaretin başlatılmasındaki ekstra bir maliyete de neden olabilir. Bir trading stratejisi büyük hareketleri kaçırmamaya yönelikse burda geri çağırma (recall) yüksek olacaktır ancak buna bağlı olarak da çok fazla işleme gireceğinde işlem maliyeti de artacak ve sonuçlarda hassasiyet (preccison) büyük olasılıkla düşük gözükcektir.

Sermaye piyasasında işlemlerin maliyet esaslı bir metriğe göre değerlendirilmesi birçok fayda sağlayabilir. Bunlardan biri, yanlış karar verme ile ilişkili maliyetin test verileri analiz edilerek değerlendirilebilmesidir. Örnek olarak sermaye piyasasında yapılan her işlem karşılığında komisyona ödenmesi gereken işlem maliyeti vardır. Bunun dışında işlem yapılırken yatırılan para başka fırsatlar için kullanılamamaktadır, tüm süreç ele alındığında fırsat maliyetlerinin doğru değerlendirilmesi gerektiği sonucuna varılmaktadır. Bunun devamında girilen her işlemde kâr elde edilemeyeceğinden tüm diğer maliyetler dâhil edilip kâr zarar analizinin düzgün yapılması gerekmektedir. Bir bireyin yada kurumun, alacağı karar doğrultusunda sermaye piyasasındaki herhangi bir enstrümanın fiyat yönünü tahmin etmeye çalıştığı örneği ele aldığımızda T zamanında, hisse senedi yukarı yönlü, aşağı yönlü hareket yapabilir yada fiyatta herhangi bir değişiklik olmayabilir; $t + n$ zamanında yön bilinmemektedir, bu Şekil 4.6'de bu durum ifade edilmiştir. $T + 1$ süresi için, yukarı yönlü tahmin için satın alma işlemine girmesi, aşağı yönlü hareket için de açığa satış işleminin yapılması anlamına gelecektir. Sınıflandırmadaki hatalar ekstra maliyetlere neden olacaktır. Yukarı yönlü hareket bekleyen bir firma, hamle beklentisiyle hisse senedini satın alır, ancak müteakip bir aşağı yönlü hareket fiyat değişikliğinden daha zararlı olur. Gerçek bir düşüş derhal bir ticaret kaybına yol

açacak, oysa fiyatta hiçbir değişiklik geçici bir fırsat maliyetiyle sonuçlanmayacak ve stok hala istenen yönde gitme potansiyeline sahip olacak. Ayrıca yanlış bir “değişiklik yok” tahmini, sadece bir fırsatın kaybedilmesine yol açacaktır, ancak bir firma değişmemiş bir piyasa beklentisiyle (değişiklik yok) ticaret yapamayacağı için gerçek para riske atılmayacaktır.

Şekil 4.7’de akademik literatürün çoğunda temsil edilen bir ticaret modelini temsil etmekte olup, burada sınıflandırıcı, ikinci bir kural setine geçirilen sonuçla piyasa fiyatındaki yukarı, aşağı veya hiç bir değişiklik tahminiyle veriler üzerine kurulmuştur. Bu kurallar, örneğin, “yukarı” bir tahminin, örneğin hisse senedi satın almak, daha fazla hisse satın almak veya daha önce kısaltılmış bir pozisyonu geri almak için eşit olması gerektiğinde yönlendirme sağlar. Yatırım yapılacak hisse senedi miktarı, alınacak risk miktarı, vb. gibi konular da kural listesinde yer almaktadır.

Bir modelin karlılığını göz önünde bulundurarak, literatür genellikle otomatik bir ticaret modelinin şeklini izler, yani “Model satın almayı söylediği zaman satın alın, ardından n dakika / saat / gün sayısından sonra satış yapın [191]” yada “Model satın almayı söylediği zaman satın alın, sonra pozisyonun % x kadar yukarı olması durumunda satılır veya n dakika / gün / saat sonra satılır [192–194].” Teixeira bireysel ticaret sırasında zararların belirli bir dolar miktarını geçmesini önleyen başka bir kural ekledi [195] (ticaret içerisinde “stop loss” olarak adlandırıldı).



Şekil 4.7 Sermaye piyasalarında algoritmik ticaret süreci

Bu çalışmanın amacı, kanıtlanmış kârlılığa sahip bir "kullanıma hazır" ticaret sistemi sağlamak değil, hiperparametrelerin optimizasyonu ile elde edilen derin öğrenme ve makine öğrenme yöntemleri ile sermaye piyasalarında ticaret kararlarına yardımcı olup olamayacağını ortaya koymaktır. Buna ek olarak, trading literatüründe ne kadar hisse senedi alacağınıza veya satılacağınıza, bir pozisyonda ne kadar paranın riske gireceğine, işlemlerin ne sıklıkla yapılacağına, ne zaman alınıp satılacağına dair birçok farklı kural vardır; Bu soruların her biri başlı başına araştırma konusudur. Uygulamada, trading sistemleri, genellikle birden çok risk yönetimi katmanı yoluyla filtrelenen tahmin ve optimizasyon metodolojileri gibi birçok kontrol katmanını içerir. Bunun dışında, olağandışı durumlarda sistemi devre dışı bırakmaya karar

verebilecek bir insan denetçisine / risk yöneticisine ihtiyaç duyar [196]. Bu nedenle bu tez çalışmasının odağı, sınıflandırıcının optimizasyonu ile kalacaktır; Farklı piyasa koşullarıyla karşılaşıldığında öngörülebilirliğin en üst düzeye çıkarılması hedeflenmektedir.

4.8 Tahmin Modellerinin Performans Ölçüm Metrikleri

Yatırımcıların her iki taraftan da kâr elde edebileceklerinden, borsa ister yukarı ister aşağı yönde hareket ediyor olsun, piyasa yönünü tahmin etmek aynı derecede önemlidir. Bu nedenle, endeks yükselişini ve endeks düşüşünü tahmin etmek ayrı olarak modellenmiştir. İlk modelde sistem, bir yükseliş olup olmayacağını tahmin etmek için eğitilir ve ikinci modelde sistem, bir düşüş olup olmayacağını tahmin etmek üzere eğitilir. İşlem maliyetleri sorununun üstesinden gelmek için işlem maliyetlerinden düşük olan küçük getirileri ortadan kaldırmamıza yardımcı olan dinamik bir eşik değişkeni kullandık. Sınıflandırıcıların öngörülebilirliğini ölçmek ve karşılaştırmak için değerlendirme metriklerine ihtiyaç vardır. Önerilen modellerin performansını ve sağlamlığını değerlendirmek için, doğruluk (accuracy), hassasiyet (precision) ve geri çağırma (recall) gibi karışıklık matrisinden türetilen performans metriklerini kullandık. Modelin performansını finansal getiri perspektifinden değerlendirmek için bileşik getiri ve yatırım getirisi metriklerini kullandık. Ayrıca, modelin yatırım riskini değerlendirmek için maksimum düşüş ölçümü kullanılmıştır.

4.8.1 Karışıklık Matrisi (Confusion Matrix)

Makine öğrenimi algoritmalarında, sınıflandırıcıların performans değerlendirmesi esas olarak karışıklık matrisi tarafından yapılır. Doğru ve yanlış tahminlerin sayısı, her bir sınıf tarafından ayrılan değerlerin sayılması ile özetlenir. Bir algoritmanın performansını ve sağlamlığını görselleştirmek için basit bir yol sağlar.

İşlem maliyetlerini kapsayan ve küçük getirileri ortadan kaldırmaya odaklanan kazançları tahmin etmeyi amaçladığımızdan, Denklem (4.11) ve (4.12)'de gösterildiği gibi eşik yapısını kullanıyoruz. Yukarı hareket tahminlerinin değerlendirilmesi için, karışıklık matrisi Tablo 4.9'te gösterilmiştir. Ayrıca aşağı doğru hareket tahminlerini değerlendirmek için karışıklık matrisi Tablo 4.10'te gösterilmiştir. Yukarı doğru hareket için, pozitif gözlem *Yükseliş* ve negatif gözlem *Yükseliş Yok*. Benzer şekilde, aşağı doğru hareket için, pozitif gözlem *Düşüş* ve negatif gözlem *Düşüş Yok*.

Önerilen modellerin performans ve sağlamlık değerlendirmeleri, karışıklık matrisinin bu dört değerine göre hesaplanır. Doğruluk, Hassasiyet, Geri Çağırma ve F-Skoru, bu değerlerden hesaplanan önemli ölçümler arasındadır.

Tablo 4.9 Yükseliş yönündeki karışıklık matrisi

Gerçek/Öngörülen	Yükseliş	Yükseliş Yok
Yükseliş	TP	FN
Yükseliş Yok	FP	TN

Tablo 4.10 Düşüş yönündeki karışıklık matrisi

Gerçek/Öngörülen	Düşüş	Düşüş Yok
Düşüş	TP	FN
Düşüş Yok	FP	TN

Doğruluk yüzdesi hesaplaması Denk. 4.13’de verilmiştir. Doğruluk gerçek işlemleri ölçtüğü ve veri setimiz dengesiz olduğu için sadece doğrulukla model değerlendirmesi yeterli olmayacaktır.

$$Accuracy\% = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (4.13)$$

Ticaret modelinde, Yanlış Pozitif (FP) aslında kâr için bir fırsat olmadığı anlamına gelir, ancak model ticarete girmeniz (alım veya satım) gerektiğini gösterir. Bu durumda, mümkün olan en kötü senaryodur ve sonuçta para kaybedersiniz. Bu nedenle, minimum FP’ye sahip bir model seçmek çok önemlidir. Bu, hassasiyeti en üst düzeye çıkararak elde edilebilir. Hassasiyet yüzdesinin hesaplanması Denklem 4.14’de gösterilmiştir.

$$Precision\% = \frac{TP}{TP + FP} \times 100 \quad (4.14)$$

Öte yandan, Yanlış Negatif (FN), ticaretten para kazanma fırsatı olmasına rağmen, modelin bunu belirtmediği anlamına gelir. Bu durumda, para kazanma fırsatı kaçmış olacak, ancak ticaretin pazarın her hareketini tahmin etme beklentisi olmadığı için büyük bir sorun olarak algılanmayacak. Geri çağırma maksimizasyonu FN minimizasyonunu gösterir. Geri çağırma hesaplamasının yüzdesi Denklem 4.15 ’de gösterilmiştir.

$$Recall\% = \frac{TP}{TP + FN} \times 100 \quad (4.15)$$

Son olarak, F-Skoru, kesinlik ve geri çağırma arasındaki ilişki için bilgiler sağlar. Kesinlik ve geri çağırma eşit olarak önceliklendirildiğinden, F1 Puanı F-score olarak

kullanılır. Denklem [1], F1 Puanının tanımını sağlar.

$$F1score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4.16)$$

4.8.2 Bileşik Getiri (Compound Return)

Tahminlerimizin getiri oranını doğru hesaplamak temel endişelerden biridir. Her işlemde, bir önceki işlemlerden elde edilen karları çıkarmadan yada zararları telafi etmeden işleme girileceği varsayılmaktadır. Bileşik getiri, bu amaca uygun en iyi ölçüm araçlarından biridir. Yüzde olarak gösterilen bileşik getirisi, ilk yatırımda bir süre boyunca sürekli olarak bir dizi kar veya zararın sonucunu gösterir.

Bir yatırımın belirli bir dönemdeki getirisinin performansını değerlendirirken, bir ölçüm aracı olarak ortalama getirinin bileşik getiri kadar uygun olmadığı bilinmektedir. Bunun nedeni, ortalama getiri kullanıldığında, getirilerin birbirinden bağımsız olması ve her bir getiri etkisinin bir sonraki adıma taşınamamasıdır, bu da modelin başarısını açıkça belirleyememesine neden olur. Ortalama getiri hesaplaması için ayrı getiri kullanılabilir. Ayrı getiri dönüşler Denklem (4.17)'de gösterildiği gibi hesaplanır, burada P_t t zamanında fiyatı ve P_{t+1} $t + 1$ zamanında fiyatı temsil eder.

$$PE_d(t, t + 1) = \frac{P_{t+1}}{P_t} - 1 \quad (4.17)$$

Ortalama getiri hesaplanırken, ayrı getiriler toplanır ve dönem sayısına bölünür. Birleştirilmiş çok dönemli performansın getirisi, yalnızca dönem getirileri katkıda bulunursa doğru olacaktır. Ayrı getiriler çarpımsal olduğundan, bu durumda uygun olmayacaktır. Böylece, doğru birleştirilmiş performans, Denklem (4.18) 'de gösterildiği gibi bileşik geri dönüş formülü kullanılarak hesaplanır [197].

$$PE_d(0, T) = \prod_0^{T-1} (1 + PE_d(t, t + 1)) - 1 \quad (4.18)$$


Her dönemin başında, eğitilmiş modeller ticarete girip girmeyeceğine karar verir. Eğer bir ticarete girerse, dönem sonunda ticaret kapanır. Her ticaret için ayrı getiri hesaplanır. Bu, saatlik bir zaman diliminde işlem görürse, saatin başında, modelin bir emir açılması gerekip gerekmediğine karar verir. Ve saatin sonunda model açık işlemleri kapatır.

4.8.3 Maximum Düşüm (Maximum Drawdown)

Yatırımın ana kaygıları sermaye koruması ve tutarlı tahminlerdir. Maksimum Düşüş (MDD) bir ticaret stratejisi için en önemli risk ölçümlerinden biri olduğundan, tahmin modelinin performansını değerlendirmede önemli bir rol oynar [198]. MDD değeri Denklem (4.19)'de gösterildiği gibi hesaplanır, burada P en büyük kayıptan önceki en yüksek kârı temsil eder ve L yeni kâr pik oluşmadan önce en düşük kayıp değerini temsil eder.

$$MDD = \frac{P - L}{P} \quad (4.19)$$

MDD, en yüksek sermaye seviyesi ile en düşük sermaye seviyesi arasındaki farkı ifade etmek için kullanılır. En yüksek sermaye seviyesi, en düşük sermaye seviyesinden önce gerçekleşmelidir. Maksimum düşüş süresi, tahmin modelinin sermaye kaybını geri kazanması için geçen en uzun süredir [199]. MDD yapısı Şekil 4.8'de gösterilmiştir. Bu çalışmada, düşüşler yüzde cinsinden ölçülmüştür.



Şekil 4.8 Maksimum düşüş yapısının grafiksel gösterimi

5 DENEYSEL SONUÇLAR

Arz ve talep, borsadaki herhangi bir enstrümanın fiyatını veya katılımcıların (yatırımcı ya da trader) ticaret yapma istekliliğini belirlemeye yardımcı olur. Alıcılar, karşılığında, genellikle satıcıların taleplerinden daha düşük olan, ödemek istedikleri maksimum bir tutar sunar. Bir ticaretin gerçekleşmesi için, alıcı fiyatı artırır veya satıcı fiyatı düşürür. Buna göre, eğer alım gerçekleşirse, fiyat artar ya da satış yapılırsa fiyat düşer. Bu, yatırımcıların kararının fiyat üzerinde doğrudan bir etkiye sahip olduğunu göstermektedir.

Buna göre bu çalışmada traderlerin davranışlarını modelleyerek teknik analize dayanan yöntemlerin gerçekten işe yarayıp yaramadığı ikilemine katkı sağlamış oluyoruz.

Daha önce de belirtildiği gibi, yatırımcıların karar vermede teknik analiz yöntemlerini kullandıklarını biliyoruz. Bu çalışmadaki ana fikir, piyasanın hareket yönü traderlerin aldıkları kararlara göre yaptıkları işlemler ile şekilleniyorsa [19] ve traderlerin büyük çoğunluğu da karar verme aşamasında bir şekilde teknik analiz yöntemlerini kullanıyorsa [25], derin öğrenme ve klasik makine öğrenmesi yöntemleri teknik analize göre eğitilip market yönünü tahmin edilmeye çalışırsak aslında traderlerin davranışlarını modellemiş oluyoruz.

Bu fikri güçlendirmek için, her şeyden önce, en iyi zaman çerçevelerini seçmek zorundaydık. Yüksek frekanslı ticaret (HFT) çalışmalarını [200] inceleyerek işe başladık. Bu çalışmalarda işlem süresi milisaniye ile saniyeler arasında değişiyordu ve piyasa yapımcıların bu stratejileri sıklıkla kullandıklarını gözlemledik. Uygun bir altyapımız olmadığından, bu yöntemlerin bizim için geçerli olmayacağına karar verdik çünkü bu dönemlerde yapılacak işlemler maliyetleri karşılamayacaktır.

Ayrıca derin öğrenme ve makine öğrenmesi yöntemlerinin başarıyla uygulandığı çalışmaları da araştırdık. Bu çalışmalarda genelde haftalık, aylık veya yıllık tahminler gibi daha geniş zaman dilimleri tahmin edilmeye çalışılmıştır [4]. Bu tür geniş zaman

aralıklarında örneklem büyüklüğü önemli ölçüde azaldığından kullanmak için uygun bulmadık. Böyle uzun ufuklar için tahmin yapmanın çok riskli olacağını düşünüyoruz.

Uzun bir literatür taramasından sonra günlük, haftalık veya aylık zaman periyotları yerine gün içi aralıklara odaklanmaya karar verdik. Kararımız, son çalışmaların büyük çoğunluğunun gün içi ticaret araştırmalarına odaklandığı gerçeğine dayanmaktadır. Ayrıca, kümülatif getirileri daha büyük zaman çerçevelerinden daha yüksektir. Bu gerçekler gün içi zaman periyotlarına odaklanılmasının ana nedenleridir. Buna ek olarak, daha az riskli olmak bizi gün içi endeks yönü tahminini incelemeye zorlayan bir diğer önemli faktördür.

Hazırlanan veri kümesine göre sınıflandırma tekniklerinin performansını karşılaştırmak için, üç farklı zaman diliminde dört farklı makine öğrenme yöntemi kullanılmış ve altı farklı eşik değeri üzerinde çift yönlü (alış / satış) işlemleri test edilmiş ve sonuçta toplam 144 sonuç elde edilmiştir. Endeksin yönünü tahmin etmek için gözetimli bir sınıflandırma modeli tasarlanırken ortaya çıkabilecek aşırı uygunluk (over-fitting) probleminden kaçınmak için, k değerinin on olarak ayarlandığı her yönteme k -kat çapraz doğrulaması uygulanır. Derin öğrenme ve makine öğrenimi yöntemlerine göre uygulanan stratejilerde her dönemde 48 farklı sonuç vardır. Elde edilen sonuçlarda, eşik değeri, sıfırdan başlayarak 0.5'e kadar, 0.1'lik kademeli artımlarla toplam altı farklı eşik değeri ile test edilmiştir.

BIST 100 endeks yönü tahmin performansının yukarı yönlü ayrıntılı değerlendirmesi Tablo 5.1, 5.2, 5.3; aşağı yönlü ayrıntılı değerlendirmesi de Tablo 5.4 , 5.5, 5.6' da listelenmiştir. Derin Sinir Ağları (DNN), Destek Vektör Makinesi (SVM), Rastgele Orman (RF) ve Lojistik Regresyonun (LR), örneklem dışı test seti üzerindeki karışıklık matris değerleri, doğruluk (*accuracy* – *acc.*%), hassasiyet (*precision* – *pre.*%), geri çağırma (*recall* – *rec.*%) ve F1-skor ($f1\%$) a göre öngörü performansı karşılaştırılmıştır. Ayrıca, performans değerlendirme metriklerine maksimum düşüş (*maxdrawdown* – *mdd.*%) ve bileşik getiri (*compoundreturn* – *cmp.*) eklenmiştir.

Trading modelinin tahminini değerlendirmek için sadece geleneksel makine öğrenmesi performans değerlendirme parametrelerini kullanmak yanıltıcı olabilir. Ticaret uygulamaları için, tahminlerde daha yüksek doğruluk her zaman daha yüksek kârlar anlamına gelmez. Herhangi bir işlem stratejisi sonuçta, bir dizi ardışık işlemdeki komisyonlar, spreadlar ve fişler ile ilişkili işlem maliyetlerinin üzerine çıkacak kadar yüksek değilse, strateji kâğıt üzerinde kârlı görünse bile para kaybedecektir. Belirli bir şekilde, kullanılan eşik değeri, işlem başına ortalama getiri, maksimum düşüş ve bileşik getiri gibi parametreler, bu tür bir çalışma için daha uygun değerlendirme yöntemleri olacaktır [39].

Tablo 5.1 Yukarı yönlü işlemlerin tahmin sonuçları - 30 dakikalık zaman periyodu

Eşik	Metrik	DNN	LOG	SVM	RND
0	pre. %	59.30	54.81	53.30	53.47
	rec. %	70.29	77.98	59.39	56.58
	acc. %	58.70	58.40	56.33	55.93
	f1 %	64.33	64.37	56.18	54.98
	ret. %	0.15	0.13	0.13	0.13
	mdd. %	2.60	3.44	4.47	6.04
	cmp.	3.34	3.43	1.98	1.76
0.1	pre. %	60.35	55.26	51.26	50.57
	rec. %	68.57	83.42	72.95	55.72
	acc. %	61.50	61.01	59.80	59.43
	f1 %	64.20	66.48	60.21	53.02
	ret. %	0.19	0.16	0.15	0.15
	mdd. %	2.58	1.87	3.79	2.74
	cmp.	2.35	2.28	2.09	2.07
0.2	pre. %	53.95	56.59	45.53	45.63
	rec. %	64.23	73.67	59.66	49.60
	acc. %	64.63	64.90	62.67	62.69
	f1 %	58.64	64.01	51.65	47.53
	ret. %	0.24	0.21	0.19	0.17
	mdd. %	2.58	1.95	2.90	2.67
	cmp.	1.65	1.56	1.86	1.70
0.3	pre. %	52.15	56.33	39.93	41.86
	rec. %	58.82	63.57	71.79	47.44
	acc. %	69.28	69.34	65.08	67.22
	f1 %	55.28	59.73	51.31	44.48
	ret. %	0.27	0.27	0.19	0.19
	mdd. %	2.58	1.35	4.33	1.58
	cmp.	1.37	1.20	1.66	1.53
0.4	pre. %	49.76	55.00	40.42	38.92
	rec. %	55.85	79.08	66.48	43.16
	acc. %	73.39	73.63	70.44	71.47
	f1 %	52.63	64.88	50.27	40.93
	ret. %	0.29	0.26	0.22	0.21
	mdd. %	2.58	2.10	2.95	4.18
	cmp.	1.21	1.25	1.91	1.31
0.5	pre. %	48.06	52.13	38.26	37.13
	rec. %	49.21	80.33	47.34	38.79
	acc. %	77.00	77.13	74.48	75.61
	f1 %	48.63	63.23	42.32	37.94
	ret. %	0.33	0.30	0.25	0.24
	mdd. %	2.69	2.10	3.67	2.09
	cmp.	1.12	1.24	1.61	1.31

Tablo 5.2 Yukarı yönlü işlemlerin tahmin sonuçları - saatlik zaman periyodu

Eşik	Metrik	DNN	LOG	SVM	RND
0	pre. %	54.76	52.26	58.52	48.27
	rec. %	67.43	86.01	47.02	49.77
	acc. %	57.02	57.87	58.37	56.00
	f1 %	60.44	65.01	52.15	49.01
	ret. %	0.20	0.20	0.20	0.19
	mdd. %	3.51	2.11	1.54	3.58
	cmp.	2.05	1.69	1.33	1.42
0.1	pre. %	62.22	64.04	68.33	44.55
	rec. %	72.80	56.44	33.61	49.51
	acc. %	60.75	62.70	62.64	59.60
	f1 %	67.10	60.00	45.05	46.90
	ret. %	0.26	0.24	0.23	0.22
	mdd. %	1.46	0.96	0.96	2.97
	cmp.	1.66	1.11	1.07	1.56
0.2	pre. %	57.38	60.99	60.00	43.91
	rec. %	69.44	83.50	11.88	44.93
	acc. %	64.07	67.26	66.74	64.70
	f1 %	62.84	70.49	19.83	44.42
	ret. %	0.29	0.27	0.24	0.24
	mdd. %	1.42	1.15	0.96	3.43
	cmp.	1.35	1.19	1.02	1.53
0.3	pre. %	57.06	60.58	54.55	39.76
	rec. %	64.74	78.75	12.50	41.62
	acc. %	68.40	71.56	71.15	68.84
	f1 %	60.66	68.48	20.34	40.67
	ret. %	0.34	0.28	0.23	0.26
	mdd. %	0.96	1.23	1.00	3.50
	cmp.	1.22	1.14	1.00	1.25
0.4	pre. %	59.02	58.82	57.14	40.28
	rec. %	63.72	58.82	5.63	41.29
	acc. %	72.77	75.60	75.51	73.64
	f1 %	61.28	58.82	10.26	40.78
	ret. %	0.35	0.36	0.23	0.29
	mdd. %	1.23	1.04	0.94	3.57
	cmp.	1.07	1.06	1.00	1.33
0.5	pre. %	52.78	51.28	33.33	34.69
	rec. %	55.07	60.61	1.89	39.14
	acc. %	76.00	78.53	78.49	76.49
	f1 %	53.90	55.56	3.57	36.79
	ret. %	0.40	0.38	0.23	0.36
	mdd. %	1.59	1.09	0.90	3.03
	cmp.	1.05	1.06	1.01	1.24

Tablo 5.3 Yukarı yönlü işlemlerin tahmin sonuçları - iki saatlik zaman periyodu

Eşik	Metrik	DNN	LOG	SVM	RND
0	pre. %	51.93	51.40	50.56	51.45
	rec. %	73.53	70.23	53.67	56.98
	acc. %	52.42	51.81	50.34	50.94
	f1 %	60.88	59.35	52.07	54.08
	ret. %	0.22	0.22	0.22	0.22
	mdd. %	7.93	7.95	8.09	11.77
	cmp.	1.22	1.22	1.02	1.18
0.1	pre. %	46.33	51.56	45.11	46.34
	rec. %	38.61	77.94	49.10	54.02
	acc. %	54.49	56.30	50.64	52.72
	f1 %	42.12	62.06	47.02	49.89
	ret. %	0.37	0.26	0.26	0.24
	mdd. %	4.35	5.15	6.74	5.20
	cmp.	1.12	1.41	1.20	1.13
0.2	pre. %	52.42	51.67	38.74	41.63
	rec. %	34.57	75.00	40.45	47.18
	acc. %	62.19	62.23	52.94	57.40
	f1 %	41.67	61.19	39.58	44.23
	ret. %	0.45	0.39	0.29	0.28
	mdd. %	2.79	5.27	7.82	4.51
	cmp.	1.13	1.18	1.07	1.15
0.3	pre. %	61.54	49.02	32.75	36.08
	rec. %	17.78	58.14	51.98	44.07
	acc. %	67.55	67.40	55.43	62.45
	f1 %	27.59	53.19	40.19	39.68
	ret. %	0.62	0.60	0.32	0.34
	mdd. %	0.82	4.00	8.59	5.82
	cmp.	1.04	1.05	1.01	1.12
0.4	pre. %	64.29	42.11	29.02	30.48
	rec. %	69.23	44.44	33.59	36.64
	acc. %	71.77	71.51	57.55	66.45
	f1 %	66.67	43.24	31.14	33.28
	ret. %	0.52	0.55	0.35	0.38
	mdd. %	0.61	1.81	9.87	7.63
	cmp.	1.04	1.00	1.12	1.08
0.5	pre. %	50.00	40.00	24.00	31.91
	rec. %	66.67	40.00	26.80	35.55
	acc. %	75.70	75.62	62.94	72.49
	f1 %	57.14	40.00	25.32	33.63
	ret. %	0.53	0.74	0.39	0.43
	mdd. %	0.43	1.15	10.83	1.77
	cmp.	1.02	1.01	1.05	1.13

Tablo 5.4 Aşağı yönlü işlemlerin tahmin sonuçları - 30 dakikalık zaman periyodu

Eşik	Metrik	DNN	LOG	SVM	RND
0	pre. %	61.05	60.47	53.98	55.84
	rec. %	49.11	34.38	47.79	52.72
	acc. %	57.51	57.69	56.18	57.12
	f1 %	54.44	43.84	50.69	54.24
	ret. %	0.19	0.18	0.14	0.14
	mdd. %	2.04	2.47	1.90	2.40
	cmp.	3.77	3.35	2.59	2.54
0.1	pre. %	61.18	61.12	53.39	51.00
	rec. %	52.37	27.84	30.89	45.82
	acc. %	61.14	60.44	60.04	59.73
	f1 %	56.43	38.26	39.14	48.27
	ret. %	0.26	0.24	0.17	0.16
	mdd. %	1.64	2.58	1.83	2.66
	cmp.	2.39	1.73	1.56	2.13
0.2	pre. %	58.80	59.33	49.23	46.15
	rec. %	48.22	40.46	35.41	42.24
	acc. %	64.91	64.67	63.99	63.03
	f1 %	52.99	48.11	41.19	44.11
	ret. %	0.30	0.29	0.20	0.19
	mdd. %	1.75	1.35	2.46	2.07
	cmp.	1.72	1.44	1.54	1.80
0.3	pre. %	56.25	59.20	51.36	45.36
	rec. %	49.51	51.75	21.62	39.84
	acc. %	69.12	69.01	68.95	67.84
	f1 %	52.67	55.22	30.43	42.42
	ret. %	0.37	0.33	0.23	0.21
	mdd. %	1.64	1.19	1.17	2.14
	cmp.	1.46	1.24	1.58	1.60
0.4	pre. %	56.08	57.89	45.97	41.77
	rec. %	50.00	30.77	22.54	37.58
	acc. %	73.25	73.14	72.54	71.75
	f1 %	52.87	40.18	30.25	39.56
	ret. %	0.38	0.35	0.25	0.24
	mdd. %	1.10	1.19	1.76	2.13
	cmp.	1.38	1.12	1.47	1.47
0.5	pre. %	55.24	60.00	33.93	39.38
	rec. %	54.11	28.57	26.14	37.71
	acc. %	76.96	76.92	74.54	75.65
	f1 %	54.67	38.71	29.53	38.53
	ret. %	0.43	0.40	0.26	0.28
	mdd. %	1.10	0.50	1.66	1.80
	cmp.	1.33	1.14	1.29	1.41

Tablo 5.5 Aşağı yönlü işlemlerin tahmin sonuçları - saatlik zaman periyodu

Eşik	Metrik	DNN	LOG	SVM	RND
0	pre. %	62.53	61.97	50.09	49.60
	rec. %	49.38	22.49	61.47	48.10
	acc. %	57.64	58.37	57.40	57.15
	f1 %	55.18	33.00	55.20	48.84
	ret. %	0.31	0.30	0.29	0.20
	mdd. %	1.97	1.26	3.18	3.35
	cmp.	2.51	1.32	1.53	1.72
0.1	pre. %	65.04	63.03	52.91	46.66
	rec. %	53.38	70.09	82.73	41.75
	acc. %	61.58	62.74	62.33	60.77
	f1 %	58.63	66.37	64.54	44.07
	ret. %	0.39	0.40	0.36	0.23
	mdd. %	1.26	0.84	1.80	2.29
	cmp.	1.83	1.28	1.22	1.62
0.2	pre. %	63.68	66.00	51.10	42.11
	rec. %	50.94	37.50	92.08	41.10
	acc. %	65.27	66.82	66.59	64.14
	f1 %	56.60	47.83	65.72	41.60
	ret. %	0.51	0.50	0.39	0.26
	mdd. %	0.73	0.71	1.75	2.43
	cmp.	1.55	1.16	1.28	1.50
0.3	pre. %	63.33	54.05	52.81	39.89
	rec. %	55.56	32.79	90.38	38.05
	acc. %	69.60	70.88	70.92	68.73
	f1 %	59.19	40.82	66.67	38.95
	ret. %	0.57	0.55	0.49	0.31
	mdd. %	1.24	0.74	0.89	3.35
	cmp.	1.38	1.10	1.19	1.46
0.4	pre. %	59.41	57.58	47.24	38.48
	rec. %	54.55	57.58	95.24	37.50
	acc. %	73.58	75.00	74.77	72.87
	f1 %	56.87	57.58	63.16	37.98
	ret. %	0.56	0.59	0.46	0.33
	mdd. %	1.24	0.71	1.38	1.26
	cmp.	1.32	1.11	1.21	1.41
0.5	pre. %	61.25	50.00	48.00	40.71
	rec. %	59.04	40.63	96.00	36.18
	acc. %	77.17	78.47	78.39	77.35
	f1 %	60.12	44.83	64.00	38.31
	ret. %	0.62	0.60	0.53	0.39
	mdd. %	1.24	0.71	0.97	2.47
	cmp.	1.26	1.07	1.20	1.41

Tablo 5.6 Aşağı yönlü işlemlerin tahmin sonuçları - iki saatlik zaman periyodu

Eşik	Metrik	DNN	LOG	SVM	RND
0	pre. %	53.52	53.62	49.92	50.17
	rec. %	30.93	34.14	46.81	44.62
	acc. %	53.43	54.00	51.40	51.58
	f1 %	39.21	41.72	48.32	47.23
	ret. %	0.24	0.24	0.23	0.23
	mdd. %	3.87	4.07	8.08	4.85
	cmp.	1.31	1.38	1.19	1.12
0.1	pre. %	47.51	53.96	42.26	46.24
	rec. %	55.40	26.09	38.41	38.74
	acc. %	56.83	58.42	51.62	55.66
	f1 %	51.15	35.18	40.24	42.16
	ret. %	0.32	0.28	0.27	0.27
	mdd. %	4.23	2.87	6.29	5.72
	cmp.	1.20	1.20	1.09	1.15
0.2	pre. %	45.81	58.62	37.69	38.62
	rec. %	63.80	33.55	36.02	33.44
	acc. %	62.72	64.00	54.42	58.72
	f1 %	53.33	42.68	36.84	35.84
	ret. %	0.41	0.31	0.30	0.30
	mdd. %	3.03	1.79	6.15	4.31
	cmp.	1.13	1.14	1.13	1.12
0.3	pre. %	40.32	50.00	35.86	32.40
	rec. %	83.33	40.91	20.10	25.55
	acc. %	67.74	68.19	63.55	63.92
	f1 %	54.35	45.00	25.76	28.57
	ret. %	0.50	0.51	0.34	0.35
	mdd. %	1.14	1.04	3.18	7.89
	cmp.	1.07	1.07	1.17	1.02
0.4	pre. %	75.00	56.52	30.42	31.73
	rec. %	70.59	54.17	26.11	26.06
	acc. %	72.15	71.96	61.02	68.11
	f1 %	72.73	55.32	28.10	28.62
	ret. %	0.54	0.52	0.37	0.40
	mdd. %	0.28	1.07	4.24	4.40
	cmp.	1.06	1.06	1.24	1.07
0.5	pre. %	83.33	60.00	26.93	26.09
	rec. %	71.43	60.00	24.12	23.08
	acc. %	76.23	76.04	65.77	72.60
	f1 %	76.92	60.00	25.45	24.49
	ret. %	0.58	0.51	0.40	0.41
	mdd. %	0.06	0.76	3.96	3.36
	cmp.	1.05	1.05	1.19	1.02

Bu çalışmadaki ana hedefimiz, BIST 100 endeksini derin öğrenme ve makine öğrenimi sınıflandırma yaklaşımlarını kullanarak tutarlı bir şekilde tahmin etmenin mümkün olup olmadığını araştırmaktır. Finansal piyasalardaki kararları desteklemek için sonuçlar “Al ve Beklet” stratejisiyle karşılaştırılmıştır. Test periyodunda BIST 100 endeksindeki “Al ve Beklet” stratejisinin ortalama getirisi % 15 olduğundan, hem DNN’nin hem de diğer yöntemlerin bileşik getirisi “Al ve Beklet” den daha iyi performans gösterdiği görülmüştür.


Yukarı yönlü işlem tahmin sonuçlarını gösteren Tablo 5.1, Tablo 5.2, Tablo 5.3 ve aşağı yönlü işlem tahmin sonuçlarını gösteren Tablo 5.4, Tablo 5.5, Tablo 5.6’den, ortalama 10 kat çapraz validasyon ile elde edilen sonuçların, doğruluk ve bileşik geri dönüşü arasındaki ters korelasyonu gösterdiği belirtilebilir. Örneğin, DNN için 0 ila 0.5 arasında değişen eşik değerleri göz önüne alındığında Tablo 5.1’de, kesinlik ve bileşik geri dönüşünün (cmp.) 60’dan 48’e ve 3.34’den 1.12’ye düştüğü, doğruluk ve ortalama getirinin (ret.) ticaret başına sırasıyla 58’den 77’ye ve 0.15’den 0.33’e yükselir. Ek olarak, zaman periyodu 30 dakikadan 2 saate yükseltilerek bileşik geri dönüşü azalır. Doğruluktaki artışın ve bileşik getirideki azalmanın nedeni, eşik değerini artırarak riski en aza indirmeyi ve ticaret başına getiriyi en üst düzeye çıkarmayı hedeflememizdir. Sonuçlar, işlem sayısını en aza indirme ve ticaret başına getiriyi artırma hedefimize ulaştığımızı göstermektedir. Daha büyük getirileri hedefleyerek, işlem sayısını azaltır ve daha küçük getirileri ortadan kaldırırız, bu da bileşik getirinin azalmasına neden olur. Doğru tahmin sayısı artıyor ve doğruluk da artıyor. İşlem sayısını sınırladığımız için geri çağırma (rec.) azalır.

Benzer sonuçlar aşağı yönünün tahmin edildiği Tablo 5.4’de görülebilir. Beklendiği gibi, DNN daha fazla kayıt olan daha küçük zaman periyotlarında daha iyi performans gösterir. Örneklerin sayısı azalmakla DNN performansı düşer. Öte yandan, Random Forest ve SVM performansı artar. *Eşik değeri* ve *zaman periyodu* yapıları, yatırımcıların, alınan riskin potansiyel kazanca değip değmeyeceğine, karar verme riskine karşı potansiyel ödülü tartmalarını sağlar.


Fiyat artışını tahmin etmek için elde edilen sonuçlar Tablo 5.1’de verilmektedir. Tüm modeller, her bir eşik değerine karşılık gelen test sonuçlarına göre karşılaştırılmıştır. Tablo 5.1’den, minimum düşüş ve maksimum hassasiyetle en yüksek bileşik getirinin DNN modeli ile elde edilebileceği sonucuna varılabilir.

Riski en aza indirmek için yatırımcılar portföylerini çeşitlendirmeyi hedeflemektedir. Birçok bireysel hisse senedi satın almadan bunu sağlayabilmek için endeks fonlarına yatırım yapıyorlar. Ancak finansal sistem düzensiz davranışlardan ve yüksek oynaklıktan muzdarip olduğunda endekse yatırım bile yatırımcılara bir kayıp olarak

yansır. Şekil 5.1 ve Şekil 5.2, endeks iyi performans gösterdiğinde ve kayba neden olduğunda, farklı zaman aralıklarında DNN modellerimizle BIST 100 endeks getirisini karşılaştırmaktadır.



Şekil 5.1 BIST 100 endeksinin en kârlı dönemlerinden birinin 30 dakikalık DNN getirisiyle karşılaştırılması.



Şekil 5.2 BIST 100 endeksinin en kötü dönemlerinden birinin 30 dakikalık DNN getirisiyle karşılaştırılması.

2009, veri setimizdeki BIST 100 endeksinin en kârlı dönemlerinden biridir. Şekil 5.1'de DNN modelinin sonuçları bu dönemin BIST 100 endeks getirisi ile karşılaştırılmıştır. Ayrıca, Şekil 5.2'de, DNN modelinin sonuçları 2016'da zarar gören

Tablo 5.7 Yukarı yönlü işlemlerin tahmin sonuçları

Eşik	Doğru İşlem	Doğru Ort.	Hatalı işlem	Hatalı Ort.	Ort. Fark %
0	727	0.00185	542	-0.00117	0.58351
0.1	338	0.00231	267	-0.00115	1.00678
0.2	180	0.00270	163	-0.00121	1.23105
0.3	106	0.00305	104	-0.00142	1.15288
0.4	65	0.00345	70	-0.00155	1.22519
0.5	44	0.00377	53	-0.00198	0.90413

Tablo 5.8 Aşağı yönlü işlemlerin tahmin sonuçları

Eşik	Doğru İşlem	Doğru Ort.	Hatalı işlem	Hatalı Ort.	Ort. Fark %
0	524	-0.00233	393	0.00106	1.18654
0.1	267	-0.00292	213	0.00098	1.99290
0.2	150	-0.00354	131	0.00093	2.80590
0.3	95	-0.00409	88	0.00088	3.64201
0.4	68	-0.00469	67	0.00085	4.53878
0.5	50	-0.00529	52	0.00081	5.56999

BIST 100 endeksi ile karşılaştırılmıştır. Her iki sonuçtan da görülebileceği gibi, çeşitlendirilmiş bir portföy elde etmek için Endekse yatırım yapmak bile kayıplara yol açabilir. Önerilen derin öğrenme ve makine öğrenmesi modellerine göre yatırım yaparak daha istikrarlı bir yatırım aracı elde edilebilir. İyi veya kötü performans gösteren endeksten bağımsız olarak, önerilen modelle eş zamanlı olarak bileşik getiri artarken riskler en aza indirilebilir.

Derin Öğrenme ve Makine Öğrenmesi yöntemleriyle BIST 100 endeksinin yönünü tahmin ederken, gerçek-pozitif işlemlerin kazançlarının yanlış-pozitif işlemlerin kayıplarından çok daha yüksek olduğunu fark ettik. Test sonuçlarımızın doğruluğu ve hassasiyeti % 60'a yakındır, bu da doğruluk ve hassasiyet % 50 seviyesine yakın olsa bile, gerçek pozitif işlemlerden elde edilen kazançlar yanlışlardan kaynaklanan kayıplardan daha büyük olduğu için sistem kârlı olacaktır anlamına gelmektedir. Bunla ilgili elde edilen sonuçların yukarı yönlü işlem tahminleri Tablo 5.7'de, aşağı yönlü işlem tahminlerinin sonuçları da Tablo 5.8'de gösterilmiştir. Doğru yöndeki işlem sayısı *Doğru İşlem* kolonunda, doğru işlemlerin ortalama getirisi *Doğru Ort.* kolonunda, hatalı işlem sayısı *Hatalı işlem* kolonunda, hatalı işlemlerden kaynaklanan zararın işlem başına ortalaması *Hatalı Ort.* kolonunda ve olumlu işlemlerin işlem başına düşen getiri ortalaması ile hatalı işlemlerin işlem başına düşen zararın götürüsü arasındaki fark ta *Ort. Fark %* kolonunda gösterilmiştir.

Derin öğrenme ve makine öğreniminin uygulandığı çalışmaların çoğunda, işlem başına ortalama getiri değerlendirilmemiştir [16, 39, 188]. Ayrıca sonuçlarında kümülatif

getirileri değerlendiren çok fazla çalışma da yoktur [4]. Bunun dışında işlem başına ortalama getirinin karşılaştırıldığı herhangi bir çalışma bulamadık.

Yukarı yönlü işlem tahminlerinin eşik değerine göre doğru ve yanlış işlem sayıları ve doğru ve yanlış işlemlerin ortalama getirileri Tablo 5.7 gösterilmiştir. Görüldüğü üzere eşik (*Eşik*) değeri artarken işlem sayısı (*Doğru İşlem ve Hatalı işlem*) azalmaktadır, buna karşın doğru yöndeki işlemlerin ortalama getirileri (*Doğru Ort.*) artmaktadır. Tüm eşik değerleri için olumlu işlemlerin ortalama getirileri olumsuz işlemlerin ortalama götürülerinden daha büyük olduğu görülmektedir. Benzer şekilde aşağı yönlü işlem tahminlerinin eşik değerine göre doğru ve yanlış işlem sayıları ve doğru ve yanlış işlemlerin ortalama getirileri Tablo 5.8 gösterilmiştir. Aşağı yönlü işlemlerin tahmininde de eşik değeri artarken işlem sayısı azalmaktadır, buna karşın doğru yöndeki işlemlerin ortalama getirileri aşağı yönlü olduğu için ters yönlü artmaktadır. Tablo 5.1 ve Tablo 5.4'den görülebileceği gibi getiri yüzdesini (% ret) ifade eden satır pozitifdir ve eşik değeri ve zaman periyodu arttıkça artar. 30 dakikalık zaman periodunu ifade eden Tablo 5.1'da eşik değeri 0 olduğunda getiri yüzdesi 0,15 iken iki saatlik zaman periyodu ifade eden Tablo 5.3'da ve eşik değeri 0,5 olduğunda getiri yüzdesi 0,74'e yükselir. Benzer şekilde 30 dakikalık zaman periodunu ifade eden Tablo 5.4'da eşik değeri 0 olduğunda getiri yüzdesi 0,19 iken iki saatlik zaman periyodu ifade eden Tablo 5.6'da ve eşik değeri 0,5 olduğunda getiri yüzdesi 0,58'e yükselir.

Sonuçlara göre, DNN'nin işlem başına daha yüksek ortalama getiriye sahip olduğunu gözlemliyoruz. Doğru kararlardan elde edilen kâr, yanlış kararlardan kaynaklanan kayıptan daha fazladır ve bu da daha yüksek bileşik getiri ile sonuçlanır. Para yönetiminin temel amacı, yanlış kararlardan kaynaklanan kayıplara kıyasla doğru kararlardan daha fazla kâr elde etmektir. Soros Kuantum Fonu müdürü Druckenmiller'in Şekil 5.2'deki alıntısında ifade ettiği gibi, "George Soros'tan [201] birçok şey öğrendim, ama belki de en önemlisi, doğru ya da yanlış karar vermiş olman çok da önemli değildir; önemli olan doğru karar verdiğinde ne kadar para kazandığın, hatalı karar verdiğinde de ne kadar zarar ettiğindir" [202]. Sonuçlarımızdan, BIST 100 yönünü tahmin etmek için derin öğrenme ve makine öğrenmesi yöntemleri uygulayarak doğru yönde olma kârının yanlış yönde olma kayıplarından daha büyük olacağını çıkarımına varabiliriz.

Sonuçlardan, daha küçük zaman periyotlarında bileşik getirinin (*cmp.*) daha büyük ve maksimum düşüşün (*maxdrawdown – mdd.*%) daha düşük olduğunu görebiliriz. Bu nedenle, daha küçük zaman periyotları kullanarak daha düşük risk alıp kârı artırabiliriz. Tahmin performansını ve farklı zaman aralıklarında bileşik getirileri karşılaştırmak için üç farklı zaman aralığı kullanılmıştır. Zaman dilimi seçimi, farklı değerler denenerek optimize edilebilir, ancak zaman dilimi optimizasyonu bu

“

"I've learned many things from him [George Soros], but perhaps the most significant is that it's not whether you're right or wrong that's important, but how much money you make when you're right and how much you lose when you're wrong." – Stanley Druckenmiller

”

Şekil 5.3 Druckenmiller'den alıntı.

çalışmanın ana odağı değildir. Sonuçlarımızdan, zaman aralığı seçimini optimize ederek bileşik getirinin artabileceğini ve maksimum düşüşün azaltılabileceğini gözlemleyebilmekteyiz.

Elde edilen sonuçlardan yapılabilecek en önemli çıkarımlarından biri, Derin Öğrenme ve Makine Öğrenmesi yöntemlerinin piyasa yönünü tahmin etmede kullanıldığında başarılı sonuçlar elde edilebileceğini göstermesidir. Ayrıca sonuçlarımız büyük fonların ve finans alanındaki uzmanların finansal piyasaları tahmin etmek için Derin Öğrenme ve Makine Öğrenimi yöntemlerini kullanmaya ve incelemeye neden bu kadar çok yönediklerini nedenini ortaya koymaktadır [203].

5.1 Deneysel Sonuçlardan Çıkarımlar

Elde edilen sonuçları özetlemek gerekirse, geleneksel makine öğrenmesi teknikleri tahmin analizinde hala tercih edilen yöntemler olmasına rağmen, son araştırmalar bu yöntemlerin karmaşık, doğrusal olmayan problemlerde derin öğrenme yöntemleri kadar iyi performans sağlayamadığını göstermektedir. Buna göre, bu deneyler Derin Öğrenme algoritmasının dolaylı olarak bilginin uygun bir temsiliyi üretme kapasitesine sahip olduğunu göstermektedir.

Karışıklık matrisine göre DNN modeli, bileşik getiri, maksimum düşüş ve hassasiyete göre diğer modellerden önemli ölçüde daha iyi performans gösterse de, gözlemlenen herhangi bir farkın istatistiksel olarak anlamlı olup olmadığını belirlemeyi amaçladık. Modellerin istatistiksel önemini karşılaştırmak için McNemar testi kullanılır, burada her iki modelin yaptığı hataları yakalar [204]. Null hipotez, sınıflandırıcıların test setinde benzer hata oranlarına sahip olduğu ifadesidir. McNemar testinde p değeri sadece DNN - RF karşılaştırmasında verilen bir eşğin (0.05) altındadır. P-değeri 0.048 olduğu için sıfır hipotezini reddedebilir ve DNN ve RF sınıflandırıcılar arasındaki farkın istatistiksel olarak anlamlı olduğunu belirleyebiliriz. Ancak, istatistiksel olarak anlamlı olmak, ticaret modelinin başarılı olacağı anlamına gelmez, çünkü büyük bir kayıp

birden fazla kazanca neden olacaktır. Bu nedenle model değerlendirmede işlem başına getiri göz önünde bulundurulmalıdır.

Endeks yönü tahmini ile ilgili sonuçlarımız, Derin Öğrenme ile klasik Makine Öğrenimi yöntemlerinden daha iyi sonuçların elde edildiğini göstermektedir. Bununla birlikte, derin öğrenme modellerinin karmaşık mimarisi göz önünde bulundurulmalıdır. Tensorflow ve Keras gibi gelişmiş kütüphaneler kullanılsa bile, bu modelleri verimli bir şekilde kullanmak için kapsamlı bir anlayışa ve sağlam deneylere ihtiyaç vardır.

6 SONUÇ VE ÖNERİLER

Son eğilimler, hem profesyonel hem de bireysel yatırımcıların teknik göstergeleri kullandığını ortaya koyarak, teknik göstergelere dayanan model çalışmalarında artışa neden olmuştur. Çoğu insanın yatırımlarını teknik göstergelere göre yaptığını varsayarsak, teknik göstergelerin aslında yatırımcıların davranışlarını gösterdiğini doğrulayabiliriz. Bu doğrultuda, BIST 100 endeks verilerine uygulanan teknik göstergeler, Derin Öğrenme ve Makine Öğrenim Yöntemleri kullanılarak Trader davranışının modellenmesinde girdi olarak kullanılmıştır.

Test sonuçlarından çıkarılabileceği gibi, bu çalışmanın ana katkısı, OHLC fiyatları ve işlem maliyetleri göz önüne alınarak geliştirilen derin öğrenme modeli ile piyasada olumsuz haberler ve endeks kaybı olsa bile yatırımcıların kar elde etmelerine olanak sağlayabilecek bir yöntem sunmaktır.

Bu çalışmada, farklı eşik değerleri kullanarak gün içi dönemlerde BIST 100 endeksinin yönünü öngörmeye Derin Sinir Ağları, Destek Vektör Makinesi, Rastgele Orman ve Lojistik Regresyon ile karşılaştırılmıştır. Bu modellerin sağlamlığını ve performansını test etmek için, bu makine öğrenmesi yöntemleri üzerinde üç farklı zaman diliminde ampirik çalışmalar yapılmıştır. İki yönlü (alım / satım) işlemleri altı farklı eşik değeri üzerinde test edildi ve bu da toplam 144 farklı yöntemle sonuçlandı. Aşırı uydurma problemini önlemek için, k değerinin on olarak ayarlandığı her yöne k -kat çapraz doğrulaması uygulanır. Doğruluk, kesinlik, geri çağırma, F1score, bileşik getiri ve maksimum düşüş gibi metrikler, bu modellerin yön tahminindeki performansını değerlendirmek için kullanılmıştır.

Ampirik bulgular, önerilen DNN modelinin bileşik getiri, ticari işlem başına ortalama getiri ve maksimum düşüş temelinde değerlendirildiğinde daha düşük eşik değerleri ve daha küçük zaman periyotları üzerindeki üstünlüğünü göstermektedir. Eşik değeri arttıkça, DNN modelinin diğer makine öğrenme yöntemlerine göre üstünlüğü azalır. Ayrıca DNN ve makine öğrenmesi yöntemlerini kullanarak, gerçek pozitif işlem sayısının yanlış pozitif işlemlerden daha yüksek olduğu bir model elde edebiliriz.

Aynı zamanda, gerçek pozitif emirlerin işlem başına ortalama getirileri, yanlış pozitif emirlerin işlem başına ortalama kayıplarından daha yüksektir.

Bu çalışmadan elde edilen sonuçlara göre modelin karışıklık matrisine göre hassasiyeti yüzde 60'a yakın bir değer olup modeli kullanmanın sonucu karlı olacaktır. Elde edilen sonuçların pratikte bir borsa simsarı için ne anlama geldiği düşünülürse. Model tarafından önerilen on işlemten altısı doğru yönde olacak ve bu işlemlerin getirisi hatalı işlemlerin zararından daha yüksek olacaktır. Yatırım sabit ise, seçilen eşik değerine bağlı olarak, model doğru işlemlerden 100 TL kazanırsa, hatalı olanlardan 75 TL zarar eder. Buna göre, model ortalama 600 TL ($6 * 100$) kar ve 300 TL ($4 * 75$) zarar edecektir. Toplamda yaklaşık 300 TL kar elde edilecektir.

Elde edilen sonuçlar araştırma sırasında kullanılan veri setine aittir ve ortaya çıkan potansiyel de bu dönem için geçerlidir. Yapılan araştırmalar bu dönemdeki piyasa dinamikleriyle de ilgilidir. Bilindiği üzere piyasa dinamikleri birçok farklı nedenden dolayı zamanla değişmektedir. Eğitilen modellerde pazar dinamiklerinin değişebileceği düşünülerek, modeller belirli aralıklarla yeniden eğitilip dinamik değişimin etkilerini en aza indirmeye özen gösterilmelidir. Elde edilen sonuçlar ve ortaya çıkan potansiyel bu dönem için geçerli olmakla birlikte, aynı yöntem ve eğitim modellerinin kullanılması halinde farklı pazar dinamikleri ve farklı dönemler için benzer potansiyellerin ortaya çıkması beklenmektedir.

Bu çalışmanın devamında yapılabilecek ve bu çalışmanın performansını iyileştirebilecek iki potansiyel çalışma ile devam edilebileceğini düşünmekteyiz. Bunlardan biri, modellerin eğitilmesi için kullanılan öznitelik vektörlerinin seçiminde derin öğrenme yöntemlerinden faydalanılmasıdır. Derin öğrenme çok farklı problemlerde çok iyi sonuçlar verdiği için öznitelik seçim problemini ayrı bir problem olarak ele alıp sadece o adımın iyileştirilmesi için derinlemesine çalışmalar yapılabileceğini düşünmekteyiz. İkinci iyileştirme de zaman periyodlarının seçilmesi ile ilgili daha detaylı bir çalışmanın yapılabileceğini düşünmekteyiz. Bu çalışmada kullanılan üç zaman periyoduna ek olarak daha fazla zaman periyodu kullanıp elde edilen sonuçlar da grid search e göre taranıp maksimum getiri ve minimum risk hedeflenip yapılabilecek yatırımların daha detaylı incelenebilmesine olanak sağlamaktır.

- [1] L. Di Persio O. Honchar, “Artificial neural networks architectures for stock price prediction: Comparisons and applications,” vol. 10, pp. 403–413, Jan. 2016.
- [2] C. S. Vui, G. K. Soon, C. K. On, R. Alfred, P. Anthony, “A review of stock market prediction with artificial neural network (ann),” *2013 IEEE International Conference on Control System, Computing and Engineering*, 2013. DOI: 10.1109/iccsce.2013.6720012.
- [3] E. Bastı, C. Kuzey, D. Delen, “Analyzing initial public offerings short-term performance using decision trees and svms,” *Decision Support Systems*, vol. 73, pp. 15–27, 2015. DOI: 10.1016/j.dss.2015.02.011.
- [4] M. Ballings, D. V. D. Poel, N. Hespeels, R. Gryp, “Evaluating multiple classifiers for stock price direction prediction,” *Expert Systems with Applications*, vol. 42, no. 20, pp. 7046–7056, 2015. DOI: 10.1016/j.eswa.2015.05.013.
- [5] A. Dutta, G. Bandopadhyay, S. Sengupta, “Prediction of stock performance in the indian stock market using logistic regression,” *International Journal of Business and Information*, vol. 7, no. 1, Jun. 2012.
- [6] A. Shihavuddin, M. N. Ambia, M. M. N. Arefin, M. Hossain, A. Anwar, “Prediction of stock price analyzing the online financial news using naive bayes classifier and local economic trends,” *2010 3rd International Conference on Advanced Computer Theory and Engineering (ICACTE)*, 2010. DOI: 10.1109/icacte.2010.5579624.
- [7] J. Patel, S. Shah, P. Thakkar, K. Kotecha, “Predicting stock market index using fusion of machine learning techniques,” *Expert Systems with Applications*, vol. 42, no. 4, pp. 2162–2172, 2015. DOI: 10.1016/j.eswa.2014.10.031.
- [8] L. Khaidem, S. Saha, S. Basak, S. Kar, S. Dey, “Predicting the direction of stock market prices using random forest,” Apr. 2016.
- [9] S. Boonpeng P. Jeatrakul, “Decision support system for investing in stock market by using oaa-neural network,” *2016 Eighth International Conference on Advanced Computational Intelligence (ICACI)*, 2016. DOI: 10.1109/icaci.2016.7449794.
- [10] A. Booth, E. Gerding, F. McGroarty, “Automated trading with performance weighted random forests and seasonality,” *Expert Systems with Applications*, vol. 41, no. 8, pp. 3651–3661, 2014. DOI: 10.1016/j.eswa.2013.12.009.
- [11] R. K. Nayak, D. Mishra, A. K. Rath, “A naïve svm-knn based stock market trend reversal analysis for indian benchmark indices,” *Applied Soft Computing*, vol. 35, pp. 670–680, 2015. DOI: 10.1016/j.asoc.2015.06.040.

- [12] M. Pekkaya C. Hamzaçebi, “Pekkaya, mehmet and coşkun hamzaçebi (2007). “an application on forecasting exchange rate by using neural network (yapay sinir ağları ile döviz kuru tahmini üzerine bir uygulama),” congress of yaem 2007, izmir,” Jan. 2007.
- [13] A. Ç. Pehlivanlı, B. Aşıkil, G. Gülay, “Indicator selection with committee decision of filter methods for stock market price trend in ise,” *Applied Soft Computing*, vol. 49, pp. 792–800, 2016. DOI: 10.1016/j.asoc.2016.09.004.
- [14] M. Göçken, M. Özçalıcı, A. Boru, A. T. Dosdoğru, “Integrating metaheuristics and artificial neural networks for improved stock price prediction,” *Expert Systems with Applications*, vol. 44, pp. 320–331, 2016. DOI: 10.1016/j.eswa.2015.09.029.
- [15] M. Matsugu, K. Mori, Y. Mitari, Y. Kaneda, “Subject independent facial expression recognition with robust face detection using a convolutional neural network,” *Neural Networks*, vol. 16, no. 5-6, pp. 555–559, 2003. DOI: 10.1016/S0893-6080(03)00115-1.
- [16] H. Gunduz, Y. Yaslan, Z. Cataltepe, “Intraday prediction of borsa istanbul using convolutional neural networks and feature correlations,” *Knowledge-Based Systems*, vol. 137, pp. 138–148, 2017. DOI: 10.1016/j.knosys.2017.09.023.
- [17] Y. Peng H. Jiang, “Leverage financial news to predict stock price movements using word embeddings and deep neural networks,” *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2016. DOI: 10.18653/v1/n16-1041.
- [18] A. W. Lo J. Hasanhodzic, *The evolution of technical analysis: financial prediction from Babylonian tablets to Bloomberg terminals*. Bloomberg Press/Wiley, 2010.
- [19] J. J. Murphy, *Technical analysis of the financial markets: a comprehensive guide to trading methods and applications*. New York Institute of Finance, 1999.
- [20] A. O. Hoffmann H. Shefrin, “Technical analysis and individual investors,” *Journal of Economic Behavior and Organization*, vol. 107, pp. 487–511, 2014. DOI: 10.1016/j.jebo.2014.04.002.
- [21] R. T. F. Nazário, J. L. E. Silva, V. A. Sobreiro, H. Kimura, “A literature review of technical analysis on stock markets,” *The Quarterly Review of Economics and Finance*, vol. 66, pp. 115–126, 2017. DOI: 10.1016/j.qref.2017.01.014.
- [22] Q. Lin, “Technical analysis and stock return predictability: An aligned approach,” *Journal of Financial Markets*, vol. 38, pp. 103–123, 2018. DOI: 10.1016/j.finmar.2017.09.003.
- [23] Y.-H. Lui D. Mole, “The use of fundamental and technical analyses by foreign exchange dealers: Hong kong evidence,” *Journal of International Money and Finance*, vol. 17, no. 3, pp. 535–545, 1998. DOI: 10.1016/S0261-5606(98)00011-4.
- [24] L. Menkhoff M. P. Taylor, “The obstinate passion of foreign exchange professionals: Technical analysis,” *Journal of Economic Literature*, vol. 45, no. 4, pp. 936–972, 2007. DOI: 10.1257/jel.45.4.936.

- [25] L. Menkhoff, "The use of technical analysis by fund managers: International evidence," *Journal of Banking and Finance*, vol. 34, no. 11, pp. 2573–2586, 2010. DOI: 10.1016/j.jbankfin.2010.04.014.
- [26] I. H. Witten, E. Frank, M. A. Hall, "Embedded machine learning," *Data Mining: Practical Machine Learning Tools and Techniques*, pp. 531–538, 2011. DOI: 10.1016/b978-0-12-374856-0.00015-8.
- [27] E. Formisano, F. D. Martino, G. Valente, "Multivariate analysis of fmri time series: Classification and regression of brain responses using machine learning," *Magnetic Resonance Imaging*, vol. 26, no. 7, pp. 921–934, 2008. DOI: 10.1016/j.mri.2008.01.052.
- [28] C. Jiang, H. Zhang, Y. Ren, Z. Han, K.-C. Chen, L. Hanzo, "Machine learning paradigms for next-generation wireless networks," *IEEE Wireless Communications*, vol. 24, no. 2, pp. 98–105, 2017. DOI: 10.1109/mwc.2016.1500356wc.
- [29] H. F. Alan J. Kaur, "Can android applications be identified using only tcp/ip headers of their launch time traffic?" *Proceedings of the 9th ACM Conference on Security and Privacy in Wireless and Mobile Networks - WiSec 16*, 2016. DOI: 10.1145/2939918.2939929.
- [30] E. I. Zacharaki, S. Wang, S. Chawla, D. S. Yoo, R. Wolf, E. R. Melhem, C. Davatzikos, "Classification of brain tumor type and grade using mri texture and shape in a machine learning scheme," *Magnetic Resonance in Medicine*, vol. 62, no. 6, pp. 1609–1618, 2009. DOI: 10.1002/mrm.22147.
- [31] N. M. Ball R. J. Brunner, "Data mining and machine learning in astronomy," *International Journal of Modern Physics D*, vol. 19, no. 07, pp. 1049–1106, 2010. DOI: 10.1142/s0218271810017160.
- [32] W. Zhang, T. Yoshida, X. Tang, "Text classification based on multi-word with support vector machine," *Knowledge-Based Systems*, vol. 21, no. 8, pp. 879–886, 2008. DOI: 10.1016/j.knosys.2008.03.044.
- [33] D. Pratas, M. Hosseini, R. M. Silva, A. J. Pinho, P. J. S. G. Ferreira, "Visualization of distinct dna regions of the modern human relatively to a neanderthal genome," *Pattern Recognition and Image Analysis Lecture Notes in Computer Science*, pp. 235–242, 2017. DOI: 10.1007/978-3-319-58838-4_26.
- [34] M. Göçken, M. Özçalıcı, A. Boru, A. T. Dosdoğru, "Integrating metaheuristics and artificial neural networks for improved stock price prediction," *Expert Systems with Applications*, vol. 44, pp. 320–331, 2016. DOI: 10.1016/j.eswa.2015.09.029.
- [35] Z. H. Khan, T. S. Alin, A. Hussain, "Price prediction of share market using artificial neural network ann," *International Journal of Computer Applications*, vol. 22, no. 2, pp. 42–47, 2011. DOI: 10.5120/2552-3497.
- [36] Y. Zhang L. Wu, "Stock market prediction of s&p 500 via combination of improved bco approach and bp neural network," *Expert Systems with Applications*, vol. 36, no. 5, pp. 8849–8854, 2009. DOI: 10.1016/j.eswa.2008.11.028.

- [37] B. M. Henrique, V. A. Sobreiro, H. Kimura, "Stock price prediction using support vector regression on daily and up to the minute prices," *The Journal of Finance and Data Science*, vol. 4, no. 3, pp. 183–201, 2018. DOI: 10.1016/j.jfds.2018.04.003.
- [38] N. Sapankevych R. Sankar, "Time series prediction using support vector machines: A survey," *IEEE Computational Intelligence Magazine*, vol. 4, no. 2, pp. 24–38, 2009. DOI: 10.1109/mci.2009.932254.
- [39] E. A. Gerlein, M. McGinnity, A. Belatreche, S. Coleman, "Evaluating machine learning classification for financial trading: An empirical approach," *Expert Systems with Applications*, vol. 54, pp. 193–207, 2016. DOI: 10.1016/j.eswa.2016.01.018.
- [40] E. Chong, C. Han, F. C. Park, "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies," *Expert Systems with Applications*, vol. 83, pp. 187–205, 2017. DOI: 10.1016/j.eswa.2017.04.030.
- [41] D. Heaven, "News preview 2019: Ai beats the best at big battle games," *New Scientist*, vol. 240, no. 3209-3210, p. 36, 2018. DOI: 10.1016/s0262-4079(18)32354-6.
- [42] J. B. Heaton, N. G. Polson, J. H. Witte, "Deep learning for finance: Deep portfolios," *Applied Stochastic Models in Business and Industry*, vol. 33, no. 1, pp. 3–12, Jul. 2016. DOI: 10.1002/asmb.2209.
- [43] A. Hasan, O. Kalipsiz, S. Akyokus, "Predicting financial market in big data: Deep learning," *2017 International Conference on Computer Science and Engineering (UBMK)*, 2017. DOI: 10.1109/ubmk.2017.8093449.
- [44] R. Cervelló-Royo, F. Guijarro, K. Michniuk, "Stock market trading rule based on pattern recognition and technical analysis: Forecasting the djia index with intraday data," *Expert Systems with Applications*, vol. 42, no. 14, pp. 5963–5975, 2015. DOI: 10.1016/j.eswa.2015.03.017.
- [45] Y. Hu, K. Liu, X. Zhang, L. Su, E. Ngai, M. Liu, "Application of evolutionary computation for rule discovery in stock algorithmic trading: A literature review," *Applied Soft Computing*, vol. 36, pp. 534–551, 2015. DOI: 10.1016/j.asoc.2015.07.008.
- [46] B. Buchanan, "Artificial intelligence in finance," *The Alan Turing Institute*, 2019. DOI: 10.5281/zenodo.2612537.
- [47] *Future today institute (2017) tech trends annual report*. [Online]. Available: <https://futuretodayinstitute.com/2017-tech-trends/> (visited on 01/01/2020).
- [48] V. H. Martinez I. Rosu, "High frequency traders, news and volatility," *SSRN Electronic Journal*, 2012. DOI: 10.2139/ssrn.2024391.
- [49] F. Pasquale, *The black box society: the secret algorithms that control money and information*. Harvard University Press, 2016.
- [50] V. JESS, "The future of investing? ai-run hedge funds. this ai could predict market trends better than a whole team of experts," in, 2016. [Online]. Available: <https://futurism.com/the-future-of-investing-ai-run-hedge-funds/> (visited on 06/02/2020).

- [51] H. Ellyatt, *How to stop 'extremely disruptive' ai from harming society: Robert shiller*, 2018. [Online]. Available: <https://www.cnbc.com/2018/01/18/ai-is-extremely-disruptive-robert-shiller.html> (visited on 02/01/2020).
- [52] S. Brush, *Robots in finance bring new risks to stability, regulators warn*. 2017. [Online]. Available: <https://www.bloomberg.com/news/articles/2017-11-01/robots-in-finance-bring-new-risks-to-stability-regulators-warn> (visited on 01/02/2020).
- [53] N. C. Brown, R. M. Crowley, W. B. Elliott, "What are you saying? using topic to detect financial misreporting," *Journal of Accounting Research*, vol. 58, no. 1, pp. 237–291, 2020. DOI: 10.1111/1475-679x.12294.
- [54] M. Childs, *John mccarthy: Computer scientist known as the father of ai*, 2011. [Online]. Available: <https://www.independent.co.uk/news/obituaries/john-mccarthy-computer-scientist-known-as-the-father-of-ai-6255307.html> (visited on 04/04/2020).
- [55] *Artificial intelligence and machine learning financial services*. 2017. [Online]. Available: <http://www.fsb.org/2017/11/artificial-intelligence-and-machine-learning-in-financial-service/> (visited on 01/04/2020).
- [56] J. Kaplan, *Artificial intelligence: what everyone needs to know*. Oxford University Press, 2016.
- [57] A. Turing, "Computing machinery and intelligence," *Mind*, vol. LIX, no. 236, pp. 433–460, 1950. DOI: 10.1093/mind/lix.236.433.
- [58] A. Newell, J. C. Shaw, H. A. Simon, "Empirical explorations of the logic theory machine," *Papers presented at the February 26-28, 1957, western joint computer conference: Techniques for reliability on - IRE-AIEE-ACM 57 (Western)*, 1957. DOI: 10.1145/1455567.1455605.
- [59] A. Gilmarin K. J. Newell H. Simon, "A program modeling short-term memory under strategy control," *The structure of human memory*, pp. 15–30, 1976.
- [60] A. Newell H. Simon, "Gps, a program that simulates human thought," *Readings in Cognitive Science*, pp. 453–460, 1988. DOI: 10.1016/b978-1-4832-1446-7.50040-6.
- [61] J. Lighthill, "Artificial intelligence: A general survey," *Artificial Intelligence: a paper symposium, Science Research Council*, 1973.
- [62] J. Hendler, "Avoiding another ai winter," *IEEE Intelligent Systems*, vol. 23, no. 2, pp. 2–4, 2008.
- [63] N. Brown C.E. Nielson M. Phillips, "Expert systems for personal financial planning," *Journal of Financial Planning*, pp. 137–143, 1990.
- [64] K. W. Kindle, R. S. Cann, M. R. Craig, T. J. Martin, "Pfps–personal financial planning system," [Online]. Available: <https://www.aaai.org/Library/IAAI/1989/iaai89-006.php> (visited on 05/05/2020).
- [65] E. J. Finnerty Y. H. Park, "Empirical evidence on stock index arbitrage: The case of program trading," *BEBR faculty working paper*, 1321st ser., 1987.

- [66] K. Chen T.-P. Liang, "Protrader: An expert system for program trading," *Managerial Finance*, vol. 15, no. 5, pp. 1–6, 1989. DOI: 10.1108/eb013623.
- [67] B. Keith R. Todd, "Fico blaze advisor highlights," [Online]. Available: <https://community.fico.com/s/blog-post/a5Q2E000000YLauUAG/fico2043> (visited on 06/05/2020).
- [68] P. Cheeseman, "In defense of probability," in *Proceedings of the 9th International Joint Conference on Artificial Intelligence - Volume 2*, ser. IJCAI'85, Los Angeles, California: Morgan Kaufmann Publishers Inc., 1985, pp. 1002–1009, ISBN: 0934613028.
- [69] J. Pearl, *Morgan Kaufmann Series in Representation and Reasoning. Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan Kaufmann, 1988.
- [70] N. Jennings M. J. Wooldridge, *Agent technology: foundations, applications, and markets*. Springer, 1998.
- [71] G. Cybenko, "Approximation by superpositions of a sigmoidal function," *Mathematics of Control, Signals, and Systems*, vol. 2, no. 4, pp. 303–314, 1989. DOI: 10.1007/bf02551274.
- [72] W. S. McCulloch W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The Bulletin of Mathematical Biophysics*, vol. 5, no. 4, pp. 115–133, 1943. DOI: 10.1007/bf02478259.
- [73] C. Chakraborty A. Joseph, "Machine learning at central banks," *SSRN Electronic Journal*, 2017. DOI: 10.2139/ssrn.3031796.
- [74] S. Makridakis, "The forthcoming artificial intelligence (ai) revolution: Its impact on society and firms," *Futures*, vol. 90, pp. 46–60, 2017. DOI: 10.1016/j.futures.2017.03.006.
- [75] A. Kirilenko, A. S. Kyle, M. Samadi, T. Tuzun, "The flash crash: High-frequency trading in an electronic market," *The Journal of Finance*, vol. 72, no. 3, pp. 967–998, 2017. DOI: 10.1111/jofi.12498.
- [76] S. GANDEL, "Why knight lost \$440 million in 45 minutes," *Fortune*, 2012. [Online]. Available: <https://fortune.com/2012/08/02/why-knight-lost-440-million-in-45-minutes/> (visited on 04/02/2020).
- [77] C. Brummer Y. Yadav, "The fintech trilemma," *SSRN Electronic Journal*, 2017. DOI: 10.2139/ssrn.3054770. [Online]. Available: <https://scholarship.law.vanderbilt.edu/faculty-publications/1084>.
- [78] R. Wigglesworth C. Flood, "Blackrock bulks up research into artificial intelligence," *Financial Times*, 2018. [Online]. Available: <https://www.ft.com/content/4f5720ce-1552-11e8-9376-4a6390addb44> (visited on 03/02/2020).
- [79] "China ai development report 2018," *China Institute for Science and Technology Policy at Tsinghua University*, 2018. [Online]. Available: http://www.sppm.tsinghua.edu.cn/eWebEditor/UploadFile/China_AI_development_report_2018.pdf (visited on 03/01/2020).

- [80] B. Buchanan C. Cao, "Quo vadis?: A comparison of the fintech revolution in china and the west," *SWIFT Institute Working Paper*, vol. 2017, no. 2, 2018. [Online]. Available: <https://ssrn.com/abstract=3264146>.
- [81] "Top ai trends to watch in 2018," *CB Insights*, 2018. [Online]. Available: <https://www.cbinsights.com/research/report/artificial-intelligence-trends-2018/> (visited on 07/01/2020).
- [82] "Bank of the future: The abcs of digital disruption in finance," *Citi GPS: Global Perspectives & Solutions*, 2018. [Online]. Available: <https://www.citi.com/commercialbank/insights/assets/docs/2018/The-Bank-of-the-Future/> (visited on 03/09/2020).
- [83] T. Philippon, "Finance vs. wal-mart: Why are financial services so expensive?" New York University, Tech. Rep., 2012. [Online]. Available: https://www.investmentoffice.com/rc/doc/Philippon_v3_4999.pdf (visited on 06/07/2019).
- [84] —, "The fintech opportunity," National Bureau of Economic Research, Inc, NBER Working Papers 22476, 2016. [Online]. Available: <https://EconPapers.repec.org/RePEc:nbr:nberwo:22476> (visited on 01/07/2019).
- [85] B. Guillaume, "Financial consumption and the cost of finance: Measuring financial efficiency in europe (1950-2007)," Paris School of Economics, Working Papers, 2013. [Online]. Available: <https://www.parisschoolofeconomics.eu/IMG/pdf/jobmarket-1paper-bazot-pse.pdf> (visited on 08/01/2019).
- [86] "Would you let a robot control your savings for a 5% return?" *which.co*, 2017. [Online]. Available: <https://www.which.co.uk/news/2017/04/would-you-let-a-robot-control-your-savings-for-a-5-return/> (visited on 01/07/2020).
- [87] "Megabanks in japan embrace artificial intelligence, robot technology," *The Japan News - Asia News Network*, 2017. [Online]. Available: <https://business.inquirer.net/239571/megabanks-japan-embrace-artificial-intelligence-robot-technology> (visited on 06/02/2020).
- [88] C. Sara, "Allstate's 'digital colleague' amelia answers questions for call center reps," *Wall Street Journal*, 2018. [Online]. Available: <https://blogs.wsj.com/cio/2018/03/30/allstates-digital-colleague-amelia-answers-questions-for-call-center-reps/> (visited on 05/07/2020).
- [89] "Don't believe the hype – the lemonade story,"
- [90] W. Don, "China's debt collectors focus in on \$200 billion p2p debt pile," *Financial Times*, 2018. [Online]. Available: <https://www.ft.com/content/a219cd72-67a3-11e8-8cf3-0c230fa67aec> (visited on 05/02/2020).
- [91] C. Gerrard, "Robo advisors start to take hold in europe," *Wall Street Journal*, 2018. [Online]. Available: <https://www.wsj.com/articles/robo-advisers-start-to-take-hold-in-europe-1517799781> (visited on 03/02/2020).

- [92] M. Uhl P Rohner, "Robo-advisors versus traditional investment advisors: An unequal game," *The Journal of Wealth Management*, vol. 21, pp. 44–50, Apr. 2018. DOI: 10.3905/jwm.2018.21.1.044.
- [93] A. A. Kirilenko A. W. Lo, "Moore's law versus murphy's law: Algorithmic trading and its discontents," *Journal of Economic Perspectives*, vol. 27, no. 2, pp. 51–72, May 2013. DOI: 10.1257/jep.27.2.51. [Online]. Available: <https://www.aeaweb.org/articles?id=10.1257/jep.27.2.51>.
- [94] I. Aldridge S. Krawciw, "Real-time risk: What investors should know about fintech, high-frequency trading, and flash crashes," pp. 203–212, Feb. 2017. DOI: 10.1002/9781119319030.index.
- [95] N. Laura, "Banks look to the stars to spot trading mistakes," *Financial Times*, 2018. [Online]. Available: <https://www.ft.com/content/578c2f26-430d-11e8-803a-295c97e6fd0b> (visited on 01/02/2020).
- [96] B. Biais, T. Foucault, S. Moinas, "Equilibrium high-frequency trading," *SSRN Electronic Journal*, 2012. DOI: 10.2139/ssrn.2024360.
- [97] V. H. Martinez I. Rosu, "High frequency traders, news and volatility," *SSRN Electronic Journal*, 2012. DOI: 10.2139/ssrn.2024391.
- [98] R. Culkin, "Machine learning in finance : The case of deep learning for option pricing," 2017.
- [99] J. Brogaard, T. Hendershott, R. Riordan, "High frequency trading and price discovery," *Review of Financial Studies*, vol. 27, Apr. 2013. DOI: 10.2139/ssrn.1928510.
- [100] T. Hendershott R. Riordan, "High frequency trading and price discovery," *SSRN Electronic Journal*, 2012. DOI: 10.2139/ssrn.1928510.
- [101] A. Menkveld, "High frequency trading and the new market makers," *Journal of Financial Markets*, vol. 16, pp. 712–740, Nov. 2013. DOI: 10.1016/j.finmar.2013.06.006.
- [102] J. Hasbrouck G. Saar, "Low-latency trading," *Journal of Financial Markets*, vol. 16, no. 4, pp. 646–679, 2013. DOI: 10.1016/j.finmar.2013.05.003.
- [103] R. Paul, "Sentient technologies built an autonomous hedge fund, then applied its artificial intelligence platform to marketing," *Marketingai Institute*, 2017. [Online]. Available: <https://www.marketingaiinstitute.com/blog/sentient-technologies-spotlight> (visited on 03/01/2020).
- [104] P. Efi, "Numerai, a small cap ai blockchain gem," *Daily Fintech*, 2019. [Online]. Available: <https://dailyfintech.com/2019/06/04/numerai-a-small-cap-ai-blockchain-gem/> (visited on 03/10/2020).
- [105] N. Laura, "Ing launches artificial intelligence bond trading tool katana," *Financial Times*, 2017. [Online]. Available: <https://www.ft.com/content/1c63c498-de79-11e7-a8a4-0a1e63a52f9c> (visited on 03/08/2020).
- [106] P. Maija, "Artificial intelligence is guiding venture capital to start-ups," *Financial Times*, 2017. [Online]. Available: <https://www.ft.com/content/dd7fa798-bfcd-11e7-823b-ed31693349d3> (visited on 02/09/2020).

- [107] B. Ariel, “Demystifying the black box that is ai,” *Scientific American - ENGINEERING*, 2017. [Online]. Available: <https://www.scientificamerican.com/article/demystifying-the-black-box-that-is-ai/> (visited on 01/07/2020).
- [108] Y. Yesha, “How algorithmic trading undermines efficiency in capital markets,” *68 Vanderbilt Law Review* 1607, 2015. [Online]. Available: <https://scholarship.law.vanderbilt.edu/vlr/vol68/iss6/3> (visited on 10/12/2019).
- [109] M. Lewis, *Flash boys: a Wall Street revolt*. W. W. Norton & Company, 2015.
- [110] M. Jethro, “Uk pound plunges more than 6% in mysterious flash crash,” *CNN Business*, 2016. [Online]. Available: <https://money.cnn.com/2016/10/06/investing/pound-flash-crash-currency-brexit/index.html> (visited on 03/07/2019).
- [111] W. Robin, “Volatility how ‘algorithms’ changed the rhythm of the market,” *Financial Times*, 2019. [Online]. Available: <https://www.ft.com/content/fdc1c064-1142-11e9-a581-4ff78404524e> (visited on 03/02/2020).
- [112] B. J. Dietvorst, J. P. Simmons, C. Massey, “Overcoming algorithm aversion: People will use imperfect algorithms if they can even slightly modify them,” *Manage. Sci.*, vol. 64, no. 3, pp. 1155–1170, Mar. 2018, ISSN: 0025-1909. DOI: 10.1287/mnsc.2016.2643. [Online]. Available: <https://doi.org/10.1287/mnsc.2016.2643>.
- [113] —, “Algorithm aversion: People erroneously avoid algorithms after seeing them err,” *Journal of Experimental Psychology: General*, vol. 144, no. 1, pp. 114–126, 2015. DOI: 10.1037/xge0000033.
- [114] C. ONeil, *Weapons of math destruction: how big data increases inequality and threatens democracy*. Crown, 2017.
- [115] T. John, “Britain urged to take ethical advantage in artificial intelligence,” *Financial Times*, 2018. [Online]. Available: <https://www.ft.com/content/b21d1fb8-3f3e-11e8-b9f9-de94fa33a81e> (visited on 07/07/2019).
- [116] B. YOLANDE, “Around the world in dollars and cents. trends in international real estate trading,” *SAVILLS WORLD RESEARCH*, 2016. [Online]. Available: <https://pdf.euro.savills.co.uk/global-research/around-the-world-in-dollars-and-cents-2016.pdf> (visited on 01/07/2019).
- [117] S. Abhinav, “Deep learning tools are shaping corporate real estate today,” *Corenet Global*, 2017. [Online]. Available: <http://www.corenetglobal.org/applications/KC0/Document.aspx?itemNumber=36409&download=1> (visited on 02/03/2019).
- [118] C. Anthony, “How drones, data and ai are changing the property sector,” *World Economic Forum*, 2018. [Online]. Available: <https://www.weforum.org/agenda/2018/01/proptech-drones-data-ai-property-sector/> (visited on 08/07/2019).
- [119] I. Erel, L. Stern, C. Tan, M. Weisbach, “Selecting directors using machine learning,” 2018. DOI: 10.3386/w24435.

- [120] B. R. Routledge, S. Sacchetto, N. A. Smith, "Predicting merger targets and acquirers from text," 2013.
- [121] K. Li, F. Mai, R. Shen, X. Yan, "Measuring corporate culture using machine learning," *SSRN Electronic Journal*, 2018. DOI: 10.2139/ssrn.3256608.
- [122] D. Bjorkegren D. Grissen, "Behavior revealed in mobile phone usage predicts loan repayment," *SSRN Electronic Journal*, 2018. DOI: 10.2139/ssrn.2611775.
- [123] R. Oliver, "Hank greenberg backs funding round for underwriting start up," *Financial Times*, 2017. [Online]. Available: <https://www.ft.com/content/7d9867c8-d9c4-11e7-a039-c64b1c09b482> (visited on 01/07/2019).
- [124] W. Frame, L. Wall, L. White, "Technological change and financial innovation in banking: Some implications for fintech," *Federal Reserve Bank of Atlanta, Working Papers*, Jan. 2018. DOI: 10.29338/wp2018-11.
- [125] P. Domingos, *The master algorithm: how the quest for the ultimate learning machine will remake our world*. Basic books, a member of the Perseus Book Group, 2018.
- [126] H. R. Varian, "Big data: New tricks for econometrics," *Journal of Economic Perspectives*, vol. 28, no. 2, pp. 3–28, May 2014. DOI: 10.1257/jep.28.2.3. [Online]. Available: <https://www.aeaweb.org/articles?id=10.1257/jep.28.2.3>.
- [127] L. Wall, "Some financial regulatory implications of artificial intelligence," *Journal of Economics and Business*, Jun. 2018. DOI: 10.1016/j.jeconbus.2018.05.003.
- [128] B. van Liebergen, "Machine learning: A revolution in risk management and compliance?" *The Capco Institute Journal Of Financial Transformation*, 2018. [Online]. Available: <https://www.capco.com/Capco-Institute/Journal-45-Transformation/Machine-learning-a-revolution-in-risk-management-and-compliance> (visited on 09/02/2019).
- [129] A. E. Khandani, A. J. Kim, A. Lo, "Consumer credit-risk models via machine-learning algorithms," *Journal of Banking & Finance*, vol. 34, no. 11, pp. 2767–2787, 2010. [Online]. Available: <https://EconPapers.repec.org/RePEc:eee:jbfina:v:34:y:2010:i:11:p:2767-2787> (visited on 08/10/2019).
- [130] L. Einav J. Levin, "The data revolution and economic analysis," *Innovation Policy and the Economy*, vol. 14, May 2013. DOI: 10.1086/674019.
- [131] S. Mullainathan J. Spiess, "Machine learning: An applied econometric approach," *Journal of Economic Perspectives*, vol. 31, pp. 87–106, May 2017. DOI: 10.1257/jep.31.2.87.
- [132] V. Chernozhukov, D. Chetverikov, M. Demirer, E. Duflo, C. Hansen, W. Newey, *Double/debiased/neyman machine learning of treatment effects*, 2017. arXiv: 1701.08687 [stat.ML].
- [133] S. Athey, "The impact of machine learning on economics," in *The Economics of Artificial Intelligence: An Agenda*. University of Chicago Press, Jan. 2018, pp. 507–547. [Online]. Available: <http://www.nber.org/chapters/c14009> (visited on 08/01/2019).

- [134] S. Athey G. W. Imbens, “The state of applied econometrics: Causality and policy evaluation,” *Journal of Economic Perspectives*, vol. 31, no. 2, pp. 3–32, May 2017. DOI: 10.1257/jep.31.2.3. [Online]. Available: <https://www.aeaweb.org/articles?id=10.1257/jep.31.2.3>.
- [135] S. W. Bauguess, “The role of big data, machine learning, and ai in assessing risks: A regulatory perspective,” *SSRN Electronic Journal*, 2017. DOI: 10.2139/ssrn.3226514.
- [136] P. C. TETLOCK, “Giving content to investor sentiment: The role of media in the stock market,” *The Journal of Finance*, vol. 62, no. 3, pp. 1139–1168, 2007. DOI: 10.1111/j.1540-6261.2007.01232.x. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1540-6261.2007.01232.x>. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.2007.01232.x>.
- [137] P. C. TETLOCK, M. SAAR-TSECHANSKY, S. MACSKASSY, “More than words: Quantifying language to measure firms’ fundamentals,” *The Journal of Finance*, vol. 63, no. 3, pp. 1437–1467, 2008. DOI: 10.1111/j.1540-6261.2008.01362.x. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/j.1540-6261.2008.01362.x>. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.2008.01362.x>.
- [138] N. R. Sinha, “Underreaction to news in the us stock market,” *SSRN Electronic Journal*, 2010. DOI: 10.2139/ssrn.1572614.
- [139] F. Li, “Annual report readability, current earnings, and earnings persistence,” *Journal of Accounting and Economics*, vol. 45, no. 2, pp. 221–247, 2008, Economic Consequences of Alternative Accounting Standards and Regulation, ISSN: 0165-4101. DOI: <https://doi.org/10.1016/j.jacceco.2008.02.003>. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0165410108000141>.
- [140] A. Manela A. Moreira, “News implied volatility and disaster concerns,” *Journal of Financial Economics*, vol. 123, no. 1, pp. 137–162, 2017. [Online]. Available: <https://EconPapers.repec.org/RePEc:eee:jfinec:v:123:y:2017:i:1:p:137-162>.
- [141] L. Guo, F. Shi, J. Tu, “Textual analysis and machine learning: Crack unstructured data in finance and accounting,” *The Journal of Finance and Data Science*, vol. 2, no. 3, pp. 153–170, 2016, ISSN: 2405-9188. DOI: <https://doi.org/10.1016/j.jfds.2017.02.001>. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S2405918816300496>.
- [142] C. Kearney S. Liu, “Textual sentiment in finance: A survey of methods and models,” *International Review of Financial Analysis*, vol. 33, no. C, pp. 171–185, 2014. [Online]. Available: <https://EconPapers.repec.org/RePEc:eee:finana:v:33:y:2014:i:c:p:171-185> (visited on 09/02/2019).

- [143] T. LOUGHRAN B. MCDONALD, "Textual analysis in accounting and finance: A survey," *Journal of Accounting Research*, vol. 54, no. 4, pp. 1187–1230, 2016. DOI: 10.1111/1475-679X.12123. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/1475-679X.12123>. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/1475-679X.12123>.
- [144] Y. Bao A. Datta, "Simultaneously discovering and quantifying risk types from textual risk disclosures," *Management Science*, vol. 60, no. 6, pp. 1371–1391, 2014. [Online]. Available: <https://EconPapers.repec.org/RePEc:inm:ormnsc:v:60:y:2014:i:6:p:1371-1391>.
- [145] A. H. Huang, R. Lehavy, A. Y. Zang, R. Zheng, "Analyst information discovery and interpretation roles: A topic modeling approach," *Management Science*, vol. 64, no. 6, pp. 2833–2855, 2018. DOI: 10.1287/mnsc.2017.2751.
- [146] W. Antweiler M. Z. Frank, "Is all that talk just noise? the information content of internet stock message boards," *The Journal of Finance*, vol. 59, no. 3, pp. 1259–1294, 2004. DOI: 10.1111/j.1540-6261.2004.00662.x. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.2004.00662.x>.
- [147] T. Renault, "Intraday online investor sentiment and return patterns in the u.s. stock market," *Journal of Banking & Finance*, vol. 84, no. C, pp. 25–40, 2017. [Online]. Available: <https://EconPapers.repec.org/RePEc:eee:jbfina:v:84:y:2017:i:c:p:25-40>.
- [148] R. Tibshirani, "Regression shrinkage and selection via the lasso," *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 58, no. 1, pp. 267–288, 1996. DOI: 10.1111/j.2517-6161.1996.tb02080.x. [Online]. Available: <https://rss.onlinelibrary.wiley.com/doi/abs/10.1111/j.2517-6161.1996.tb02080.x>.
- [149] A. Belloni V. Chernozhukov, "Least squares after model selection in high-dimensional sparse models," *Bernoulli*, vol. 19, no. 2, pp. 521–547, May 2013. DOI: 10.3150/11-BEJ410. [Online]. Available: <https://doi.org/10.3150/11-BEJ410>.
- [150] R. E. Bellman, *Dynamic programming*. Dover, 2015.
- [151] M. Corazza F. Bertoluzzo, "Q-learning-based financial trading systems with applications," *SSRN Electronic Journal*, 2014. DOI: 10.2139/ssrn.2507826.
- [152] P. N. Kolm G. Ritter, "Modern perspectives on reinforcement learning in finance," *SSRN Electronic Journal*, 2019. DOI: 10.2139/ssrn.3449401.
- [153] L. Breiman, "Random forests," *English, Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, ISSN: 0885-6125. DOI: 10.1023/A:1010933404324. [Online]. Available: <http://dx.doi.org/10.1023/A%3A1010933404324>.
- [154] A. R. Bagherpour, "Predicting mortgage loan default with machine learning methods," 2017.
- [155] C.-C. Yeh, D.-J. Chi, Y.-R. Lin, "Going-concern prediction using hybrid random forests and rough set approach," *Inf. Sci.*, vol. 254, pp. 98–110, Jan. 2014, ISSN: 0020-0255. DOI: 10.1016/j.ins.2013.07.011. [Online]. Available: <https://doi.org/10.1016/j.ins.2013.07.011>.

- [156] D. John, "Wall street must recognise challenges posed by machine learning," *Financial Times*, 2017. [Online]. Available: <https://www.ft.com/content/e2645d5e-d67e-11e7-8c9a-d9c0a5c8d5c9> (visited on 08/09/2019).
- [157] M. C. Medeiros, G. F. R. Vasconcelos, Á. Veiga, E. Zilberman, "Forecasting inflation in a data-rich environment: The benefits of machine learning methods," *Journal of Business & Economic Statistics*, vol. 0, no. 0, pp. 1–22, 2019. DOI: 10.1080/07350015.2019.1637745.
- [158] F. Barboza, H. Kimura, E. Altman, "Machine learning models and bankruptcy prediction," *Expert Syst. Appl.*, vol. 83, no. C, pp. 405–417, Oct. 2017, ISSN: 0957-4174. DOI: 10.1016/j.eswa.2017.04.006. [Online]. Available: <https://doi.org/10.1016/j.eswa.2017.04.006>.
- [159] C. Robert D. Sanjiv, "Machine learning in finance : The case of deep learning for option pricing," 2017.
- [160] R. C. Lacher, P. K. Coats, S. C. Sharma, L. F. Fant, "A neural network for classifying the financial health of a firm," *European Journal of Operational Research*, vol. 85, no. 1, pp. 53–65, 1995. [Online]. Available: <https://EconPapers.repec.org/RePEc:eee:ejores:v:85:y:1995:i:1:p:53-65>.
- [161] E. I. Altman, G. Marco, F. Varetto, "Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the italian experience)," *Journal of Banking & Finance*, vol. 18, no. 3, pp. 505–529, 1994, ISSN: 0378-4266. DOI: [https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8). [Online]. Available: <http://www.sciencedirect.com/science/article/pii/0378426694900078>.
- [162] P. K. Coats L. F. Fant, "Recognizing Financial Distress Patterns Using a Neural Network Tool," *Financial Management*, vol. 22, no. 3, Fall 1993. [Online]. Available: <https://ideas.repec.org/a/fma/fmanag/coats93.html>.
- [163] M. Cecchini, H. Aytug, G. Koehler, P. Pathak, "Detecting management fraud in public companies," *Management Science*, vol. 56, pp. 1146–1160, Jul. 2010. DOI: 10.1287/mnsc.1100.1174.
- [164] W. Härdle, R. Moro, L. Hoffmann, *Learning Machines Supporting Bankruptcy Prediction*. Humboldt-Universität zu Berlin, Wirtschaftswissenschaftliche Fakultät, 2010. DOI: <http://dx.doi.org/10.18452/4260>.
- [165] E. F. Fama, "The behavior of stock-market prices," *The Journal of Business*, vol. 38, no. 1, p. 34, 1965. DOI: 10.1086/294743.
- [166] —, "Efficient capital markets: A review of theory and empirical work," *The Journal of Finance*, vol. 25, no. 2, p. 383, 1970. DOI: 10.2307/2325486.
- [167] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mane, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viegas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, X. Zheng, *Tensorflow*:

- Large-scale machine learning on heterogeneous distributed systems*, 2016. arXiv: 1603.04467 [cs.DC].
- [168] A. Géron, *Hands-On Machine Learning with Scikit-Learn and TensorFlow*. O'Reilly Media, Inc, 2017.
 - [169] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, A. Müller, J. Nothman, G. Louppe, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, É. Duchesnay, *Scikit-learn: Machine learning in python*, 2012. arXiv: 1201.0490 [cs.LG].
 - [170] *Data preparation for data mining*. Morgan Kaufmann, 1999.
 - [171] C. T. Brownlees G. M. Gallo, “Financial econometric analysis at ultra-high frequency: Data handling concerns,” *SSRN Electronic Journal*, 2006. DOI: 10.2139/ssrn.886204.
 - [172] T. N. Falkenberry, “High frequency data filtering,” *Tick Data Inc*, 2002.
 - [173] N. Hautsch, *Econometrics of financial high-frequency data*. Springer, 2012.
 - [174] M. Rechenstein W. N. Street, “Using conditional probability to identify trends in intra-day high-frequency equity pricing,” *Physica A: Statistical Mechanics and its Applications*, vol. 392, no. 24, pp. 6169–6188, 2013. DOI: 10.1016/j.physa.2013.08.003.
 - [175] R. C. A. Oomen, “Properties of realized variance under alternative sampling schemes,” *Journal of Business & Economic Statistics*, vol. 24, no. 2, pp. 219–237, 2006. DOI: 10.1198/073500106000000044.
 - [176] C. Ting, “Which daily price is less noisy?” *Financial Management*, vol. 35, no. 3, pp. 81–95, 2006. DOI: 10.1111/j.1755-053x.2006.tb00148.x.
 - [177] C. T. Brownlees G. M. Gallo, “Financial econometric analysis at ultra-high frequency: Data handling concerns,” *SSRN Electronic Journal*, 2006. DOI: 10.2139/ssrn.886204.
 - [178] N. V. Chawla, K. W. Bowyer, L. O. Hall, W. P. Kegelmeyer, “Smote: Synthetic minority over-sampling technique,” *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, Jun. 2002, ISSN: 1076-9757. DOI: 10.1613/jair.953. [Online]. Available: <http://dx.doi.org/10.1613/jair.953>.
 - [179] O. Maimon L. Rokach, *Data Mining and Knowledge Discovery Handbook*. Berlin, Heidelberg: Springer-Verlag, 2005, ISBN: 0387244352.
 - [180] H. He E. Garcia, “Learning from imbalanced data,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 21, no. 9, pp. 1263–1284, 2009. DOI: 10.1109/tkde.2008.239.
 - [181] A. K. Palit D. Popovic, *Computational intelligence in time series forecasting: theory and engineering applications*. Springer, 2005.
 - [182] F. Virili B. Freisleben, “Nonstationarity and data preprocessing for neural network predictions of an economic time series,” *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium*, vol. 5, 129–134 vol.5, 2000.

- [183] J. D. Cryer K.-s. Chan, *Time series analysis with applications in R*. Springer, 2011.
- [184] R. S. Tsay, *Analysis of financial time series: financial econometrics*. Wiley, 2005.
- [185] M. Gaber, A. Zaslavsky, S. Krishnaswamy, "Mining data streams: A review," *SIGMOD Record*, vol. 34, pp. 18–26, Jun. 2005. DOI: 10.1145/1083784.1083789.
- [186] *Borsa istanbul datastore*. [Online]. Available: <http://datastore.borsaistanbul.com> (visited on 06/02/2020).
- [187] J. Z. S. I. P. Marković M. B. Stojanović M. M. Božić, "Stock market trend prediction using support vector machines," *Automatic Control and Robotics*, vol. 13, no. 3, pp. 147–158, 2014.
- [188] D. Kumar, S. S. Meghwani, M. Thakur, "Proximal support vector machine based hybrid prediction models for trend forecasting in financial markets," *Journal of Computational Science*, vol. 17, pp. 1–13, 2016. DOI: 10.1016/j.jocs.2016.07.006.
- [189] P. Domingos, "Metacost," *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining - KDD 99*, 1999. DOI: 10.1145/312129.312220.
- [190] C. Elkan, "The foundations of cost-sensitive learning," in *In Proceedings of the Seventeenth International Joint Conference on Artificial Intelligence*, 2001, pp. 973–978.
- [191] S. Masteika R. Simutis, "Stock trading system based on formalized technical analysis and ranking technique," *Computational Science – ICCS 2006 Lecture Notes in Computer Science*, pp. 332–339, 2006. DOI: 10.1007/11758549_49.
- [192] V. Lavrenko, M. Schmill, D. Lawrie, P. Ogilvie, D. Jensen, J. Allan, "Language models for financial news recommendation," *Proceedings of the ninth international conference on Information and knowledge management - CIKM 00*, 2000. DOI: 10.1145/354756.354845.
- [193] M.-A. Mittermayer, "Forecasting intraday stock price trends with text mining techniques," *37th Annual Hawaii International Conference on System Sciences, 2004. Proceedings of the*, 2004. DOI: 10.1109/hicss.2004.1265201.
- [194] R. P. Schumaker H. Chen, "Textual analysis of stock market prediction using breaking financial news," *ACM Transactions on Information Systems*, vol. 27, no. 2, pp. 1–19, 2009. DOI: 10.1145/1462198.1462204.
- [195] L. A. Teixeira A. L. I. D. Oliveira, "A method for automatic stock trading combining technical analysis and nearest neighbor classification," *Expert Systems with Applications*, vol. 37, no. 10, pp. 6885–6890, 2010. DOI: 10.1016/j.eswa.2010.03.033.
- [196] F. J. Fabozzi, S. Focardi, C. Jonas, "Trends in quantitative equity management: Survey results," *Quantitative Finance*, vol. 7, no. 2, pp. 115–122, 2007. DOI: 10.1080/14697680701195941. eprint: <https://doi.org/10.1080/14697680701195941>. [Online]. Available: <https://doi.org/10.1080/14697680701195941>.

- [197] J. Hauptmann, *Properties of linear, discrete and continuous returns*. [Online]. Available: <https://www.anevis-solutions.com/2016/properties-linear-discrete-continuous-returns/> (visited on 09/07/2019).
- [198] R. Pardo, *The Evaluation and Optimization of Trading Strategies*. John Wiley & Sons, Inc., 2011.
- [199] E. P. Chan, *Quantitative trading: how to build your own algorithmic trading business*. John Wiley & Sons, 2009.
- [200] I. Aldridge, *High-frequency trading: a practical guide to algorithmic strategies and trading systems*. John Wiley & Sons, Inc., 2013.
- [201] G. Soros, *The Alchemy of Finance*. John Wiley & Sons, 2003.
- [202] C. M. Corcoran, *Long/short market dynamics: trading strategies for today's markets*. Wiley, 2007.
- [203] L. Cao, "Portfolio managers, artificial intelligence is coming for your jobs," *CFA Institute*, Feb. 2018. [Online]. Available: <https://blogs.cfainstitute.org/investor/2018/03/09/portfolio-managers-artificial-intelligence-is-coming-for-your-jobs/> (visited on 03/07/2020).
- [204] T. G. Dietterich, "Approximate statistical tests for comparing supervised classification learning algorithms," *Neural Computation*, vol. 10, no. 7, pp. 1895–1923, 1998. DOI: 10.1162/089976698300017197.

TEZDEN ÜRETİLMİŞ YAYINLAR

İletişim Bilgileri: affan.hasan@hotmail.com

Makale

1. Afan HASAN, Oya KALIPSIZ, and Selim AKYOKUŞ. "Modeling Traders' Behavior with Deep Learning and Machine Learning Methods: Evidence from BIST 100 Index", Hindawi, Complexity, Volume 2020, Article ID 8285149, 16 pages, <https://doi.org/10.1155/2020/8285149>

Konferans Bildirisi

1. Afan HASAN, Oya KALIPSIZ, and Selim AKYOKUŞ. "Predicting financial market in big data: Deep learning", International Conference on Computer Science and Engineering (UBMK), 2017
2. Afan HASAN, Oya KALIPSIZ, and Selim AKYOKUŞ. "Application of Machine Learning Techniques for the Prediction of Financial Market Direction on BIST 100 Index", Computational Methods and Telecommunication in Electrical Engineering and Finance, 2018

Proje

1. "Şirket Duyuruları Esnasında Pay Piyasasında Gün İçi Alım-Satım Dinamikleri" T.A.E1-15-01464 TÜBİTAK.