

T.C.
İSTANBUL OKAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ
BANKACILIK ANABİLİM DALI
BANKACILIK PROGRAMI

Hakan KAYA

MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE ZAMAN SERİSİ
ALGORİTMALARININ KARŞILAŞTIRILMASI:
BİST TEMETTÜ 25

DANIŞMAN
Prof. Dr. Halit Targan ÜNAL

İSTANBUL, Haziran 2025

T.C.
İSTANBUL OKAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ
BANKACILIK ANABİLİM DALI
BANKACILIK PROGRAMI

Hakan KAYA
(212503002)

MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE ZAMAN SERİSİ
ALGORİTMALARININ KARŞILAŞTIRILMASI:
BİST TEMETTÜ 25

Tezin Enstitüye Teslim Edildiği Tarih:

Tezin Savunulduğu Tarih : 30.05.2025

Tez Danışmanı : Prof. Dr. Halit Targan ÜNAL
(Doğuş Üniversitesi)

Diğer Jüri Üyeleri : Doç. Dr. Edin Güçlü SÖZER
(İstanbul Okan Üniversitesi)

Doç. Dr. Hakan ÖZCAN
(İstanbul Gelişim Üniversitesi).....

Doç. Dr. Turgay MÜNYAS
(İstanbul Okan Üniversitesi)

Dr. Öğr. Üyesi Beyza TOKSOY
(İstanbul Okan Üniversitesi)

İSTANBUL, Haziran 2025

ÖNSÖZ

Yetiştirdiği onlarca öğrencilerden biri olmakla gurur duyduğum, bilim üretmenin yanı sıra kendi alan uzmanını yetiştirebilen, eğitim sistemine her kademedede profesyonel katkılar sunan, öğrenme, öğretme ve performans geliştirme olanakları sunabilen, çalışma disipliniyle ve duruşuyla "Hocaların Hocası" olan değerli Prof. Dr. Halit Targan ÜNAL Hocama, bilimsel bir bakışla ışık tutan Doç. Dr. Edin Güçlü SÖZER'e, kazandırdıklarıyla sigortacılık çevrelerinde artık bir fenomen haline gelen Doç. Dr. Hakan ÖZCAN'a, her zaman titiz değerlendirmeleriyle çalışmamı daha iyi hale getiren Doç. Dr. Turgay MÜNYAS'a, pozitif, sabırlı ve yapıcı yaklaşımı için Dr. Öğretim Üyesi Beyza TOKSOY'a, ve başarımda büyük katkısı olan aileme sonsuz sevgi, saygı ve teşekkürlerimi sunarım.

Hakan KAYA

Haziran, 2025

İÇİNDEKİLER

	<u>SAYFA NO</u>
ÖZET	VIII
SUMMARY	IX
SEMBOLLER	X
KISALTMALAR	XI
ŞEKİL LİSTESİ	XIII
TABLO LİSTESİ	XIX
BÖLÜM 1: GİRİŞ	1
1.1.PROBLEMİN DURUMU	1
1.2.ÇALIŞMANIN AMACI VE ÖNEMİ	1
1.3.MODELİN KURGUSU	2
1.4.HİPOTEZLER.....	3
1.5.ÇALIŞMANIN SINIRLILIKLARI	3
1.6.LİTERATÜR	3
BÖLÜM 2: FİNANS SEKTÖRÜNDE DİJİTAL DÖNÜŞÜM	10
2.1.ENDÜSTRİ 4.0.....	12
2.2.NESNELERİN İNTERNETİ	13
2.3.HİZMETLERİN İNTERNETİ	14
2.4.SİBER-FİZİKSEL SİSTEMLER	15
2.5.ENDÜSTRİ 4.0 VE İNOVASYONA ETKİLERİ	16
2.6.FİNANSAL TEKNOLOJİNİN DOĞUŞU VE GELİŞİMİ	16
2.7.FİNANS SEKTÖRÜNDE BANKACILIĞIN YERİ VE ÖNEMİ	18
2.8.BANKACILIKTA ENDÜSTRİ 4.0.....	18
2.8.1.Nesnelerin İnterneti Ve Bankacılık Sektörü İlişkisi	19
2.8.2.Büyük Veri Ve Veri Madenciliği İle Bankacılık Sektörü İlişkisi	19

2.8.3.Yapay Zekâ, Makine Öğrenmesi Ve Derin Öğrenmenin Bankacılık Sektörü İlişkisi	21
2.8.4.Gömülü Finans Ve Bankacılık Sektörü İlişkisi	21
2.8.5.Metaverse Ve Bankacılık İlişkisi	23
2.8.6.Kuantum Hesaplama Ve Bankacılık İlişkisi	26
2.9.FİNTEK	28
2.9.1.Fintek Tarihçesi	29
2.9.2.Fintek Ekosistemi	30
2.9.3.Fintek'in Geleceği	33
2.10.FİNANSAL TEKNOLOJİLER VE BİLGİ GÜVENLİĞİ	34
2.11.FİNANSAL OKURYAZARLIK	35
2.12.TOPLUM 5.0 VE BANKACILIK	39
2.13.BİST TEMETTÜ 25 (XTM25) ENDEKSİ	41
BÖLÜM 3: DİJİTAL FİNANS	44
3.1.FİNANSAL HİZMETLERDE DİJİTAL DÖNÜŞÜMÜ SAĞLAYAN TEKNOLOJİLER	45
3.1.1.Yapay Zekâ Teknolojileri	47
3.1.2.Makine Öğrenmesi Konsepti	49
3.1.2.1.Klasik Öğrenme	53
3.1.2.1.1.Gözetimli (Supervised) Öğrenme	53
3.1.2.1.1.1.Regresyon (Regression)	53
3.1.2.1.1.1.1.Lojistik	54
3.1.2.1.1.2.Sınıflandırma (Classification)	55
3.1.2.1.1.2.1.SVM	55
3.1.2.1.1.2.2.Naive Bayes	55
3.1.2.1.1.2.3.K-NN	55
3.1.2.1.1.2.4.Karar Ağaçları (Decision Trees)	56
3.1.2.1.2.Gözetimsiz (Unsupervised)	58
3.1.2.1.2.1.Boyutsal Küçültme (Dimensionality Reduction)	58
3.1.2.1.2.1.1.LDA	58
3.1.2.2.Topluluk Öğrenme (Ensemble)	58
3.1.2.2.1.Arttırma (Boosting)	59
3.1.2.2.1.1.AdaBoost	59
3.1.2.2.1.2.Gradient Boosting	60
3.1.2.2.2.Bagging	61

3.1.2.2.3.Rastgele Ormanlar (Random Forests)	62
3.1.2.3.Derin Öğrenme	62
3.1.2.3.1.Yapay Sinir Ağları (YSA)	64
3.1.2.3.1.1.Çok Katmanlı Algılayıcılar (MLP)	64
3.1.2.4.Veri Kümesinin Sınıflandırılması	65
3.1.2.4.1.Eğitim (Train)	66
3.1.2.4.2.Test	67
3.1.2.5.Performans Ölçütleri Analizi	68
3.1.2.5.1.Doğruluk (Accuracy)	68
3.1.2.5.2.Kök Ortalama Kare Hatası (Root Mean Squared Error – RMSE)	69
3.2.ZAMAN SERİLERİ	69
3.2.1.Basit Öngörü Yöntemleri	70
3.2.1.1.Naif Yöntem (Naive Method)	70
3.2.1.2.Basit Ortalama (Simple Average)	71
3.2.1.3.Basit Hareketli Ortalama (Simple Moving Average – SMA)	71
3.2.2.Arima Modelleri İle Öngörü	73
3.2.2.1.Mevsimsel Arima (Sarimax)	74
3.2.3.Python Kütüphaneler	76
BÖLÜM 4: ARAŞTIRMA METODOLOJİSİ.....	78
4.1.ARAŞTIRMANIN MODELİ VE HİPOTEZLERİ	78
4.2.MATERYAL VE YÖNTEM	79
4.3.VERİ SETİ VE KAPSAMI	80
BÖLÜM 5: BULGULAR.....	86
5.1.ANALİZ	86
5.1.1.RMSE - Hata Karelerinin Ortalamasının Karekökü (Root Mean Squared Error)	86
5.1.2.Doğruluk	87
5.2.TARTIŞMA	89
5.2.1.RMSE	89
5.2.2.Doğruluk	92
BÖLÜM 6: SONUÇ VE ÖNERİLER.....	94
6.1.TARTIŞMA	94
6.2.ARAŞTIRMANIN LİTERATÜRE KATKISI	96
6.3.ARAŞTIRMANIN LİTERATÜR BULGULARI İLE KARŞILAŞTIRILMASI	97

6.4.YENİ ARAŞTIRMA SORULARI	98
6.5.SONUÇ	100
6.6.ÖNERİLER	102
KAYNAKLAR.....	105
EKLER.....	119
EK A.....	119



ÖZET

MAKİNE ÖĞRENMESİ YÖNTEMLERİ VE ZAMAN SERİSİ ALGORİTMALARININ KARŞILAŞTIRILMASI: BİST TEMETTÜ 25

Bu tez çalışması, Borsa İstanbul (BİST) Temettü 25 Endeksi'nde bulunan şirketlerin hisse başına net temettü fiyatlarını tahmin etmek için makine öğrenimi yöntemleri ile zaman serisi algoritmalarının performansını karşılaştırmayı amaçlamaktadır. Bu çalışma, finansal teknolojilerin hızla ilerlediği bir dönemde yatırımcılara temettü odaklı yatırım stratejileri konusunda rehberlik etmeyi ve hangi tahmin modellerinin daha etkili sonuçlar doğurduğunu belirlemeyi hedeflemektedir. Bu bağlamda, Naif Yöntem, Basit Ortalama, Basit Hareketli Ortalama ve SARIMA gibi zaman serisi modellerinin yanı sıra Lojistik Regresyon, SVM, Naive Bayes, K-NN, Karar Ağaçları, LDA, AdaBoost, Gradient Boosting, Bagging, Random Forest ve MLP gibi makine öğrenmesi algoritmaları tercih edilmiştir.

Araştırma, 2011 ile 2024 yılları arasında BİST Temettü 25 Endeksi'nde bulunan 25 şirketin hisse senedi fiyatlarını kapsayan 13 yıla ait bir veri seti üzerinde yapılmıştır. Tahmin modellerinin başarısı, RMSE (Hata Karelerinin Ortalamasının Karekökü) ve doğruluk (accuracy) gibi ölçütler aracılığıyla analiz edilmiştir. Sonuçlar, zaman serisi analizinde SARIMA modelinin ve makine öğrenimi yöntemleri arasında ise LDA, Random Forest ile Naive Bayes'in en düşük hata oranlarına sahip olduğunu ortaya koymuştur. Bu modeller, tahmin başarılarıyla dikkat çekmektedir. Ayrıca, genel olarak, makine öğrenimi modellerinin elde ettiği doğruluk değerlerinin zaman serisi modellerine kıyasla daha yüksek olduğu gözlemlenmiştir.

Bu çalışma, temettü odaklı yatırımcılar ve yazılım şirketleri için ölçülebilir içgörüler sunan etkili tahmin modelleri sağlayarak hibrid modelleme ve sektörel analizler ile literatüre katkıda bulunmaktadır.

Anahtar Kelimeler: BİST Temettü 25 Endeksi, Zaman Serileri, Makine Öğrenmesi, Yatırım Stratejileri, Hisse Başı Net TL

Tarih: Haziran 2025

SUMMARY

COMPARISON OF MACHINE LEARNING METHODS AND TIME SERIES ALGORITHMS: BIST DIVIDEND 25

The thesis objective of this study is to evaluate how machine learning approaches and time-series based algorithms in estimating the net dividend per share of companies for Borsa Istanbul (BIST) Dividend 25 Index. The purpose of the study is to aid investors employing a dividend investment policy in devising the most effective forecasting models during this era of advancing financial technologies. In this research scope, time series models including Naïve Method, Simple Average, Simple Moving Average, and SARIMA were implemented alongside machine learning algorithms of varying complexity such as Logistic Regression, SVM, Naïve Bayes, K-NN, Decision Trees, LDA, AdaBoost, Gradient Boosting, Bagging, MLP, and Random Forest.

The analysis in this study was centered on the stock price data of 25 companies which constitute the BIST Dividend 25 Index covering the years 2011 to 2024, for a total of thirteen years. The study evaluated the performance of the different forecasting models using RMSE (root mean square error) and several other accuracy measures. The study found that among the time series approaches, SARIMA was the most accurate while among the machine learning approaches LDA, Random Forest and the Naïve Bayes models had the minimum error rates. Furthermore, the results indicated that machine learning models did outperform time series models in regards to the accuracy values but not significantly.

This study pops up new in the literature by providing useful prediction modeling for investment-driven dividends for stock investors and software firms, alongside hybrid model suggestions and analyses based on sectors.

Keywords: BIST Dividend 25 Index, Time Series, Machine Learning, Investment Strategies, Net TL Per Share

Date: June 2025

SEMBOLLER

b_0	: Sabit terimi (intercept)
b_1	: Bağımsız değişken katsayısı
d	: İki nokta arasındaki mesafe
$d(x,y)$	: İki nokta arasındaki mesafe
e	: Euler sayısı (yaklaşık 2.718)
i	: Şirket
n	: Veri noktalarının boyutu (özellik sayısı)
ÖT_i	: Toplam brüt nakit temettü tutarı
PD_i	: Piyasa değeri
SAT_i	: Toplam rüçhan ve bedelli sermaye artırım tutarı
SMA_t	: t Zamanındaki Hareketli Ortalama
TV_i	: Temettü verimi
x	: Bağımsız değişken
x_i	: Birinci noktanın i. özelliğinin değeri
y	: Olasılık
y_i	: İkinci noktanın i. özelliğinin değeri
$y^{\wedge}_i$	: Tahmin edilen değerler
y_t	: t Zamanındaki Gerçek Gözlem Değer
$y^{\wedge}_{t+1}$	: t+1 Zamanındaki Tahmin Edilen Değer
z	: Doğrusal regresyon modeli
Σ	: Toplam

KISALTMALAR

AI	: Artificial Intelligence
AIIB	: Asya Altyapı Yatırım Bankası
ANN	: Artificial Neural Networks
AR	: Augmented Reality
ARIMA	: AutoRegressive Integrated Moving Average
ATM	: Automated Teller Machine
BİST	: Borsa İstanbul
CART	: Classification and Regression Trees
CPS	: Cyber-Physical Systems
DeFi	: Decentralized Finance
DL	: Deep Learning
DLT	: Distributed Ledger Technology
DÖ	: Derin Öğrenme
GZTF	: Güçlü, Zayıf, Tehdit, Fırsat
IN	: Intelligent Network
IoS	: Internet of Services
IoT	: Internet of Things
K-NN	: K-Nearest Neighbors
KYC	: Know Your Customer
LDA	: Linear Discriminant Analysis
M2M	: Machine-to-Machine
ML	: Machine Learning
MLP	: Multilayer Perceptron
MÖ	: Makine Öğrenmesi
MSB	: Mobile Broadband System
NFC	: Near Field Communication
OECD	: Organisation for Economic Co-operation and Development
OVP	: Orta Vadeli Program
P2P	: Peer-to-Peer

POS	: Point of Sale
QC	: Quantum Computing
QR	: Quick Response
RMSE	: Root Mean Squared Error
RPA	: Robotic Process Automation
SARIMAX	: Seasonal AutoRegressive Integrated Moving Average with eXogenous variables
SMA	: Simple Moving Average
SNARC	: Stochastic Neural Analog Reinforcement Computer
STEM	: Science, Technology, Engineering, Mathematics
SVM	: Support Vector Machines
TOGG	: Türkiye'nin Otomobili Girişim Grubu
VR	: Virtual Reality
XTM25	: BİST Temüttü 25 Endeksi
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ
6G	: Sixth-Generation Wireless Technology

ŞEKİL LİSTESİ

Şekil 1: Endüstri 4.0 Gelişim Süreçleri.....	12
Şekil 2: Endüstri 1.0'dan 4.0'a Doğru.....	13
Şekil 3: Geleneksel ve Metaverse Ekonomisi.....	24
Şekil 4: 6.Nesil (6G) İletişim Ağının Gelişim Süreçleri.....	26
Şekil 5: Fintek Tarihçesi.....	30
Şekil 6: Fintek Ekosisteminde Yer Alan Unsurlar.....	31
Şekil 7: Fintek GZTF Analizi.....	32
Şekil 8: Fintek ve Bilgi Güvenliği GZTF Analizi.....	35
Şekil 9: Finansal Okuryazarlık GZTF Analizi.....	36
Şekil 10: BİST 100 Kapanış Fiyatları (2003-2023).....	37
Şekil 11: BİST 100 Kapanış Fiyatları (2003-2013).....	37
Şekil 12: BİST 100 Kapanış Fiyatları (2013-2018).....	38
Şekil 13: BİST 100 Kapanış Fiyatları (2018-2023).....	38
Şekil 14: Toplum 5.0 ve Bankacılık.....	39
Şekil 15: Temettü Verimi.....	42
Şekil 16: BİST TEMETTÜ 25 Endeksi ve Temettü Yatırımları GZTF Analizi.....	43
Şekil 17: Finansal Hizmetlerde Dijital Dönüşümü Sağlayan Başlıca Teknolojiler.....	45
Şekil 18: Yapay Zekâ ve Alt Kümeleri.....	47
Şekil 19: Yapay Zekâ GZTF Analizi.....	48
Şekil 20: Makine Öğrenmesi Bileşenleri.....	49
Şekil 21: Makine Öğrenmesi Modelleri.....	50
Şekil 22: Makine Öğrenmesinde Kullanılan Adımlar.....	51
Şekil 23: Makine Öğrenmesi GZTF Analizi.....	52
Şekil 24: Gözetimli (Supervised) Makine Öğrenmesi.....	53
Şekil 25: Lojistik Regresyon Denklemi.....	54
Şekil 26: K-NN Denklemi.....	56
Şekil 27: Karar Ağaçları.....	57
Şekil 28: Gözetimsiz (UnSupervised) Makine Öğrenmesi.....	58
Şekil 29: Topluluk Öğrenme (Ensemble).....	59

Şekil 30: MLP Mimari Yapısı.....	65
Şekil 31: Doğruluk Formülü.....	68
Şekil 32: RMSE Formülü.....	69
Şekil 33: Naif Yöntem Formülü.....	70
Şekil 34: Naif Yöntemi Kod Satırları.....	71
Şekil 35: Basit Ortalama Yöntemi Formülü.....	71
Şekil 36: Basit Ortalama Yöntemi Kod Satırları.....	72
Şekil 37: Basit Hareketli Ortalama Yöntemi Formülü.....	72
Şekil 38: Basit Hareketli Ortalama Yöntemi Kod Satırları.....	73
Şekil 39: ARIMA Yöntemi Kod Satırları.....	74
Şekil 40: SARIMAX Yöntemi Kod Satırları.....	76
Şekil 41: Araştırmanın Modeli (RMSE).....	78
Şekil 42: Araştırmanın Modeli (Doğruluk).....	79
Şekil 43: Makine Öğrenmesi Modelinin Çalışması.....	80
Şekil 44: Sektörel Dağılım Grafiği.....	82
Şekil 45: RMSE Öngörü Analizi Kod Satırları.....	86
Şekil 46: RMSE Analizi Sonuçları Kod Satırları.....	87
Şekil 47: AEFES Genel Görünüm.....	119
Şekil 48: AEFES Eğitim ve Test Veri Kümesi.....	119
Şekil 49: AEFES Naif Model Öngörülleri.....	120
Şekil 50: AEFES Basit Ortalama Öngörülleri.....	120
Şekil 51: AEFES Basit Hareketli Ortalama Öngörülleri.....	120
Şekil 52: AEFES Sarima Öngörülleri.....	121
Şekil 53: AKBNK Genel Görünüm.....	121
Şekil 54: AKBNK Eğitim ve Test Veri Kümesi.....	121
Şekil 55: AKBNK Naif Model Öngörülleri.....	122
Şekil 56: AKBNK Basit Ortalama Öngörülleri.....	122
Şekil 57: AKBNK Basit Hareketli Ortalama Öngörülleri.....	122
Şekil 58: AKBNK Sarima Öngörülleri.....	123
Şekil 59: AKSA Genel Görünüm.....	123
Şekil 60: AKSA Eğitim ve Test Veri Kümesi.....	123
Şekil 61: AKSA Naif Model Öngörülleri.....	124
Şekil 62: AKSA Basit Ortalama Öngörülleri.....	124
Şekil 63: AKSA Basit Hareketli Ortalama Öngörülleri.....	124

Şekil 64: AKSA Sarima Öngörülleri.....	125
Şekil 65: AKSEN Genel Görünüm.....	125
Şekil 66: AKSEN Eğitim ve Test Veri Kümesi.....	125
Şekil 67: AKSEN Naif Model Öngörülleri.....	126
Şekil 68: AKSEN Basit Ortalama Öngörülleri.....	126
Şekil 69: AKSEN Basit Hareketli Ortalama Öngörülleri.....	126
Şekil 70: AKSEN Sarima Öngörülleri.....	127
Şekil 71: BIMAS Genel Görünüm.....	127
Şekil 72: BIMAS Eğitim ve Test Veri Kümesi.....	127
Şekil 73: BIMAS Naif Model Öngörülleri.....	128
Şekil 74: BIMAS Basit Ortalama Öngörülleri.....	128
Şekil 75: BIMAS Basit Hareketli Ortalama Öngörülleri.....	128
Şekil 76: BIMAS Sarima Öngörülleri.....	129
Şekil 77: BRYAT Genel Görünüm.....	129
Şekil 78: BRYAT Eğitim ve Test Veri Kümesi.....	129
Şekil 79: BRYAT Naif Model Öngörülleri.....	130
Şekil 80: BRYAT Basit Ortalama Öngörülleri.....	130
Şekil 81: BRYAT Basit Hareketli Ortalama Öngörülleri.....	130
Şekil 82: BRYAT Sarima Öngörülleri.....	131
Şekil 83: CIMSA Genel Görünüm.....	131
Şekil 84: CIMSA Eğitim ve Test Veri Kümesi.....	131
Şekil 85: CIMSA Naif Model Öngörülleri.....	132
Şekil 86: CIMSA Basit Ortalama Öngörülleri.....	132
Şekil 87: CIMSA Basit Hareketli Ortalama Öngörülleri.....	132
Şekil 88: CIMSA Sarima Öngörülleri.....	133
Şekil 89: DOAS Genel Görünüm.....	133
Şekil 90: DOAS Eğitim ve Test Veri Kümesi.....	133
Şekil 91: DOAS Naif Model Öngörülleri.....	134
Şekil 92: DOAS Basit Ortalama Öngörülleri.....	134
Şekil 93: DOAS Basit Hareketli Ortalama Öngörülleri.....	134
Şekil 94: DOAS Sarima Öngörülleri.....	135
Şekil 95: ECILC Genel Görünüm.....	135
Şekil 96: ECILC Eğitim ve Test Veri Kümesi.....	135
Şekil 97: ECILC Naif Model Öngörülleri.....	136

Şekil 98: ECILC Basit Ortalama Öngörülleri.....	136
Şekil 99: ECILC Basit Hareketli Ortalama Öngörülleri.....	136
Şekil 100: ECILC Sarıma Öngörülleri.....	137
Şekil 101: ENJSA Genel Görünüm.....	137
Şekil 102: ENJSA Eğitim ve Test Veri Kümesi.....	137
Şekil 103: ENJSA Naif Model Öngörülleri.....	138
Şekil 104: ENJSA Basit Ortalama Öngörülleri.....	138
Şekil 105: ENJSA Basit Hareketli Ortalama Öngörülleri.....	138
Şekil 106: ENJSA Sarıma Öngörülleri.....	139
Şekil 107: ENKAI Genel Görünüm.....	139
Şekil 108: ENKAI Eğitim ve Test Veri Kümesi.....	139
Şekil 109: ENKAI Naif Model Öngörülleri.....	140
Şekil 110: ENKAI Basit Ortalama Öngörülleri.....	140
Şekil 111: ENKAI Basit Hareketli Ortalama Öngörülleri.....	140
Şekil 112: ENKAI Sarıma Öngörülleri.....	141
Şekil 113: FROTO Genel Görünüm.....	141
Şekil 114: FROTO Eğitim ve Test Veri Kümesi.....	141
Şekil 115: FROTO Naif Model Öngörülleri.....	142
Şekil 116: FROTO Basit Ortalama Öngörülleri.....	142
Şekil 117: FROTO Basit Hareketli Ortalama Öngörülleri.....	142
Şekil 118: FROTO Sarıma Öngörülleri.....	143
Şekil 119: GARAN Genel Görünüm.....	143
Şekil 120: GARAN Eğitim ve Test Veri Kümesi.....	143
Şekil 121: GARAN Naif Model Öngörülleri.....	144
Şekil 122: GARAN Basit Ortalama Öngörülleri.....	144
Şekil 123: GARAN Basit Hareketli Ortalama Öngörülleri.....	144
Şekil 124: GARAN Sarıma Öngörülleri.....	145
Şekil 125: ISCTR Genel Görünüm.....	145
Şekil 126: ISCTR Eğitim ve Test Veri Kümesi.....	145
Şekil 127: ISCTR Naif Model Öngörülleri.....	146
Şekil 128: ISCTR Basit Ortalama Öngörülleri.....	146
Şekil 129: ISCTR Basit Hareketli Ortalama Öngörülleri.....	146
Şekil 130: ISCTR Sarıma Öngörülleri.....	147
Şekil 131: ISMEN Genel Görünüm.....	147

Şekil 132: ISMEN Eğitim ve Test Veri Kümesi.....	147
Şekil 133: ISMEN Naif Model Öngörülleri.....	148
Şekil 134: ISMEN Basit Ortalama Öngörülleri.....	148
Şekil 135: ISMEN Basit Hareketli Ortalama Öngörülleri.....	148
Şekil 136: ISMEN Sarima Öngörülleri.....	149
Şekil 137: KCHOL Genel Görünüm.....	149
Şekil 138: KCHOL Eğitim ve Test Veri Kümesi.....	149
Şekil 139: KCHOL Naif Model Öngörülleri.....	150
Şekil 140: KCHOL Basit Ortalama Öngörülleri.....	150
Şekil 141: KCHOL Basit Hareketli Ortalama Öngörülleri.....	150
Şekil 142: KCHOL Sarima Öngörülleri.....	151
Şekil 143: MAVI Genel Görünüm.....	151
Şekil 144: MAVI Eğitim ve Test Veri Kümesi.....	151
Şekil 145: MAVI Naif Model Öngörülleri.....	152
Şekil 146: MAVI Basit Ortalama Öngörülleri.....	152
Şekil 147: MAVI Basit Hareketli Ortalama Öngörülleri.....	152
Şekil 148: MAVI Sarima Öngörülleri.....	153
Şekil 149: SAHOL Genel Görünüm.....	153
Şekil 150: SAHOL Eğitim ve Test Veri Kümesi.....	153
Şekil 151: SAHOL Naif Model Öngörülleri.....	154
Şekil 152: SAHOL Basit Ortalama Öngörülleri.....	154
Şekil 153: SAHOL Basit Hareketli Ortalama Öngörülleri.....	154
Şekil 154: SAHOL Sarima Öngörülleri.....	155
Şekil 155: SISE Genel Görünüm.....	155
Şekil 156: SISE Eğitim ve Test Veri Kümesi.....	155
Şekil 157: SISE Naif Model Öngörülleri.....	156
Şekil 158: SISE Basit Ortalama Öngörülleri.....	156
Şekil 159: SISE Basit Hareketli Ortalama Öngörülleri.....	156
Şekil 160: SISE Sarima Öngörülleri.....	157
Şekil 161: TCELL Genel Görünüm.....	157
Şekil 162: TCELL Eğitim ve Test Veri Kümesi.....	157
Şekil 163: TCELL Naif Model Öngörülleri.....	158
Şekil 164: TCELL Basit Ortalama Öngörülleri.....	158
Şekil 165: TCELL Basit Hareketli Ortalama Öngörülleri.....	158

Şekil 166: TCELL Sarima Öngörülleri.....	159
Şekil 167: TOASO Genel Görünüm.....	159
Şekil 168: TOASO Eğitim ve Test Veri Kümesi.....	159
Şekil 169: TOASO Naif Model Öngörülleri.....	160
Şekil 170: TOASO Basit Ortalama Öngörülleri.....	160
Şekil 171: TOASO Basit Hareketli Ortalama Öngörülleri.....	160
Şekil 172: TOASO Sarima Öngörülleri.....	161
Şekil 173: TTRAK Genel Görünüm.....	161
Şekil 174: TTRAK Eğitim ve Test Veri Kümesi.....	161
Şekil 175: TTRAK Naif Model Öngörülleri.....	162
Şekil 176: TTRAK Basit Ortalama Öngörülleri.....	162
Şekil 177: TTRAK Basit Hareketli Ortalama Öngörülleri.....	162
Şekil 178: TTRAK Sarima Öngörülleri.....	163
Şekil 179: TURSG Genel Görünüm.....	163
Şekil 180: TURSG Eğitim ve Test Veri Kümesi.....	163
Şekil 181: TURSG Naif Model Öngörülleri.....	164
Şekil 182: TURSG Basit Ortalama Öngörülleri.....	164
Şekil 183: TURSG Basit Hareketli Ortalama Öngörülleri.....	164
Şekil 184: TURSG Sarima Öngörülleri.....	165
Şekil 185: VESBE Genel Görünüm.....	165
Şekil 186: VESBE Eğitim ve Test Veri Kümesi.....	165
Şekil 187: VESBE Naif Model Öngörülleri.....	166
Şekil 188: VESBE Basit Ortalama Öngörülleri.....	166
Şekil 189: VESBE Basit Hareketli Ortalama Öngörülleri.....	166
Şekil 190: VESBE Sarima Öngörülleri.....	167
Şekil 191: YKBNK Genel Görünüm.....	167
Şekil 192: YKBNK Eğitim ve Test Veri Kümesi.....	167
Şekil 193: YKBNK Naif Model Öngörülleri.....	168
Şekil 194: YKBNK Basit Ortalama Öngörülleri.....	168
Şekil 195: YKBNK Basit Hareketli Ortalama Öngörülleri.....	168
Şekil 196: YKBNK Sarima Öngörülleri.....	169

TABLO LİSTESİ

Tablo 1: Literatür Taraması.....	4
Tablo 2: Fintek'in Kullandığı Teknolojiler.....	29
Tablo 3: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Kıyaslamaları.....	63
Tablo 4: Değişkenler.....	78
Tablo 5: Şirketler.....	81
Tablo 6: Ana Kategori.....	82
Tablo 7: Alt Kategori.....	83
Tablo 8: Şirket Sayısı İtibariyle Sektörel Dağılımı.....	83
Tablo 9: Doğruluk Değeri Genel Sonuçları.....	87
Tablo 10: RMSE Performans Genel Sonuçları.....	89
Tablo 11: RMSE Performans Özet Sonuçları.....	90
Tablo 12: Doğruluk Değerleri Özet Sonuçları.....	92

BÖLÜM 1: GİRİŞ

Finans sektöründeki dijital dönüşüm, bankacılıkta büyük veri analitiği, yapay zekâ ve diğer ileri teknolojilerin yaygınlaşması ile birlikte bir evrim geçirmektedir. Bankacılık sektöründe yapılan ileri seviye tahminler, yatırım stratejileri belirleme sürecinde büyük kritik öneme sahiptir. Yatırım kararlarında, teknik analiz, makine öğrenmesi ve zaman serisi algoritmaları gibi ileri düzey tahmin sistemleri kullanılır. Fakat bu yöntemlerin doğruluğu ve etkinliği konusunda farklı modellerin karşılaştırmalı olarak değerlendirilmesi gereklidir.

1.1. PROBLEM DURUMU

Analizlerin temel uygulama alanlarından biri ise yatırımcılar açısından önemli bir sinyal niteliği taşıyan Borsa İstanbul'da (BİST) işlem gören şirketlerin temettü dağıtım süreçleri olmaktadır. Temettü 25 endeksinde yer alan şirketlerin hisse fiyat hareketleri yatırımcının karar alma sürecinde belirleyici bir faktördür. Bu çalışmada, farklı makine öğrenmesi teknikleri ve zaman serisi analiz yöntemlerinin doğruluk performansları incelenerek en başarılı modelin belirlenmesi hedeflenmiştir.

1.2. ÇALIŞMANIN AMACI VE ÖNEMİ

Bu çalışmanın temel amacı, BIST Temettü 25 Endeksi'nde yer alan şirketlerin hisse senedi fiyat verilerinin tahmini için kullanılan farklı makine öğrenimi ve zaman serisi algoritmalarının performanslarını karşılaştırmaktır. Çalışma kapsamında, Python programlama dili kullanılarak Naif Yöntem, Basit Ortalama, Basit Hareketli Ortalama ve SARIMA gibi zaman serisi modelleri ile Lojistik Regresyon, SVM, Naive Bayes, K-NN, Karar Ağaçları, LDA, AdaBoost, Gradient Boosting, Bagging, RandomForest ve MLP gibi makine öğrenmesi yöntemlerinin performansları analiz edilmiştir.

Bu çalışma, finansal piyasalarla ilgili olan akademisyenler, yatırımcılar ve yazılım geliştiriciler için değerli bilgiler sunmaktadır. Doğru tahmin modellerinin belirlenmesi, yatırımcılara daha sağlam tahminler elde etme imkânı sağlayarak, risk yönetimini iyileştirme potansiyeline sahiptir. Aynı zamanda, bankacılık ve finans alanında yapay zekâ temelli analizlerin benimsenmesi ve etkili bir şekilde kullanımı açısından rehberlik eden bir yön taşımaktadır.

1.3. MODELİN KURGUSU

Çalışmada kullanılacak modeller, finansal veri setlerinin zaman serisi analizi ile işlenmesini ve çeşitli makine öğrenimi algoritmalarının uygulanmasını içermektedir. Bu süreç temel olarak aşağıdaki adımlardan oluşmaktadır:

- **Veri Toplama:** BİST Temettü 25 endeksinde bulunan şirketlerin geçmiş fiyat hareketleri ile temettü verilerinin bir araya getirilmesi.
- **Veri Ön İşleme:** Eksik verilerin tamamlanması, veri setinin uygun bir biçime dönüştürülmesi ve normalizasyon süreçlerinin gerçekleştirilmesi.
- **Modelleme:** Naif Yöntem, Basit Ortalama, Basit Hareketli Ortalama ve SARIMA gibi zaman serisi analiz modelleri, Lojistik Regresyon, SVM, Naive Bayes, K-NN, Karar Ağaçları, LDA, AdaBoost, Gradient Boosting, Bagging, RandomForest ve MLP gibi makine öğrenmesi tekniklerinin uygulanması.
- **Performans Değerlendirmesi:** RMSE (Root Mean Square Error) ve doğruluk ölçütü kullanarak model sonuçlarının karşılaştırılması.
- **Sonuçların Analizi:** Finansal karar süreçlerindeki en etkili tahmin modelini belirlemek ve bu modelin potansiyel etkilerinin incelemesi.

Bu çalışmada, bağımlı değişken olarak hisse başına net TL (Net TL Per Share) kullanılmıştır ve tarih ise bağımsız değişken olarak değerlendirilmiştir. Gruplandırmayı sağlayan öge ise hisse adıdır. Modeller, zaman serisi ve makine öğrenmesi yöntemlerini bir araya getirerek geçmiş verilerden kalıpları analiz etmeyi ve gelecekteki temettü ödemelerini tahmin etmeyi amaçlamaktadır.

1.4. HİPOTEZLER

Çalışmada, öngörü performansını karşılaştırmak amacıyla RMSE ölçütü temelinde 4 hipotez belirlenmiş ve en yüksek doğruluk değerine sahip modellerin veri setine en uygun model olduğu varsayımı altında toplam 11 hipotez geliştirilmiştir. Toplamda 15 hipotez incelenmiştir. Bu hipotezlerin amacı, değişik yöntemlerin etkinliğini karşılaştırmak ve en iyi tahmin modelini bulmaktır.

1.5. ÇALIŞMANIN SINIRLILIKLARI

Bu çalışma, aşağıda belirtilen sınırlamalar doğrultusunda yapılmıştır:

- **Veri Seti:** Analizler, sadece BİST Temettü 25 endeksinde bulunan şirketlerin 2011-2024 dönemine ait verileri ile kısıtlanmıştır.
- **Model Performansı:** Analizler, yalnızca BİST Temettü 25 endeksindeki şirketlerin 2011-2024 yılları arasındaki verileriyle sınırlıdır.
- **Piyasa Koşulları:** Çalışma, önceki verilere dayanarak yapılan analizler sunmaktadır; bu nedenle piyasalardaki hızlı değişimler ya da makroekonomik olaylar gibi dış faktörlerin etkisini doğrudan göz önünde bulundurmamaktadır.

Bu araştırma, yatırımcılar ve yazılım şirketleri için çeşitli tahmin tekniklerinin güçlü ve zayıf yönlerini belirleyerek, daha bilinçli kararlar almalarına destek olmayı amaçlamaktadır.

1.6. LİTERATÜR

Literatürde temettü, zaman serileri ve makine öğrenimi konularında yerli ve yabancı birçok çalışma bulunmaktadır. Ancak bu araştırmaların arasında, Hisse Başlı Net TL temettü verileri incelenerek Zaman ve Mevsimsel ARIMA (SARIMAX) Öngörüleme Sistemleri, Yapay Sinir Ağları ve Makine Öğrenmesi yöntemleri kullanılarak doğru tahmin yapabilen tekniklerin RMSE ölçütüne göre karşılaştırıldığı bir çalışma yapılmamıştır. Bu alanda en düşük hata sonucunu veren yöntemler üzerine kapsamlı bir değerlendirme eksikliği mevcuttur.

Fintek, temettü, zaman serisi ve makine öğrenmesi konularında literatürde gerçekleştirilen çalışmaların incelenmesi sonucunda;

Tablo 1: Literatür Taraması

Referans İsmi	Yazar	Yıl	Araştırmanın Evreni	Sonuç
The Evolution of Fintek: A New Post-Crisis Paradigm?	Arner, D. W., Barberis, J., Buckley, R.P.	2015	Finansal teknolojilerin küresel evrimi	Fintek, finansal kriz sonrası yeni bir paradigma olarak ortaya çıkmıştır ve finansal sistemin dönüşümüne katkıda bulunmaktadır.
The rise of Fintek opportunities and challenges	Pollari, I.	2016	Finansal teknolojilerin yükselişi	Fintek, finansal hizmetlerde fırsatlar sunarken, düzenleyici ve güvenlik zorluklarını da beraberinde getirmektedir.
Digitization of the Financial Services Industry	Puschmann, T.	2017	Finansal hizmetler endüstrisinin dijitalleşmesi	Dijitalleşme, finansal hizmetler endüstrisinde verimliliği artırırken, yeni iş modelleri ve rekabet dinamikleri yaratmaktadır.
Yükselen Finansal Teknolojilerin Ekonomi Politikası: Fintek ve Bitcoin Örnekleri	Yağcı, M.	2018	Finansal teknolojiler ve Bitcoin	Fintek, finansal sistemde şeffaflık ve erişilebilirlik sağlarken, Bitcoin gibi kripto paralar geleneksel finansal sistemlere alternatif oluşturmaktadır.
Digital Finance and Fintek: current research and future research directions	Gomber, P., Koch, J., Siering, M.	2017	Dijital finans ve Fintek	Dijital finans ve Fintek alanında mevcut araştırmalar ve gelecekteki araştırma yönleri incelenmiştir.
Fintek and the transformation of the financial industry	Alt, R., Beck, R., Smits, M.T.	2018	Finansal endüstrinin dönüşümü	Fintek, finansal endüstrinin dönüşümünde kilit bir rol oynamakta ve yeni iş modelleri yaratmaktadır.
A survey on Fintek	Gai, K., Qiu, M., Sun, X.	2018	Finansal teknolojiler	Fintek, finansal hizmetlerde yenilikçi çözümler sunarken, güvenlik ve gizlilik sorunlarını da beraberinde getirmektedir.
Fintek: Ecosystem, business models, investment decisions, and challenges	Lee, I., Shin, Y. J.	2018	Fintek ekosistemi	Fintek ekosistemi, yeni iş modelleri ve yatırım kararlarıyla finansal hizmetleri dönüştürmektedir.

The evolution of the financial technology ecosystem	Palmié, M., Wincent, J., Parida, V., Caglar, U.	2019	Finansal teknoloji ekosistemi	Finansal teknoloji ekosistemi, disruptif yeniliklerle birlikte gelişmekte ve gelecekteki araştırmalar için bir yol haritası sunmaktadır.
Bankalarda Finansal Teknoloji Ve Yenilikler	Danacı, M. C., Çetintaş, Ö.	2020	Bankacılık sektörü	Bankalar, finansal teknolojileri benimseyerek müşteri deneyimini iyileştirmekte ve operasyonel verimliliği artırmaktadır.
Finans sektöründe Fintek etkisi	Bulazar, A. R., Küçükçolak, Ö. Ü. R. A.	2021	Finans sektörü	Fintek, finans sektöründe yenilikçi çözümler sunarken, geleneksel finansal kurumların dönüşümünü hızlandırmaktadır.
The analysis of Fintek sector in Turkey	Karaömer, Y.	2021	Türkiye'de Fintek sektörü	Türkiye'de Fintek sektörü hızla büyümekte ve finansal kapsayıcılığı artırmaktadır.
Temettü Tahmini Ve Borsa İstanbul Sanayi Sektörü Üzerine Bir Araştırma	Arsoy, M. F., Yıldız, B.	2015	Borsa İstanbul Sanayi Sektörü	Temettü tahmini, firma performansı ve piyasa koşullarına bağlı olarak değişmektedir.
Nakit Temettü Tahmininde Makine Öğrenmesi Yaklaşımı	Arsoy, M. F., Güreşen, E.	2016	İmalat sektörü	Makine öğrenmesi, nakit temettü tahmininde geleneksel yöntemlere göre daha doğru sonuçlar vermektedir.
Temettü Ödemelerinin Belirleyicileri Ve Firma Değeri	Çelik, Ş., Yenice, S., Onat, O. K.	2016	Firma değeri ve temettü ödemeleri	Temettü ödemeleri, firma değerini etkileyen önemli bir faktördür ve finansal performansla ilişkilidir.
İmalat Sanayi Ve Finansal Sektörde Temettü Dağıtımlarının Kısa Dönemli Fiyat Etkisi	Okuyan, H. A., Sakarya, Ş., Aydın, C., Deniz, D.	2020	Borsa İstanbul	Temettü dağıtımları, kısa dönemde hisse senedi fiyatlarını etkilemektedir.
Testing Dividend Signaling Theory in Turkey	Kaymaz, Ö., Kaymaz, O., Güvemli, B.	2021	Borsa İstanbul'da halka açık firmalar	Temettü sinyal teorisi, Türkiye gibi gelişmekte olan piyasalarda geçerliliğini korumaktadır.
Makine Öğrenmesi Ve Derin Öğrenme Algoritmalarını Kullanarak Hisse Senedi Fiyat Tahmini	Arslankaya, S., Toprak, Ş.	2021	Hisse senedi fiyat tahmini	Makine öğrenmesi ve derin öğrenme algoritmaları, hisse senedi fiyat tahmininde geleneksel yöntemlere göre daha yüksek doğruluk sağlamaktadır.

A New Hybrid Financial Time Series Prediction Model	Alhnaity, B., Abbod, M.	2020	Finansal zaman serileri	Hibrit finansal zaman serisi tahmin modelleri, geleneksel modellere göre daha iyi performans göstermektedir.
Modaugnet: A New Forecasting Framework For Stock Market Index Value	Baek, Y., Kim, H. Y.	2018	Hisse senedi endeks değerleri	Modaugnet, hisse senedi endeks değerlerini tahmin etmede aşırı öğrenmeyi önleyen yeni bir çerçeve sunmaktadır.
Forecasting The Volatility Of Stock Price Index	Kim, H. Y., Won, C. H.	2018	Hisse senedi endeks volatilitesi	Hibrit modeller, hisse senedi endeks volatilitelerini tahmin etmede geleneksel modellere göre daha etkilidir.
Stock Closing Price Prediction Using Machine Learning Techniques	Vijh, M., Chandola, D., Tikkiwal, V. A., Kumar, A.	2020	Hisse senedi kapanış fiyatları	Makine öğrenmesi teknikleri, hisse senedi kapanış fiyatlarını tahmin etmede etkili sonuçlar vermektedir.
Firmalarda Temettü Politikalarını Etkileyen Unsurlar	Yıldız, B., Gökbulut, R. İ., Korkmaz, T.	2014	BİST Sanayi İşletmeleri	Temettü politikaları, firma karlılığı, büyüme oranları ve finansal yapı gibi faktörlerden etkilenmektedir.
Hisse Senedi Endeks Getirileri Ve Temettü Verimi	İlhan, E. G. E., Ulaş, Ü. N. L. Ü., Bayrakdaroğlu, A.	2009	İMKB 100 ve S&P 500 Endeksleri	Hisse senedi endeks getirileri ile temettü verimi arasında anlamlı bir ilişki bulunmaktadır.
Time series analysis of the relationships among (macro) economic variables, the dividend yield and the price level of the S&P 500 Index	Serfling, M. A., Miljkovic, D.	2011	S&P 500 Endeksi ve makroekonomik değişkenler	Makroekonomik değişkenler ve temettü verimi, S&P 500 fiyat seviyeleri ile ilişkilidir.
Fintech Risk Management: A Research Challenge for Artificial Intelligence in Finance	Giudici P	2018	Fintech ve yapay zeka	Yapay zeka, Fintech risk yönetiminde önemli bir araç olarak öne çıkmaktadır.
Explainable AI in Fintech Risk Management	Bussmann N, Giudici P, Marinelli D, Papenbrock J	2020	Fintech ve açıklanabilir yapay zeka	Açıklanabilir yapay zeka, Fintech risk yönetiminde şeffaflığı artırmaktadır.

Managing Risks In Fintech: Applications And Challenges Of Artificial Intelligence-Based Risk Management	Rolando, B., Mulyono, H.	2024	Fintech ve yapay zeka tabanlı risk yönetimi	Yapay zeka, Fintech'te risk yönetimi için etkili bir araçtır, ancak uygulama zorlukları bulunmaktadır.
Risk Management in Fintech	Tyagi, A.	2024	Fintech ve risk yönetimi	Fintech'te risk yönetimi, yapay zeka ve makine öğrenimi ile geliştirilebilir.
Relationship banking and information technology: the role of artificial intelligence and FinTech	Jakšič, M., Marinč, M.	2019	Bankacılık ve Fintech	Yapay zeka ve Fintech, ilişki bankacılığını dönüştürmektedir.
Discussion on the Enterprise Financial Risk Management Framework Based on AI Fintech	Liu, Y.	2024	Kurumsal finansal risk yönetimi ve AI Fintech	AI Fintech, kurumsal finansal risk yönetimi için yeni bir çerçeve sunmaktadır.
Dividend Policy as a Tool to Increase Firm Value	Lubis, E., Khaddafi, M., Satriawan, B.	2024	Temettü politikası ve firma değeri	Temettü politikası, firma değerini artırmada etkili bir araçtır.
Feature Selection and Hyperparameters Optimization Employing a Hybrid Model Based on Genetic Algorithm and Artificial Neural Network	Konak, F., Bülbül, M.A., Türkoğlu, D.	2024	Temettü ödeme oranı tahmini	Genetik algoritma ve yapay sinir ağları, temettü ödeme oranı tahmininde etkilidir.
Predictive Analytics in Finance: Leveraging AI and Machine Learning for Investment Strategies	Chhikara, H., Chhikara, S., Gupta, L.	2025	Finansal analiz ve yatırım stratejileri	Yapay zeka ve makine öğrenimi, finansal analiz ve yatırım stratejilerinde önemli bir rol oynamaktadır.

AI-Based Predictive Analytics for Financial Risk Management	Alsaadi, M., Almashhadany, M. T., Obaed, A. S., Furaijl, H. B., Kamil, S., Ahmed, S. R.	2024	Finansal risk yönetimi ve yapay zeka	Yapay zeka tabanlı tahmine dayalı analizler, finansal risk yönetiminde etkilidir.
Leveraging Predictive Analytics in Financing Decision-Making for Comparative Analysis and Optimization	Wirawan, P.	2023	Finansal karar alma ve tahmine dayalı analizler	Tahmine dayalı analizler, finansal karar alma süreçlerini optimize etmektedir.
The impact of predictive analytics on financial risk management in businesses	Chowdhury, R. H., Al Masum, A., Farazi, M. Z. R., Jahan, I.	2024	İşletmelerde finansal risk yönetimi	Tahmine dayalı analizler, işletmelerde finansal risk yönetimini iyileştirmektedir.
What drives FinTech adoption? A multi-method evaluation using an adapted technology acceptance model	Singh, S., Sahni, M.M., Kovid, R.K.	2020	Fintech kabulü	Fintech kabulü, teknoloji kabul modeli ile açıklanabilir.
Adoption of FinTech Products: A Systematic Literature Review	Utami, A. F., Ekaputra, I. A., Japutra, A.	2021	Fintech ürünlerinin benimsenmesi	Fintech ürünlerinin benimsenmesi, çeşitli faktörlere bağlıdır.
Evaluating Drivers of Fintech Adoption in the Netherlands	Hasan, R., Ashfaq, M., Shao, L.	2024	Hollanda'da Fintech benimsenmesi	Hollanda'da Fintech benimsenmesi, teknolojik ve sosyal faktörlere bağlıdır.
Fintech adoption across generations: Financial fitness in the information age	Carlin, B., Olafsson, A., Pagel, M.	2017	Fintech benimsenmesi ve nesiller	Fintech benimsenmesi, nesiller arasında farklılık göstermektedir.
Analysts' use of dividends in earnings forecasts	Das, S., Schaberl, P.D., Sen, P.K.	2024	Temettüleri ve kazanç tahminleri	Analistler, temettüleri kazanç tahminlerinde kullanmaktadır.

Analyst dividend forecasts and their usefulness to investors	Bilinski, P., Bradshaw, M. T.	2022	Temettü tahminleri ve yatırımcılar	Temettü tahminleri, yatırımcılar için faydalıdır.
Multimodal deep learning for finance: integrating and forecasting international stock markets	Lee, S.I., Yoo, S.J.	2020	Uluslararası borsa piyasaları	Çok modlu derin öğrenme, uluslararası borsa piyasalarının tahmininde etkilidir.
Global challenges and regulatory strategies to fintech	Gurreá-Martinez, A., Remolina, N.	2020	Fintech ve küresel düzenlemeler	Fintech, küresel düzenleme zorluklarıyla karşı karşıyadır.
Fintech, the digital age of financial services	Narez-Sánchez, I. A., Berttolini-Díaz, G. M.	2022	Fintech ve dijital finansal hizmetler	Fintech, finansal hizmetlerin dijitalleşmesinde önemli bir rol oynamaktadır.
Using machine learning algorithms on prediction of stock price	Chen, L. P.	2020	Hisse senedi fiyat tahmini	Makine öğrenimi algoritmaları, hisse senedi fiyat tahmininde etkilidir.
Predicting Stock Price Using Two-Stage Machine Learning Techniques	Zhang, J., Li, L., Chen, W.	2021	Hisse senedi fiyat tahmini	İki aşamalı makine öğrenimi teknikleri, hisse senedi fiyat tahmininde etkilidir.
Stock prediction using convolutional neural network	Chen, S., He, H.	2018	Hisse senedi tahmini	Evrişimli sinir ağları, hisse senedi tahmininde etkilidir.
Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Karşılaştırılması: Bir Borsa İstanbul Hissesi Örneği	Erden, C.	2023	Borsa İstanbul hisse senetleri	RNN algoritmasının diğerlerine göre daha iyi tahmin performansı gösterdiği ve test verisinde ortalama %93 doğrulukla tahmin yaptığı bulunmuştur.
Makine Öğrenmesi ile Finansal Zaman Serisi Tahminleme	Doğan, S., Büyükkör, Y.	2022	Finansal zaman serileri	Literatürde sıklıkla kullanılan SVR, RF ve XGBoost makine öğrenmesi yöntemlerinin teorik altyapısı sunulmuştur.

BÖLÜM 2: FİNANS SEKTÖRÜNDE DİJİTAL DÖNÜŞÜM

Finans sektöründe dijital dönüşüm, geleneksel finansal hizmetlerin dijital teknolojilerin kullanımıyla dönüştürülmesi ve yenilikçi çözümlerin sunulması sürecini ifade eder. Bu dönüşüm, finans kurumlarının müşteri deneyimini iyileştirmesine, operasyonel verimliliği artırmasına ve yeni iş modelleri geliştirmesine olanak sağlar.

Şirketler, dijital dönüşümü sadece teknoloji bazlı bir strateji olarak nitelendirmemelidir. Dijital dönüşümü; şirketlerin iş süreçlerinin, metotlarının ve verilerinin, alışılmış bir işletmeden modernize bir dijital işletmeye değişimi ile bilişim teknolojilerini kullanım yeteneklerini ve yaklaşımlarını arttırmasıyla birçok alanda önemli kazanımlar elde edebilmektedir (KPMG, 2021). Güncel bilişim teknolojileri sayesinde şirketlerin iş verimliliği artmakta ve iş süreçleri kolaylaşmaktadır (TOBB, 2021).

Geleneksel nakit ve kart tabanlı ödeme yöntemlerine alternatif olarak dijital ödeme sistemleri yaygınlaşmaktadır. Mobil cüzdanlar, QR kod tabanlı ödemeler, dijital para birimleri ve blockchain teknolojisi gibi inovasyonlar, ödeme süreçlerini hızlandırır, güvenliği artırır ve kullanıcı deneyimini geliştirir (Akbaba ve Gündoğdu, 2021).

Dijital kanallar aracılığıyla bankacılık hizmetlerinin sunulması, müşterilere kolaylık, erişilebilirlik ve daha kişiselleştirilmiş deneyim sağlar. Mobil bankacılık uygulamaları, internet bankacılığı ve dijital hesap açma gibi hizmetler, müşterilerin finansal işlemlerini istedikleri zaman ve yerde gerçekleştirmelerine olanak tanır (Balcıoğlu, 2023).

Dijital dönüşüm, yatırım süreçlerini ve finansal planlamayı da etkilemiştir. Dijital yatırım platformları, robo-danışmanlık ve algoritmik ticaret gibi teknolojiler, yatırımcılara daha hızlı ve daha düşük maliyetli yatırım imkânı sunar. Ayrıca, yapay zekâ ve büyük veri analitiği kullanarak finansal hedeflere ulaşmak için kişiselleştirilmiş önerilerde bulunabilir (Körpe, 2021).

Finansal teknolojiler (Fintek), finans sektöründeki dijital dönüşümün itici güçlerinden biridir. Fintek şirketleri, geleneksel finansal kuruluşlara meydan okuyarak yenilikçi çözümler sunar. Örneğin, dijital ödeme platformları, kitle fonlaması, blockchain tabanlı finansal ürünler, veri analitiği ve yapay zekâ gibi alanlarda yenilikçi çözümler sunulmaktadır.

KONDA Araştırma ve Danışmanlık A.Ş.'nin PwC Türkiye ile birlikte hazırladığı 250 kişinin katılım sağladığı Gelecek Trendleri “2022” çevrim için anket araştırmasına göre, ankete katılanların %77’si nakitsiz ekonomiye geçişin hızlanacağını öngörmektedir (PwC Türkiye, 2022).

Salgın sürecinin kazandırdığı ivme ile teknolojik gelişmeler ve dijitalleşme, tüm trendleri tetikleyerek nakitsiz ekonomiye geçişte yeni denklemlerin temelini oluşturmuştur. Temassız ödeme seçenekleri, sosyal mesafeyi korumak adına tercih edilirken temel ihtiyaçların karşılanmasında e-ticaret portallarının kullanımı artmıştır (Akın, 2020). Böylece, nakit kullanımındaki düşüş ile kayıt dışı ekonomide bulunan harcamaların, ekonomik büyüme ve kalkınmaya destek olacak potansiyel bir ilerlemesi olarak değerlendirilebilir. Buradan, kayıt altına giren harcamaları “büyük veri” odaklı yaklaşım analizi ile şirketlerin operasyonlarına, stratejilerine ve başta çalışanlar olmak üzere toplumun tüm paydaşlarına olan etkilerine bakarak, şirketlerin her katmanda karar verme süreçlerindeki ortak noktaların çalışılabilirliğini artıracaktır.

Dijital finans, finans sektöründe önemli bir dönüşümü temsil etmektedir. Kullanıcılar ve şirketler arasındaki finansal etkileşimi kolaylaştırarak, daha verimli ve erişilebilir bir finansal sistem sağlamayı hedefler.

2024-2026 dönemine ait 6 Eylül 2023 Tarihli Resmi Gazete'de Yayımlanan OVP kapsamında; 9. maddedeki “Dijital Dönüşüm” başlığı altındaki 29. alt başlıkta, fintek esaslı yerli üretim ve teknolojik kabiliyetlerin geliştirilmesine yönelik inovasyon temelli desteklere, 30. alt başlıkta ise Blokzincir tabanlı akıllı sözleşmeler ile menkul kıymet ihraç süreçlerinin dijitalleştirilmesi için etkili bir çözüm sağlanacağına değinilmiştir. Diğer önemli konular; dijital faaliyetlerdeki kayıt dışılığı engellemek için vergi uygulamalarının geliştirilmesi, uluslararası ekonomi düzenlemeleri doğrultusunda sürdürülebilirlik kapsamında rekabetçiliğin korunması ve artırılmasına uyumlu olarak finansal sistemin güçlendirilmesi, yeşil ve dijital dönüşümdeki

yetkinlik açığının kapatılması için meslek standartlarında gerekli güncellemeler yapılması, mevzuat boşluklarının giderilmesidir (OVP, 2023).

2.1. ENDÜSTRİ 4.0

Endüstri 4.0 kavramı, 2011 yılında Almanya hükümeti tarafından tanıtılan bir inisiyatifle ortaya çıkmıştır. Bu inisiyatif, Almanya'nın imalat sektöründe dijitalleşmeyi teşvik etme ve rekabetçiliğini artırma amacıyla başlatılmıştır (Polat ve Erkollar, 2020).

Endüstri 4.0'ın temelinde, üretim süreçlerinde dijital teknolojilerin ve akıllı sistemlerin kullanımının yoğunlaştırılması yatmaktadır. Bu sayede otomasyon, veri analitiği, yapay zekâ, nesnelerin interneti gibi teknolojilerin entegrasyonu ile üretim süreçleri daha verimli, esnek, otomatik ve bağlantılı hale getirilmektedir (Filgueiras vd., 2024).

Şekil 1: Endüstri 4.0 Gelişim Süreçleri



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

İnternetin yaygınlaşması, nesnelerin interneti, yapay zekâ, büyük veri analitiği ve diğer dijital teknolojilerin ilerlemesi, üretim süreçlerinde dijital dönüşümün mümkün hale gelmesine olanak sağlamıştır. Küresel rekabetin artması ve yeni ekonomik güçlerin yükselişi, geleneksel imalat sektörlerinin daha verimli ve rekabetçi olmalarını gerektirmiştir. Endüstri 4.0, bu rekabetçilik ihtiyacına cevap verebilecek bir yaklaşım sunmuştur. Nesnelerin interneti kavramının ortaya çıkışı, üretim süreçlerinde makinelerin ve cihazların birbirleriyle bağlantı kurabilmesini ve veri paylaşabilmesini

mümkün kılmıştır. Bu da üretim süreçlerinin daha akıllı ve verimli hale gelmesine olanak sağlamıştır (Machkour ve Abriane, 2020).

Geçmişten günümüze endüstriyel devrim süreci 4 başlık halinde temsil edilmektedir. Birinci sanayi devriminden daha önce de kullanıldığı bilinse de su ve buhar güçlerinin birlikte daha yoğun kullanılmasından dolayı bu dönem birinci sanayi devrimi olarak tanımlanmıştır. Henry Ford'un üretim bandı tasarımı ve elektriği seri üretimde kullanmaya başlamasıyla ikinci sanayi devrimine geçiş başlamıştır. Üçüncü sanayi devrimi ise 1970'lerde üretimde mekanik ve elektronik teknolojilerin yerini dijital teknolojiye bırakmasına sebep olan programlanabilir makinelerin kullanılmaya başlanmasıyla ortaya çıkmıştır. Endüstri 4.0 ise dijital teknolojilerin yoğunlaşmasıyla beraber ortaya çıkan temelinde her bir verinin toplandığı ve iyi bir şekilde izlenip analiz edilmesine imkan sağlayan nesnelerin interneti, internetin hizmetleri ve siber-fiziksel sistemlerden oluşan bir değerler bütünü temsil etmektedir.

Şekil 2: Endüstri 1.0'dan 4.0'a Doğru



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

2.2. NESNELERİN İNTERNETİ

Kısaca ‘‘The IoT’’ olarak anılan nesnelerin interneti, fiziksel nesnelerin internete bağlanması ve birbirleriyle iletişim kurmasıyla oluşturulan bir ağ sistemidir. IoT, sensörler, cihazlar, yazılımlar ve veri iletişimi teknolojileri sayesinde nesnelerin verilerini toplar, analiz eder ve paylaşır. Makineler arası (M2M) iletişime imkân tanıyan bu sistem olağanüstü bir şekilde gelişmeye devam etmektedir (Roblek vd., 2016).

IoT, bankacılık sektöründe de birçok farklı uygulama alanı bulmuştur. Bankacılık sektörü, IoT'yi kullanarak müşterilere daha iyi hizmet sunmak, operasyonel verimliliği artırmak ve güvenlik önlemlerini iyileştirmek gibi amaçlarla bu teknolojiden faydalanmaktadır.

IoT, ATM'leri daha akıllı hale getirerek müşterilerin hızlı ve güvenli bir şekilde işlemlerini gerçekleştirmesini sağlar. IoT ile donatılmış ATM'ler, uzaktan izleme ve yönetim, veri analizi ve doluluk durumunun takibi gibi özelliklere sahip olabilir. Müşterilerin şubeye giriş yapmasıyla birlikte akıllı sistemler, müşteriye özel hizmetleri sunabilir, bekleme sürelerini azaltabilir ve müşteri deneyimini iyileştirebilir. Bankacılık sektörü, giyilebilir cihazlar aracılığıyla müşterilerin finansal işlemlerini daha kolay ve hızlı bir şekilde gerçekleştirebilir (Khanboubi vd., 2019). Örneğin, akıllı saatler aracılığıyla bakiye sorgulama, ödeme yapma veya hesap hareketlerini takip etme gibi işlemler gerçekleştirir ve NFC (Yakın Alan İletişimi) teknolojisiyle entegre edilmiş ödeme cihazları ve akıllı telefonlar, temassız ödemelerin kolayca yapılmasını sağlar. Büyük veri analitiği ve gerçek zamanlı veri toplama imkânı sağlayarak, bu sayede bankalar müşteri davranışlarını daha iyi anlayabilir, dolandırıcılık tespiti ve risk değerlendirmesi gibi konularda daha etkin önlemler alabilir (Mohaghar vd., 2021).

Her ne kadar kolaylık sağlansa da, IoT uygulamalarıyla birlikte bazı zorluklar da ortaya çıkmaktadır. Bunlar arasında güvenlik riskleri, gizlilik endişeleri, veri yönetimi, standardizasyon ve entegrasyon gibi konular yer alır. Bu zorlukların çözülmesi için güçlü güvenlik önlemleri, uygun veri yönetimi politikaları ve sektörler arası işbirliği önemlidir.

2.3. HİZMETLERİN İNTERNETİ

Hizmetlerin İnterneti (Internet of Services - IoS), dijital teknolojilerin ve internetin hizmet sektöründe kullanılmasıyla ortaya çıkan bir kavramdır. IoS, hizmetlerin daha verimli, erişilebilir ve kişiselleştirilebilir bir şekilde sunulmasını hedefler.

IoS, müşterilerin banka hesaplarını ve finansal işlemlerini çevrimiçi olarak yönetmelerini çeşitli dijital kanallar aracılığıyla erişilebilir kılmasını sağlar. Bu sayede hizmetler daha geniş bir kitleye ulaşabilir, kişiselleştirilebilir, daha kolay erişilebilir hale gelir ve daha hızlı bir şekilde sunulabilir.

İnternet bankacılığı platformları, müşterilere hesap bakiyesi sorgulama, para transferi, fatura ödeme gibi işlemleri gerçekleştirme imkânı sunar. Müşteriler, akıllı telefonlarından veya tabletlerinden mobil bankacılık uygulamalarını kullanarak finansal işlemlerini gerçekleştirebilir, hesaplarını takip edebilir ve banka hizmetlerinden faydalanabilir. Dijital ödeme sistemleri aracılığıyla bankaların müşterilerine kolay ve güvenli ödeme seçenekleri sunmasını sağlar. NFC teknolojisi, QR kodları veya diğer dijital ödeme yöntemleriyle müşteriler, alışverişlerini daha hızlı ve pratik bir şekilde gerçekleştirebilir.

2.4. SİBER-FİZİKSEL SİSTEMLER

Siber-fiziksel sistemler (Cyber-Physical Systems - CPS), bilgisayar tabanlı sistemlerin ve fiziksel dünyanın birleştiği ve etkileşimde bulunduğu sistemlerdir. CPS, gerçek dünya olaylarını algılayan, işleyen ve yanıt veren bir bilgisayar sistemini içerir. Bu sistemler, sensörler, aktüatörler, kontrol algoritmaları ve ağ bağlantıları gibi bileşenlerin entegrasyonunu kullanarak fiziksel dünyayı kontrol eder ve yönetir (Al-Salman ve Salih, 2019).

Siber-fiziksel sistemlerde, yerleşik üretim faktörlerine gömülü yazılımlar ve sensörler sayesinde daha önceden programlanan sistemler M2M iletişimi sağlayarak herhangi bir müdahale gerektirmeden çalışabilmektedir (Oesterreich ve Teuteberg, 2016).

CPS'in temel amacı, bilgi teknolojilerini ve fiziksel sistemleri bir araya getirerek daha akıllı, daha verimli ve daha güvenli sistemler oluşturmaktır. Örneğin, akıllı kamera sistemleri ve yüz tanıma teknolojileri kullanılarak güvenlik önlemleri güçlendirilebilir. Ayrıca, biyometrik verilerin kullanımı ile müşterilerin kimlik doğrulama süreçleri hızlanabilir (Ochoa vd., 2017).

Banka şubelerindeki işlemler ve operasyonlar, CPS kullanılarak optimize edilebilir. Örneğin, akıllı kuyruk yönetim sistemleri sayesinde müşterilerin bekleme süreleri azaltılabilir. Ayrıca, sensörler ve veri analizi ile şube envanteri ve stok yönetimi daha verimli hale getirilebilir (Colombo vd., 2014).

CPS, büyük miktarda verinin hızlı bir şekilde analiz edilmesini sağlar. Bankalar, müşteri verilerini analiz ederek dolandırıcılık tespiti, risk yönetimi ve kredi değerlendirmesi gibi konularda daha etkili kararlar alabilir.

2.5. ENDÜSTRİ 4.0 VE İNOVASYONA ETKİLERİ

Endüstri 4.0, inovasyonla bağlantılı bir kavram olduğundan sanayileşme sürecinde yeni konseptler oluşturmaktadır. Böylece, merkezi kavramlar olarak bilgi, veri ve IoT ile inovasyona dayalı bir ekonomiye geçişi temsil etmektedir (Çetinkaya, 2021).

Bu geçişle, endüstriyel çağın mevcut yapısını, pazarlarını ve iş süreçlerini etkileyecek yeni bir dijitalleşme çağına, üretim sistemlerinin “daha akıllı” ağlara ve birbirine bağlı iş süreçlerine giden yolu açacaktır (Morrar vd., 2017).

Endüstri 4.0, bankacılık sektöründe de önemli bir dönüşüm sağlamaktadır ve inovasyonu etkileyen birçok faktörü içermektedir.

Dijital dönüşüm ile bankalar, müşteri deneyimini iyileştirmek ve operasyonel verimliliği artırmak için dijital teknolojileri benimseyerek inovasyon sağlar. Müşteri hizmetleri, ödeme sistemleri, veri analitiği, mobil bankacılık uygulamaları ve dijital platformlar gibi alanlarda inovatif çözümler sunulabilir. Büyük veri analitiği ve yapay zekâ teknolojileri sayesinde bankaların müşterilere daha kişiselleştirilmiş hizmetler sunmasını sağlar. Müşteri verileri ve davranışları analiz edilerek, ihtiyaçlara uygun ürün ve hizmetler önerilebilir. Sanal asistanlar gibi yapay zekâ tabanlı araçlarla müşteri deneyimi daha interaktif hale getirilmiştir (Aydınbaş ve Erdinç, 2023). Yapay zekâ ve makine öğrenmesi algoritmaları, anormal aktiviteleri tespit edebilir ve siber saldırılara karşı daha etkili bir şekilde önlem alınabilir. Blockchain teknolojisi, veri bütünlüğünü sağlamak ve kimlik doğrulama süreçlerini güçlendirmek için kullanılmaktadır. Bankalar, büyük miktardaki veriyi analiz ederek, müşteri kredibilitesini, kredi riskini ve dolandırıcılık riskini daha etkili bir şekilde değerlendirebilir. Gerçek zamanlı veri analizi ile piyasa hareketleri ve yönelimleri kolaylıkla izlenebilmektedir. Yenilikçi Fintek çözümlerini benimseyerek, ödeme sistemleri, para transferleri, kredi değerlendirmeleri ve diğer finansal hizmetlerde rekabet avantajı elde edilmektedir (Uçucu, 2023).

2.6. FİNANSAL TEKNOLOJİNİN DOĞUŞU VE GELİŞİMİ

Fintek, ilk olarak teknoloji ve finans kurumlarının temel teknolojik sorunlarını çözmek üzere uygulanmıştır. 21. yüzyılda ortaya çıkan bu kavram, finansal hizmet ve süreçleri geliştirmeyi amaçlayan finansal teknolojiler platformu olarak nitelendirilmektedir. Blockchain teknolojileri, perakende bankacılık, finansal

okuryazarlık gibi finansal hizmetler sektöründeki teknolojik deęişimlerin öncü etkileri ile kısıtlı tanımından çıkarak, küresel aęında desteęiyle giderek genişleyen bir sektöre dönüşmüştür (Akkan, 2018).

Bankacılık hizmetlerinin her yerde görülmesiyle birlikte özellikle kendisini yeni nesil ödeme alanında Finteklere bırakmıştır. Bunun farkına varan birçok ödeme alanında faaliyet gösteren startuplar, yatırımlarını bu alana yönlendirmişlerdir. Finansal teknoloji şirketlerinin ön safta yer almasına olanak tanıyan entegrasyonlar, esas durum olarak görülmektedir. Bankaların finansal inovasyonu benimsemesi ile şirketler, gömülü finans başta olmak üzere dięer finansal hizmetlerin startuplara yatırım yapması ve yeşil ışık yakmasıyla beraber Fintek sektörü için en önemli hususlardan biri olarak katlanarak büyümektedir (Güzer, 2019).

Finansal teknolojinin doğuşu ve gelişimi, teknolojik ilerlemeler ve deęişen tüketici davranışlarına baęlı olarak ortaya çıkmıştır.

İnternetin ve mobil cihazların yaygınlaşması, finansal hizmetlerin dijitalleşmesini sağlamıştır. Bankacılık işlemlerinin çevrimiçi olarak gerçekleştirilebilmesi, kullanıcıların finansal hizmetlere erişimini kolaylaştırmış ve geleneksel bankacılık kurumlarına alternatif çözümler sunmuştur.

Büyük veri analitięi, finansal verilerin analiz edilmesi ve kullanıcı davranışlarının anlaşılması için önemli bir araç haline gelmiştir. Veri analitięi, kredi deęerlendirmesi, dolandırıcılık tespiti, risk yönetimi ve kişiselleştirilmiş hizmetler gibi alanlarda kullanılarak daha iyi kararlar alınmasını sağlamaktadır.

Akıllı telefonların yaygınlaşması ve mobil uygulamaların gelişimi, finansal hizmetlerin mobil platformlarda sunulmasını sağlamıştır. Mobil cihazlar aracılığıyla ödeme yapma, para transferi, yatırım yönetimi gibi işlemler kolaylıkla gerçekleştirilebilir hale gelmiştir.

Blockchain, dağıtık defter teknolojisi olarak bilinir ve finansal işlemlerin güvenli ve şeffaf bir şekilde gerçekleştirilmesini sağlar. Blockchain, kripto para birimlerinin ortaya çıkmasını ve dijital varlık transferlerinin güvenli bir şekilde gerçekleştirilmesini sağlamıştır (Küçük ve Kaynar, 2023).

Finansal teknolojinin gelişimi, regölasyonlardaki deęişimlere de baęlıdır. Birçok ülke, Fintek şirketlerini desteklemek ve inovasyonu teşvik etmek amacıyla

düzenlemeleri güncellemiştir. Bu da Fintek girişimlerinin büyümesine ve finans sektöründe rekabetin artmasına katkıda bulunmuştur (Öznur ve Gezer, 2025).

2.7. FİNANS SEKTÖRÜNDE BANKACILIĞIN YERİ VE ÖNEMİ

Finans sektörü, ekonominin can damarı olarak kabul edilir ve bankacılık sektörü bu sektörün en önemli bileşenlerinden biridir. Bankacılık, bir ülkenin ekonomik büyümesi, yatırımların finansmanı, tasarrufların yönlendirilmesi ve para dolaşımının sağlanması gibi birçok temel işlevi yerine getirir (Danacı ve Çetintaş, 2020).

Bankalar, bireysel ve kurumsal müşterilere çeşitli finansal araçlar sunar. Bu araçlar arasında mevduat hesapları, krediler, kredi kartları, yatırım fonları, sigorta ürünleri ve diğer finansal enstrümanlar bulunur. Müşterilere sunulan, ödeme sistemleri, kredi kartları, banka havaleleri, elektronik fon transferleri gibi yöntemlerle para transferleri kolaylıkla gerçekleştirilebilir (Tanrıverdi, 2021). Ekonomik faaliyetlerin sürdürülmesine destek olarak, ticaretin ve işlemlerin sorunsuz bir şekilde gerçekleşmesiyle güvence altına alınır. Tasarruflar, kredi imkânları ve yatırım fonları aracılığıyla şirketlere ve bireylere finansman sağlamak için kullanılır. Bu sayede yatırımların finanse edilmesi, ekonomik büyümeyi destekler ve istihdamı artırır. Kredi riski değerlendirmeleri, risk yönetimi politikaları ve finansal analizler, bankaların müşterilerine uygun kredi imkânları sunmasını sağlar. Bankalar ayrıca finansal istikrarın sağlanması ve sistemik risklerin kontrol altında tutulması için düzenleyici otoritelerle yakın işbirliği yapar (Öznur ve Gezer, 2025).

Bankacılık sektörü, finans sektörünün temel taşı olarak ekonomik kalkınmanın sürdürülmesinde önemli bir rol oynamaktadır. İşletmelerin ve girişimcilerin finansman ihtiyaçlarını karşılaması, tasarrufların yönlendirilmesi, yatırımların finansmanı ve ekonomik faaliyetlerin desteklenmesi, istihdamın artırılması ve gelir düzeyinin yükseltilmesi açısından kritik bir görev üstlenir.

2.8. BANKACILIKTA ENDÜSTRİ 4.0

Teknolojik gelişmelerin arasında, "Bankacılıkta Endüstri 4.0 ne demek?" sorusu kadar "Bankacılıkta Endüstri 4.0 nasıl işliyor?" sorusuna dair izlere rastlanmaktadır. Endüstri 4.0, bankacılık sektöründe büyük dönüşümlere yol açan birçok teknolojik yeniliği beraberinde getirmiştir.

Endüstri 4.0 ile birlikte dijitalleşme bankacılık sektöründe hız kazanmıştır. Bankalar, müşterilerine daha kolay erişim imkânı sunan çevrimiçi ve mobil bankacılık hizmetlerini geliştirmiştir. Bu sayede müşteriler, bankacılık işlemlerini istedikleri zaman ve yerde gerçekleştirebilirler (Ustaömer, 2019).

Bankalar, robotik süreç otomasyonu (RPA) teknolojisini kullanarak tekrarlayan ve zaman alıcı işleri otomatikleştirebilir. Bu sayede iş süreçleri daha verimli hale gelir, hata payı azalır ve çalışanlar daha stratejik görevlere odaklanabilir (Yetiz vd., 2021).

Endüstri 4.0 teknolojileri, bankacılık sektöründe müşteri deneyimini iyileştirmeye yönelik önemli fırsatlar sunar. Kişiselleştirilmiş hizmetler, interaktif sanal asistanlar, 24/7 müşteri desteği gibi uygulamalar, müşterilerin memnuniyetini artırır ve sadakatlerini sağlar.

2.8.1. Nesnelerin İnterneti ve Bankacılık Sektörü İlişkisi

IoT, fiziksel nesnelerin internete bağlanarak veri alışverişinde bulunabildiği bir teknolojidir. Bu teknoloji, bankacılık sektöründe de önemli etkiler yaratmıştır.

IoT, ATM ve POS cihazlarının daha verimli çalışmasını sağlar. Bu cihazlar, internete bağlanarak güncel verilere erişebilir, anlık ödeme işlemlerini gerçekleştirebilir ve işlem verilerini anında banka sistemine aktarabilir (Rimer, 2017).

IoT, akıllı şehir projeleriyle birlikte bankacılık hizmetlerini de dönüştürür. Örneğin, akıllı park sistemleri, park ücretlerinin otomatik olarak ödenmesini sağlayabilir. Akıllı evlerdeki enerji tüketimi verileri, bankaların müşterilerine özelleştirilmiş enerji tasarrufu tavsiyeleri sunmasına yardımcı olabilir.

Akıllı telefonlar, akıllı saatler veya giyilebilir cihazlar, ödeme işlemlerinin kolaylıkla gerçekleştirilmesini sağlayabilir. NFC teknolojisi sayesinde, bu cihazlarla temassız ödemeler yapmak mümkündür. Bu gelen veriler sayesinde, müşteri davranışlarını daha iyi anlama, dolandırıcılık tespiti ve risk analizi gibi konularda kullanılabilir. Bu da bankaların daha etkin risk yönetimi yapmasına ve müşterilerini daha iyi korumasına yardımcı olur (Mandal ve Shill, 2024).

2.8.2. Büyük Veri ve Veri Madenciliği ile Bankacılık Sektörü İlişkisi

Veri günümüz dünyasında artık kıymetli menkul gibi önemli bir değer olarak nitelendirildiği görülmektedir. İlişkilendirme, gruplandırma, yorumlama ve

anlamlandırma yapılması gereken, bilgiye temel oluşturan ham bilgiye veri denilmektedir (Kevser ve Doğan, 2021).

Bilgi teknolojilerinin gelişim hızına bağlı, veri boyutunun ve çeşitliliğinin yoğun bir şekilde artmasıyla “Büyük Veri (Big Data)” ifade edilen kavramı ortaya çıkarmaktadır.

Veri madenciliği, verinin analizi, veri setleri arasındaki düzenlemesi ve yazılım tekniklerinin kullanılmasıyla değerli olan veriyi belirli yöntemler ve işlem süreçleri sonrası ortaya çıkarır.

Kısaca büyük veri, büyük miktarda yapılandırılmış ve yapılandırılmamış verileri ifade ederken, veri madenciliği ise bu verilerden anlamlı bilgileri çıkarmak için istatistiksel ve matematiksel yöntemlerin kullanılmasıdır.

Günümüzde rekabet ortamında sürdürülebilirliğin sağlanması ve kalıcı olunabilmesi için büyük veri kapsamındaki olanaklardan yararlanabilmek amacıyla tüketicilerin istek ve ihtiyaçlarının dikkate alındığı veri madenciliği teknikleri ile sosyal medya davranışları, profil, ürün kullanım geçmişi vb. özelliklere ait büyük miktarda veriden bilgi çıkarma etkili olmaktadır. Bu analizler ile tüketici davranış tahminleri yapılabilmekte ve mevcut tüketicilerin elde tutulması ile yeni tüketici kazanılması için uygulanacak stratejiler belirlenebilmektedir (Bulut, 2019).

Bankacılık sektöründe, rekabet koşullarının inanılmaz derecede hızlı ve değişken olduğu göz önünde bulundurulursa pazarlama alanında tüketici sadakati ölçülebilmekte, çapraz satış imkânları değerlendirilmekte, kişiselleştirilmiş ürün önerileri ve kampanyalar oluşturulabilmektedir.

Büyük veri analitiği ve veri madenciliği teknikleri ile dolandırıcılık modelleri, alışılmadık aktiviteleri ve anormal işlem desenlerini belirlemek için büyük veri setlerini analiz edebilir. Müşteri verileri, finansal durumlar, ödeme geçmişleri, sosyal medya aktiviteleri gibi faktörler analiz edilerek, kredi başvurularının olası riskleri belirlenebilir. Bu da bankaların daha iyi kredi değerlendirmeleri yapmasına ve riskli müşterileri belirlemesine olanak sağlar. Ayrıca, iş süreçlerinin optimize edilmesi ve kaynakların daha verimli kullanılması için de büyük veri analitiği kullanılabilir (Kaya ve Sağbaş, 2024).

2.8.3. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Bankacılık Sektörü İlişkisi

YZ, MÖ ve DÖ, bankacılık sektöründe büyük bir etkiye sahip olan teknolojilerdir. Bu teknolojiler kullanılarak yapılan analizler ile yatırım fırsatları, yatırım yapılması için en uygun zaman, yüksek risk profiline sahip müşteriler gibi faktörler belirlenebilmekte veya siber izleme yolu ile sahtekârlık işlemleri tespit edilebilmektedir (Yıldız, 2022). Örneklendirecek olursak, YZ, MÖ ve DÖ teknikleri, bankaların dolandırıcılık faaliyetlerini tespit etmelerine yardımcı olur. Örüntü tanıma, anomaliliği tespit, sahtecilik modelleri ve davranış analizi gibi teknikler kullanılarak, alışılmadık ve potansiyel dolandırıcılık durumları belirlenebilir. Yine YZ ve MÖ algoritmalarıyla Chatbotlar aracılığıyla, müşterilere hızlı ve etkili bir şekilde müşteri sorularını yanıtlayabilir, hesap bilgilerini sunabilir, önerilerde bulunabilir ve hatta bazı basit işlemleri gerçekleştirebilir (Demirel, 2024).

MÖ ve DÖ algoritmaları kullanılarak müşteri verileri analiz edilerek, kredi başvurularının risk seviyesi belirlenebilir, kredi değerlendirme süreci otomatikleştirilebilir, müşteri tercihleri, ihtiyaçları ve davranışları hakkında bilgiler elde ederek müşterilere özel kişisel teklifler yapabilir ve müşteri memnuniyetini artırabilir.

Operasyonel süreçlerin de optimize edilmesinin yanında büyük veri setleri analiz edilerek, piyasa koşulları, ekonomik faktörler ve müşteri davranışları gibi veriler kullanılarak risk analizi ve tahminleri yapılabilir. Bu, bankaların daha iyi kararlar almasına ve risk yönetimini güçlendirmesine olanak tanır.

2.8.4. Gömülü Finans ve Bankacılık Sektörü İlişkisi

Gömülü finans, bir varlığın veya değerın bir blockchain ya da kripto para birimi gibi bir dijital platform üzerinde akıllı sözleşmeler adı verilen programlanabilir kodların yönetilmesini ifade eder. Bu, varlıkların insan etkisi olmadan otomatik ve güvenilir işlem süreçleri sayesinde, belirli koşullara ve işlem protokollerine bağlı olarak otomatik olarak işlem yapılabilir, fonları serbest bırakabilir, varlıkları takas edebilir (Erdoğan ve Bodur, 2020).

Gömülü finans ve bankacılık sektörü arasında birçok ilişki vardır. Gömülü finans, bankacılık sektöründe mevcut olan birçok işlemi ve hizmeti etkileyebilir, dönüştürebilir veya tamamlayabilir.

Gömülü finansın en popüler uygulama alanlarından biri, merkezi olmayan finans (DeFi) geleneksel finansal araçları ortadan kaldırmayı veya azaltmayı amaçlayan kripto para birimleri ve blockchain üzerine inşa edilmiş finansal uygulamaları ifade eder. Örnek olarak; borç verme ve ödünç alma, likidite sağlama, tahmin piyasaları ve türev işlemler gibi finansal süreçler, hizmetleri otomatikleştirerek ve merkezi bir otoriteye ihtiyaç duymadan gerçekleştirerek bankaların rolünü sorgulayabilir (Akbaş, 2023).

Gömülü finansın temeli olan akıllı sözleşmeler, bankacılık işlemlerini otomatikleştirmek ve hızlandırmak için kullanılabilir. Örneğin; bir akıllı sözleşme aracılığıyla otomatik olarak gerçekleştirilen bir para transferi veya ödeme işlemi, bankacılık işlemlerini insan etkisinden uzaklaştırabilir ve daha hızlı bir şekilde gerçekleştirebilir (Kırbaş, 2018).

Akıllı Sözleşmelerde, normal sözleşmeler gibi bir anlaşmanın koşullarını içermekte fakat anlaşma şartları blockchain ile doğrulama mekanizmaları ile sağlandığından kullanıcıların mutabakata vardıkları şartları yerine getirmesiyle otomatik olarak yürürlüğe girer ve blockchain ağında kayıt altına alınır. Şartlar, kodlara gömülü olduğundan yoruma açık değildir. İşlemler otomatik olarak yapıldığı için sözleşmenin doğruluğu için noter gibi üçüncü kişilerin onayına gerek kalmamaktadır (Yavuz, 2019).

Gömülü finans, varlıkların tokenleştirilmesi yoluyla finansal ürünlerin oluşturulmasını sağlayabilir. Örneğin; emtialar, gayrimenkuller veya hisse senetleri gibi varlıklar, bir blockchain’de temsil edilebilir ve bu sayede daha likit ve erişilebilir hale gelebilir. Bankalar, tokenleştirilmiş varlıkları yönetmek, ticaretini yapmak veya müşterilerine sunmak için gömülü finans teknolojilerinden yararlanabilir. Blockchain teknolojisi sayesinde veri güvenliği ve kimlik yönetimi konularında bankalara yardımcı olabilir. Akıllı sözleşmeler ve kriptografi kullanarak, müşteri kimlikleri ve finansal veriler daha güvenli bir şekilde depolanabilir ve işlenebilir. Bu da kimlik hırsızlığı ve veri ihlali gibi sorunları azaltabilir (Keskin, 2025).

Gömülü finans, finansal sisteme daha fazla şeffaflık, güvenlik ve otomatiklik getirebilirken, aynı zamanda bazı riskleri de beraberinde getirebilir. Akıllı sözleşme hataları, güvenlik açıkları ve piyasa dalgalanmaları gibi faktörler, gömülü finansın karşılaşılabileceği riskler arasındadır. Merkezi olmayan yapıların bazı dezavantajları arasında, işlemlerin geri alınamaz olması veya hatalı akıllı sözleşme kodlarının ortaya çıkması gibi riskler söz konusu olabilir. Dolayısıyla, bu tür finansal uygulamaları kullanmadan önce, riskleri ve potansiyel sonuçları dikkate almak önemlidir (Efe, 2021).

Gömülü finans örnekleri arasında Amazon'un kasiyersiz süpermarket konsepti Amazon Go, Jaguar ve Shell'in iş birliğiyle gerçekleştirilen dünyanın ilk araç içi yakıt ödemeleri, Mercedes'in ardından Uber'ın Venmo ile bölünmüş ödemeleri etkinleştirmesi, Starbucks'ın uygulaması üzerinden ödeme yapılması, Zara ve H&M gibi perakendecilerin Klarna aracılığıyla satış noktası finansmanı sunmaları (H&M'nin Klarna'ya 20 milyon dolar yatırım yapması), ayrıca Amazon'un Goldman Sachs ve ING Almanya ile yaptığı iş birlikleri ile pazaryeri satıcı finansmanı sağlaması bulunmaktadır (Web-6).

2.8.5. Metaverse ve Bankacılık İlişkisi

Metaverse (sanal evren) kavramı, ilk kez Neal Stephenson'ın 1992'de Snow Crash adlı romanında yer almıştır. Metaverse, avatarların içinde bulunduğu, sanal ve gerçekliğin etkileşime girdiği sürükleyici bir üç boyutlu geniş dijital ortamı ifade etmektedir. 33 yıl öncesinde bir hayalden ibaret olan bu bilim kurgu eseri, artık günümüzde birçok alanda kullanılmaya başlamıştır (Güler, 2022; Bülbül ve Ersöz, 2022). Bu dijital dünya, kullanıcıların etkileşimde bulunabileceği ve içinde yaşayabileceği sanal ortamlar, oyunlar, sosyal ağlar, iş platformları ve daha fazlasını kapsar. Kullanıcılar, avatarlar aracılığıyla metaverse içinde dolaşabilir, etkinliklere katılabilir, sosyal bağlantılar kurabilir, alışveriş yapabilir, eğitim alabilir, iş yapabilir ve daha pek çok aktiviteyi gerçekleştirebilir (Er ve Yücel, 2023).

Metaverse, son yıllarda popülerlik kazanan ve teknolojik gelişmelerle desteklenen bir konsept haline gelmiş ve hala birçok teknik, etik, güvenlik ve düzenleyici zorluklar da mevcuttur ve bu alanlarda çalışmalar devam etmektedir. Özellikle sanal gerçeklik,


artırılmış gerçeklik, blockchain ve dijital varlık yönetimi gibi alanlardaki ilerlemeler, metaverse'in gelişimine katkı sağlamaktadır (Kıvrak ve Hatipoğlu, 2023).

Metaverse ve bankacılık arasındaki ilişki, finansal teknolojilerin gelişimi ve dijital dünyanın ilerlemesiyle giderek önem kazanmaktadır. Metaverse, sanal ve gerçek dünyaların birleştiği geniş bir dijital ortamı ifade ederken, bankacılık ise finansal hizmetlerin sunulduğu bir sektördür (Akıllıoğlu, 2024).

Metaverse ortamında, ticaret ve ödeme işlemlerinde sanal para birimleri (cryptocurrency) kullanılabilir. Bankacılık sektörü, dijital cüzdanlar, sanal banka hesapları veya sanal krediler gibi ödeme sistemleri sunarak, kullanıcılar da bu sanal para birimlerini kullanarak alışveriş yapabilir ve finansal işlemleri gerçekleştirebilir (Dönmez, 2022).

DeFi olarak bilinen ve merkezi olmayan finansal uygulamalar, metaverse içinde de etkili olabilir. DeFi protokolleri, bankaların aracılığı olmadan finansal işlemleri gerçekleştirebilen akıllı kontratlar ve blockchain teknolojisiyle çalışan sistemlerdir (Karagöz, 2023). Metaverse içindeki kullanıcılar, DeFi protokolleri üzerinden kredi alabilir, kredilendirme yapabilir veya likidite havuzlarına katılabilir. Temel amacı, dünyanın neresinde ikamet ettiği fark etmeksizin bir kripto para cüzdanı ve internet erişimi olan herkesin araçlara ihtiyaç duymadan bankacılık sistemlerini kullanmaya ilişkin başka herhangi bir engel olmadan Merkeziyetsiz Finans dünyasıyla kullanmasını sağlamaktır (Kahraman, 2022).

Şekil 3: Geleneksel ve Metaverse Ekonomisi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Metaverse'ün finansal hizmetler konusunda sunduğu birçok yenilik bulunmaktadır. Bankalar ve Fintek kuruluşları, NFT ve kripto paraların kullanım alanlarının doğmasıyla bu alanda ciddi bir dönüşümü başlatmış ve gelişerek farklı bir konuma erişeceğinden önümüzdeki dönemde, bireysel ve kurumsal bankacılıkta ihtiyaçlar için alternatifleri görmemiz söz konusu olacaktır (Ağırman ve Barakalı, 2022).

Metaverse mağazaları, çeşitli sanal gerçeklik ve artırılmış gerçeklik platformlarında bulunabilir. Coca-Cola, Uluslararası Dostluk Günü için NFT koleksiyonlarını açık artırmaya çıkartarak dahil olduğu birkaç pazarlama kampanyasını desteklemek amacıyla dijital varlıklarını piyasaya sürdü (Web-1). Gucci, fiziksel bir mekânın lansmanı ile uyumlu olan marka temalı odaların bulunduğu Gucci Garden'ını Roblox üzerinde başlattı (Web-2). AnamXR, 3D immersif alışveriş deneyimleri için bulut tabanlı sanal e-ticaret platformları oluşturmak için oyun motoru teknolojisini kullanmaktadır (Web-3). Adidas'ın Bored Ape Yacht Club NFT piyasaya sürümü, fiziksel sokak giyim ürünlerine erişim sağlayarak sadakati artırdı ve sanal ürünleri etrafında bir topluluk oluşturdu (Web-4). Güney Kore'nin önde gelen bankalarından HanaBank, metaverse üzerinde bir eğitim merkezi kurarak çalışanlarını dijital bankacılık konusunda eğitmeye başlamıştır. Bu sayede, metaverse üzerinden eğitim sertifikaları alan banka çalışanları, müşterilerine çevrimiçi bankacılık hizmetlerinden finansal yatırım ürünlerine kadar birçok alanda kişiselleştirilmiş hizmet sunabilme imkanına sahip olmuştur. Bank of America, Amerika genelindeki 4300 şubesinde çalışanları için metaverse teknolojisine uyum sağlamak amacıyla sanal gerçeklik eğitimleri başlatacağını duyururken; Singapur'un en büyük bankası DBS, gıda israfını azaltmaya yönelik metaverse konseptini açıklamıştır. Öte yandan, HSBC Sandbox metaverse'ü üzerinde, JP Morgan ise Decentraland metaverse'ü üzerinde girişimlerini başlatarak dijital dünyada var olma yolunda adımlar atmıştır. BNP Paribas ve Kuveyt'in devlet bankası Bank of Kuwait de dijital ortamda hesap faaliyetlerine erişmeyi mümkün kılan sanal gerçeklik temelli şubeler için çalışmalarını başlatmıştır (Ağırman ve Barakalı, 2022). Garanti BBVA, Türkiye'nin ilk bankacılık sanal asistanı Ugi aracılığıyla müşterilerine para transferinden kart bilgilerini sorgulamaya kadar 200'den fazla bankacılık işlemini sadece sesli komutlarla gerçekleştirme olanağı sunmaktadır. Müşterilerinin ihtiyaçları Ugi'nin yeteneklerinin ötesine geçtiğinde,

proaktif bir yaklaşımla Ugi, Garanti BBVA canlı destek birimine yönlendirilerek artırılmış bir müşteri deneyimi sağlamaktadır (Web-5).


Tüketim kültürü, Influencer pazarlama ve marka fanatizmi etkisiyle sanal gayrimenkuller başta olmak üzere dijital öncelikli giyim, alışveriş yapmak, yeni yerler keşfetmek, film seyretmek, tiyatro izlemek, konsere gitmek gibi pek çok gerçek faaliyeti sanal bir evrende de yaşamaktadır. Bankacılık ve metaverse arasındaki ilişkinin potansiyelini gösteren daha fazla hizmet ve yeniliklerin ortaya çıkması beklenmektedir. Bu doğrultuda şirketler, tüketicilerin veri tabanındaki bilgilerine istinaden gerçek hayat ve meta evrendeki davranışlarına, kararlarına ve tercihlerine göre pazarlama stratejilerini sanal bir ekonomide kullanılabilecek şekilde dönüştürmesi gerekecektir (Ooi, 2023).

Metaverse içindeki kullanıcılar, dijital varlıklara sahip olabilir ve bunları yönetebilir. Bankalar, kullanıcıların sanal mülklerini ve diğer dijital varlıklarını yönetebilir, alım-satım işlemleri yapabilir ve yatırımlarını yönlendirebilir. Kullanıcılar, sanal mağazalarda veya diğer metaverse ortamlarında banka hesapları veya diğer ödeme araçları aracılığıyla ödeme yapabilir.

2.8.6. Kuantum Hesaplama ve Bankacılık İlişkisi

QC yöntemlerinde, geleneksel bilgisayar sistemlerinde 0 ve 1'lerden oluşan ikili veri (bit) yerine “qubit” olarak isimlendirilen, verinin 0, 1 ve her ikisinin de aynı olduğu, hizmet odaklı tamamen akıllı bir 6.Nesil iletişim ağının isteklerini gerçekleştirmede daha hızlı ve etkili bir şekilde işlem yapma potansiyeline sahip yeni bir bilgi işlem paradigmasıdır (Şahin, 2024).

Şekil 4: 6.Nesil (6G) İletişim Ağının Gelişim Süreçleri



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Kuantum hesaplama, finansal piyasalarda yüksek frekanslı ticaret ve sahtekârlığı tespit etmek için kredi riski yönetimi hakkında önemli bir ilişki kurmaktadır. Klasik bilgisayarlar, bazı finansal işlemleri ve analizleri, özellikle büyük veri kütleleriyle uğraşırken, yüksek hesaplama gücüne ihtiyaç duyarlar. Kuantum bilgisayarlar ise özellikle optimizasyon, portföy yönetimi, risk analizi ve kriptografi gibi alanlarda geleneksel bilgisayarlara kıyasla önemli avantajlar sunabilir (Küçükvardar ve Aslan, 2021). Örneğin, kuantum hesaplama, yatırım uzmanlarının hisse senetleri, tahviller, para birimleri ve diğer varlıklar arasındaki korelasyonları belirlemek için birden çok büyük miktarda veriyi ele alırken, işlemleri daha hızlı gerçekleştirebilir ve daha kesin sonuçlarla birden çok değişken arasında optimize edilmiş portföy bileşimi sağlayabilir. Böylece, yatırımcının portföyünü en iyi şekilde çeşitlendirmesi ve riski minimize etmesine imkân sunabilir. Yatırımcıların, nereye yatırım yapacakları konusunda daha bilinçli kararlar vermelerine yardımcı olabilir.

Kuantum bilgisayarlar, henüz geliştirme aşamasında olduklarından finansal sektörde tam manasıyla yaygın değildir (Genç, 2022). Başta, potansiyel güvenlik tehditlerine karşı da önlemler alınması olmak üzere gelişim devam ettikçe bankacılık ve finans sektörü de bu teknolojiyenin elde edebileceği avantajları takip etmek için çaba gösterecektir. Bankaların ve finansal kurumların kriptografi algoritma güncellemelerine yönelik hazırlıklı olmalarını gerektirir (Güler, 2022).

Kuantum teknolojisinin finans alanındaki olası kullanımını Deutsche Börse, risk analizini ölçmek için 1000 parametre içeren bir Monte Carlo Simülasyonu yapmıştır. Geleneksel bilgisayarların 10 yılda yapacağı simülasyonu, bir kuantum bilgisayar ile 30 dakika yapılabildiğini kanıtlamıştır (Deutsche Börse, 2021).

Dolandırıcılık yüzünden, yıllık yaklaşık 10 ila 40 milyar\$ (IBM, 2019) arasında finansal kuruluşların gelir kaybına uğradığı tespit edilmiştir. Dolandırıcılığın tespiti ve engellenmesi konusunda, kuantum bilgisayarların, işlem kabiliyeti ve yapay zekâ alt kümelerini kullanarak tepki süresindeki hızı da dikkate alınarak önemli bir rol oynayacağı belirtilmektedir.

IBM, özel finansal uygulamalar oluşturmak için Barclays ve JP Morgan gibi ticari şirketlerle iş birliği yapmaktadır. Yakın gelecekte ultra hızlı kuantum bilgisayarların yardımıyla yeni bilgisayarlı ticaret stratejileri belirleme, risk modellerini dikkate alma,

veri hırsızlığı ve finansal dolandırıcılık girişimlerinin tanınması süreçlerini hızlandırabileceği belirtiliyor (Teifurova, 2021).

Kuantum bilgisayar deneyimleme fırsatına sahip birkaç finans kuruluşlarında arasında bulunan J.P Morgan, 2020 yılında Chicago Quantum Exchange'in desteğiyle şirket içinden optimizasyon, yapay zeka ve alt kümelerinin de dahil olduğu kuantum sonrası şifreleme konusunda çalışmalarına katkı sunan bir kuantum takımı kurmuştur. HSBC ise siber güvenlik makine öğrenmesi ve risk analizinde kuantum bilgisayarların önemini fark etmiştir. Bu doğrultuda, 4 sene için \$5.5 milyonluk bir bütçe ile The European NEASQC firmasıyla yaptığı ortaklık doğrultusunda çeşitli kullanım denemelerine başlamıştır. Citi Bank, QC Ware ve 1QBit gibi kuantum startuplarına yatırım yapmasının yanı sıra 2019 yılında, 5 teknoloji trendi arasında kuantum bilgisayarları göstererek, risk analizi, portföy optimizasyonu, dolandırıcılıkları engelleme ve ticaret algoritmaları geliştirme gibi konularda öne çıkacağını açıklamıştır. Wells Fargo'nun IBM ve MIT ile 2019 yılında yaptığı anlaşmayla birlikte kuantum teknolojisi kullanılarak daha akıllı, güvenli, hızlı ve kolay olacağını belirtmiştir. Finans sektöründeki bu alandaki değişimlere karşı gerekli hazırlıklarına başlamıştır. ABN AMRO, kuantum algoritmaları ve şifrelemeler ana ilgi alanları üzerine yine Hollanda'da bulunan Rabobank ile 2020 yılında araştırmaya başlamışlardır. Barclays, güvenli işlem konularındaki çalışmalara önderlik etmektedir. Kuantum bilgisayarların henüz kullanımı yaygın olmasa da, gelecek 10 yıl içerisinde finans sektöründe aktif olarak yer almayacağını öngörmektedir (Akbank, 2021).

2.9. FİNTEK

Fintek kavramı, bugünün modern toplumunda dijital teknolojilerden faydalanarak teknoloji odaklı oluşturulan finansal hizmetleri sağlayan sektör işletmelerini tanımlamaktadır (Türkiye Cumhuriyeti Cumhurbaşkanlığı Finans Ofisi, 2022).

Fintek, finans sektöründe teknolojinin kullanımıyla ortaya çıkan yenilikçi çözümleri ifade eder. Fintek şirketleri fonlama, ödeme sistemleri, elektronik cüzdan, elektronik ticaret, elektronik sigorta ve belki de hepsinden çok gündemde yer bulan kripto paralar gibi alternatifler ürünlerle donanmış durumdadır (Bussmann, 2020).

Tablo 2: Fintek'in Kullandığı Teknolojiler

	Finansal Faaliyetler ve Hizmetler							
	Ödemeler	Danışmanlık	Yatırım	Finansman	Sigortacılık	Güvenlik	Operasyon	İletişim
Dağıtık Defter Teknolojisi (DLT)	✓	✓	✓	✓	✓	✓	✓	✓
Büyük Veri (Big Data)		✓	✓	✓	✓	✓	✓	✓
Nesnelerin İnterneti (IoT)					✓			✓
Bulut Bilişim (Cloud Computing)				✓			✓	
Yapay Zekâ (AI)		✓	✓		✓			✓
Biyometrik Veri (Biometric)					✓	✓		
Artırılmış gerçeklik (AR) / Sanal gerçeklik (VR)		✓	✓					✓

Kaynak: OECD, 2018, s.14

2.9.1. Fintek Tarihçesi

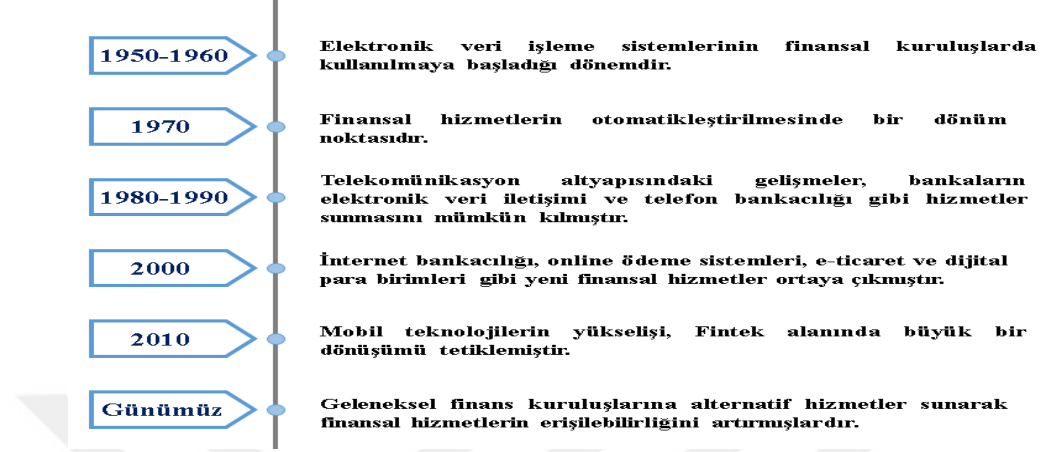
Fintek'in tarihi, teknolojinin finans sektöründe kullanımının gelişimiyle bağlantılı olarak şekillenmiştir.

1950 - 1960 dönemlerinde hesaplama makineleri ve anahtar delikli kartlar gibi teknolojiler, finansal işlemlerin hızını ve doğruluğunu artırmak için kullanılmıştır. 1970'lerde ATM'ler, müşterilerin nakit çekme ve hesap sorgulama gibi temel bankacılık işlemlerini yapmalarını sağlamıştır. 1980 – 1990 arasında bankalar, müşterilerine telefon üzerinden hizmet verme imkânı sağlayarak finansal erişimi artırmışlardır. 2000'lerde internetin yaygınlaşmasıyla birlikte Fintek'in gelişimi hız kazanmıştır. 2010'larda mobil bankacılık uygulamaları, dijital cüzdanlar, mobil ödeme sistemleri ve P2P kredilendirme platformları gibi yenilikçi çözümler kullanıcıların finansal işlemlerini kolaylaştırmıştır (Jakšič ve Marinč, 2019).

Günümüzde Fintek, geleneksel finans kuruluşlarından bağımsız olarak büyümeye devam etmektedir. Yeni nesil Fintek şirketleri, yapay zekâ, büyük veri analitiği,

blockchain ve diğer ileri teknolojileri kullanarak finansal hizmetlerin daha hızlı, daha güvenli ve daha kullanıcı odaklı bir şekilde sunulmasını sağlamaktadır.

Şekil 5: Fintek Tarihçesi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

1950 yılında müşterisini yemeğe davet eden “Diners Club’ün” kurucusu Frank Mc Namara, cüzdanının üzerinde olmadığını fark edince kartvizitinin arkasını imzalayarak hesabı öder. Vakit kaybetmeden kişilerin yanında nakit para taşımaksızın alışveriş yapabileceği düşüncesiyle günümüzde hala varlığını sürdüren, sloganı “ye ve imzala” (dine and sing) olan bir ödeme aracı geliştirmeye karar verir (Teoman, 1996; Kaya, 2009).

Fintek’in tarihi, teknolojik ilerlemelerle eş zamanlı olarak finans sektöründe dönüşümü tetiklemiştir. Geleneksel finans kuruluşları, bu teknolojik yeniliklere ayak uydurmak ve dijital dönüşümü benimsemek zorunda kalmışlardır. Bu süreç, Fintek’in büyümesini ve finans sektöründe kitle fonlaması, varlık yönetimi, kredilendirme, sigorta ve sermaye piyasası hizmetleri gibi yeni iş modellerinin ortaya çıkmasını sağlamıştır (Singh vd., 2020; Utami vd., 2021).

2.9.2. Fintek Ekosistemi


Devletler, finansal kurumlar ve girişimciler Fintek ekosisteminin temel oyuncularındır. Devletlerin rolü ekosisteminin gelişimini kolaylaştıracak sınırlı olan politikaları belirlemek, girişimcilik faaliyetlerini teşvik desteklemek ve yasal düzenlemeleri oluşturmaktır (Gurreá-Martinez ve Remolina, 2020).

Fintek ekosisteminin geniş katılımcıları arasında, yenilikçi teknolojik çözümleri ile katkıda bulunan girişimciler (teknoloji şirketleri) ve kuluçka merkezleri ile altyapı şirketleri gibi unsurlar bulunmaktadır.

Fintek ekosistemi, finans sektöründe faaliyet gösteren çeşitli aktörlerin bir araya geldiği ve inovasyon, işbirliği ve teknolojik gelişim üzerine odaklanan bir yapıdır. Bu ekosistem, geleneksel finans kuruluşları, Fintek şirketleri, teknoloji sağlayıcıları, yatırımcılar, düzenleyici kurumlar ve müşteriler arasındaki etkileşimi içerir (Narez-Sánchez, 2022).

Geleneksel Finans Kuruluşları; başta olmak üzere bankalar, sigorta şirketleri ve diğer finansal kurumlar ile dijital dönüşümü gelişmelerini sağlar. Fintek Şirketleri ise alternatif kredi ve dijital varlık yönetimi platformları ile mobil ödeme uygulamaları gibi farklı alanlarda faaliyet gösteren yenilikçi finansal çözümler sunar ve geliştirmelerinde yer alır. Yapay zekâ, veri analitiği platformları, bulut bilişim sağlayıcıları ve blockchain çözümleri gibi teknoloji altyapısı sağlayan ve onların gelişimi teknoloji sağlayıcılarının görevidir. Kurumsal yatırımcılar, risk sermayesi şirketleri ve melek yatırımcılar, şirketlerin büyümelerini ve gelişmelerini sağlayarak ekosistemin önemli bir parçasını oluşturmaktadır. Şirketlerinin faaliyetlerini denetlemek, düzenlemek ve tüketici haklarının korunmasını sağlamak amacıyla düzenlemeler ve yönetmelikler geliştiren Düzenleyici Kurumlar, ekosistemde etkin bir rol oynamaktadır (Liu, 2024). Ekosisteminin merkezinde yer alan müşteri odaklılık, bir şirketin pazardaki gelişmeleri odak olarak belirleyerek, müşterilere kendilerini değerli hissettirecek bir adil ve eşitlik anlayışını temsil etmektedir.

Şekil 6: Fintek Ekosisteminde Yer Alan Unsurlar




Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Fintek ekosisteminin temel dinamikleri arasında; dijital dönüşüm, yenilikçilik ve müşteri deneyimi odaklı çalışmaların yer almasıyla farklı aktörler arasındaki işbirliğini teşvik ederek finansal hizmetlere erişimi genişletir (Karaki vd., 2023).

Büyüyen pazarda, inovasyon ve dijital dönüşümü hızlandırdıklarından daha kolay ve kullanıcı odaklı finansal hizmetler sunulmasının yanında erişimi sınırlı olan kesimlere finansal hizmetlere erişim imkânı sağlar. Yapay zekâ, büyük veri analitiği ve otomasyon teknolojileri kullanarak dijitalleşme sayesinde finansal süreçlerde verimliliği artırabilir, işlemler daha hızlı ve daha az maliyetli hale gelebilir (Gülbaşı ve Karahan, 2023).

Fintek çözümlerinin yaygınlaşması ile verilerin güvenliği ve gizliliği önemli bir konu haline gelmiştir. Bunun yanı sıra teknolojiye güçlü bir şekilde bağımlı olduğundan arızalar, güncelleme, planlı veya plansız kesinti gereksinimleri de hizmet kalitesini etkileyebilir. Farklı ülkelerdeki düzenleyici çerçevelere uyum sağlanamaması, gereksinimlerin karşılanamaması ve düzenlemelerin değişkenliği yayılmayı sınırlayabilir (Gümüş vd., 2023).

Şekil 7: Fintek GZTF Analizi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Fintek şirketlerinin finansman zorluklarıyla karşılaşmasının başlıca nedenleri arasında yatırımcı ilgisindeki değişimler veya risk sermayesi kaynaklarının kısıtlanması olabilir. Şirketler, finansal piyasalardaki dalgalanmalar başta olmak üzere her türlü zorluklarla, başarılarını sürdürebilmeleri adına güçlü bir risk yönetimi ve

uyum stratejileri geliřtirmelidir. Fintek řirketlerinin başarısını saęlamak, sřrdřrřlebilir břyřme ve rekabet avantajı elde etmesinde mřřteri verilerinin gřvenlięi, dřzenleyici uyumluluk ve operasyonel sřrekliplik gibi konuları benimsemeleri nemlidir (Giudici, 2018).

2.9.3. Fintek'in Geleceęi

Fintek'in geleceęi olduka parlak ve břyřk bir potansiyele sahiptir. Geliřen teknolojiler, deęiřen třketici tercihleri ve finansal hizmetlere eriřimdeki artan talep, Fintek sektřrřnřn břyřmesini ve geliřmesini desteklemektedir.

Fintek řirketleri, daha fazla dijitalleřme ve otomasyon ile finansal hizmetleri daha eriřilebilir ve kullanıcı dostu hale getirecektir. Mobil demeler, dijital cřzdanlar, online kredi bařvuruları gibi alanlarda břyřme ve yenilikler beklenmektedir. Mřřteri davranıřlarını anlamak, risk deęerlendirmesi yapmak, kiřiselleřtirilmiř hizmetler sunmak ve dolandırıcılık tespiti gibi alanlarda yapay zekâ ve veri analitięi cřřřmleri kullanılacaktır (Kmřrcřřoęlu ve Akyazı, 2020). Kripto para birimleri, sınırları ařan hızlı ve dřřk maliyetli para transferleri iin kullanılabilir ve finansal enstrřmanlar olarak daha fazla benimsenebilir. Fintek sektřrřndeki břyřme ile birlikte dřzenleyici otoriteler, gřvenlik ve třketici koruması konusunda daha sıkı dřzenlemeler getirebilir. Fintek řirketlerinin dřzenleyici uyumluluęa ve veri gřvenlięine daha fazla nem vermesi beklenmektedir. Finansal altyapı saęlayıcıları ile entegrasyon ve veri paylařımı, mřřterilere daha kapsamlı ve entegre finansal cřřřmler sunulmasını saęlayabilir (Rolando ve Mulyono, 2024).

Fintek sektřrř, křresel lekte břyřmeye devam edecektir. Geliřmekte olan řlkelerde finansal hizmetlere eriřimdeki artan talep ve dijital altyapının hızla geliřmesi, Fintek řirketlerinin yeni pazarlara aılma fırsatlarını artıracaktır.

Fintek'in geleceęi, teknolojik yeniliklere, dřzenleyici geliřmelere ve třketici beklentilerine baęlı olarak řekillenecektir. Ancak, hızlı deęiřen bir sektřr olduęu iin Fintek řirketlerinin esneklik, inovasyon ve mřřteri odaklılık konularında sřrekli olarak kendilerini yenilemeleri gerekmektedir.

2.10. FİNANSAL TEKNOLOJİLER VE BİLGİ GÜVENLİĞİ

Finansal teknolojiler, geleneksel finansal hizmetlerin sağlanmasında ödeme sistemleri, dijital para birimleri, yatırım ve risk yönetimi, kredi değerlendirme, sigorta ve diğer finansal hizmetlerin otomasyonu gibi birçok alanda yenilikler getirerek finans sektöründe büyük değişimlere yol açmıştır (Olaiya vd., 2024).


Finansal teknolojilerin benimsenmesiyle birlikte bilgi güvenliği önemi de artmıştır. Finansal verilerin dijital platformlarda saklanması ve işlenmesi, siber saldırılara ve veri ihlallerine maruz kalma riskini beraberinde getirir. Dolayısıyla, finansal teknoloji şirketleri ve finans kurumların bilgilerinin gizliliğini ve güvenliğini sağlamak için güçlü bir bilgi güvenliği stratejisi uygulamak zorundadır (Tyagi, 2024).

Bu doğrultuda alınması gereken bazı önlemler; çok faktörlü kimlik doğrulama, önemli finansal verilerde tek kullanımlık ve güçlü parolalar olarak belirlenmesi, yazılımları güncel tutarak ve iyi yapılandırılmış güvenlik duvarları ile ağları ve sistemleri korumak önemlidir. Veri kaybını önlemek için düzenli veri yedeklemesi ve kurtarma planları oluşturulmalıdır. Diğer bir hususta, çalışanların sosyal mühendislik saldırılarına karşı bilinçlenmesi üzerine düzenli olarak güvenlik eğitimi verilmesidir (Sirenk vd., 2020).

Bahsi geçen önlemler, finansal teknoloji şirketlerinin ve finans kurumlarının bilgi güvenliğini sağlamak için temel olarak düşünülebilir. Siber tehditler sürekli olarak gelişmek olduğundan, her bir organizasyonun benzersiz riskleri ve gereksinimleri bulunduğu için güvenlik önlemlerinin sürekli olarak gözden geçirilmesi, belirli bir güvenlik stratejisi oluşturulması ve uygun önlemlerin alınması da büyük önem arz etmektedir (Idayani vd., 2024).

Finansal teknolojiler ve bilgi güvenliği konularında GZTF analizi Şekil 8’teki gibi olabilir.

Şekil 8: Fintek ve Bilgi Güvenliği GZTF Analizi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Geleneksel finansal hizmetlere yenilikçi yaklaşımlar getirerek sektörde büyük bir fark oluşturmuştur. Dijitalleşme süreci ile finansal hizmetlere erişimi kolaylaştırarak, hızlı ve verimli bir şekilde daha fazla finansal kaynaklara ulaşılmasını sağlar. Özellikle gelişmekte olan ülkelerde finansal hizmetlere erişimi artırma potansiyeli, büyük veri, veri madenciliği ve yapay zekâ gibi ileri teknolojileri teknikleri kullanarak finansal karar alma süreçlerini iyileştirebilir ve daha iyi müşteri deneyimi sağlayabilir. Hızla değişen düzenleyici ortamlara uyum sağlanması ve sıkı regülasyonlar, siber saldırılar ve veri ihlalleri gibi güvenlik zorluklarıyla mücadele ve büyük finansal kurumlarla rekabet etmek zor olabilir (Vučinić ve Luburić, 2022).

2.11. FİNANSAL OKURYAZARLIK


Finansal okuryazarlık, bireylerin finansal konuları anlama ve yönetme becerilerine sahip olmaları anlamına gelir. Finansal okuryazarlık, kişilerin gelir, harcama, tasarruf, yatırım, borç yönetimi gibi finansal konuları anlama ve bu konularda bilinçli kararlar alma yeteneğini içerir (Fettahoğlu ve Kıldize, 2019).

Finansal riskler değerlendirilerek ve yönetme becerisi geliştirilerek yatırım seçeneklerini değerlendirmesini sağlar. Finansal hedeflerin belirlenmesine ve bu hedeflere ulaşılmasına yardımcı olur (Doğan, 2020). Böylece, riskleri azaltma ve olası sorunlara karşı hazırlıklı olma yeteneği kazanılır. Finansal kararların bilinçli olarak alınması ile gelir artırma, tasarruf etme, yatırım yapma ve emeklilik için birikim yapma

gibi hedeflere ulaşım daha etkili bir şekilde gerçekleşir ve finansal bağımsızlıklarını artırma becerisini geliştirir (Terzi ve İşli, 2020).

Eğitim programlarına erişimdeki yaşanabilecek bazı zorluklar ve yetersiz eğitim durumlarında bilinçlendirme çabalarını sınırlandırabilir. Diğer bir durumda, bilgi kirliliği ve yanlış bilgilendirme ile karşılaşabilir, bu da finansal kararların doğru şekilde alınmasını engelleyebilir. Bazı bireyler, finansal konulara ilgi duymayabilir veya finansal okuryazarlık eğitimine gereken önemi vermeyebilir (Sarigül, 2020). Finansal kuruluşlar, sivil toplum kuruluşları ve eğitim kurumları arasındaki işbirlikleri ile eğitim programlarının geliştirilmesi ve yaygınlaştırılmasıyla daha fazla kişilerin finansal konuları anlaması sağlanabilir. İnteraktif öğrenme deneyimleri sunularak, bazı eğitim sistemlerinde yetersiz veya eksik olunan konular hakkında bilgi sahibi olmasını engellenebilir.

Şekil 9: Finansal Okuryazarlık GZTF Analizi




Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Finansal okuryazarlık, bireylerin finansal refahını artırır, riskleri yönetmeyi öğretir ve geleceğe yönelik finansal hedeflerini gerçekleştirmelerine yardımcı olur. Bu nedenle, bireylerin finansal okuryazarlık becerilerini geliştirmek için eğitim, kaynaklar ve danışmanlık hizmetlerinden yararlanmaları önemlidir.


Şekil 10'te 2003-2023 Haziran dönemlerini içeren BİST100 endeksinin TL bazlı grafiği yer almaktadır. 2003 yılının ortalarında endeks 108'li seviyelerdeyken 20 yıl sonrasında 5750'li seviyelere kadar çıkmıştır. Bu bilgilere istinaden BİST 100 endeksinin 20 yılda 53 kat artmış olduğunu söyleyebiliriz.

Şekil 10: BİST 100 Kapanış Fiyatları (2003-2023)




2003 ve 2004 yıllarında 50 – 100 seviyeleri arasında artış ve azalışlar sergileyen BİST 100 endeksi, 2004 yılı ortasından itibaren yükselişe başlamış ve 2006 yılının ilk çeyreği olan 500’li seviyelere kadar yükselişini devam ettirmiştir. Akabinde, 4 ay kadar süreyle 300’lü seviyelerine kadar gerilemiştir. 2006 yılı ortasında yeniden yükselişe geçmiş ve 2007 yılının üçüncü çeyreğinde 600’lü seviyeleri test etmiştir. 2008 yılının başlangıcından sonuna kadar düşüşler devam etmiş ve tekrardan 210’lu seviyelere kadar düşüş gerçekleşmiştir. 2009 yılının Mart ayından itibaren tekrar yükselişe geçmiş ve bu yükseliş 2010 yılının üçüncü çeyreğine kadar 750’li seviyelere ulaşmıştır.

Şekil 11: BİST 100 Kapanış Fiyatları (2003-2013)




2010 ve 2016 yılları arasında yaşanan dalgalanmalar ile BİST 100 endeksi 550-900 seviyelerinde seyretmiştir. 2016 yılının sonunda 700’lü seviyede bulunan BİST 100 endeksi, 2018 yılının başına kadar 1200’lü seviyelere ulaşmıştır.

Şekil 12: BİST 100 Kapanış Fiyatları (2013-2018)



Pandeminin yavaş yavaş etki göstermesi ile tüm dünya genelindeki emtialarda yaşanan satış baskısı yüzünden BİST 100 endeksi de etkilenmiş ve 2020 yılının ikinci çeyreğinden itibaren 850 seviyelerine kadar düşmüş ve aynı yılın sonunda 1350 seviyelerinden kapanmıştır.

Şekil 13: BİST 100 Kapanış Fiyatları (2018-2023)



2020 yılının ortalarından sonra yabancı uyruklu kişilerin, fonlarını ve hisse senetlerini satmasıyla birlikte BİST 100 endeksinde TL bazlı yükselişler gözlemlenmiştir.

2023 yılına ait Ocak-Mayıs döneminde yatırımcısını üzen BİST 100 endeksi, Türkiye'de seçim belirsizliklerinin sona ermesiyle rekor üstüne rekor kırmaya devam ettiği, Birleşik Arap Emirlikleri arasında imzalanan 50,7 milyar dolar değerindeki anlaşma ve mutabakat zaptı ile yukarı yönlü yükselişe işaret etmektedir (İletişim Başkanlığı, 2023). Türkiye'nin büyüme tarafında kalma çabası ile yatırımcıların

borsaya ilgisinin tekrar artmaya başlayacağı ve enflasyona karşı yatırımcıların alternatif arayışının süreceğini söyleyebiliriz.


2.12. TOPLUM 5.0 VE BANKACILIK

Toplum 5.0, Japonya'nın bir vizyonu olarak ortaya çıkan bir kavramdır. Bu kavram, geleneksel endüstrilerin dijital dönüşümü ve sürdürülebilir bir toplum oluşturma hedefini içerir. Hem farklı şirketlere hizmet hem de sosyal hayattaki zorlukları kapsayan, bunları çözme kavuşturan bir toplumun oluşturulması yapay zekâ, robot teknolojileri, büyük veri analitiği ve diğer ileri teknolojilerin kullanımını teşvik ederek insanların yaşam kalitesini artırmayı hedefler.

Bankacılık sektörü, Toplum 5.0 vizyonunun önemli bir bileşenidir. Bankacılık, finansal hizmetlerin temel bir parçası olduğundan sağladığı dijitalleşme ve teknolojik ilerlemelerden etkilenir. Toplum 5.0 felsefesine uygun olarak, bankacılık sektörü değişim ve dönüşüm sürecine girerek birçok teknolojik yenilikle müşterilere daha iyi hizmet sunmaktadır.

Toplum 5.0, bilimsel ve teknolojik gelişmelerin yardımıyla toplumları ve bireyleri ana değer olarak varsayan, insanı merkeze alan, bir topluma kesin dönüşüm olarak ifade edilmektedir (Körpe, 2021). Bu sayede geleceğin toplumu, yeni değerleri ve hizmetleri eksiksiz olarak şekillendiren insanların yaşamlarını daha sürdürülebilir ve uyumlu hale getiren bir toplum olabilecektir (Kent, 2018).

Şekil 14: Toplum 5.0 ve Bankacılık



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Yapay zekâ destekli müşteri hizmetleri ve kişiselleştirilmiş hizmetler ile bankalar, müşterilerin finansal ihtiyaçlarına uygun kredi, yatırım ve sigorta ürünleri sunar

(Alimohammadlou ve Khoshsepehr, 2023). Müşterilerin finansal işlemlerinin güvenliğini sağlamak, işlemlerini şeffaf bir şekilde gerçekleştirmek ve dolandırıcılığı önlemek için blockchain teknolojisini kullanmaktadır (Carayannis ve Morawska-Jancelewicz, 2022).

Toplum 5.0, teknolojik gelişmeleri kullanarak finansal hizmetlere erişimi kolaylaştırmayı ve finansal kapsayıcılığı artırmayı hedeflemektedir. Bankalar, finansal teknolojileri benimseyerek inovasyon odaklı çözümler sunmaktadır (Arı, 2021). Örnek olarak; yapay zeka ve büyük veri analitiği kullanarak müşterilere kişiselleştirilmiş finansal danışmanlık sağlamak, blockchain teknolojisiyle güvenli ve şeffaf finansal işlemler gerçekleştirmek gibi uygulamaları hayata geçirebilirler. Yine, mobil cüzdanlar aracılığıyla banka hesabı olmayan kişilere ödeme yapma ve para transferi imkânı sağlamak gibi çözümler sunabilirler. Özellikle gelişmekte olan bölgelerde ve dezavantajlı gruplarda finansal hizmetlere erişimi kolaylaştırmak amacıyla dijital bankacılık çözümleri ve mikrofinans projeleri geliştirilir (Mehdiabadi vd., 2022).

Toplum 5.0'nin bir diğer önemli unsuru olan sosyal sorumluluk, bankaları sürdürülebilir ve toplum odaklı yatırımları teşvik etmeye yönlendirmektedir (Mahawar vd., 2024). Bankacılık sektörü, sürdürülebilirlik ilkelerini benimseyerek yeşil finansman ve topluma pozitif etkisi olan sosyal etki yatırımları ve çevresel faktörleri dikkate alan krediler gibi uygulamalarını destekleyerek sosyal etki yatırımlarına odaklanmaktadır (Vittala vd., 2025). Örneğin, yenilenebilir enerji projeleri, enerji verimliliği yatırımları ve çevre dostu projelere finansman sağlama, dezavantajlı gruplara yönelik kredi programları veya sosyal girişimlere destek verme gibi uygulamalar gerçekleştirir ve toplumun sürdürülebilir kalkınmasına katkıda bulunurlar.

Bankaların desteklediği bazı Toplum 5.0 sosyal projeleri şunlardır: Asya Altyapı Yatırım Bankası (AIIB), Özbekistan'ın Buhara Bölgesi'nde temiz içme suyu sağlama projesini finanse etmektedir. Proje kapsamında hedeflenen bölgelerde kanalizasyon ağı bulunmamakta, bu yüzden su ve sanitasyon altyapısının güçlendirilmesi büyük önem taşıyor. 1.15 milyon kişiyi etkileyecek bu projenin amacı, sadece temiz su sağlamakla kalmayacak; aynı zamanda su hizmetlerinin operasyonel performansını güçlendirmesi ve sağlık sonuçlarını iyileştirmesi gibi faydalar da sağlamaktadır. AIIB'nin desteğiyle, bu proje su kaynaklarının sürdürülebilir kullanımına ve toplumun

refahına katkı sağlamaktadır (AIIB, 2023). Türkiye'de faaliyet gösteren bir banka olan Garanti BBVA tarafından yenilenebilir enerji projesi desteklenmektedir. Proje, Türkiye'nin enerji ihtiyacını karşılamak için rüzgâr, güneş, jeotermal ve biyokütle gibi yenilenebilir enerji kaynaklarını kullanmayı amaçlamaktadır. Proje, hem çevresel hem de ekonomik açıdan sürdürülebilir bir enerji modeli oluşturmayı hedeflemektedir (Garanti BBVA, 2021). Japonya'da faaliyet gösteren bir banka olan Mizuho Bank tarafından desteklenen afet yardımı projesi, Japonya'da meydana gelen deprem, tsunami, tayfun gibi doğal afetlerde zarar gören insanlara yardım etmeyi amaçlamaktadır. Mizuho, etkilenen bölgede yardım sağlayan kuruluşlara 10 milyon JPY bağışta bulunuyor. Proje, hem finansal hem de gönüllü olarak afetzedelere destek sağlamaktadır (Mizuho Bank, 2023).

Bu örnekler, Toplum 5.0 vizyonunun bankacılık sektöründe nasıl şekillendiğini göstermektedir. Bankacılık sektörü, dijitalleşme, sürdürülebilirlik ve sosyal sorumluluk gibi alanlarda yenilikçi çözümler sunarak toplumun daha sürdürülebilir, erişilebilir ve yaşanabilir bir geleceğe doğru ilerlemesine katkıda bulunmaktadır.

2.13. BİST TEMETTÜ 25 (XTM25) ENDEKSİ

Temettü, bir şirketin karından hissedarlara dağıttığı kâr payıdır. Temettü miktarı genellikle şirketin finansal durumu, yatırım ihtiyaçları, borçluluk düzeyi, geçmiş temettü ödemeleri, sektör eğilimleri, büyüme hedefleri ve piyasa koşulları gibi faktörlere bağlı olarak belirlenir. Ancak, her şirketin temettü politikası ve temettü ödeme düzeni farklı olabilir, bu nedenle yatırımcılar hisse senedi seçiminde temettü politikasını ve temettü ödemelerini de dikkate almalıdır (Kaya, 2024).

Temettü ödemeleri genellikle belirli periyotlarda yapılır, yıllık veya dönemsel olarak açıklanır. Şirketler, temettü ödemelerini genel kurul toplantılarında hissedarlara duyururlar. Temettü ödemeleri genellikle nakit olarak yapılır, ancak bazı durumlarda hisse senedi bölünmesi şeklinde de dağıtılabilir (Yılmaz ve Gül, 2023).

BİST TEMETTÜ 25 Endeksleri, 01.07.2011 tarihinde hesaplanmaya başlayarak Borsa İstanbul'da işlem gören şirketler arasından güçlü finansal duruma ve istikrarlı temettü ödeme geçmişine sahip olan temettü verimliliği açısından en yüksek 25 şirketi içermektedir. Bu endeks, yatırımcılara temettü ödemeleri üzerinden getiri elde etmeyi

hedefleyen bir referans noktası oluşturmak için kullanılabilecek şirketleri belirlemektedir.

Her yıl belirli bir döneme göre şirketlerin temettü verimliliklerini değerlendirerek oluşturulur. Endekste yer alacak şirketler, temettü ödemeleri yapılan döneme göre seçilir ve yüksek temettü verimliliği gösteren şirketler tercih edilir. Temettü Verimi Şekil 15'teki gibi hesaplanmaktadır:

Şekil 15: Temettü Verimi


$$TV_i = \frac{(\ddot{O}T_i - SAT_i)}{PD_i}$$

Buradaki formülde yer alan “i” şirketi ifade etmektedir. “ TV_i ”, değerlendirme gününe takiben hesaplanan temettü verimini, “ $\ddot{O}T_i$ ”, içinde bulunulan mali dönemde ödediği toplam brüt nakit temettü tutarını, “ SAT_i ”, içinde bulunulan mali dönemde ortaklara rüçhan hakkı kullandırmak suretiyle yaptığı rüçhan hakkı kullandırma fiyatı ve bedelli sermaye artırımı tutarının çarpılması sonucunda elde edilen tutarların toplamını, “ PD_i ”, değerlendirme günü piyasa değerini belirtmektedir (BİST, 2023).

Farklı sektörler ve şirketler; operasyonel, ekonomik durgunluklarda ve dalgalanmalarda zorluklarla karşılaştığında ya da kriz dönemlerinde temettü politikasında azaltma veya tamamen kesme kararı değişikliği yapabilirler. Ayrıca, şirketler karlarını artırmak veya yatırımlara yönlendirmek için temettü politikalarını değiştirebilir. Dolayısıyla, yatırımcılar bu temettü gelirinden beklenen geliri elde edemeyebilir ve mahrum kalabilirler.

Temettü yatırımları, hisse senedi fiyatlarındaki büyük artışlardan yoksun kalabilir. Diğer yatırım stratejilerine göre potansiyel getiri düşük olabilir. Endeks, sadece temettü ödemesi yapan şirketlerden oluştuğu için bazı sektörleri ve şirketleri dışarıda bırakabilir. Bu yüzden, temettü yatırımcıları hisse senedi fiyatlarının yanı sıra temettü verimini de dikkate almalıdır. Şirketlerin kar payı ödemeleri, genellikle karlılık ve finansal durumlarına dayandığından sürdürülebilir kar payı politikaları olan şirketler, yatırımcılar için güvenilir bir seçenek olabilir.

Şekil 16: BİST TEMETTÜ 25 Endeksi ve Temettü Yatırımları GZTF Analizi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Yatırımcılar, BİST TEMETTÜ 25 endeksi üzerindeki performansı takip ederek temettü odaklı portföylerini yönlendirebilirler. Fakat, endekste ki şirketlerin temettü ödemeleri ve performansı sürekli olarak değişebilir, bu nedenle yatırımcıların güncel verileri ve şirket analizlerini takip etmeleri önemlidir.

BÖLÜM 3: DİJİTAL FİNANS

Dijital finans, finansal hizmetlerin dijital teknolojilerin kullanımıyla sunulduğu bir kavramdır. Bu kavram, geleneksel finansal hizmetlerin dijitalleşmesi, süreçlerin ve iş modellerinin teknolojik yenilikler ile beraber finans sektöründe yaygınlaşmasıyla ortaya çıkmıştır. Dijital finans, kullanıcıların finansal işlemlerini daha hızlı, kolay ve erişilebilir bir şekilde gerçekleştirmelerini sağlar (Gomber vd., 2017).

Dijitalleşme, ekonomiyi çeşitli düzeylerde etkileme gücüne sahiptir. Ekonominin üretim tarafında, dijital dönüşüm, işletme operasyonlarının otomasyonunu, işlem maliyetlerindeki azalmayı ve bunlara bağlı olarak ortaya çıkan operasyonel verimliliği beraberinde getirmektedir (Katz, 2017).

Nakit para kullanımını azaltarak ödemelerin daha hızlı ve kolay yapılmasını sağlayan online ödeme sistemleri, mobil ödemeler, dijital cüzdanlar ve kripto para birimleri gibi elektronik ödeme yöntemlerini içerir. Bankacılık hizmetlerinin dijital kanallar aracılığıyla sunulması, Mobil bankacılık uygulamaları, internet bankacılığı ve ATM'ler gibi dijital araçlar üzerinden hesap işlemleri, para transferleri, kredi başvuruları ve diğer bankacılık işlemleri gerçekleştirilebilir.

Dijital finansı destekleyen finansal teknolojiler, finansal hizmetlerin dijitalleşmesini ve yenilikçi çözümler sunulmasını sağlar. Fintek, yapay zekâ, büyük veri analitiği, blockchain teknolojisi ve otomasyon gibi ileri teknolojileri kullanarak finansal süreçleri geliştirir ve finansal erişilebilirliği artırır.

Dijital yatırım platformları ve finansal planlama araçları, yatırımcıların portföy yönetimini kolaylaştırır ve finansal hedeflerine ulaşmalarına yardımcı olur. Geleneksel bankacılığa erişimi sınırlı olan kişiler, dijital bankacılık ve ödeme yöntemleri sayesinde finansal hizmetlere daha kolay erişebilirler. Ödemelerin anında yapılabilmesi, bankacılık işlemlerinin evden veya cep telefonundan kolayca yapılabilmesi gibi avantajlar vardır. Örneğin, peer-to-peer krediler, kitle fonlaması ve otomatik yatırım platformları gibi yeni finansal modeller popüler hale gelmiştir.


İnovasyon, müşteri deneyimi, dijital ve teknolojik yetkinlik gelişmelerinden azami düzeyde yarar sağlamak ve riskleri nasıl değerlendireceğimize olanak tanınması için önce yetkinlik dönüşümü yani STEM (Bilim, Teknoloji, Mühendislik, Matematik) yetkinlikleri değerlendirilmelidir (PwC Türkiye, 2022).

Daha iyi kullanıcı deneyimi, yenilikçi finansal çözümler, daha hızlı ve kolay finansal işlem avantajlarının yanı sıra dijital dönüşümün bazı zorlukları da vardır. Bunları, güvenlik ve veri gizliliği riskleri, altyapı ve donanım, yönetim, iş operasyonları ve regülasyon zorlukları olarak sınıflandırabiliriz (Gai vd, 2018). Finans kuruluşlarının müşteri güvenini koruması ve bu zorluklarla başa çıkması için ek olarak güvenlik önlemleri alması, bütünlüğü, yetkilendirme ve kullanılabilirliği sağlamalıdır (Mehrban vd, 2020).

3.1. FİNANSAL HİZMETLERDE DİJİTAL DÖNÜŞÜMÜ SAĞLAYAN TEKNOLOJİLER

Dijital dönüşüm, Şekil 17’de gösterildiği gibi birçok finansal hizmetler sektöründe kullanılabilmektedir ve belirtilen başlıca alanların önümüzdeki yıllarda daha hızlı bir gelişim göstermesi beklenmektedir.

Şekil 17: Finansal Hizmetlerde Dijital Dönüşümü Sağlayan Başlıca Teknolojiler



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Bulut bilişim ile daha fazla veri kapasitesiyle, finansal kurumların verilerini ve uygulamalarını depolayarak, işbirliği ve maliyet tasarrufu ile internet tabanlı bir altyapı kullanılması sağlanır. Veri analitiği, kişiselleştirilmiş hizmetler, dolandırıcılık tespiti ve risk değerlendirmesi alanlarında büyük veri ve veri analitiği teknolojilerini kullanarak büyük veri kümelerini analiz edebilir ve müşteri davranışlarını, riskleri ve pazar trendlerini anlamalarına yardımcı olur. AI ve ML teknolojileri yardımlarıyla

finansal kurumların verileri analiz etmesini, öngörüler yapmasını ve otomatik kararlar almasını sağlar. Mobil uygulamalar ve ödemeler ile finansal hizmetlere erişim kolaylaşır. Ödeme, yatırım ve bütçe yönetimi gibi işlemleri mobil cihazlar aracılığıyla hızlı ve güvenli bir şekilde transferlerini mümkün kılar. RPA, finansal kurumların tekrarlayan ve zaman alıcı iş süreçlerini otomatikleştirmelerine olanak sağlar. Böylece, veri girişi, hesaplamalar, raporlama ve diğer rutin görevleri otomatik hale getirir.

Blockchain teknolojisi kullanılarak finansal işlemleri güvenli ve değiştirilemez bir şekilde kaydetmeye olanak sağlandığından para transferleri, akıllı sözleşmeler, KYC süreçleri ve takas işlemleri gibi alanlarda etkin olarak faaliyetlerde bulunur. Düzenleyici ortam ya da yüksek güvenli finans uygulamalarında kullanıldığından, tüm bileşenlerin düzgün bir şekilde entegre edildiği, sistemlerin ve işlevlerinin güvenli ve aktif çalışması için bir takım testler belirli periyotlarda ve uygun prosedürlerde yapılmalıdır. Bunlardan; fonksiyonel, entegrasyon, hata ayıklama, sistem performans, akıllı sözleşmeler ve API testleri önemli birer değerlendirme aracı olarak dikkate alınması gereken esasların başında gelmektedir (Özenen, 2023).

Muhabir Bankacılık, esasında yerel bir bankanın yurtdışında şubesi bulunmadığı başka bir ülkedeki banka ya da finans kuruluşuna kendi adına operasyonları yöneten bankadır. Teminat mektupları, para transferleri, nakit yönetimi, döviz bozdurma, fon aktarımı gibi ticari işlemlerin tümüne aracılık etmektedir. Dağıtık defterler teknolojisi ile bankalar arası işlemlerde masraflar en aza indirgenirken, çapraz kurlara göre gerçek zamanlı ödemeleri de mümkün kılacaktır. Bu sistem sayesinde, günlerce süren para transfer işlemleri saniyeler içinde yapılabilecek ve tüm işlem süreçleri şeffaf olarak sağlanabilecektir (Güler, 2019).

Togg'un dijital platform uygulaması Trumore; IoT, NFT, fintek, insurtek, blokzinciri, yapay zeka gibi yeni nesil teknolojilerle entegre edilmiş bir platformdur. Earn.more servisi altında bulunan e-cüzdan sayesinde mobil ödeme ya da araç içi ödeme yapabilir, ödül programları ile birlikte aktifleşecek olan dijital varlık cüzdanı oluşturulabilirsiniz (TOGG, 2023).

3.1.1. YAPAY ZEKÂ TEKNOLOJİLERİ


Yapay zekâ teknolojileri, bilgisayar sistemlerinin insan benzeri zekâ ve öğrenme yeteneklerini kullanarak görevleri gerçekleştirmesini sağlayan bir dizi teknik ve yöntemleri kapsar.

Alan Turing'in ünlü Turing Testi bu alanda önemli bir dönüm noktası olmuştur. 1950 yılında yayımladığı "Computing Machinery and Intelligence" başlıklı makalesinde, bir insanın bir makineyle iletişim yoluyla anlam ve bilinç açısından ayırt edilemez bir şekilde etkileşime geçtiği durumda, makinenin yapay zekâyâ sahip olduğunu kabul etmek gerektiğini öne sürmüştür. Bu test, yapay zekânın insan düşüncesi ve zekâsıyla benzerliklerini değerlendirmek için hala kullanılmaktadır (Turing, 2004; Turing, 2009).

Sibernetik, yapay sistemlerde bilgi, haberleşme, geri besleme karar çıktısının geri bildirim girişi olarak sistemi tetiklemesi esasına dayanana, oto kontrol ve oto bakım üzerine yoğunlaşan, insan ihtiyaçlarını ve davranışlarını toplumun düzenine göre iyileştirmeyi düzenleyebilen yönetim sistemleridir. Sibernetik sistemler, insani müdahaleye gerek duymadan, makinenin değişen durumlara göre kendi kendini düzenleyebilen bir düzeltme mekanizması olarak tanımlanabilir.

Sibernetik bir yaklaşımla modellenmiş bir Yapay Beyin, Sembolik bir yaklaşımla insan aklına benzetilmiş bilişsel süreçler ve Yapay Bilinç sistemi, insan aklı kadar esnek ve duyguları olan bir İrade (Karar alma yetisi), Uzman sistemler kadar yetkin bir bilgi birikimi ve rasyonel yaklaşımın dengeli bir karışımı sayesinde Yapay Zekâ, gelecekte insan zekâsına bir alternatif oluşturabilir.

Şekil 18: Yapay Zekâ ve Alt Kümeleri




Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Yapay zekâ, bankacılık ve finans sektöründe büyük bir etkiye sahip olmuştur. Finans sektöründe özellikle otomatik risk değerlendirmesi, dolandırıcılık tespiti, risk analizi, kişiselleştirilmiş hizmetler, portföy yönetimi, tahmin, müşteri davranışı analizi, otomatik yatırım danışmanlığı, müşteri hizmetleri ve Chatbotlar gibi alanlarda yapay zeka teknolojilerinden faydalanılmaktadır.

Makine Öğrenmesi, bir bilgisayarın belirli bir görevi yapabilmek için veri kullanarak kendini eğitmesini sağlayan bir yapay zekâ yöntemidir. Makine öğrenmesi algoritmaları, veri setlerindeki desenleri ve ilişkileri tanıyarak tahminlerde bulunabilir, sınıflandırma yapabilir veya kararlar alabilir.

Derin Öğrenme, sinir ağları olarak bilinen yapay sinir ağı modellerini kullanarak karmaşık veri yapılarını işlemeyi hedefleyen bir makine öğrenmesi alt dalıdır. Derin öğrenme algoritmaları, çok katmanlı sinir ağlarını kullanarak veriye dayalı öğrenmeyi gerçekleştirir ve genellikle görüntü tanıma, ses işleme ve doğal dil işleme gibi karmaşık görevlerde etkilidir.

Şekil 19: Yapay Zekâ GZTF Analizi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Yapay Zekâ, büyük miktarda veriyi hızlı bir şekilde analiz edebilir ve karmaşık işlemleri otomatikleştirebilir, bu da verimliliği artırır. İnsanlar gibi fiziksel ve zihinsel sınırlamalardan etkilenmez, sürekli olarak çalışabilir. Veri analizi ve algoritmalar kullanarak sürekli olarak öğrenebilir ve kendini geliştirebilir. Tekrar eden ve rutin işleri insan hatalarından arındırır ve doğruluk oranını artırır.

Yapay Zekâ sistemleri, yüksek kalitede ve güvenilir veriye ihtiyaç duyduğundan, yetersiz veya yanlış veri, yanlış sonuçlara yol açabilir. İnsanlarla duygusal bağ kurma, benzeri düşünme ve anlama yeteneğine veya ikna etme yeteneğine sahip olmadığından, bazı hizmetlerde müşteri memnuniyetini etkileyebilir. Bu durum, finansal risklerin yanlış değerlendirilmesine veya hatalı yatırım kararlarına yol açabilir.

Yapay Zekânın kullanılmasıyla, iş süreçlerini otomatikleştirerek ve verimliliği artırarak maliyetleri düşürebilir ve iş süreçlerini hızlandırabilir. Müşteri davranışlarını analiz ederek kişiselleştirilmiş öneriler sunabilir ve müşteri deneyimini iyileştirebilir. Birçok uygulama alanına sahip olduğundan ve yeni fırsatlar sunmaktadır.

Yapay Zekânın yaygınlaşması, bazı işlerin otomatikleştirilmesine ve iş gücü talebinde azalmalara neden olabilir. Özellikle veri kullanımı, algoritmik adalet ve etik standartlar gibi konular dikkate alınmalıdır. Hassas bilgilerin korunması ve kötü niyetli kullanımlara karşı önlemler alınmalıdır.

Sistem hataları ve teknik sorunlar, özellikle karmaşık finansal işlemlerin otomatikleştirildiği durumlarda, sistem hatalarının finansal kayıplara yol açma potansiyeli olduğundan finansal süreçlerde aksamalara veya hatalara neden olabilir. Etiğe İlişkin Sorunlarda ise yapay zekâ algoritmaları tarafından verilen kararlar, adaletsizlik, ayrımcılık veya önyargı gibi sorunlara neden olabilir. Böylece, finans sektöründe güvenilirlik ve itibar sorunlarına yol açabilir.

3.1.2. MAKİNE ÖĞRENMESİ KONSEPTİ

Makine öğrenimi, algoritmaların veri üzerinde otomatik olarak öğrenme yapmasını ve sonuçları tahmin etmesini sağlayan bir yapay zekânın bir alt dalıdır. Kural tabanlı programlamaya dayanmadan verilerden öğrenebilen, mümkün olan en doğru tahminleri yapmak için tasarlanan algoritmalardır. Çalışma prensibi; "Model olarak X, Y ve Z verildiğinde A'yı tahmin etmede % 16 doğruluğa sahiptir" şeklindedir.

Şekil 20: Makine Öğrenmesi Bileşenleri




Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Tarihler 1958 yılını gösterdiğinde, halka açık bir konferansta "Makine düşünebilir mi ve nasıl düşünebilir?" sorusunu gündeme getiren Arf, bir insan düşüncesinin belli bir parçasını taklit etmeye çalışan kimi özelliklere sahip makinelerin tespitlerde bulunmasını örnek çözümler ile ele almıştır. Arf'in 1959 yılında yazdığı makalesinde öne sürülen ispatlarla makine ve insan arasındaki kıyaslamalara yer verilmiş ve düşünen makine tasarımları incelenmiştir. Arf, temel farkı makinelerde eksik olan estetik bilincin insanın sahip olduğu gibi kazandırılmasını istemektedir (Arf, 1959).

Şekil 21, tezde araştırma yapılan makine öğrenmesi modellerini kapsamaktadır. Yukarıda bahsedilen makine öğrenmesi ve bazı temel özellikler ilerleyen bölümlerde açıklanmıştır.

Şekil 21: Makine Öğrenmesi Modelleri



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Makine öğrenmesi teknolojisi ile bilgisayarların programlanmaktan ziyade verileri kullanarak kendilerini geliştirmesine olanak tanır. Bu süreçte, algoritma geçmiş verileri kullanır, bu verilere dayalı olarak modeller oluşturur ve bu modelleri yeni verilere uygular. Gelecek hakkında tahminler yapılabilmesi için; test ve eğitim veri setleri olmak üzere iki alt sınıfa ayrılır. Oluşturulan modelde, eğitim verilerinden elde

edilen verilere göre oluşturulur. Modelin eksik veya aşırı öğrenmesi durumunda, model yeterli öngöründe bulunamayacağından tahminlerde hata oranı yüksek olacaktır.

Makine öğrenmesi yöntemleri, zaman serisi verilerini analiz etmek ve gelecekteki temettü ödemelerini tahmin etmek için kullanılabilir. Makine öğrenmesi modelleri, temettü ödemelerindeki desenleri, geçmiş performansı ve diğer ilgili faktörleri dikkate alarak gelecekteki temettü ödemelerini tahmin etmek için kullanılabilir.

Makine öğrenmesinde kullanılan temel adımlar; Veri, Algoritma, Öğrenme ve Değerlemedir.


İlk adımda yer alan ve makine öğrenmesi için temel olan veri, belirli bir problem veya görevle ilişkili olan girdi ve çıktı bilgilerini içerir. Veri setleri genellikle eğitim verileri, doğrulama verileri ve test verileri olarak ayrılır. Verilerde mevcut olan tutarsızlık yanlış tahminlere yol açabileceğinden fazlalık ve gereksiz veriler temizlenmelidir.

Makine öğrenmesi algoritmaları, verileri analiz etmek, desenleri belirlemek ve modeller oluşturmak için kullanılır. Bu aşamada, farklı tahmin değişkenleri arasındaki ilişki tespit edilmeli ve anlaşılmalıdır. Çeşitli veri değişkenleri arasındaki ilişkiyi bulmamız gereken en önemli adımlardan biridir.

Bir Makine Öğrenimi modeli oluşturulmasındaki temel amaç, algoritmanın verilerden öğrenmesini sağlamaktır. Bu, algoritmanın verileri analiz etmesi, desenleri tanınması ve yeni verilere uygulamak için model oluşturması anlamına gelir.

Model Değerlendirmesinde, temel olarak makine öğrenimi modelinin verimliliğini test edilir. Eğitim verilerine dayalı olarak gelecekteki veriler için tahminler yapılabilir ve kararlar verilebilir. İyileştirme için herhangi bir yer varsa, parametre ayarı yapılır. Böylece, modelin doğruluğunu artırılır.

Şekil 22: Makine Öğrenmesinde Kullanılan Adımlar




Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Doğru veri setlerinin kullanılması, modelin doğru şekilde eğitilmesi, veri gizliliği ve etik konuları gibi dikkate alınması gereken zorluklar ve risklerin yanında büyük

veri analizi, öngörülebilirlik, kişiselleştirilmiş hizmetler ve otomasyon gibi alanlarda önemli faydalar sağlayabilir.

Makine öğrenmesi, bankacılık ve finans sektöründe birçok farklı alanda kullanılan bir teknolojidir. Örneğin, bir makine öğrenmesi modeli, belirli bir müşterinin bir ürünü satın alma olasılığını tahmin edebilir veya bir e-postanın spam olup olmadığını belirleyebilir. Risk analizi, hisse senedi fiyatları, döviz kurları ve emtia fiyatları gibi piyasa trendleri tahmini, müşteri segmentasyonu, dolandırıcılık tespiti ve otomatik karar verme gibi alanlarda makine öğrenmesi teknikleri kullanılabilir.

Şekil 23: Makine Öğrenmesi GZTF Analizi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Makine öğrenmesi, büyük veri setlerine ait karmaşık desenleri hızlı bir şekilde işleyebilme, analiz edebilme, otomatik kararlar verebilme ve ölçekleyebilme ilişkileri tanımlama yeteneğine sahiptir. Bireysel kullanıcıların tercihlerine ve davranışlarına dayalı olarak kişiselleştirilmiş hizmetler sunma yeteneği ile yeni verilerle beslenerek sürekli olarak gelişebilir ve daha doğru tahminler yapabilir, müşteri memnuniyetini artırabilir.

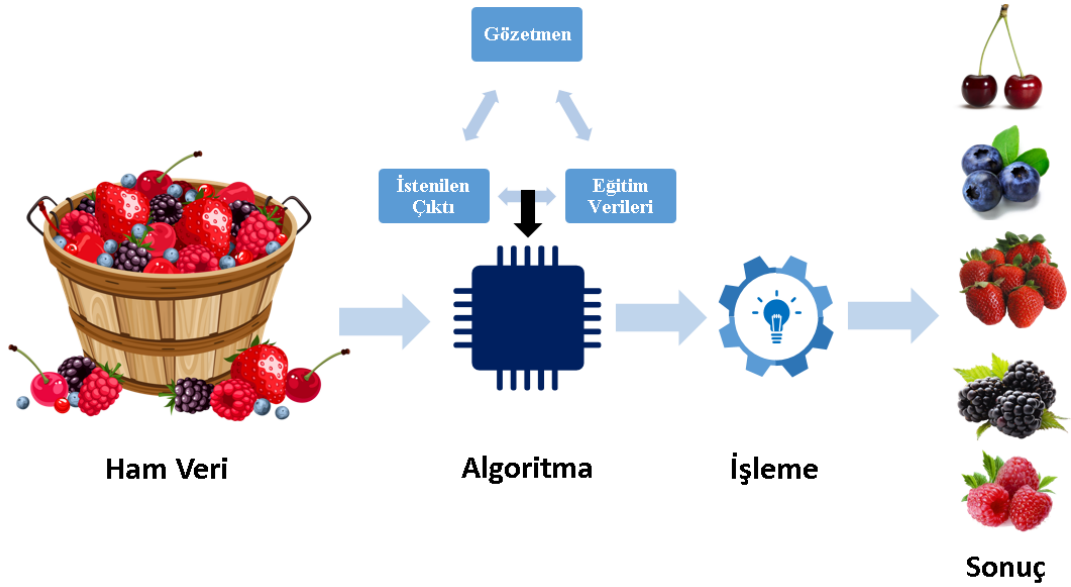
Makine öğrenmesi teknolojisi, bazı işlerin otomatikleştirilmesine ve insan iş gücünün yerini almasına neden olabilir. Makine öğrenmesi modellerinin eğitimi ve yönetimi bazen uzman insan müdahalesi gerektirebilir. Eğitildiği veri setine çok sıkı bir şekilde bağlı olabilir ve genelleme yeteneği zayıf olabilir. Veri kalitesi eksikliği veya düşük kaliteli veriyle karşılaştığında performansını etkileyebilir.

3.1.2.1.Klasik Öğrenme

3.1.2.1.1.Gözetimli (Supervised) Öğrenme

Gözetimli (supervised) öğrenme yönteminde, eğitim verileriyle birlikte etiketlenmiş (label) örnekler kullanarak bir modelin öğrenmesi sağlanır. Eğitim veri setindeki örneklerle beslendiğinden yeni verileri tahmin etmek için kullanılır. Eğitim verileri bir dizi giriş ve hedef setinde oluşmaktadır. Eğitim seti, test seti arasında farklılık bulunmaktadır. Eğitim seti öğrenen algoritma için kullanılırken test seti ise araştırmacı tarafından oluşturulan hipotezlerin doğruluğunu test etmek için kullanılır ve öğrenen algoritmalarından saklanan bir örnek setidir. Model, bilinen verilere göre eğitildikten sonra, bilinmeyen verileri modelde kullanabilir ve yeni bir sonuca ulaşılabilir.

Şekil 24: Gözetimli (Supervised) Makine Öğrenmesi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Gözetimli öğrenme hedef türüne bağlı basitçe sınıflandırma ve regresyon olmak üzere iki kategoriye ayrılır.

3.1.2.1.1.1.Regresyon (Regression)

Regresyon, nicel (sayısal) değişkenler aralarındaki nedensellik ilişkisini tahmin ederek geleceği tahmin etmede yardımcı olan istatistiksel bir yaklaşımdır. Bir gözlemin ait olduğu sınıfı tahmin eden sınıflamanın tersine, regresyon sürekli bir çıktı

değişkenine dönüşür. Regresyon analizinin temelinde; gözlenen bir olayı değerlendirilirken, hangi olayların etkisi içinde olduğunun araştırılması yatmaktadır.

3.1.2.1.1.1.Lojistik

Lojistik Regresyon (Logistic Regression), bağımlı bir değişkenin (etiket) kategorik bir sınıfa ait olma olasılığını tahmin etmek için kullanılan etkili bir makine öğrenimi modelidir. Lojistik regresyon çıktı olarak bir olasılık değeri ürettiğinden hedef değişkeni için (0,1) aralığında bir ihtimal elde edilir. 0,5'ten daha az (veya eşit) (eşik olarak bilinir) ihtimaller, olumsuz olarak sınıflandırılırken 0.5'den büyük bir ihtimal olumlu olarak sınıflandırılır. Bu olasılık değeri, belirli bir sınıfa ait olma olasılığını temsil eder. Şekil 25'te örnek bir lojistik regresyon denklemi verilmiştir:

Şekil 25: Lojistik Regresyon Denklemi

$$P(y = 1 | x) = \frac{1}{1 + e^{-(b_0 + b_1 x_1 + b_2 x_2 + \dots + b_n x_n)}}$$

“e”, doğal logaritmaların tabanıdır (Euler'in sayısı veya EXP () işlevi) ve değer, dönüştürmek istediğiniz gerçek sayısal değerdir.

Lojistik regresyon eğitim modeli, veri setindeki bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi yakalamayı amaçlar. Eğitim verileri kullanılarak model parametreleri tahmin edilir.

Lojistik regresyonda, parametrelerin yorumlanması kolaydır. Birden fazla bağımsız değişken arasındaki etkileşimleri doğrudan ele almadığından bağımlı değişkenin olasılık tahminleri sağlanır. İyi performans gösterir ve hızlı hesaplamalara olanak tanır. Fakat dengesiz sınıf dağılımları gibi veri seti özellikleri performansı etkileyebilir. Model, veriye dayanarak her bir bağımsız değişkenin (X) sonucunu nasıl etkilediğini belirler. Katsayıların işareti, etkinin yönünü gösterir. Pozitif bir katsayı, bağımsız değişkendeki artışın olay gerçekleşme olasılığını artırdığını gösterirken, negatif bir katsayı tam tersini gösterir.

Katsayıların büyüklüğü, etkinin gücünü gösterir. Mutlak değeri büyük olan katsayılar, ilgili bağımsız değişkenin olay gerçekleşme olasılığı üzerinde daha büyük bir etkiye sahip olduğunu gösterir.

3.1.2.1.1.2.Sınıflandırma (Classification)

Makine öğreniminde sınıflandırma, gözlemlenen verileri içeren bir dizi eğitim verisine dayanan yeni bir gözlemin hangi kategori kümesine ait olduğunu belirleme işlemidir.

3.1.2.1.1.2.1.SVM

Destek Vektör Makinesi (Support Vector Machines), verileri analiz etmek ve kalıpları tanımak için ilişkili öğrenme algoritmalarını kullanan gözetimli makine öğrenimi teknikleridir.

SVM'de, amacımız veri noktalarını farklı sınıflara ayıran en iyi hiperdüzlemi bulmaktır. Hiperdüzlem, destek vektörlerin (hiperdüzleme en yakın veri noktaları) arasındaki marjı maksimize eden karar sınırı olarak tanımlanır ve yeni veri noktalarını sınıflandırmak için kullanılabilir.

3.1.2.1.1.2.2.Naive Bayes

Naive Bayes teoremi, bir olayın gerçekleşme olasılığının, olayın gözlemlenmiş kanıtlarına dayanarak nasıl güncelleneceğini açıklar.

Naive Bayes algoritması, bağımsız değişkenlerin birbirinden bağımsız olduğunu ve sınıf etiketinin bilindiğinde bağımsız değişkenler arasında ilişki olmadığını varsayar ve bağımlı değişkenin sınıflarının olasılıklarını hesaplar. Bu, modelin hesaplamalarını basitleştirir ve hesaplama maliyetini azaltır.

Naive Bayes, basit, hızlı ve hesaplama açısından verimlidir. Daha küçük veri setleriyle iyi sonuçlar verebilir ve genellikle iyi bir sınıflandırma performansı gösterir. Veri setinde nadir veya eksik özellikler olduğunda yanlış sonuçlar verebilir. Bağımsızlık varsayımı gerçek dünyadaki verilerde her zaman geçerli olmayabilir.

3.1.2.1.1.2.3.K-NN

K-En Yakın Komşu (K-Nearest Neighbors), bir veri noktasının yakınlık tabanlı sınıflandırmasında, en yakın komşularının sınıflarına bakarak karar veren bir tahminleme modelidir. K, veri kümesindeki veri sayısını ifade etmektedir.

➤ K-NN algoritmasının çalışma prensibi şu şekildedir:

1. Adım: Sınıflandırma durumunda, yeni bir veri noktasının sınıfını tahmin etmek için K-NN, yeni veri noktasının komşu k-en yakın noktalarını Öklid mesafesi kullanarak belirler. K, kullanıcı tarafından belirlenen bir parametredir ve genellikle tek sayı olarak seçilir.
2. Adım: Tahmin yapmak için, k-en yakın komşuların sınıfları (etiketleri) göz önünde bulundurulur. Sınıflandırma durumunda, en yaygın sınıf etiketi tahmin olarak seçilir. Yani yeni veri etiketlenmiş (label) olur.

➤ K-NN algoritmasının bazı önemli noktaları şunlardır:

- K-NN, eğitim aşamasında veriler üzerinde bir model oluşturmaz. Bunun yerine, tahmin yapmak için örnek verileri kullanır.
- K-NN, veriye dayalı bir öğrenme yöntemidir, bu nedenle eğitim süresi çok kısa olabilir.
- Parametre olarak seçilen K değeri, modelin performansını etkileyen önemli bir faktördür. Farklı K değerleri farklı sonuçlar verebilir.
- Veri kümesindeki özelliklerin ölçeklenmesi, K-NN algoritmasında önemlidir.

K-NN, basit ve anlaşılır bir algoritma olmasının yanı sıra yüksek boyutlu verilerle çalışırken hesaplama maliyeti ve boyutluluk problemleri ortaya çıkabilir.

Şekil 26: K-NN Denklemi

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

3.1.2.1.1.2.4. Karar Ağaçları (Decision Trees)

Karar Ağaçları, veri kümesini ağaç yapısıyla temsil eden ve her düğümde bir karar kuralı uygulayan bir modeldir. Verileri kategorik veya sayısal özelliklerine göre sınıflandırır veya regresyon yapar.


Karar Ağaçları, bir makine öğrenmesi algoritmasıdır ve sınıflandırma ve regresyon problemlerini çözmek için kullanılır. CART (Classification and Regression Trees), Decision Tree algoritmasının bir uygulamasıdır ve hem sınıflandırma hem de regresyon problemlerini ele alabilir.

Karar ağaçları, çok değişkenli analizin basit ama güçlü bir şeklidir. Verileri dal benzeri bölümlere ayırmanın çeşitli yollarını tanımlayan algoritmalar tarafından üretilirler. Karar ağaçları, verileri girdi değişkenlerinin kategorilerine göre alt kümelerle bölerek birinin karar yolunu anlamaya yardımcı olur.

➤ Karar Ağaçları algoritmasının çalışma prensibi şu şekildedir:

1. Adım: Veri kümesi, özellikler ve hedef değişkenlerden oluşur. Her bir örnek, özellik değerleriyle temsil edilen bir nokta olarak düşünülür.
2. Adım: Algoritma, veri kümesi üzerinde bir kök düğüm (root node) oluşturur. Bu kök düğüm, en iyi ayrışma (split) kriterine göre en önemli özelliği seçer.
3. Adım: Seçilen özellik ve eşik değeri üzerinde bir ayrışma yapılır ve veri kümesi bu ayrışmaya göre alt kümelerine ayrılır.
4. Adım: Her alt küme için, adım 2 ve 3 tekrarlanarak ağacın bir sonraki seviyesi oluşturulur. Bu işlem, belirli bir durumun tam olarak sınıflandırıldığı yaprak düğümlere (leaf node) kadar devam eder.
5. Adım: Tahmin yapmak için, bir test örneği ağaçta gezinir ve özellik değerlerine göre uygun dalı takip eder. En sonunda, test örneği yaprak düğümüne ulaşır ve bu düğümün tahmin değeri, test örneği için tahmin olarak kullanılır.

Şekil 27: Karar Ağaçları




Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

Bir karar ağacı, bir kök düğümden yukarıdan aşağıya oluşturulur ve verileri benzer değerlere sahip (homojen) örnekler içeren alt kümeler ayırmayı içerir.

3.1.2.1.2.Gözetimsiz (Unsupervised)

Gözetimsiz Öğrenme (Unsupervised Learning), etiketlenmemiş veriler kullanılarak modelin öğrenmesi gerçekleştirilir. Modelde etiket bilgisi yoktur, veri seti içerisindeki yapıları ve ilişkileri keşfetmeye çalışır.

Şekil 28: Gözetimsiz (UnSupervised) Makine Öğrenmesi



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

3.1.2.1.2.1.Boyutsal Küçültme (Dimensionality Reduction)

3.1.2.1.2.1.1.LDA

LDA, bir veri setinden etiketlenmemiş verilerini kullanarak yalnızca işe yarayacak özellikleri çıkarmak için verilerin boyut küçültme kullanılır.


LDA modeli, verileri temsil eden vektörler elde etmek ve bu vektörleri kullanarak verileri gruplamak, benzer verileri bulmak veya verilerdeki önemli konuları keşfetmek gibi birçok uygulamada kullanılabilir.

3.1.2.2.Topluluk Öğrenme (Ensemble)

Topluluk Modelleri, daha doğru bir çözüm sağlamak için her biri veriler içinde farklı modeller bulan çeşitli makine öğrenimi modellerini birleştirir. Bu teknikler, daha fazla eğilim yakaladıkları için performansı artırabilir.

Bir topluluk yönteminin genel ilkesi, tek bir modele göre sağlamlığı artırmak için belirli bir öğrenme algoritması ile oluşturulmuş birkaç modelin tahminlerini birleştirmektir.

Şekil 29: Topluluk Öğrenme (Ensemble)



3.1.2.2.1. Arttırma (Boosting)

3.1.2.2.1.1. AdaBoost

AdaBoost (Adaptive Boosting), sınıflandırma problemlerinde kullanılan etkili bir ensemble algoritmasıdır. Veri kümesindeki zayıf öğrencilerin hatalarını düzelterek, yüksek doğruluk sağlayan bir güçlü öğrenci oluşturur.

➤ AdaBoost algoritmasının çalışma prensibi şu şekildedir:

1. Adım: Başlangıçta her veri örneği için eşit ağırlıklar atanır. İlk olarak, zayıf bir öğrenci (örneğin, karar ağacı) bu veri kümesinde eğitilir.
2. Adım: Zayıf öğrenci, eğitim veri kümesindeki örnekleri sınıflandırır. Ancak, bazı örnekler doğru bir şekilde sınıflandırılamayabilir.
3. Adım: Sınıflandırma hataları yapılan örneklerin ağırlıkları artırılır, doğru sınıflandırılan örneklerin ağırlıkları ise azaltılır. Bu sayede, sonraki zayıf öğrencilerin daha fazla odaklanması gereken örnekler belirlenir.
4. Adım: Bir sonraki zayıf öğrenci, ağırlıkları güncellenmiş veri kümesinde eğitilir ve sınıflandırma hataları yapar.
5. Adım: 3. ve 4. adımlar, belirlenmiş bir sayıda zayıf öğrenci oluşturulana kadar tekrarlanır. Her bir zayıf öğrenci, önceki öğrencilerin hatalarını düzeltmek için odaklanır.
6. Adım: Son olarak, tüm zayıf öğrencilerin katkıları birleştirilerek güçlü bir öğrenci (ensemble) oluşturulur. Bu genellikle sınıfların oylama veya ağırlıklı oylama yöntemleriyle yapılır.

➤ AdaBoost algoritmasının bazı önemli özellikleri şunlardır:

Her bir zayıf öğrenici, yalnızca veri kümesinin belirli bir kısmına odaklanır ve bu kısmı daha fazla öğrenmek için ağırlıklarla vurgular. Bu, AdaBoost'un veriye adaptif bir şekilde odaklanmasını sağlar.

3.1.2.2.1.2.Gradient Boosting

Gradient Boosting (Gradyan Artırma), gözlemleri artırma işlemine göre değil hataya göre seçtiğinden önceki tahminlerden yapılan hatalardan ders çıkarıldığından sonraki tahminlerde bu öğrendiği mantığı kullanır.

Bu algoritma aynı zamanda birkaç birleşik karar ağacı kullanır, ancak Random Forest aksine ağaçlar ilişkilidir. Her seferinde bir ağaç oluşturur, böylece bir sonraki ağacın önceki ağaçtaki kusurları düzeltmesini sağlar.

➤ Gradient Boosting algoritmasının çalışma prensibi şu şekildedir:

1. Adım: Başlangıçta, bir zayıf öğrenici (örneğin, karar ağacı) oluşturulur ve veri kümesi üzerinde eğitilir.
2. Adım: Oluşturulan model, eğitim veri kümesi üzerinde tahminler yapar ve bu tahminlerin hataları hesaplanır.
3. Adım: Hatalar, bir sonraki zayıf öğreniciyi eğitmek için kullanılır. Ancak, Gradient Boosting algoritması, sadece hataların değil, aynı zamanda bu hatalara en iyi uyan öğreniciyi de bulmaya çalışır. Bu nedenle, her bir zayıf öğrenici, önceki öğrenicilerin hatalarını düzeltmek için optimize edilir.
4. Adım: Hataların düzeltildiği bir sonraki zayıf öğrenici oluşturulur ve eğitim veri kümesi üzerinde tahminler yapar.
5. Adım: 3. ve 4. adımlar, belirlenmiş bir sayıda zayıf öğrenici oluşturulana kadar tekrarlanır. Her bir zayıf öğrenici, önceki öğrenicilerin hatalarını düzeltmek için optimize edilir.
6. Adım: Son olarak, tüm zayıf öğrenicilerin tahminleri birleştirilerek güçlü bir öğrenici (ensemble) oluşturulur. Bu genellikle sınıfların oylama veya ağırlıklı oylama yöntemleriyle yapılır.

3.1.2.2. Bagging

Bagging (Bootstrap Aggregating), birden çok örneklem seti oluşturarak ve bu örneklem setleri üzerinde ayrı ayrı modeller oluşturarak çalışır. Her bir modelin tahminleri birleştirilerek genel bir tahmin elde edilir.

➤ Bagging algoritmasının çalışma prensibi şu şekildedir:

1. Adım: Veri kümesinden, tekrarlı örnekleme (bootstrap örnekleme) yöntemiyle birden çok örnekleme seti oluşturulur. Bootstrap örnekleme, rastgele örnekleme yaparken, orijinal veri kümesinden örnekleri birden çok kez seçme ve bazı örnekleri seçmeme olasılığına sahiptir.
2. Adım: Her bir örnekleme seti üzerinde, aynı öğrenme algoritması (genellikle karar ağacı) kullanılarak ayrı ayrı modeller oluşturulur.
3. Adım: Her bir model, kendi örnekleme seti üzerinde eğitilir ve tahminler yapar.
4. Adım: Sınıflandırma problemlerinde, tahminler genellikle oylama yöntemiyle birleştirilir. Yani, her bir modelin tahmini için bir oy sayılır ve en çok oy alan sınıf tahmin olarak seçilir. Regresyon problemlerinde, tahminlerin ortalaması alınarak genel tahmin elde edilir.

Tahmine dayalı analitik, en yaygın olarak güvenlik, pazarlama, operasyonlar, risk ve dolandırıcılık tespiti için kullanılır. Tahmine dayalı analitik ve makine öğreniminin farklı sektörlerde nasıl kullanıldığına dair birkaç örnek:

Bankacılık ve finansal hizmetler sektöründe, dolandırıcılığı tespit etmek ve azaltmak, piyasa riskini ölçmek, fırsatları belirlemek ve çok daha fazlası için tahmine dayalı analitik ve makine öğrenimi birlikte kullanılır.

Siber güvenliğin günümüzde her işletmenin gündeminin başında yer almasıyla tahmine dayalı analitik ve makine öğreniminin güvenlikte önemli bir rol oynaması şaşırtıcı olmamalı. Güvenlik kurumları, genellikle hizmetleri ve performansı iyileştirmek için tahmine dayalı analitiği kullanır, aynı zamanda anormallikleri, sahtekârlığı tespit etmek, tüketici davranışını anlamak ve veri güvenliğini geliştirmek için de kullanır.

3.1.2.2.3.Rastgele Ormanlar (Random Forests)

Rastgele Ormanlar, hiçbirini birbiriyle ilişkili olmayan birçok karar ağacının bir araya gelmesiyle oluşur. Her ağacın bağımsız olarak tahmin yapması ve sonuçların bir araya getirilmesiyle daha güvenilir tahminler elde edilir.

➤ Rastgele Ormanlar algoritmasının çalışma prensibi şu şekildedir:

1. Adım: Veri kümesinden rastgele örneklemeler (örneklem çekme) alınır ve bu örneklemeler üzerinde karar ağaçları (decision tree) oluşturulur.
2. Adım: Her bir karar ağacı, veri kümesinin farklı alt kümesiyle eğitilir. Alt küme oluşturma işlemi, örneklem çekme aşamasında gerçekleştirilen rastgelelikle sağlanır.
3. Adım: Karar ağaçları oluşturulurken, her bir düğümdeki en iyi bölünme noktasını belirlemek için genellikle karar ağacı algoritmasındaki özellikler kullanılır. Ancak Random Forest algoritması, bölünme noktasını belirlerken, rastgele bir özellik alt kümesini kullanır. Bu, her bir karar ağacının farklı bir özellik setine odaklanmasını sağlar.
4. Adım: Sınıflandırma durumunda, Random Forest, karar ağaçlarının oylamasıyla tahmin yapar. Yani, her bir karar ağacının verilen örneği hangi sınıfa tahmin ettiği belirlenir ve en fazla oyu alan sınıf tahmin olarak seçilir.

3.1.2.3.Derin Öğrenme

Derin Öğrenme (Deep Learning - DL), yapay sinir ağları ve büyük veri setleri üzerinde çalışarak karmaşık problemleri çözmek için kullanılan bir makine öğrenmesi yaklaşımıdır. Derin Öğrenme'deki "derin" sıfatı, ağda birden çok katmanın kullanımına atıfta bulunur.

Derin öğrenme, yapay sinir ağlarının çok katmanlı (derin) yapısını kullanarak veriye dayalı öğrenme ve desen tanıma yeteneklerini artırır. Bu katmanlar, giriş katmanı, gizli katmanlar ve sonuç katmanı olarak adlandırılır. Derin Öğrenme, gözetimli denetimli veya gözetimsiz olabilir. Verinin yapısına göre hangi parametrelere ne ağırlık verileceğini kendisi keşfetmektedir.

Öğrenebilen ilk sinir ağı makinesi, 1951'de Marvin Minsky ve Dean Edmonds tarafından yapay zekâyı donanıma uyguladıkları SNARC (Stochastic Neural Analog Reinforcement Computer)'tır.

- Derin öğrenme algoritmalarının çalışma prensibi şu şekildedir:
- **Veri Hazırlığı:** Derin öğrenme için öncelikle uygun bir veri seti toplanır ve hazırlanır. Bu veri seti genellikle büyük miktarda etiketli veri içermelidir.
 - **Mimari Tasarımı:** Derin öğrenme modelinin mimarisi belirlenir. Bu, kullanılacak katman sayısı, katman türleri, nöron sayıları, bağlantılar ve aktivasyon fonksiyonları gibi faktörleri içerir.
 - **İlk Değer Ataması:** Ağırlık ve bias değerleri rastgele veya önceden belirlenmiş başlangıç değerleriyle atanır.
 - **İleri Yayılım (Forward Propagation):** Veri, ağırlık giriş katmanına verilir ve ardından katmanlardan geçerek çıkış katmanına ulaşır. Her katmanda aktivasyon fonksiyonları kullanılarak çıktılar hesaplanır.
 - **Geri Yayılım (Backpropagation):** İleri yayılım sonucunda elde edilen çıktılar ile gerçek değerler arasındaki hata (loss) hesaplanır. Geri yayılım algoritması, bu hatayı kullanarak ağırlıkları ve bias değerlerini günceller. Bu adım, hatanın azaltılması ve modelin daha iyi sonuçlar üretmesi için iteratif olarak tekrarlanır.
 - **Model Optimizasyonu:** Optimizasyon algoritmaları (örneğin, gradyan inişi) kullanılarak modelin hata fonksiyonunu minimize etmek için ağırlık ve bias değerleri ayarlanır. Bu, modelin daha iyi genelleme yapmasını ve daha iyi sonuçlar üretmesini sağlar.
 - **Test ve Değerlendirme:** Eğitim süreci tamamlandıktan sonra model, ayrı bir test veri seti üzerinde değerlendirilir. Doğruluk, hassasiyet, geri çağırma ve F1 skoru gibi performans metrikleri kullanılarak modelin performansı ölçülür.

Tablo 3: Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Kıyaslamaları

Yapay Zekâ	Makine Öğrenmesi	Derin Öğrenme
Amacı, makinenin herhangi bir kişinin müdahalesi olmadan düşünmesini sağlamaktır.	Amacı, makinenin geçmiş deneyimlerden öğrenmesini sağlamaktır.	Amacı, kişilerin beyni gibi karmaşık problemleri çeşitli filtre ve algoritmalar kullanarak çözmektir.
Kişilerin davranışlarını taklit edebilen akıllı makineler oluşturmak için kullanılan bir teknolojidir. Karmaşık sorunları çözmek için farklı	Geçmiş verilerden ve deneyimlerden öğrenen bir Yapay Zekâ alt kümesidir.	Nöronlar olarak adlandırılan kişi beyin hücrelerinden ilham alan ve kişi beyninin çalışmasını taklit eden makine

Makine öğrenimi algoritmaları ve kavramları kullanır.		öğrenimi ve yapay zekânın alt kümesidir.
Büyük miktarda veri ile çalışır.	Derin öğrenme ve yapay zekâyâ kıyasla daha az miktarda veri ile çalışabilir.	Yapay Zekâyâ göre az, Makine Öğrenmesine kıyasla çok büyük miktarda veri gerektirir.

3.1.2.3.1.Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları (Artificial Neural Networks - ANN), insan beyninin çalışma prensiplerinden esinlenerek tasarlanmış bir makine öğrenmesi modelidir. Yapay Sinir Ağları, karmaşık veri yapılarını anlama, desenleri tanıma ve tahmin yapma yeteneğine sahiptir.

YSA, sinir hücrelerinden (nöronlar) ve bu nöronlar arasındaki bağlantılardan oluşur. Her bir nöron, girdi değerlerini alır, bu değerleri işler ve bir çıktı üretir. Nöronlar arasındaki bağlantılar, ağırlıklarla temsil edilir ve bu ağırlıklar, nöronların girdi değerlerine göre önem derecelerini belirler.

YSA örneklerle, tarihsel verilerle bilgi toplar ve genellemeler yapar. Daha sonra, hiç görmediği örneklere kıyasla örnek bilgilerini kullanarak bu örnekler hakkında karar verir. Bu, karmaşık sorunları başarıyla çözme yeteneğini gösterir. YSA'nın çeşitli mimarileri vardır, ancak en popüler olanı çok katmanlı algılayıcıdır (Şekil 30). Nöronlar; giriş, gizli ve sonuç katmanları olmak üzere üç katman halinde düzenlenmiştir. Giriş katmanındaki nöron sayısı, özelliklerle aynıdır ve sonuç katmanındaki nöron sayısı, sınıf sayısı ile aynıdır. Gizli katmandaki nöronlar, sınıflandırıcının doğruluğuna bağlı olarak değişebilir.


3.1.2.3.1.1.Çok Katmanlı Algılayıcılar (MLP)

MLP, çok katmanlı bir yapay sinir ağı modelidir ve Derin Öğrenme'nin temel bileşenlerinden biridir. MLP (Multilayer Perceptron - Çok Katmanlı Algılayıcı), en basit haliyle giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanından oluşan bir yapay sinir ağıdır.

- MLP'nin çalışma prensibi şu şekildedir:

- Giriş Katmanı (Input Layer): Verilerin giriş noktasıdır. Her bir giriş, bir nörona bağlanır ve nörona bir girdi değeri olarak iletilir.
- Gizli Katmanlar (Hidden Layers): Giriş katmanından gelen veriler, bir veya daha fazla gizli katmana iletilir. Her bir gizli katmandaki nöronlar, giriş değerlerine dayalı olarak ağırlıklarını güncelleyerek giriş değerlerine dayalı olarak çıktı üretir.
- Sonuç Katmanı (Result Layer): Son gizli katmandan gelen çıktılar, sonuç katmanına iletilir. Sonuç katmanı, yapay sinir ağının tahmin veya sınıflandırma sonucunu temsil eden çıktıları üretir.

Şekil 30: MLP Mimari Yapısı



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

3.1.2.4. Veri Kümesinin Sınıflandırılması

Veri kümesinin sınıflandırılması, verileri belirli kriterlere göre gruplara ayırma işlemidir. Sınıflandırma, makine öğrenimi ve veri analitiği gibi alanlarda yaygın olarak kullanılan bir tekniktir.

Makine öğrenmesi modelinin eğitim ve test aşamaları, veri kümesini kullanarak bir model oluşturup bu modelin performansını değerlendirmek için önemli adımlardır.

Veri kümesi, eğitim ve test verisi olarak ikiye ayrılmalıdır. Eğitim verileri, sınıflandırma modelini öğrenmek için kullanılırken, test verileri modelin

performansını değerlendirmek için kullanılır. Bu ayırım, modelin genelleme yeteneğini değerlendirmenize yardımcı olur.

3.1.2.4.1. Eğitim (Train)

Eğitim, bir modelin veri seti üzerinde öğrenme sürecidir. Eğitim süreci, modelin veriler arasındaki desenleri ve ilişkileri anlamasını ve gelecekteki veriler üzerinde tahminler yapabilmesini sağlayan parametreleri ayarlamayı içerir.

Model eğitimi, makine öğreniminde birincil adımdır ve daha sonra doğrulanabilen, test edilebilen ve dağıtılabilen çalışan bir modelle sonuçlanır. Modelin eğitim sırasındaki performansı, nihai olarak son kullanıcılar için bir uygulamaya konduğunda ne kadar iyi çalışacağını belirleyecektir.

- Eğitim süreci genellikle aşağıdaki adımları içerir:
 - **Veri Hazırlığı:** Eğitim için kullanılacak veri seti toplanır ve ön işleme adımları gerçekleştirilir. Veri seti, genellikle özellik vektörleri (girişler) ve hedef etiketler (çıkışlar) olarak düzenlenir.
 - **Model Seçimi:** Kullanılacak model veya algoritma seçilir. Bu, problem alanına ve veri setinin özelliklerine bağlı olarak belirlenir.
 - **Parametre Ayarı:** Modelin başlangıç parametreleri belirlenir veya rastgele değerler atanır. Bazı algoritmalar için varsayılan değerler kullanılabilir. Ancak, performansı artırmak için parametrelerin ayarlanması gerekebilir.
 - **Model Eğitimi:** Veri seti üzerinde model eğitimi gerçekleştirilir. Bu, veri setindeki örneklerin model tarafından işlenmesini ve parametrelerin güncellenmesini içerir. Eğitim verileri, giriş özelliklerine dayalı olarak beklenen çıktılarla karşılaştırılır ve bir kayıp (hata) fonksiyonu kullanılarak hata hesaplanır.
 - **Hata Azaltma:** Eğitim sürecindeki amaç, kaybı (hata) minimize etmek ve modelin daha iyi performans göstermesini sağlamaktır. Optimizasyon algoritmaları (gradyan inişi gibi) kullanılarak parametreler güncellenir ve kayıp fonksiyonu tekrar hesaplanır.
 - **Doğrulama ve Değerlendirme:** Eğitim verilerinin üzerindeki performansı değerlendirmek için ayrı bir doğrulama veri seti kullanılabilir. Modelin

doğruluğunu, hatayı veya diğer metrikleri değerlendirmek için test verileri kullanılabilir.

- Model Ayarlaması ve Yeniden Eğitim: Modelin performansını iyileştirmek için parametreler ayarlanabilir veya modelin yapısı değiştirilebilir. Bu adımlar tekrarlanabilir ve modelin en iyi performansı göstermesi için deneme-yanılma süreci devam edebilir.

Eğitim süreci tamamlandıktan sonra, eğitilen model, yeni veriler üzerinde tahminler yapmak veya örneklerin sınıflandırılmasını gerçekleştirmek için kullanılabilir.

3.1.2.4.2. Test

Test, eğitilen bir modelin performansını değerlendirmek için kullanılan bir aşamadır. Eğitim süreci tamamlandıktan sonra, modelin genelleme yeteneğini test etmek ve gerçek dünya verilerine nasıl tepki verdiğini görmek için ayrılmış bir test veri seti kullanılır. Örneğin, bir model eğitime test setinden daha iyi örtüşüyorsa, büyük olasılıkla fazla gerçek olmayan şişirme veriler mevcuttur.

- Test aşaması genellikle aşağıdaki adımları içerir:
 - Test Veri Setinin Hazırlanması: Eğitim veri setinden bağımsız bir test veri seti oluşturulur. Bu veri seti, gerçek dünya verilerine benzer dağılım ve özelliklere sahip olmalıdır. Test veri seti, giriş özelliklerini içermeli ve gerçek hedef etiketlerle birlikte kullanılmalıdır.
 - Modelin Uygulanması: Eğitilen model, test veri setindeki örnekler üzerinde uygulanır. Giriş verileri modele verilir ve çıktı tahminleri elde edilir.
 - Performans Metriklerinin Hesaplanması: Modelin performansını değerlendirmek için çeşitli metrikler kullanılır.
 - Performansın Değerlendirilmesi: Modelin performans metriklerine dayanarak, modelin test veri seti üzerindeki başarısı değerlendirilir.

Test aşaması, modelin genelleme yeteneğini değerlendirmek için son derece önemlidir. Eğitim verileri üzerinde iyi bir performans gösteren bir modelin, test verileri üzerinde de iyi performans göstermesi beklenir. Eğer model, eğitim verilerine aşırı uymuşsa (overfitting), test verilerinde düşük performans gösterebilir. Bu nedenle,

modelin test verileri üzerindeki performansı, modelin gerçek dünya problemlerini çözebilme yeteneğini yansıtır.

3.1.2.5. Performans Ölçütleri Analizi

Performans ölçütleri analizi, bir makine öğrenimi modelinin veya bir tahmin modelinin performansını değerlendirmek için kullanılan metriklerin incelenmesidir.

Araştırmada kullanılan performans ölçütleri analizi açıklamaları aşağıda bulunmaktadır:

3.1.2.5.1. Doğruluk (Accuracy)

Bir sınıflandırma modelinin doğru sonuçlar verme yüzdesini ölçer. Yüksek doğruluk, modelin genel performansının iyi olduğunu gösterir. Ancak, dengesiz sınıf dağılımları durumunda doğruluk yanıltıcı olabilir.

Şekil 31: Doğruluk Formülü

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

- TN: Doğru sınıflandırılmış negatif vaka sayısı
- TP: Doğru sınıflandırılmış pozitif vaka sayısı
- FN: Yanlış bir şekilde negatif olarak sınıflandırılan pozitif vakaların sayısı
- FP: Doğru olarak pozitif olarak sınıflandırılan negatif vakaların sayısı

- Doğruluk, “doğru” diyagonaldeki değerlerin ortalaması alınarak verilir.
- Doğruluk = (Gerçek Pozitif + Gerçek Negatif) / Toplam Örnek

- Bu şu anlama gelir:
- Doğruluk = Toplam Doğru Tahmin Sayısı / Toplam Sayı

Doğruluk, doğru tahminlerin toplam veri sayısına oranıdır. Yani, doğru sınıflandırılan test senaryolarının toplam test senaryosu sayısına bölünmesiyle tanımlanabilir.

3.1.2.5.2.Kök Ortalama Kare Hatası (Root Mean Squared Error – RMSE)

RMSE, hataların ortalama büyüklüğünü ölçen ikinci dereceden bir puanlama kuralıdır. Tahmin ve gerçek gözlem arasındaki ortalama kare farklılıklarının kareköküdür. Şekil 32, matematiksel olarak RMSE'nin nasıl hesaplanacağını göstermektedir.

Şekil 32: RMSE Formülü

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Formülü kelimelerle ifade edersek;

- Her örnek için modelin tahmini ve gerçek değer arasındaki fark hesaplanır.
- Elde edilen fark değerleri karesi alınır.
- Fark kareleri toplanır.
- Toplam fark karelerinin ortalaması alınır.
- Ortalama fark karelerinin karekökü, RMSE değerini verir.

3.2. ZAMAN SERİLERİ

Zaman serileri, belirli zaman aralıklarında ölçülen verilerin sıralı bir şekilde kaydedildiği veri setleridir. Bu veri setlerinde, ölçümler zaman açısından ardışık olarak gerçekleştirilir ve genellikle zamana bağlı değişkenler üzerinde analiz yapmayı amaçlar.

Zaman serisi analizi, bir veri setinde zamanla değişen değişkenlerin incelenmesine odaklanan istatistiksel bir yöntemdir. Temettü ödemeleri gibi finansal veriler, zaman serisi analizi için uygun bir alan olabilir. Geçmiş temettü ödemelerini inceleyerek gelecekteki temettü tahminlerini yapmaya veya temettü ödemelerindeki trendleri belirlemeye yardımcı olmaktadır.

Zaman serisi algoritmaları verileri sırayla çizer ve zaman içindeki sürekli değerleri tahmin etmek için kullanışlıdır.

3.2.1. BASİT ÖNGÖRÜ YÖNTEMLERİ

Basit öngörü yöntemleri, zaman serisi analizinde kullanılan temel ve başlangıç düzeyindeki tahmin yöntemleridir. Bu yöntemler, geçmiş verilere dayanarak gelecekteki değerleri tahmin etmek için kullanılırlar. Araştırmada kullanılan basit öngörü yöntemi:

Hareketli ortalama yönteminde, belirli bir zaman aralığındaki gözlem değerlerinin ortalaması alınarak tahmin yapılır. Örneğin, 3 günlük hareketli ortalama yöntemi, son 3 günün değerlerinin ortalamasını alarak 4. günün değerini tahmin eder. Bu yöntem, serideki kısa vadeli dalgalanmaları yumuşatır.

3.2.1.1. Naif Yöntem (Naive Method)

Naif yöntem, zaman serisi analizinde kullanılan en basit tahmin yöntemlerinden biridir. Bu yöntemde, gelecekteki değerlerin tahmini için sadece bir önceki değer veya son birkaç değer kullanılır.

Şekil 33: Naif Yöntem Formülü

$$\hat{y}_{t+1} = y_t$$

- Naif yöntemin birkaç farklı uygulama şekli vardır:
 - Son Değer Yöntemi (Naive Last Value Method): Bu yöntemde, zaman serisinin son gözlem değeri, gelecekteki tüm değerlerin tahmin edildiği varsayımıyla kullanılır. Yani, zaman serisinin son değeri, gelecekteki tüm değerlerin tahmini olarak kabul edilir. Bu yöntem, serinin istikrarlı olduğu durumlarda ve mevsimsel etkilerin az olduğu zaman serilerinde kullanılabilir.
 - Ortalama Değer Yöntemi (Naive Average Method): Bu yöntemde, son birkaç gözlem değerinin ortalaması alınarak gelecekteki değerlerin tahmini yapılır. Örneğin, son 3 ayın ortalaması alınarak bir sonraki ayın tahmini yapılabilir.

Şekil 34: Naif Yöntemi Kod Satırları

```
#1. Naif Yöntem (Naive Method)
öngörü_dönemi = ForecastingHorizon(test_verisi.index, is_relative=False)
öngörü_modeli = NaiveForecaster(strategy="last")
öngörü_modeli.fit(eğitim_verisi['#Pay'])
naif_model_öngörüler_i = öngörü_modeli.predict(fh=öngörü_dönemi)
#Tahminleri, eğitim verisini ve test verisini görselleştirelim:
eğitim_verisi['#Pay'].plot(figsize=(12,8), label="eğitim", color='r')
test_verisi['#Pay'].plot(figsize=(12,8), label="test", color='k')
naif_model_öngörüler_i.plot(figsize=(12,8), label="naif model")
plt.xlabel("TARİH")
plt.ylabel("HİSSE BAŞI NET (TL) TEMETTÜ")
plt.title("Naif Model Öngörüler_i")
plt.legend(loc='best')
plt.grid()
plt.show()
```

3.2.1.2. BASİT ORTALAMA (SIMPLE AVERAGE)

Basit Ortalama yöntemi, zaman serisi analizinde kullanılan basit bir tahmin yöntemidir. Bu yöntemde, geçmiş veri noktalarının aritmetik ortalaması alınarak gelecekteki değerlerin tahmini yapılır. Yani, her bir geçmiş veri noktası aynı derecede önemlidir ve tahminin yapılmasında eşit katkıda bulunur.

Şekil 35: Basit Ortalama Yöntemi Formülü

$$\hat{y}_{t+1} = \frac{1}{n} \sum_{i=1}^n y_i$$

➤ Basit Ortalama yönteminin adımları şu şekildedir:

1. Adım: Veri setindeki tüm geçmiş değerlerin toplamı alınır.
2. Adım: Toplam değer, geçmiş veri noktalarının sayısına bölünerek aritmetik ortalama hesaplanır.
3. Adım: Elde edilen ortalama değer, gelecekteki tüm değerlerin tahmini olarak kabul edilir.

Basit Ortalama yöntemi, veri setinde belirgin bir trend veya mevsimsel desen olmadığı durumlarda ve geçmiş verilerin istatistiksel olarak durağan olduğu durumlarda kullanılabilir. Özellikle kısa vadeli tahminlerde ve basit bir referans noktası olarak başlangıç tahmini için tercih edilebilir.

Şekil 36: Basit Ortalama Yöntemi Kod Satırları

```
#2. Basit Ortalama (Simple Average)
#Bir sonraki dönemin öngörüsünü, geçmiş dönemlerin ortalamasına yakın bir şekilde öngörebiliriz.
basit_ortalama_öngörüler = test_verisi.copy()
basit_ortalama_öngörüler["basit_ortalama"] = eğitim_verisi["#Pay"].mean()
#Tahminleri, eğitim verisini ve test verisini görselleştirelim:
eğitim_verisi["#Pay"].plot(figsize=(12,8), label="eğitim", color='r')
test_verisi["#Pay"].plot(figsize=(12,8), label="test", color='k')
basit_ortalama_öngörüler["basit_ortalama"].plot(figsize=(12,8), label="basit ortalama")
plt.xlabel("TARİH")
plt.ylabel("HİSSE BAŞI NET (TL) TEMETTÜ")
plt.title("Basit Ortalama Öngörüler")
plt.legend(loc='best')
plt.grid()
plt.show()
```

3.2.1.3. BASİT HAREKETLİ ORTALAMA (SIMPLE MOVING AVERAGE) – SMA

Basit Hareketli Ortalama (Simple Moving Average - SMA), zaman serisi analizinde yaygın olarak kullanılan bir tahmin yöntemidir. Bu yöntemde, belirli bir zaman aralığındaki değerlerin aritmetik ortalaması alınarak gelecekteki değerlerin tahmini yapılır.

Şekil 37: Basit Hareketli Ortalama Yöntemi Formülü

$$SMA_t = \frac{y_t + y_{t-1} + \dots + y_{t-(n-1)}}{n}$$

- Basit Hareketli Ortalama yönteminin adımları şu şekildedir:
 1. Adım: Belirli bir zaman aralığı (örneğin, 5 gün, 10 gün, 20 gün) seçilir.
 2. Adım: Seçilen zaman aralığındaki değerlerin aritmetik ortalaması alınır.
 3. Adım: Elde edilen ortalama değer, gelecekteki değerlerin tahmini olarak kabul edilir.
 4. Adım: Her yeni veri noktası geldiğinde, en eski veri noktası silinir ve yeni veri noktası eklenerek tahmin güncellenir.

Örneğin, 10 günlük basit hareketli ortalama kullanılarak bir hisse senedinin 10 günlük ortalama kapanış fiyatı hesaplanabilir. Her gün yeni bir kapanış fiyatı eklenirken, en eski kapanış fiyatı çıkarılır ve yeni bir ortalama hesaplanır.

Basit Hareketli Ortalama yöntemi, veri setindeki kısa vadeli dalgalanmaları düzleştirir ve bir eğilim çizgisini yakalamaya yardımcı olur. Bu yöntem, geçmiş verilerin geçici etkilerini yumuşatır ve daha genel bir trendi ortaya çıkarır.

Basit Hareketli Ortalama yöntemi de bazı sınırlamalara sahiptir. Örneğin, geçmiş verilere eşit ağırlık verdiği için daha yeni verilere aynı önemi vermez. Ayrıca, zaman

aralığı seçimi önemlidir ve yanlış bir zaman aralığı seçilmesi, gecikmeli veya yanıltıcı tahminlere yol açabilir.

Şekil 38: Basit Hareketli Ortalama Yöntemi Kod Satırları

```
#3. Basit Hareketli Ortalama (Simple Moving Average) - SMA
#Buradaki temel düşünce, yalnızca son gözlemlerin önemli olduğudur.
#Geçmiş 8 dönemi alacağız "rolling(8)".
basit_hareketli_ortalama_öngörüler = test_verisi.copy()
basit_hareketli_ortalama_öngörüler["basit_hareketli_ortalama"] = eğitim_verisi["#Pay"].rolling(8).mean().iloc[-1]
#Tahminleri, eğitim verisini ve test verisini görselleştirelim:
eğitim_verisi["#Pay"].plot(figsize=(12,8), label="eğitim", color='r')
test_verisi["#Pay"].plot(figsize=(12,8), label="test", color='k')
basit_hareketli_ortalama_öngörüler["basit_hareketli_ortalama"].plot(figsize=(12,8), label="basit hareketli ortalama")
plt.xlabel("TARİH")
plt.ylabel("HİSSE BAŞI NET (TL) TEMETTÜ")
plt.title("Basit Hareketli Ortalama Öngörüler - SMA")
plt.legend(loc='best')
plt.grid()
plt.show()
```

3.2.2. ARIMA MODELLERİ İLE ÖNGÖRÜ

ARIMA (AutoRegressive Integrated Moving Average), Otomatik Regresif Entegre Hareketli Ortalamalar anlamına gelir. Oto regresif Entegre Hareketli Ortalamalar (ARIMA), zaman serisi verilerini tahmin etmek ve analiz etmek için kullanılan istatistiksel bir modeldir.

Zaman serisi analizinde yaygın olarak kullanılan bir modeldir ve gelecekteki değerleri tahmin etmek için kullanılır. ARIMA modelleri, zaman serisindeki trendleri, mevsimsel etkileri ve diğer düzensizlikleri yakalamak için kullanılır.

➤ ARIMA'nın üç bileşeni vardır:

- AR (AutoRegressive) oto regresif bileşeni, “p” parametresi ile tanımlanır. Geçmiş veri noktalarının regresyonu ile serinin oto regresif yapısını yakalar. Yani, serideki bir veri noktasının, önceki veri noktalarıyla ilişkili olduğunu ifade eder.
- I (Integrated) entegrasyon bileşeni, “d” parametresi ile tanımlanır. Serinin durağan olmadığı durumlarda durağan hale getirilmesi için fark alma işlemi uygulanır.
- MA (Moving Average) hareketli ortalama bileşeni, “q” parametresi ile tanımlanır. Geçmiş hataların regresyonu ile serinin hareketli ortalamasını yakalar. Yani, serinin önceki hatalarının mevcut değeri üzerindeki etkisini ifade eder.

➤ ARIMA modelinin kullanım adımları genellikle şu şekildedir:

1. Adım: Veri setinin durağanlık kontrolü: ARIMA modeli, durağan bir zaman serisi üzerinde çalışır. Veri setinin durağanlık özelliği kontrol edilir ve durağan değilse, fark alma işlemi uygulanarak durağan hale getirilir.
2. Adım: Model parametrelerinin belirlenmesi: ARIMA modelinin parametreleri olan “p”, “d” ve “q” değerleri belirlenir. “p” AR bileşeni için otoregresif terim sayısını, “d” fark alma derecesini ve “q” MA bileşeni için hareketli ortalamalı terim sayısını ifade eder.
3. Adım: Modelin uydurulması: Belirlenen “p”, “d” ve “q” değerleriyle ARIMA modeli uydurulur. Bu, modelin eğitim veri setine uydurulmasını içerir ve modelin parametrelerinin tahmin edilmesini sağlar.
4. Adım: Modelin doğrulanması: Uydurulan modelin doğrulama veri seti üzerinde performansı değerlendirilir. Bu, modelin tahmin performansını değerlendirmek için kullanılır ve modelin güvenilirliğini test etmeyi sağlar.
5. Adım: Tahmin yapma: Doğrulanmış model, gelecekteki değerlerin tahmin edilmesi için kullanılır. Tahminler, mevcut verilere dayanarak yapılır ve gelecekteki değerlerin olasılık aralıklarıyla birlikte verilebilir.

Şekil 39: ARIMA Yöntemi Kod Satırları

```
#ARIMA Modelleri ile Öngörü
#gelecek değerlerine ilişkin öngörü oluşturmak
#Mevimsel ARIMA (SARIMAX) yöntemi ile TEMETTÜ PAY öngörüsünü gerçekleştirelim:
sarima_modeli = sm.tsa.statespace.SARIMAX(eğitim_verisi['#Pay'], order=(2, 1, 4), seasonal_order=(0, 1, 1, 12)).fit()

sarima_öngörüler_i = test_verisi.copy()
sarima_öngörüler_i["sarima"] = sarima_modeli.predict(start="2011-12-31", end="2022-12-31", dynamic=True)

eğitim_verisi['#Pay'].plot(figsize=(12,8), label="eğitim")
test_verisi['#Pay'].plot(figsize=(12,8), label="test")
sarima_öngörüler_i["sarima"].plot(figsize=(12,8), label="sarima")
plt.xlabel("TARİH")
plt.ylabel("HİSSE BAŞI NET (TL) TEMETTÜ")
plt.title("SARIMA Öngörüler_i")
plt.legend(loc='best')
plt.grid()
plt.show()
```

3.2.2.1. MEVSİMSSEL ARIMA (SARIMAX)

SARIMAX (Seasonal AutoRegressive Integrated Moving Average with eXogenous variables) modeli, mevsimsel etkilere sahip zaman serilerini tahmin etmek için kullanılan genişletilmiş bir ARIMA modelidir. SARIMAX modeli, ARIMA modeline ek olarak dışsal değişkenleri (exogenous variables) içerebilir.

- SARIMAX modelinin bileşenleri şu şekildedir:
- SARIMA bileşenleri: AR (OtoRegressive), I (Integrated) ve MA (Moving Average) bileşenleri, mevsimsel etkileri ve trendleri yakalamak için kullanılır. Bu bileşenler, mevsimsel otoregresif terimler (P), mevsimsel fark alma derecesi (D), mevsimsel hareketli ortalamalı terimler (Q) ve durağanlık düzeltmesi için non-mevsimsel otoregresif (p) ve hareketli ortalamalı (q) terimler içerebilir.
 - X (Exogenous) bileşeni: SARIMAX modeli, dışsal değişkenleri içerebilir. Bu, mevsimsel etkileri açıklamak veya tahmin etmek için başka değişkenleri kullanmanıza olanak sağlar.
- SARIMAX modelinin kullanım adımları genellikle şu şekildedir:
1. Adım: Veri setinin durağanlık kontrolü: SARIMAX modeli, durağan bir zaman serisi üzerinde çalışır. Veri setinin durağanlık özelliği kontrol edilir ve durağan değilse, fark alma işlemi uygulanarak durağan hale getirilir.
 2. Adım: Model parametrelerinin belirlenmesi: SARIMAX modelinin parametreleri olan “p”, “d”, “q”, “P”, “D”, “Q” ve “s” değerleri belirlenir. “p” non-mevsimsel AR terim sayısını, “d” non-mevsimsel fark alma derecesini, “q” non-mevsimsel MA terim sayısını ifade eder. “P” mevsimsel AR terim sayısını, “D” mevsimsel fark alma derecesini, “Q” mevsimsel MA terim sayısını ve “s” mevsimsel periyodu ifade eder.
 3. Adım: Modelin uydurulması: Belirlenen parametrelerle SARIMAX modeli uydurulur. Bu, modelin eğitim veri setine uydurulmasını içerir ve modelin parametrelerinin tahmin edilmesini sağlar.
 4. Adım: Modelin doğrulanması: Uydurulan model, doğrulama veri seti üzerinde test edilir ve performansı değerlendirilir. Modelin tahmin performansını değerlendirmek için çeşitli performans ölçütleri kullanılabilir.
 5. Adım: Tahmin yapma: Doğrulanmış model, gelecekteki değerlerin tahmin edilmesi için kullanılır. Tahminler, mevcut verilere ve dışsal değişkenlere dayanarak yapılır.

SARIMAX modeli, hem mevsimsel hem de non-mevsimsel etkileri yakalayabilen kapsamlı bir modeldir. Dışsal değişkenlerin dâhil edilebilmesi, modelin daha fazla

esneklik sağlamasına ve daha doğru tahminler yapmasına olanak tanır. Bu nedenle, mevsimsel etkilere sahip karmaşık zaman serileri üzerinde etkili bir tahmin aracı olarak kullanılır.

Şekil 40: SARIMAX Yöntemi Kod Satırları

```
# `statsmodels.tsa.statespace.sarimax` modülünden `SARIMAX()` fonksiyonunun oturuma yüklenmesi:
from statsmodels.tsa.statespace.sarimax import SARIMAX
# SARIMA(2,1,4)(0,1,1)12 modelinin `emp` zaman serisi için oluşturulması:
model = SARIMAX(df, order=(2,1,4), seasonal_order=(0,1,1,12))
# modelin veriye uygulanması:
results = model.fit()
# sonucun model özetinin yazdırılması:
print(results.summary())
```

3.2.3. PYTHON KÜTÜPHANELER

Python, açık kaynaklı, nesne yönelimli, geniş kütüphane ekosistemine ve modüle sahip, genel amaçlı bir yüksek seviyeli programlama dilidir. İşletim sistemleri, web geliştirme, veri analizi, yapay zekâ, bilimsel hesaplama, oyun geliştirme gibi çeşitli alanlarda kullanılabilir.

➤ Araştırmada, kullanılan Python kütüphaneleri:

- NumPy (Numerical Python – Sayısal Python): Bilimsel-matematiksel fonksiyonlar gibi birçok işlemi destekler. Sayısal hesaplamalar, bilimsel hesaplamalar ve veri manipülasyonu için kullanılan güçlü bir kütüphanedir. Diziler ve matrisler üzerinde yüksek performanslı hesaplamalar yapmayı sağlar.
- Pandas: Veri manipülasyonu ve analizi için kullanılmaktadır. Verileri okuma, işleme, düzenleme, temizleme, filtreleme, dönüştürme, birleştirme, sorgulama, analiz etmek ve modelleme gibi işlemleri kolaylıkla yapmanızı sağlar.
- Matplotlib (Mathematical Plot Library – Matematiksel Çizim Kütüphanesi): Veri Bilimi çalışmaları için sayısal matematik hesaplamalarını 2 ya da 3 boyutlu görsel çıktılar olarak almamızı sağlayan bir çizim (görselleştirme) kütüphanesidir. Veri analizi, istatistiksel grafikler, bilimsel hesaplamalar, zaman serisi analizi ve daha birçok alanda görsel sunumlar oluşturmak için sıklıkla kullanılmaktadır.

- SciPy (Scientific tools for Python – Python için Bilimsel Araçlar): NumPy altında kullanılan bir bilimsel hesaplama kütüphanesidir. Lineer cebir, optimizasyon, sinyal işleme, istatistiksel analiz gibi birçok fonksiyonu içerir. NumPy'e göre matematiksel çözümlerden ziyade biraz daha bilimsel çözümlerin ağırlıklı olarak ele alındığı kütüphanedir.
- SciKit-Learn (Science Kit/Kits Learn – Bilim Öğrenim Kiti): Model eğitme, veri analizi gibi işlemleri gerçekleştirme imkânı sunan bir kütüphanedir. Sınıflandırma, regresyon, kümeleme, boyut indirgeme gibi birçok makine öğrenmesi algoritmasını içerir.
- Scikit-learn, NumPy, SciPy ve Matplotlib kütüphaneleri ile ağırlıklı olarak ortak kullanılmaktadır.
- Keras: Derin öğrenme modeli oluşturmamızı, tanımlamamızı, anlamlı hale getirmemizi ve onu eğitmemizi sağlayan kullanımı kolay, esnek ve hızlı prototipleme için tasarlanmış bir arayüz kütüphanesidir.
- Statsmodels (Statistical Models – İstatistiksel Modeller): İstatistiksel modelleri tahmin etmek ve istatistiksel testler yapmamızı sağlayan bir kütüphanedir. Farklı veri türleri işlemesi, geniş tanımlayıcı istatistik yapısı, istatistiksel test çözümleri, çizim fonksiyonu ve sonuç istatistikleri listesi gibi çözümlerinden dolayı çokça tercih edilmektedir.

BÖLÜM 4: ARAŞTIRMA METODOLOJİSİ

Zaman serisi ve mevsimsel modelleri ile öngörü performanslarının karşılaştırılmasında RMSE ölçütü bazında 4 adet hipotez ve doğruluk değeri en yüksek olan en uygun model için 11 adet hipotez ile genel toplamda 15 adet hipotez, Temettü 25 endeksinde yer alan şirketlere ait 2011-2024 yılları verileri değerlendirilecektir. Değişkenler arasındaki ilişkiyi ortaya koyan araştırma modeli Şekil 41 ve Şekil 42’de gösterilmektedir.


Tablo 4: Değişkenler

Bağımlı değişken (y-ekseni):	Hisse Başı Net TL
Bağımsız değişken (x-ekseni):	Tarih
Grup değişkeni:	Hisse Adı


4.1. ARAŞTIRMANIN MODELİ VE HİPOTEZLERİ

Araştırmanın modelinde öngörü performanslarının karşılaştırılmasında RMSE ölçütü bazında 4 adet hipotez ve doğruluk değeri en yüksek olan model(ler)in veri setimiz için en uygun model olduğunu varsayımına ait 11 adet hipotez kurulmuştur.

Şekil 41: Araştırmanın Modeli (RMSE)



Şekil 42: Araştırmanın Modeli (Doğruluk)



4.2. MATERYAL VE YÖNTEM


BIST Temettü Endeksinde, temettü verimine göre büyükten küçüğe sıralanan ilk 25’te olan hisseler Temettü 25 endeksini oluşturur. Bu endeks, en verimli şirketlerin takibi için oldukça önemlidir.

Hisse Senedine dair ortalama pay bilgilerinin yanı sıra Hisse Başı Net TL ve Temettü Verimini barındıracak olan verilerimizi %75 test %25 eğitim verisi olarak ayrılarak, bir döngü vasıtasıyla tek tek bütün modelleri deneyerek sonuçları karşılaştırılmıştır.

Araştırmada nicel araştırma temelli kantitatif (objektif) istatistiki, SARIMAX Öngörüleme Sistemleri, YSA ve MÖ yöntemleri tercih edilmiştir.

Zaman serisi analizinde geleceğin tahmini geçmişe ait bilgilere dayanılarak yapıldığından söz konusu olayda geçmişteki davranış biçiminin gelecekte de devam edeceği varsayılır.

Şekil 43: Makine Öğrenmesi Modelinin Çalışması



Kaynak: Literatür bilgileri doğrultusunda yazar tarafından oluşturulmuştur.

4.3. VERİ SETİ VE KAPSAMI

Araştırmanın çalışma evreni, BIST Temettü Endeksleri kapsamında yer alan ve "XTM25" endeks kodlu payları içeren şirketlerden oluşmaktadır. Bu evren, 20.01.2025 tarihi itibarıyla Borsa İstanbul'un resmi web sitesinde ("<https://borsaistanbul.com/tr/sayfa/72/temettu-endeksleri>") belirtilmiştir.

Çalışmada, 2011-2024 yılları arasında Borsa İstanbul'da işlem gören ve temettü dağıtan şirketlere ait yıllık veriler, Kamuyu Aydınlatma Platformu'nun (KAP) "<http://www.kap.gov.tr>" elektronik veri tabanından ve Fintables Bilişim Teknolojileri A.Ş.'nin "<https://fintables.com>" kurumsal web sitesinden temin edilmiştir. Toplanan bu veriler, analiz süreci için gerekli temel bilgileri sağlamaktadır.

BİST Temettü 25 Endeksi'ne dâhil olan ve analizde yer alacak şirketler, Tablo 5'te ayrıntılı bir şekilde listelenmiştir. Bu şirketler, araştırmanın ana odak noktasını oluşturmakta ve analizlerin temelini oluşturan veri setine entegre edilerek incelemelerde kullanılmaktadır.

Tablo 5: Şirketler


#	KOD	ŞİRKET UNVANI
1	AEFES	ANADOLU EFES BİRACILIK VE MALT SANAYİİ A.Ş.
2	AKBNK	AKBANK T.A.Ş.
3	AKSA	AKSA AKRİLİK KİMYA SANAYİİ A.Ş.
4	AKSEN	AKSA ENERJİ ÜRETİM A.Ş.
5	BIMAS	BİM BİRLEŞİK MAĞAZALAR A.Ş.
6	BRYAT	BORUSAN YATIRIM VE PAZARLAMA A.Ş.
7	CIMSA	ÇİMSA ÇİMENTO SANAYİ VE TİCARET A.Ş.
8	DOAS	DOĞUŞ OTOMOTİV SERVİS VE TİCARET A.Ş.
9	ECILC	EİS ECZACIBAŞI İLAÇ SİNAİ VE FİNANSAL YATIRIMLAR SANAYİ VE TİCARET A.Ş.
10	ENJSA	ENERJİSA ENERJİ A.Ş.
11	ENKAI	ENKA İNŞAAT VE SANAYİ A.Ş.
12	FROTO	FORD OTOMOTİV SANAYİ A.Ş.
13	GARAN	TÜRKİYE GARANTİ BANKASI A.Ş.
14	ISCTR	TÜRKİYE İŞ BANKASI A.Ş.
15	ISMEN	İŞ YATIRIM MENKUL DEĞERLER A.Ş.
16	KCHOL	KOÇ HOLDİNG A.Ş.
17	MAVI	MAVİ GİYİM SANAYİ VE TİCARET A.Ş.
18	SAHOL	HACI ÖMER SABANCI HOLDİNG A.Ş.
19	SISE	TÜRKİYE ŞİŞE VE CAM FABRİKALARI A.Ş.
20	TCELL	TURKCELL İLETİŞİM HİZMETLERİ A.Ş.
21	TOASO	TOFAŞ TÜRK OTOMOBİL FABRİKASI A.Ş.
22	TTRAK	TÜRK TRAKTÖR VE ZİRAAT MAKİNELERİ A.Ş.
23	TURSG	TÜRKİYE SİGORTA A.Ş.
24	VESBE	VESTEL BEYAZ EŞYA SANAYİ VE TİCARET A.Ş.
25	YKBNK	YAPI VE KREDİ BANKASI A.Ş.

Şirketler, 6 ana kategori etrafında şekillenen 13 alt kategoriden oluşmaktadır.

Tablo 6: Ana Kategori

ANA SEKTÖR	#
BİLGİ VE İLETİŞİM	1
ELEKTRİK GAZ VE SU	2
İMALAT	7
İNŞAAT VE BAYINDIRLIK	1
MALİ KURULUŞLAR	11
TOPTAN VE PERAKENDE TİCARET	3
GENEL TOPLAM	25

Şekil 44: Sektörel Dağılım Grafiği



Şekil 44'te dikkat çeken noktalar şu şekildedir: En büyük dilim (%20), "Holdingler ve Yatırım Şirketleri" başlığını taşımaktadır. İkinci büyük dilimler (%16) ise "Bankalar" ve "Metal Eşya Makine Elektrikli Cihazlar Ve Ulaşım Araçları" gibi geniş bir sektörü temsil etmektedir. Diğer sektörler (%4-%8), geri kalan sektörler daha küçük dilimlerle gösterilmiştir.

Tablo 7: Alt Kategori

ALT SEKTÖR	#
ARACI KURUMLAR	1
BANKALAR	4
ELEKTRİK GAZ VE BUHAR	2
GIDA, İÇECEK VE TÜTÜN	1
HOLDİNGLER VE YATIRIM ŞİRKETLERİ	5
İNŞAAT VE BAYINDIRLIK İŞLERİ	1
KİMYA İLAÇ PETROL LASTİK VE PLASTİK ÜRÜNLER	1
METAL EŞYA MAKİNE ELEKTRİKLİ CİHAZLAR VE ULAŞIM ARAÇLARI	4
PERAKENDE TİCARET	2
SİGORTA ŞİRKETLERİ	1
TAŞ VE TOPRAĞA DAYALI	1
TELEKOMÜNİKASYON	1
TOPTAN TİCARET	1
GENEL TOPLAM	25

Sektörlere göre borsadaki şirketler Tablo 8'de yer almaktadır.

Tablo 8: Şirket Sayısı İtibariyle Sektörel Dağılımı

SEKTÖRLER	#
BİLGİ VE İLETİŞİM / TELEKOMÜNİKASYON	1
TURKCELL İLETİŞİM HİZMETLERİ A.Ş.	
ELEKTRİK GAZ VE SU / ELEKTRİK GAZ VE BUHAR	2
AKSA ENERJİ ÜRETİM A.Ş.	
ENERJİSA ENERJİ A.Ş.	
İMALAT / GIDA, İÇECEK VE TÜTÜN	1
ANADOLU EFES BİRACILIK VE MALT SANAYİİ A.Ş.	
İMALAT / KİMYA İLAÇ PETROL LASTİK VE PLASTİK ÜRÜNLER	1

AKSA AKRİLİK KİMYA SANAYİİ A.Ş.	
İMALAT / METAL EŞYA MAKİNE ELEKTRİKLİ CİHAZLAR VE ULAŞIM ARAÇLARI	4
FORD OTOMOTİV SANAYİ A.Ş.	
TOFAŞ TÜRK OTOMOBİL FABRİKASI A.Ş.	
TÜRK TRAKTÖR VE ZİRAAT MAKİNELERİ A.Ş.	
VESTEL BEYAZ EŞYA SANAYİ VE TİCARET A.Ş.	
İMALAT / TAŞ VE TOPRAĞA DAYALI	1
ÇİMSA ÇİMENTO SANAYİ VE TİCARET A.Ş.	
İNŞAAT VE BAYINDIRLIK / İNŞAAT VE BAYINDIRLIK İŞLERİ	1
ENKA İNŞAAT VE SANAYİ A.Ş.	
MALİ KURULUŞLAR / ARACI KURUMLAR	1
İŞ YATIRIM MENKUL DEĞERLER A.Ş.	
MALİ KURULUŞLAR / BANKALAR	4
AKBANK T.A.Ş.	
TÜRKİYE GARANTİ BANKASI A.Ş.	
TÜRKİYE İŞ BANKASI A.Ş.	
YAPI VE KREDİ BANKASI A.Ş.	
MALİ KURULUŞLAR / HOLDİNGLER VE YATIRIM ŞİRKETLERİ	5
BORUSAN YATIRIM VE PAZARLAMA A.Ş.	
EİS ECZACIBAŞI İLAÇ SİNAİ VE FİNANSAL YATIRIMLAR SANAYİ VE TİCARET A.Ş.	
HACI ÖMER SABANCI HOLDİNG A.Ş.	
KOÇ HOLDİNG A.Ş.	
TÜRKİYE ŞİŞE VE CAM FABRİKALARI A.Ş.	
MALİ KURULUŞLAR / SİGORTA ŞİRKETLERİ	1
TÜRKİYE SİGORTA A.Ş.	
TOPTAN VE PERAKENDE TİCARET / PERAKENDE TİCARET	2
BİM BİRLEŞİK MAĞAZALAR A.Ş.	
MAVİ GİYİM SANAYİ VE TİCARET A.Ş.	

TOPTAN VE PERAKENDE TİCARET / TOPTAN TİCARET	1
DOĞUŞ OTOMOTİV SERVİS VE TİCARET A.Ş.	
GENEL TOPLAM	25



BÖLÜM 5: BULGULAR

Bu bölümde, analizlerin yorumlanması ve değerlendirmeler yer almaktadır. Çalışmada, naif yöntem, basit ortalama, basit hareketli ortalama ve SARIMA gibi geleneksel tahmin modellerinin yanı sıra Logistic Regresyon, SVM, Naive Bayes, K-NN, Decision Tree, LDA, AdaBoost, Gradient Boosting, Bagging, RandomForest ve MLP gibi ileri düzey makine öğrenimi algoritmaları kullanılmıştır.

5.1. ANALİZ

5.1.1. RMSE - Hata Karelerinin Ortalamasının Karekökü (Root Mean Squared Error)

Yöntemlerin performansını değerlendirmek için Kök Ortalama Kare Hata (RMSE) metriği kullanılmıştır. RMSE, tahmin edilen değerler ile gerçek değerler arasındaki sapmayı, hataların karelerinin ortalamasının karekökünü alarak ölçer. Daha düşük bir RMSE değeri, tahminlerin gerçek değerlere daha yakın olduğunu ve dolayısıyla daha yüksek bir doğruluk ve tahmin gücü anlamına geldiğini gösterir. Bu sebeple, RMSE'nin en aza indirilmesi, tahmin modellerinin güvenilirliğini artırmak için kritik bir öneme sahiptir.

Basit öngörü teknikleri ile başlayıp, ARIMA modelleri ile öngörü ve öngörülerin değerlendirilmesinde seri, eğitim ve test veri kümesi olarak iki kümeye bölünmüştür. Tahminler, eğitim verisi ve test verisi olarak görselleştirilmiştir.

Şekil 45: RMSE Öngörü Analizi Kod Satırları

```
#Seriye, eğitim ve test veri kümesi olarak iki kümeye bölelim:
eğitim_verisi = df[df.index < '2021-01-01']
test_verisi = df[df.index >= '2020-12-31']

eğitim_verisi['#Pay'].plot(figsize=(12,8), color='r')
test_verisi['#Pay'].plot(figsize=(12,8), color='k')
plt.title("Eğitim & Test Veri Kümesi")
plt.xlabel("TARİH")
plt.ylabel("HİSSE BAŞI NET (TL) TEMETTÜ")
plt.grid()
plt.show()
```

Yukarıda gerçekleştirmiş olduğumuz öngörüler, RMSE ölçütü bazında karşılaştırıldığı sonuçlar aşağıda yer almaktadır.

Şekil 46: RMSE Analizi Sonuçları Kod Satırları

```
naif_yontem_performansi = sqrt(mean_squared_error(test_verisi['#Pay'], naif_model_ongoruleri))
basit_ortalama_performansi = sqrt(mean_squared_error(test_verisi['#Pay'], basit_ortalama_ongoruleri.basit_ortalama))
basit_hareketli_ortalama_performansi = sqrt(mean_squared_error(test_verisi['#Pay'],
basit_hareketli_ortalama_ongoruleri.basit_hareketli_ortalama))
sarima_performansi = sqrt(mean_squared_error(test_verisi['#Pay'], sarima_ongoruleri.sarima))

ongoru_performansi = pd.DataFrame({"model" : ["naif yöntem", "basit ortalama", "basit_hareketli_ortalama", "sarima"],
"performans" : [naif_yontem_performansi, basit_ortalama_performansi, basit_hareketli_ortalama_performansi, sarima_performansi]})

print(ongoru_performansi.sort_values(by="performans"))
```

Analizde elde edilen RMSE değerlerinin detaylı grafiksel gösterimi, çalışmanın sonundaki Ek A'da yer almaktadır. Bu karşılaştırmalar, modellerin tahmin başarımlarını nicel olarak değerlendirilmesine ve hangi yöntemin daha etkin sonuçlar verdiğini objektif bir şekilde yorumlanmasına olanak sağlamıştır.

5.1.2.DOĞRULUK

Doğruluk değeri terimi, bir modelin ne kadar doğru sonuçlar verdiğini belirlemek için kullanılır. Kısaca, modelin doğru tahmin etme yeteneği ifade etmektedir. Genellikle yüzde cinsinden ifade edilir. Yüzde olarak doğruluk değeri ne kadar yüksekse, modelin o kadar başarılı olduğunu göstermektedir.

Tablo 9: Doğruluk Değeri Genel Sonuçları

#	Hisse Adı	Logistic Regression	Naive Bayes	Decision Tree	K-NN	SVM	Gradient Boosting	Ada Boost	Bagging	Random Forest	MLP	LDA	SONUÇ
1	AEFES	%91.79	%95.52	%86.57	%72.39	%70.15	%94.03	%84.33	%94.03	%96.27	%91.79	%97.01	LDA
2	AKBN K	%91.79	%96.27	%94.03	%71.64	%67.91	%89.55	%87.31	%86.57	%96.27	%89.55	%97.76	LDA
3	AKSA	%95.52	%95.52	%87.31	%70.15	%64.93	%83.58	%92.54	%88.81	%89.55	%37.31	%97.01	LDA
4	AKSEN	%91.79	%92.54	%88.06	%67.91	%67.16	%88.06	%56.72	%92.54	%97.01	%90.30	%97.76	LDA

5	BIMAS	%95.52	%93.28	%82.09	%64.93	%67.16	%80.60	%83.58	%88.81	%93.28	%38.06	%94.78	Logistic Regression
6	BRYAT	%94.78	%94.78	%89.55	%72.39	%68.66	%90.30	%90.30	%97.01	%98.51	%55.97	%97.01	Random Forest
7	CIMSA	%92.54	%94.03	%88.06	%72.39	%69.40	%86.57	%87.31	%90.30	%93.28	%92.54	%93.28	Naive Bayes
8	DOAS	%88.81	%92.54	%84.33	%67.16	%63.43	%82.84	%83.58	%82.09	%92.54	%86.57	%97.01	LDA
9	ECILC	%88.06	%94.03	%84.33	%71.64	%66.42	%91.04	%88.81	%87.31	%99.25	%31.34	%95.52	Random Forest
10	ENJSA	%90.30	%94.03	%86.57	%70.15	%70.15	%89.55	%55.97	%90.30	%93.28	%84.33	%98.51	LDA
11	ENKAI	%96.27	%94.78	%75.37	%66.42	%65.67	%80.60	%93.28	%79.85	%91.04	%28.36	%97.76	LDA
12	FROTO	%88.81	%94.78	%79.85	%70.90	%63.43	%82.09	%83.58	%97.01	%96.27	%61.94	%97.76	LDA
13	GARAN	%91.04	%95.52	%78.36	%69.40	%67.16	%77.61	%64.93	%81.34	%95.52	%82.09	%97.01	LDA
14	ISCTR	%91.79	%95.52	%84.33	%64.93	%67.91	%88.06	%93.28	%87.31	%94.78	%53.73	%94.78	Naive Bayes
15	ISMEN	%90.30	%98.51	%83.58	%71.64	%71.64	%91.04	%91.04	%89.55	%96.27	%24.63	%94.78	Naive Bayes
16	KCHOL	%91.79	%97.01	%94.78	%69.40	%66.42	%94.03	%92.54	%93.28	%97.76	%26.87	%97.01	Random Forest
17	MAVI	%90.30	%97.76	%95.52	%68.66	%70.90	%92.54	%90.30	%91.79	%97.01	%91.79	%94.78	Naive Bayes
18	SAHOL	%93.28	%97.01	%91.04	%72.39	%66.42	%90.30	%85.82	%92.54	%97.76	%29.85	%94.03	Random Forest
19	SISE	%92.54	%99.25	%84.33	%70.15	%66.42	%85.07	%64.93	%87.31	%97.76	%48.51	%96.27	Naive Bayes
20	TCELL	%90.30	%97.01	%89.55	%71.64	%65.67	%85.82	%88.81	%92.54	%97.01	%88.81	%98.51	LDA
21	TOASO	%94.78	%97.01	%87.31	%72.39	%70.15	%83.58	%87.31	%91.79	%97.76	%34.33	%95.52	Random Forest
22	TTRAK	%88.06	%94.78	%80.60	%70.90	%66.42	%87.31	%91.04	%94.78	%96.27	%84.33	%95.52	Random Forest

23	TURSG	%91.79	%97.76	%85.82	%66.42	%73.13	%81.34	%85.82	%85.82	%93.28	%87.31	%95.52	Naive Bayes
24	VESBE	%91.04	%94.78	%88.81	%68.66	%66.42	%90.30	%85.07	%88.06	%92.54	%63.43	%96.27	LDA
25	YKBN K	%90.30	%97.01	%82.09	%67.91	%64.93	%88.81	%88.81	%89.55	%96.27	%90.30	%95.52	Naive Bayes

5.2. TARTIŞMA

Bu bölümde RMSE ve Doğruluk (accuracy) sonuçlarına yer verilmiştir.

5.2.1.RMSE

Yöntemlerin düşük RMSE değerlerine sahip olması, tahmin yeteneklerinin iyi olduğunu ve gerçek değerlere daha yakın sonuçlar verdiğini göstermektedir.

Tablo 10: RMSE Performans Genel Sonuçları

#	Hisse Adı	Naif Yöntem	Basit Ortalama	Basit Hareketli Ortalama	Sarima	Sonuç
1	AEFES	0.590209	1.360557	1.352517	1.271306	Naif
2	AKBNK	1.044708	0.965467	0.962956	1.017563	Basit Hareketli Ortalama
3	AKSA	1.925553	1.903063	1.875658	1.740135	Sarima
4	AKSEN	0.660491	0.660491	0.660491	0.660491	Hepsi
5	BIMAS	4.883759	4.318273	4.312674	3.475930	Sarima
6	BRYAT	18.849242	19.294367	19.235848	18.826868	Sarima
7	CIMSA	1.398645	1.033835	1.030082	1.241673	Basit Hareketli Ortalama
8	DOAS	23.389257	22.986263	22.919505	22.880544	Sarima
9	ECILC	0.487253	0.417636	0.405854	0.350463	Sarima
10	ENJSA	1.177062	1.501359	1.477614	1.308724	Naif
11	ENKAI	0.681784	0.698472	0.689042	0.595467	Sarima
12	FROTO	28.348526	29.056486	28.999952	27.532946	Sarima

13	GARAN	1.517315	1.434489	1.432995	1.479456	Basit Hareketli Ortalama
14	ISCTR	0.411553	0.334401	0.333760	0.380719	Basit Hareketli Ortalama
15	ISMEN	0.851299	1.013463	0.997999	0.931831	Naif
16	KCHOL	3.216987	3.195722	3.188579	3.116728	Sarima
17	MAVI	2.013528	1.981067	1.973025	2.013528	Basit Hareketli Ortalama
18	SAHOL	1.219891	1.306515	1.297654	1.215363	Sarima
19	SISE	0.341821	0.373927	0.364952	0.309222	Sarima
20	TCELL	1.092801	1.027576	0.965543	1.041135	Basit Hareketli Ortalama
21	TOASO	7.488733	8.238921	8.152550	7.728243	Naif
22	TTRAK	39.833681	38.581565	38.484162	40.000443	Basit Hareketli Ortalama
23	TURSG	0.265357	0.265357	0.265357	0.265357	Hepsi
24	VESBE	1.208164	0.817157	0.791441	1.871506	Basit Hareketli Ortalama
25	YKBNK	0.617366	0.603185	0.599706	0.617366	Basit Hareketli Ortalama

Bu çalışmada bir performans ölçütü olarak kullanılan Karekök Ortalama Kare Hatası (RMSE) değerleri, Sarima yöntemi (RMSE = 10), Basit Hareketli Ortalama yöntemi (RMSE = 9), Naif yöntem (RMSE = 4) ve "Hepsi" yöntemi (RMSE = 2) arasında farklı seviyelerde tahmin doğruluğu sergilemektedir.

Tablo 11: RMSE Performans Özet Sonuçları

SONUÇ		#
Sarima		10
AKSA		
BIMAS		
BRYAT		

DOAS	
ECILC	
ENKAI	
FROTO	
KCHOL	
SAHOL	
SISE	
Basit Hareketli Ortalama	9
AKBNK	
CIMSA	
GARAN	
ISCTR	
MAVI	
TCELL	
TTRAK	
VESBE	
YKBNK	
Naif	4
AEFES	
ENJSA	
ISMEN	
TOASO	
Hepsi	2
AKSEN	
TURSG	
Genel Toplam	25

RMSE (Root Mean Square Error), tahminlerin gerçek değerlerden ne kadar sapma gösterdiğini ölçen bir istatistiksel ölçüttür. Daha düşük RMSE değeri, tahminlerin gerçek değerlere daha yakın olduğunu yani, tahmin gücünün diğer yöntemlere göre daha yüksek olduğunu gösterir. RMSE ölçütünü en düşük yapmak için tahminlerin doğruluğunu artırmak gerektirir.

SARIMA (10), hem trend hem de mevsimsel (dönemsellik) bileşenleri içeren zaman serilerini modellemek için geliştirilmiştir. Elde edilen RMSE (Root Mean Square Error) değerlerinin düşük çıkması, modelin tahmin performansının iyi olduğunu ifade eder.

Basit Hareketli Ortalama (9) genellikle trendi veya düzensiz dalgalanmaları yumuşatmak için kullanılır. Bu yöntem, geçmiş verilerin eşit ağırlıklı ortalamasını alarak tahmin yapar. Düşük RMSE değeri, bu yöntemin geçmiş verilere dayalı tahminlerde başarılı olduğunu gösterir.

Naif (4) ise, basitçe bir önceki değeri gelecekteki değer olarak tahmin eder. Bu yöntem, özellikle verinin belirgin bir trendi veya deseni olmadığı durumlarda kullanışlı olabilir. Yine düşük RMSE değeri, bu yöntemin veri setine uygun şekilde doğru tahminler yaptığını gösterir.

Basit Ortalama (2) ise, tüm geçmiş verilerin eşit ağırlıklı ortalamasını alarak tahmin yapar. Bu yöntem de genellikle kararlı bir trendin olduğu durumlarda etkili olabilir. Düşük RMSE değeri, modelin doğru tahminler yapabildiğini gösterir.

AKSEN VE TURSG veri setleri, çok az dalgalanma gösteren, durağan ve oldukça basit bir yapıya sahip olduğundan, RMSE değerlerinin aynı çıktığı gözlemlenmiştir.

Sonuç olarak, bulgular değerlendirilen modellerin tahmin hatalarını en aza indirmedeki göreceli etkinliğini vurgulamaktadır. Bu sonuçlar, farklı tahmin yaklaşımlarının karşılaştırmalı doğruluğu hakkında değerli bilgiler sunmaktadır.

5.2.2.DOĞRULUK

LDA (11), Naive Bayes (7), Random Forest (6) ve Logistic Regression (1) modellerinin doğruluk değerleri en yüksektir.

Tablo 12: Doğruluk Değerleri Özet Sonuçları

SONUÇ	#
LDA	11
AEFES	
AKBNK	
AKSA	
AKSEN	
DOAS	
ENJSA	
ENKAI	
FROTO	
GARAN	
TCELL	
VESBE	
Naive Bayes	7
CIMSA	
ISCTR	
ISMEN	
MAVI	
SISE	
TURSG	
YKBNK	

Random Forest	6
BRYAT	
ECILC	
KCHOL	
SAHOL	
TOASO	
TTRAK	
Logistic Regression	1
BIMAS	
Genel Toplam	25

Belirtilen modellerin doğruluk değerleri incelendiğinde, LDA, Naive Bayes ve Random Forest modellerinin en yüksek doğruluk değerlerine sahip olduğu görülmektedir.

Yüksek bir LDA değeri, modelin verilerin içerdiği konuları doğru bir şekilde belirlediği ve bu konuların veriler arasındaki dağılımını açıkladığı anlamına gelir. Bu durum, her verinin net ve ayırt edici bir konu dağılımına sahip olduğunu gösterir.

Naive Bayes, genellikle metin sınıflandırması gibi problemlerde başarılı olan basit ancak etkili bir olasılık tabanlı sınıflandırma algoritmasıdır. Yüksek doğruluk değeri, bu modelin veri setinde iyi performans sergilediğini göstermektedir.

Random Forest ise birçok karar ağacının bir araya gelmesiyle oluşturulan bir ensemble öğrenme algoritmasıdır. Geniş kullanım alanına sahip olan bu model, genellikle yüksek doğruluk sağlar. Yüksek doğruluk değeri, Random Forest modelinin veri setindeki karmaşıklıkları başarılı bir şekilde ele aldığını göstermektedir.

Çalışmanın bulguları, hibrit model yaklaşımlarının ve alternatif makine öğrenmesi algoritmalarının araştırılması için yeni fırsatlar sunmaktadır. Ayrıca, farklı veri setleri ve dışsal faktörlerin etkilerinin incelenmesi, bu alandaki bilgi birikimini artırabilir.

Sonuç olarak, her modelin doğruluk değerleri veri setine bağlı olarak değişebilir. Ancak, LDA, Naive Bayes ve Random Forest gibi modellerin yüksek doğruluk değerleri, finansal tahminlerde güvenilir sonuçlar elde etmenin önemini ortaya koymaktadır. Bu bulgular, yatırımcıların ve finansal analistlerin daha bilinçli kararlar almasına olanak tanıyacaktır.

BÖLÜM 6: SONUÇ VE ÖNERİLER

6.1. TARTIŞMA

Bu çalışma, hisse senedi ticaretinde teknik analiz yöntemlerinin uygulanmasını, finans sektöründeki dijital dönüşümü, Endüstri 4.0 ile fintech'in bankacılık üzerindeki etkilerini, gömülü finans kavramını ve metaverse'ün bankacılık sektörü üzerindeki yansımalarını detaylı incelemektedir. Özellikle BİST Temettü 25 Endeksi'nde bulunan şirketlerin hisse senedi fiyatlarını tahmin etmek amacıyla çeşitli makine öğrenimi yöntemleri ve zaman serisi algoritmalarının etkililiğinin karşılaştırılması, finansal veri setlerinde kullanılan tahmin modellerinin etkinliğini değerlendirmeye yönelik önemli bir katkı sunmaktadır. Çalışmanın bulguları, finansal piyasalarda veri temelli karar alma süreçlerini güçlendiren yeni araçların geliştirilmesine dair farklı bakış açıları sunmaktadır.

Çalışmada, SARIMA modelinin 10 farklı hisse senedi için en düşük RMSE değerine ulaşarak, trend ve mevsimsel bileşenleri içeren zaman serilerinde daha etkili olduğu belirlenmiştir. Basit Hareketli Ortalama yöntemi, 9 hisse senedinde en düşük RMSE değerini elde ederken, Naif yöntem ise 4 hisse senedinde bu başarıyı göstermiştir. Bu bulgular, SARIMA modelinin yapısal özelliklere sahip veri setlerinde daha etkili olduğunu gösteriyor. Naif yöntemin bazı durumlarda başarılı sonuçlar vermesi, finansal tahminlerde basit modellerin önemini göz ardı etmememiz gerektiğini göstermektedir. Zaman serisi analizi, geçmişteki temettü ödemelerini değerlendirerek gelecekteki temettü tahminleri yapma veya temettü ödemelerindeki eğilimleri saptama konusunda yararlı olabilir.

LDA (Linear Discriminant Analysis) modeli, doğruluk metriği açısından değerlendirildiğinde 11 farklı hisse senedi arasında en yüksek başarıyı göstererek lider konumdadır. Naive Bayes ve Random Forest modelleri, sırasıyla 7 ve 6 hisse senedinde en yüksek doğruluk oranlarını elde etmiştir. Bu sonuçlar, LDA'nın finansal tahminlerde güvenilir bilgiler sunduğunu göstermektedir. Ancak Naive Bayes ve

Random Forest'ın belirli durumlarda etkili sonuçlar vermesi, farklı modellerin birbiriyle uyumlu olduğunu gösteriyor. Bu durum, hibrit yaklaşımların daha üstün sonuçlara ulaştırma potansiyeline sahip olabileceğine işaret etmektedir. Finansal veri setlerinin karmaşık ve çeşitli doğası göz önüne alındığında, alternatif makine öğrenimi algoritmalarının yanı sıra hibrit modellerin incelenmesi, bu sektördeki bilgi birikimini zenginleştirebilir ve daha doğru sonuçlar elde edilmesine yardımcı olabilir.

Bu öngörüler, Borsa İstanbul'da temettü dağıtımını dikkate alarak yatırım yapmayı tercih eden bireylerin daha bilinçli seçimler yapmalarına, portföylerini iyileştirmelerine ve stratejilerini geliştirmelerine katkıda bulunacaktır. Geçmiş temettü ödemelerini incelemek, özellikle temettü odaklı yatırımcılar için gelecekteki ödeme eğilimlerini tahmin etmek açısından büyük önem taşımaktadır. Bu analizler, uzun vadeli yatırım kararları alırken kritik bir rol oynamaktadır. Bu açıdan, zaman serisi analizi ile makine öğrenmesi yöntemlerinin birleştirilmesi, yatırımcılara daha kapsamlı bir bilgi sunabilir.

Ayrıca, yükselen teknolojilerin finans sektöründeki etkileri de bu çalışmanın kapsamındadır. Bu çalışmanın kapsamı, yükselen teknolojilerin finans alanındaki etkilerini de içermektedir. Özellikle yapay zekâ ve blockchain gibi yenilikçi teknolojilerin İslami finans uygulamalarındaki yeri önemli bir odak noktasıdır. Böylece, müslüman pazarına yönelik karşılanamamış ihtiyaçlara hizmet verilmesi mümkün olacaktır. İslami finans, faiz istemeyen finansman anlayışına dayanmaktadır ve temel ilkeleri arasında şeffaflık, risk paylaşımı ve etik yatırım yer almaktadır. Blockchain teknolojisi, işlemlerin şeffaf bir şekilde ve değiştirilemez olarak kaydedilmesini mümkün kılarak İslami finans kurallarına uyumu artırma potansiyeline sahiptir. Benzer şekilde, yapay zekâ destekli analiz araçları, etik yatırım fırsatlarını tespit etmek ve riskleri azaltmak için kullanılabilir. Bu teknolojilerin benimsenmesi, İslami finansın gelişimine katkı sağlayacak ve küresel finansal sistemdeki yerini güçlendirecektir.

Sonuç olarak, bu çalışma, çeşitli tahmin yöntemlerinin finansal veri setleri üzerindeki performansını anlamamıza yardımcı olacak değerli veriler sunmaktadır. Özellikle SARIMA ve LDA modellerinin öne çıktığını gösteren bulgular, finansal tahminlerde bu modellerin daha sık kullanılmasını teşvik edebilir. Finansal verilerin karmaşıklığını ve sürekli değişen yapısını düşünüldüğünde, her durumda tek bir modelin en iyi sonuçları elde etmesi beklenemez. Hibrit modellerin ve alternatif

algoritmaların incelenmesi, bu alandaki bilgi birikimini geliştirerek daha doğru tahminler yapma imkânı sunabilir. Ayrıca, gelişen teknolojilerin finans sektöründeki muhtemel etkileri, özellikle İslami finans alanında yenilikçi fırsatlar sunabilir. Gelecek araştırmalar, bu teknolojilerin pratikteki uygulamalarını ve sonuçlarını daha kapsamlı bir şekilde inceleyecektir.

6.2. ARAŞTIRMANIN LİTERATÜRE KATKISI

Bu çalışma, yatırımcıların Borsa İstanbul’da temettü dağıtımına dayalı olarak daha dikkatli kararlar almalarına yardımcı olacak detaylı bir tahmin modeli sunmaktadır. Literatürde temettü tahmini üzerine yapılan zaman serisi analizi ve makine öğrenmesi çalışmaları incelendiğinde, bu çalışmanın hem metodolojik yönleriyle hem de pratik uygulamalarıyla kayda değer özgün katkılar sunduğu görülmektedir.

İlk olarak, SARIMA, LDA ve Random Forest gibi çeşitli modellerin başarılı sonuçlarının karşılaştırılması, finansal tahminlerde hangi tekniklerin daha etkili olduğunu anlamak için yeni bir bakış açısı sunuyor. Özellikle SARIMA modelinin, trend ve mevsimsel bileşenlere sahip veri setlerinde sağladığı avantaj oldukça kayda değerdir. Öte yandan, LDA'nın doğruluk ölçütleri açısından en etkili model olması dikkat çekmektedir. Bu iki modelin finansal tahmin süreçlerindeki muhtemel katkıları üzerine düşünmek önemlidir. Bu sonuçlar, literatürde yaygın olarak tercih edilen tek bir modelin ötesine geçerek, çeşitli modellerin birbirini tamamladığını göstermekte ve hibrit yaklaşımların sunduğu potansiyeli vurgulamaktadır.

Bunun yanı sıra, bu çalışma zaman serisi analizi ve makine öğrenmesi yöntemlerini bir araya getirerek temettü tahminine dair literatüre yenilikçi bir perspektif sunmaktadır. Zaman serisi analizinin geçmiş verilere dayalı desenleri keşfetme konusundaki sağladığı yararlar ile makine öğrenmesi algoritmalarının zorlu veri yapılarını modelleme kabiliyeti bir araya getirildiğinde, daha hassas ve güvenilir sonuçlar elde edilebilir. Bu entegrasyon, temettü odaklı yatırımcılar için uzun dönemli stratejiler oluşturma konusunda faydalı bir yapı sunmaktadır.

Hibrit yöntemlerin (zaman serileri ve makine öğrenmesinin bir arada kullanılması) finansal tahminlerdeki etkinliğini incelemek, gelecekteki araştırmalar için sağlam bir temel sağlayabilir. Araştırmanın bulguları, alternatif modellerin ve hibrit yaklaşımların incelenmesinin finansal tahminlerdeki bilgi birikimini

geliştirebileceğini ortaya koymaktadır. Ayrıca, bu tür entegrasyonların İslami finans veya sürdürülebilir yatırım gibi finansın özel alanlarına uyarlanması yoluyla karşılanmamış ihtiyaçları karşılamak için yenilikçi çözümler geliştirilebileceği düşünülmektedir.

Sonuç olarak, bu çalışma temettü tahmini literatürüne önemli bir katkı sağlamaktadır. Hem metodolojik yenilikler hem de pratik uygulamalar açısından öne çıkan bu çalışma, finansal tahmin süreçlerinde daha etkili ve verimli modellerin geliştirilmesi için bir ilham kaynağı olacaktır. Gelecekteki çalışmalar, bulguları daha geniş veri kümeleri ve farklı finansal bağlamlarda test ederek çalışmada önerilen modellerin genelleştirilebilirliğini ve uygulanabilirliğini daha da artırabilir.

6.3. ARAŞTIRMANIN LİTERATÜR BULGULARI İLE KARŞILAŞTIRILMASI

Mevcut literatürde temettü tahminleri çoğunlukla geleneksel istatistiksel yöntemler kullanılarak gerçekleştirilmektedir. Ancak bu çalışma, modern makine öğrenimi yöntemlerini de dahil ederek daha kapsamlı ve derinlemesine bir analiz sunmaktadır. Bu bağlamda elde edilen bulguların literatürdeki benzer çalışmalarla tutarlı olduğu görülmektedir. Arsoy ve Güreşen (2016) tarafından yapılan çalışmada, makine öğrenimi yöntemlerinin nakit temettü tahmininde geleneksel yöntemlere göre daha doğru sonuçlar verdiği belirtilmektedir. Bu çalışmanın sonuçlarına göre, LDA ve Random Forest gibi makine öğrenimi modelleri, yüksek doğruluk değerleri elde etmeleri nedeniyle literatürle uyumlu bir şekilde ilerlemektedir. Bu, makine öğrenimi yöntemlerinin finansal tahmin süreçlerindeki öneminin arttığını bir kez daha doğrulamaktadır.

Ancak bu çalışma, SARIMA ve Basit Hareketli Ortalama gibi zaman serisi modellerinin finans alanındaki performanslarının ayrıntılı bir incelemesini de sağlaması nedeniyle literatürdeki diğer çalışmalardan ayrılmaktadır. Trend ve mevsimsel bileşenleri içeren veritabanlarında SARIMA modelinin en düşük RMSE değerlerini elde etmesi, zaman serisi analizinin literatürdeki önemini vurgulamaktadır. Benzer şekilde, Basit Hareketli Ortalama yönteminin bazı hisse senetlerinde yeterli performansı, geleneksel yöntemlerin belirli koşullar altında etkili olabileceğini

göstermektedir. Bu bulgular, literatürde sıklıkla tartışılan "modern yöntemler mi yoksa geleneksel yöntemler mi daha etkilidir?" sorusuna kapsamlı bir yanıt sunmaktadır.

Bu çalışma ayrıca, Endüstri 4.0 ve dijital dönüşümün finans sektörü üzerindeki etkilerine odaklanarak teknolojinin finansal süreçlere nasıl entegre edilebileceği konusunda somut öneriler sunmuştur. Literatürde endüstri 4.0 ve dijital dönüşüm üzerine yapılan çalışmaların sayısı artarken, pratik uygulamalar hala sınırlıdır. Bu bağlamda, zaman serisi analizinin makine öğrenmesi yöntemleriyle bütünleştirilmesi ve hibrit yaklaşımların değerlendirilmesi gelecekteki araştırmalar için yeni bir çerçeve oluşturmuştur. Özellikle yapay zekâ, blockchain ve diğer ortaya çıkan teknolojilerin finansal süreçlere entegrasyonuna ilişkin önerilerle literatüre yeni bir bakış açısı eklenmiştir.

Sonuç olarak, bu çalışma literatürdeki mevcut bulgularla uyumlu bulguların yanı sıra yeni metodolojik ve pratik perspektiflerle literatüre katkıda bulunmuştur. SARIMA ve makine öğrenmesi modellerinin karşılaştırmalı analizi ve ortaya çıkan teknolojilerin finansal süreçlere entegrasyonuna ilişkin öneriler literatürdeki önemli bir boşluğu doldurmaktadır. Gelecekteki çalışmalar, bu çalışmanın bulgularını daha geniş veri kümeleri ve çeşitli finansal bağlamlarda test ederek önerilen modellerin genelleştirilebilirliğini ve uygulanabilirliğini güçlendirebilir.

6.4. YENİ ARAŞTIRMA SORULARI

Bu çalışmanın bulguları, finansal tahmin için kullanılan makine öğrenimi ve zaman serisi modellerinin performansını değerlendirmek için önemli bir temel sağlar. Yine de, sonuçlar bu çalışma alanında daha kapsamlı araştırmalar gerektiren yeni araştırma soruları ortaya koymaktadır. Bu bağlamda, aşağıdaki araştırma soruları önerilmektedir:

Model Performansının Uzun Dönem Etkileri: Farklı makine öğrenimi modellerinin uzun vadeli tahmin performansı nasıl değişmektedir? Özellikle, bu modeller piyasa kesintileri, ekonomik kriz dönemleri veya mevsimsel etkiler gibi olaylar karşısında ne kadar güvenilir ve sağlamdır? Uzun vadeli tahminlerde hangi tahmin yöntemleri daha avantajlıdır?

Hibrit Modellerin Etkisi: Hibrit yaklaşımlar (makine öğrenimini zaman serisi modellemesiyle birleştirenler) finansal zaman serilerini tahmin etmede ne kadar etkili

olabilir? Örneğin, SARIMA ve Random Forest veya LDA ve LSTM (Long Short-Term Memory) gibi kombinasyonlar çeşitli veri kümeleri arasında gerçekten en iyi performans gösteren yapılar mıdır? Hibrit modellerin dezavantajları nelerdir ve bu dezavantajlar nasıl en aza indirilebilir?

Veri Seti Çeşitliliği: Farklı sektörlerden veri kümeleri kullanarak tahminler yaparken hangi makine öğrenimi yöntemleri en iyi sonuçları verir? Örneğin, bu modeller hangi sektörlerde (sağlık, enerji, teknoloji veya tüketim malları) iyi performans gösteriyor ve nerede engellerle karşılaşılıyor? Bu sektörel çeşitliliğin model performansı üzerindeki etkisi hakkında neler öğrenebiliriz?

Model Seçim Kriterlerinin Geliştirilmesi: Model seçiminde kullanılan kriterler (örneğin, RMSE, doğruluk değerleri) daha kapsamlı bir şekilde nasıl geliştirilebilir? Mevcut değerlendirme süreçlerine yeni metrikler eklenerek bunlar nasıl daha da güçlendirilebilir? Örneğin, finansal verilerin karmaşıklığını daha iyi yansıtan ve bu verilere özel olarak geliştirilmiş metrikler neler olabilir?

Olası Dışsal Etkiler: Ekonomi, politika veya sosyal alanlardaki faktörlerin, makine öğrenmesi modellerinin tahmin performansı üzerindeki etkileri nedir? Bu tür dışsal değişkenlerin modellere entegrasyonu, temettü tahmini veya hisse senedi fiyatlarının belirlenmesinde modelin doğruluğunu artırabilir mi? Enflasyon oranları, faiz politikaları veya küresel olayların modellere dâhil edilmesi ne tür katkılar sağlıyor?

Gerçek Zamanlı Tahminler: Gerçek zamanlı veri akışları kullanılarak yapılan tahminlerin doğruluğu ve güvenilirliği nasıl artırılabilir? Hangi algoritmalar bu tür uygulamalar için daha uygundur? Örneğin, yapay sinir ağları veya derin öğrenme modelleri, gerçek zamanlı veri işlemede daha etkili olabilir mi? Ayrıca, gerçek zamanlı tahminlerde gecikme süreleri nasıl minimize edilebilir?

Bu sorular, aslında finansal tahminlerdeki hem teorik hem de pratik boşlukları dolduracak nitelikte; genelde düşündüğümüzden daha geniş bir yelpazede yeni çözümler sunuyorlar. Öneriler, gelecekte yapılacak araştırmalar için kısaca bir rehber görevi görürken, finansal karar verme süreçlerinde daha keskin ve güvenilir modeller ortaya koymaya imkân tanıyor. Ek olarak, yükselen teknolojilerin (örneğin, yapay zekâ, blockchain) finansal sistemlere entegrasyonu üzerine yapılacak çalışmalar, alanındaki bilgi birikimini artırıp beklenmedik, yenilikçi çözümlerin de ortaya çıkmasına zemin hazırlayabilir.

Anahtar Araştırma Alanları:

- Makine öğrenimi modellerinin uzun dönem performansının ayrıntılı incelenmesi
- Finansal tahminlerde hibrit yaklaşımların sunduğu potansiyelin değerlendirilmesi
- Sektör odaklı veri setlerinde modellerin birbirleriyle karşılaştırılması
- Model seçimi sürecinde kullanılacak kriterlerin geliştirilmesi ve yeni metriklerin tasarlanması
- Dış etkenlerin tahmin modellerine entegre edilerek değerlendirilmesi
- Anlık veri akışları üzerinden tahmin doğruluğunun artırılmasına yönelik yöntemlerin geliştirilmesi

Bu sorular, gelecekteki araştırmacılar için ilham kaynağı oluşturarak finansal tahminler alanında daha kapsamlı ve yenilikçi yaklaşımların ortaya çıkmasına zemin hazırlayabilir.

6.5. SONUÇ

Bu çalışma, Borsa İstanbul'da (BİST) Temettü 25 Endeksi'nde yer alan şirketlerin hisse senedi fiyatlarını tahmin etmek için farklı makine öğrenmesi ve zaman serisi modellerinin performanslarını karşılaştırmıştır. Elde edilen bulgular, yatırımcıların daha bilinçli kararlar almasına ve finansal stratejilerini geliştirmelerine katkı sağlayacak şekilde değerlendirilmiştir. Temettü tahmin modellerinin doğru kullanımı, yatırımcıların portföylerini optimize etmelerine ve piyasa analizlerini daha etkin bir şekilde yapmalarına yardımcı olabilir.

İnsanlık, Endüstri 1.0'dan 4.0'a büyük değişimler yaşamıştır. Günümüzde ekonomik dönüşümler Almanya'da Endüstri 4.0 ve Japonya'da Toplum 5.0 ile tanımlanmaktadır. Bu dönüşüm, finans sektöründe de dijitalleşmenin hızlanmasına neden olmuştur. Dijital bankacılık ve finansal teknolojiler, özellikle kırsal bölgelerde yaşayan ve geleneksel bankacılık hizmetlerine erişimi sınırlı olan kişiler için daha geniş kitlelere finansal hizmetler sunabilir. Yapay zekâ ve makine öğrenimi gibi teknolojiler, talepte bulunan bankaların ise operasyon risklerini azaltarak müşteri deneyimini en yüksek seviyeye devam ettirmelerini, güven ve sadakatlerini güçlendirmelerini sağlamaktadır.

Temettü yatırımları, uzun vadeli yatırımcılar arasında aşırı popülerdir. Çünkü hisse senedi fiyatlarındaki dalgalanmalardan bağımsız olarak sürekli gelir sağlamaktadır. Tüm yatırımlar gibi temettü yatırımları da risk içerir. Yatırım kararları kişisel tercihler, risk toleransı ve finansal hedeflere göre yapılmalıdır. Bu çalışmanın sonuçları yatırımcılara temettü odaklı stratejiler tasarlamada rehberlik edebilir.

Bu çalışmada, SARIMA, Basit Hareketli Ortalama ve Naif yöntemlerin RMSE ölçütüne göre en düşük hata değerlerine sahip olduğu tespit edilmiştir. Özellikle SARIMA modeli, trend ve mevsimsel bileşenler içeren veri setlerinde üstün performans göstermiştir. Doğruluk değerleri açısından değerlendirildiğinde ise LDA, Naive Bayes ve Random Forest modelleri en başarılı modeller olarak öne çıkmıştır. Bu bulgular, hem geleneksel istatistiksel yöntemlerin hem de modern makine öğrenmesi modellerinin belirli koşullarda etkili olduğunu ortaya koymaktadır.

Sonuç olarak, yatırımcılar ve finansal analistler, bu modellerin uygulanmalarıyla daha bilinçli bir karar verilebilir. Makalenin sonuçları, gelecekteki çalışmalar için bir köprü görevi görmek ve hibrit yöntemlerin (zaman serisi analizi ile makine öğrenmesi kombinasyonu) potansiyelini vurgulamaktadır. Ayrıca, artan teknolojilerin finansal analizlerine yönelik önerilerde özellikle İslami finans ve sürdürülebilir yatırım gibi özel finansal alanlarda gelişmiş çözümlerin geliştirilmesine ilham verilebilir.

Özetle;

- SARIMA, Basit Hareketli Ortalama ve Naif yöntemler, RMSE ölçütüne göre en düşük hata oranlarına sahiptir.
- LDA, Naive Bayes ve Random Forest modelleri doğruluk açısından en başarılı modellerdir.
- Hibrit yaklaşımların ve yükselen teknolojilerin finansal süreçlere entegrasyonu, literatüre ve uygulamaya önemli katkılarda bulunmaktadır.
- Temettü tahmini modelleri, yatırımcıların daha bilinçli kararlar almasına ve portföylerini optimize etmelerine yardımcı olabilir.
- Yapay zeka ve makine öğrenimi, finansal ekosistemde müşteri deneyimini ve operasyonel verimliliği artırmaktadır.

Bu çalışma, finansal tahminlerde kullanılan modellerin etkinliğini değerlendirmek ve yatırımcılara pratik bir çerçeve sunmak amacıyla geliştirilmiştir. Gelecekteki çalışmalar, bu çalışmanın bulgularını daha geniş veri setleri ve farklı finansal

bağlamlar üzerinde test ederek, önerilen modellerin genellenebilirliğini ve uygulanabilirliğini daha da güçlendirebilir.

6.6. ÖNERİLER

Bu çalışma kapsamında elde edilen sonuçlar, finansal tahminlerin iyileştirilmesi ve yatırımcılara daha bilinçli kararlara ulaşmalarının sağlanması hususunda çeşitli öneriler sunmaktadır. Bu öneriler yazılım firmaları, temettü yatırımcıları ve devlet gibi farklı paydaş gruplarına hitap etmektedir. Aşağıda, her bir gruba yönelik öneriler ayrıntılı olarak açıklanmıştır.

Finans sektörü sürekli gelişen ve teknolojiye bağlı olarak dönüşen bir alandır. Bu bağlamda, yazılım firmalarının aşağıdaki öneriler doğrultusunda hareket etmesi önemlidir:

Sektör İhtiyaçlarını İyi Analiz Etme: Finans sektörünün neye ihtiyacı olduğunu ve hangi sorunlarla karşılaştığını derinlemesine inceleyerek, hem yenilikçi hem de araştırmaya dayalı çözümler üretmelidir. Özellikle yapay zekâ, makine öğrenimi ve blockchain gibi yükselen teknolojileri kullanarak sektöre değer katabilirler.

Veri Güvenliği ve Gizliliği: Veri güvenliği ve gizliliği konusunda en üst düzeyde standartlara sahip olmak, müşterilerin güvenini kazanmak için hayati önem taşımaktadır. Siber güvenlik önlemleri ve uyumluluk politikaları titizlikle uygulanmalıdır.

Müşteri Geri Bildirimlerini Değerlendirme: Müşterilerden gelen geri bildirimleri değerlendirerek çözümleri sürekli iyileştirmek, müşteri memnuniyetini artırır ve uzun süreli ilişkiler kurulmasına yardımcı olur.

Hibrit Model Çözümleri Geliştirme: Tahminlerin doğruluğunu artırmak için farklı zaman serisi analizi ve makine öğrenimini bir araya getiren yaklaşımlar, finansal tahminlerde daha başarılı sonuçlar verebilir.

Temettü yatırımları, özellikle uzun vadeli yatırımcılar arasında popülerdir. Ancak bu tür yatırımların başarılı bir şekilde yönetilmesi için aşağıdaki öneriler göz önünde bulundurulmalıdır:

Piyasa Koşullarını İyi Analiz Etme: Temettü yatırımı yapmadan önce şirketin bulunduğu sektör, genel piyasa durumu ve ekonomik faktörler iyice

incelenmelidir. Ayrıca, şirketin geçmişte ne kadar temettü dağıttığı ve finansal performansı da gözden geçirilmelidir.

Portföy Çeşitlendirmesi: Riskleri azaltmak için portföyü çeşitlendirmek önemlidir. Farklı sektörlerden hisse senetlerine yatırım yaparak olası kayıplara karşı önlem alınabilir.

Rasyonel Karar Alma: Duygusal davranmak yerine mantıklı kararlar almak ve finansal bilgi birikimini sürekli güncel tutmak gerekmektedir. Piyasadaki gelişmelere sakın bir şekilde yaklaşılmalı ve duygusal tepkilerden kaçınılmalıdır.

Profesyonel Destek Alınması: Gerekirse finans uzmanlarından veya portföy yöneticilerinden destek alarak daha bilinçli kararlar verilebilir. Uzman görüşleri, yatırımcıların stratejilerini geliştirmelerine yardımcı olabilir.

Devletler, finans sektörünün büyümesini ve sürdürülebilirliğini desteklemek için aşağıdaki adımları atabilir:

Küçük İşletmelere Teşvik Sağlama: Girişimleri fon ya da karşılıksız yardımlarla desteklemek, özgün projelerin hayata geçirilmesine imkân tanır. Özellikle finansal teknoloji alanında faaliyet gösteren girişimcilere maddi destek verilmelidir.

Düşük Vergi ve Harç Politikaları: Fintek yapısının gelişimi için cüzi vergi ve harç uygulamaları ile mali avantajlar temin edilmelidir. Bu durum, hem yerel hem de uluslararası yatırımcıları cezbederek ekonomik büyümeye destek sağlayabilir.

Yasal Çerçeve ve Düzenlemeler: Finansal teknolojilerin yaygınlaşmasıyla birlikte, veri güvenliği, müşteri hakları ve şeffaflık mevzularında kuvvetli yasal yapılar oluşturulmalıdır. Bu düzenlemeler, sektördeki güveni artırır ve istikrarı sağlar.

Aşağıda ise çalışmanın bulgularına dayalı olarak geliştirilen genel öneriler sunulmaktadır.

Çalışmanın Genişletilmesi: Bu çalışma, Borsa İstanbul'da Temettü 25 Endeksi'nde bulunan şirketler üzerine yoğunlaşmıştır. Ancak, gelecekteki çalışmalar, yabancı sektörler ve değişik endeksler üzerinde genişletilerek daha detaylı analizler gerçekleştirilebilir. Özellikle, uluslararası piyasalarda kullanılan modellerin karşılaştırılması, literatüre önemli katkılar sağlayabilir.

Finansal Eğitim ve Bilinçlendirme: Hem bireysel hem de kurumsal yatırımcılar için finansal eğitim programlarının yaygınlaştırılması, daha şuurlu yatırım kararları alınmasına ön ayak olur. Ek olarak, teknolojinin finansal süreçlere entegrasyonu hakkında farkındalık yükseltilmelidir.

Yenilikçi Arařtırmalar: Hibrit modeller, anlık veri akıřları ve harici faktörlerin entegrasyonu gibi yenilikçi arařtırma sahaları, finansal tahminlerin tutarlılıđını artırmada büyük bir potansiyele sahiptir. Gelecekteki çalışmalar bu alanlara odaklanarak yeni yöntemler geliřtirebilir.

Bu öneriler, finansal tahminlerin iyileřtirilmesi, yatırımcıların bilinçlenmesi ve finans sektörünün teknolojik dönüşümüne katkı sağlamak hedefiyle hazırlanmıştır. Her bir tavsiye, ilgili tarafların ihtiyaçlarını ve mevcut zorlukları göz önünde bulundurarak pratik ve sürdürülebilir çözümler sunmayı amaçlamaktadır.



KAYNAKLAR

- [1]. Ağırman E. ve Barakalı, O. C. (2022). Finans ve Finansal Hizmetlerin Geleceği: Metaverse. *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi*, 9(2), 329-346.
- [2]. AIIB: (2023). AIIB-Investor-Presentation, <https://www.aiib.org/en/treasury/common/download/AIIB-Investor-Presentation-Sep-2023.pdf>, 18, (Erişim Tarihi: 13.02.2024)
- [3]. Akbaba, A. İ. ve Gündoğdu, Ç. (2021). Bankacılık hizmetlerinde yapay zekâ kullanımı. *Journal of Academic Value Studies*, 7(3), 298-315.
- [4]. Akbank: (2021). <https://www.akbanklab.com/tr/guncel/blog/gelecegin-finansal-servislerinde-kuantum-bilgisayarlar> (Erişim Tarihi: 03.08.2023).
- [5]. Akbaş, F. (2023). Bankacılıkta Dijital Dönüşüm ve FinTech. *Uluslararası Ekonomik Araştırmalar Dergisi*, 9(2), 1-12.
- [6]. Akıllıoğlu, F. S. (2024). Banking in the Metaverse Era: Opportunities, Challenges, and Future Directions: Metaverse Çağında Bankacılık: Fırsatlar, Zorluklar Ve Gelecek Yönelimleri. *Socrates Journal of Interdisciplinary Social Studies*, 10(46), 44-60.
- [7]. Akın, F. (2020). Dijital dönüşümün bankacılık sektörü üzerindeki etkileri. *Balkan ve Near Eastern Journal of Social Sciences (BNEJSS)*, 6(2).
- [8]. Akkan, M. M. (2018). Dünya'nın Yükselen Yıldızı: Fintek Uygulamaları ve Türkiye, Konya Ticaret Odası Yayınları, s.2.
- [9]. Alhnaity, B. ve Abbod, M. (2020). A New Hybrid Financial Time Series Prediction Model. *Engineering Applications Of Artificial Intelligence*, 95, 103873.
- [10]. Alimohammadlou, M. ve Khoshsepehr, Z. (2023). The role of Society 5.0 in achieving sustainable development: a spherical fuzzy set approach. *Environmental Science and Pollution Research*, 30(16), 47630-47654.
- [11]. Alsaadi, M., Almashhadany, M. T., Obaed, A. S., Furaijl, H. B., Kamil, S., ve Ahmed, S. R. (2024, November). AI-Based Predictive Analytics for Financial Risk

Management. In *2024 8th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-7). IEEE.

[12]. Al-Salman, H. I. ve Salih, M. H. (2019, December). A review Cyber of Industry 4.0 (Cyber-Physical Systems (CPS), the Internet of Things (IoT) and the Internet of Services (IoS)): Components, and Security Challenges. In *Journal of Physics: Conference Series* (Vol. 1424, No. 1, p. 012029). IOP Publishing.

[13]. Alt, R., Beck, R. ve Smits, M.T. (2018). Fintek and the transformation of the financial industry. *Electron Markets* 28, 235–243. <https://doi.org/10.1007/s12525-018-0310-9>

[14]. Arf, C. (1959). Makine Düşünebilir Mi ve Nasıl Düşünebilir?, *Atatürk Üniversitesi – Üniversite Çalışmalarını Muhite Yayma ve Halk Eğitimi Yayınları Konferanslar Serisi No: 1, 1959, Erzurum*, 91-103.

[15]. Arı, E. S. (2021). Süper akıllı toplum: Toplum 5.0. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 23(1), 455-479.

[16]. Arner, D. W., Barberis, J. ve Buckley, R.P. (2015). The Evolution of Fintek: A New PostCrisis Paradigm? *University of Hong Kong Faculty of Law*, 1-14.

[17]. Arsoy, M. F. ve Yıldız, B. (2015). Temettü Tahmini Ve Borsa İstanbul Sanayi Sektörü Üzerine Bir Araştırma. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 16(2).

[18]. Arsoy, M. F. ve Güreşen, E. (2016). Nakit Temettü Tahmininde Makine Öğrenmesi Yaklaşımı: İmalat Sektörü Üzerine Bir Araştırma. *Çankırı Karatekin Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 6(1), 307-333.

[19]. Arslankaya, S. ve Toprak, Ş. (2021). Makine Öğrenmesi Ve Derin Öğrenme Algoritmalarını Kullanarak Hisse Senedi Fiyat Tahmini. *International Journal Of Engineering Research And Development*, 13(1), 178-192.

[20]. Aydınbaş, G. ve Erdinç, Z. (2023). Endüstri 4.0 devriminin ekonomik büyümeye etkileri üzerine panel veri analizi. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 41(3), 363-387.

[21]. Baek, Y. ve Kim, H. Y. (2018). Modaugnet: A New Forecasting Framework For Stock Market Index Value With An Overfitting Prevention Lstm Module And A Prediction Lstm Module. *Expert Systems With Applications*, 113, 457-480.

[22]. Balcıoğlu, Y. S. (2023). Dijital Dönüşüm ve Dijital Asistanların Finans Sektörüne Etkisi. *Finans Sektöründe Dijital Dönüşüm*, 1.

- [23]. Bartodziej, C. J. (2017). The Concept Industry4.0. In: The Concept Industry 4.0. *Springer Gabler, Wiesbaden*, 27-50.
- [24]. Bilinski, P. ve Bradshaw, M. T. (2022). Analyst dividend forecasts and their usefulness to investors. *The Accounting Review*, 97(4), 75-104.
- [25]. Borsa İstanbul: (2023), Temettü Endeksleri. <https://www.borsaistanbul.com/tr/sayfa/72/temettu-endeksleri> (Erişim Tarihi: 26.07.2023).
- [26]. Bulazar, A. R. ve Küçükçolak, Ö. Ü. R. A. (2021). Finans sektöründe Fintek etkisi. *Working Paper Series*, 2(1), 53-63.
- [27]. Bulut, F. (2019). Bankacılık Sektöründe Makine Öğrenmesi Yöntemleriyle Müşteri İlişkileri Yönetiminin Zenginleştirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 382-394.
- [28]. Bussmann, N., Giudici, P., Marinelli, D., ve Papenbrock, J. (2020). Explainable AI in fintech risk management. *Frontiers in Artificial Intelligence*, 3, 26. <https://doi.org/10.3389/frai.2020.00026>
- [29]. Bülbül, H. A. L. İ. L. ve Ersöz, B. (2022). Eğitimde Yapay Zekâ Sanal Gerçeklik Ve Sanal Evren (Metaverse).
- [30]. Carayannis, E. G. ve Morawska-Jancelewicz, J. (2022). The futures of Europe: Society 5.0 and Industry 5.0 as driving forces of future universities. *Journal of the Knowledge Economy*, 13(4), 3445-3471.
- [31]. Carlin, B., Olafsson, A., ve Pagel, M. (2017). Fintech adoption across generations: Financial fitness in the information age (No. w23798). *National Bureau of Economic Research*.
- [32]. Chen, L. P. (2020). Using machine learning algorithms on prediction of stock price. *Journal of Modeling and Optimization*, 12(2), 84-99.
- [33]. Chen, S. ve He, H. (2018, November). Stock prediction using convolutional neural network. In *IOP Conference series: materials science and engineering* (Vol. 435, p. 012026). IOP Publishing.
- [34]. Chhikara, H., Chhikara, S. ve Gupta, L. (2025). Predictive Analytics in Finance: Leveraging AI and Machine Learning for Investment Strategies. In *Utilizing AI and Machine Learning in Financial Analysis* (pp. 325-336). IGI Global Scientific Publishing.

- [35]. Chowdhury, R. H., Al Masum, A., Farazi, M. Z. R. ve Jahan, I. (2024). The impact of predictive analytics on financial risk management in businesses. *World Journal of Advanced Research and Reviews (WJARR)*, 23(3), 1378-1386.
- [36]. Çelik, Ş., Yenice, S. ve Onat, O. K. (2016). Temettü Ödemelerinin Belirleyicileri Ve Firma Değeri: Kavramsal Bir Model Ve Tahminlemesi. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 31(2), 115-146.
- [37]. Colombo, A. W., Karnouskos, S. ve Bangemann, T. (2014). Towards the next generation of industrial cyber-physical systems. In *Industrial cloud-based cyber-physical systems: The IMC-AESOP Approach* (pp. 1-22). Cham: Springer International Publishing.
- [38]. Çetinkaya, F. F. (2021). Endüstri 4.0 farkındalığının inovasyon üzerindeki etkisi. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 21(2), 571-598.
- [39]. Danacı, M. C. ve Çetintaş, Ö. (2020). Bankalarda Finansal Teknoloji Ve Yenilikler. *Turkish Business Journal*, 1(2), 179-187.
- [40]. Das, S., Schaberl, P. D., ve Sen, P. K. (2024). Analysts' use of dividends in earnings forecasts. *Review of Accounting Studies*, 29(2), 1192-1234. <https://doi.org/10.1007/s11142-022-09735-8>
- [41]. Demirel, D. Ö. Ü. S. (2024). Bankacılıkta Yapay Zekâ Uygulamalarının Geleneksel Bankacılık Üzerine Etkisi. *ESAM Ekonomik ve Sosyal Araştırmalar Dergisi*, 5(2), 164-201.
- [42]. Deutsche Börse: (2021), <https://deutsche-boerse.com/dbg-en/products-services/insights-innovation-new-technologies-en/Quantum-computing-opening-up-new-business-horizons--2570224> (Erişim Tarihi: 03.08.2023)
- [43]. Diners Club: (2021), The Diners Club Legacy. Diners Club International. Erişim Linki: <https://www.dinersclub.com/about-us/history> (17.07.2023)
- [44]. Doğan, S. ve Büyükkör, Y. (2022). Makine öğrenmesi ile finansal zaman serisi tahminleme. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 24(3), 1205-1230.
- [45]. Doğan, M. B. A. (2020). İslami finans okuryazarlığı ve finansal tercihlere etkisi. *BDDK Bankacılık ve Finansal Piyasalar Dergisi*, 14(1), 69-98.
- [46]. Dönmez, N. (2022). Metaverse Bankacılığı Yolunda Değişen Müşteri Beklentilerine Hitaben Gelişen Pazarlama Anlayışları Üzerine Bir

İnceleme. *Uluslararası Bankacılık Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(1), 97-132.

[47]. Efe, A. (2021). Yapay zekâ ve endüstri 4.0 ilişkisinin siber güvenlik perspektifinden analizi. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 8(1), 123-143.

[48]. Er, H. ve Yücel, R. (2023). Finans Sektöründe Metaverse Teknolojisinin Bugünü ve Geleceği. *Finans Sektöründe Dijital Dönüşüm*, 97.

[49]. Erden, C. (2023). Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Kıyaslanması: Bir Borsa İstanbul Hissesi Örneği. *Yönetim ve Ekonomi Dergisi*, 30(3), 419-438.

[50]. Erdoğan, S. ve Bodur, D. (2020). Blockchain teknolojisi ve günümüz finansal sistemine olası etkileri. *Mali çözüm dergisi*, 30, 281-295.

[51]. Fettahoğlu, S. ve Kıldız, D. (2019). Dijital finansal okuryazarlık ve bireylerin finansal teknoloji kullanma konusundaki tutumları. *OPUS International Journal of Society Researches*, 12, 867-889.

[52]. Filgueiras, I. F. L. V., de Melo, F. J. C., Sobral, E. F. M., Barbosa, A. A. L., de Medeiros, D. D., de Almeida Pinto, P. A. L., ve Amorim, B. P. (2024). Analyzing the Benefits of Industry 4.0 Technologies That Impact Sustainability 4.0 in Banking Services. *Sustainability*, 16(14), 6179.

[53]. Gai, K., Qiu, M. ve Sun, X. (2018). A survey on Fintek. *Journal of Network and Computer Applications*, 103, 262-273. <https://doi.org/10.106/j.jnca.2017.10.011>

[54]. Garanti BBVA: (2021), https://temizenerji.org/2021/01/21/garanti-bankasi-temiz-enerji-karma-fonunu-hayata-gecirdi/?gad_source=1&vegclid=Cj0KCQIAw6yuBhDrARIsACf94RXlQvvfEKUzhYi62EhkfNrHshiMc_JDt2XC_g3eOn-k_rFN2NZpDAEaAnG4EALw_wcB (Erişim Tarihi: 13.02.2024)

[55]. Genç, S. (2022). Bilişim Teknolojilerinde Blok Zincir ve Kuantum Hesaplamanın Ortak Geleceği: Kuantum Blok Zinciri. *Veri Bilimi*, 5(2), 53-63.

[56]. Giudici, P. (2018). Fintech Risk Management: A Research Challenge for Artificial Intelligence in Finance. *Front. Artif. Intell.* 1:1. <https://doi.org/10.3389/frai.2018.00001>

- [57]. Gomber, P., Koch, J. ve Siering, M. (2017). Digital Finance and Fintek: Current research and future research directions. *J Bus Econ* 87, 537–580. <https://doi.org/10.1007/s11573-017-0852-x>
- [58]. Gurrea-Martinez, A. ve Remolina, N. (2020). Global challenges and regulatory strategies to fintech, 1-39.
- [59]. Gülbaşı, A. ve Karahan, F. (2023). Finansal sistemde bilgi teknolojileri ve kullanımı. *Uluslararası Sosyal ve Ekonomik Çalışmalar Dergisi*, 4(2), 296-319.
- [60]. Güler, H. N. (2022). Metaverse (Sanal Evren) Kavramı için Twitter’da Yer Alan İçeriklerin Analizi. *Yeni Yüzyıl’da İletişim Çalışmaları*, 1(5), 97-107.
- [61]. Güler, H. N. (2022). Türk Finans Sektöründe Dijitalleşme ve Yenilikler. *Avrasya Dosyası*, 13(2), 181-200.
- [62]. Güler, K. (2019). Uluslararası ticaretin dijitalleşmesi ve sanayi akımlarının etkisi: Endüstri 4.0 devrimi üzerine bir araştırma.
- [63]. Gümüş, Ö., Ağırkaya, M. B., Ekici, F. ve Karadeniz, M. (2023). Law and Economics in Fintech with Swot Analysis: A Theoretical Approach. *Turkish Studies-Economics, Finance, Politics*, 18(3).
- [64]. Güzer, E. (2019). Finansal Teknoloji, <https://www.youtube.com/watch?v=KdQDyU5g2h8>, (Erişim Tarihi: 03 Mayıs 2022).
- [65]. Hasan, R., Ashfaq, M. ve Shao, L. (2024). Evaluating Drivers of Fintech Adoption in the Netherlands. *Global Business Review*, 25(6), 1576-1589. <https://doi.org/10.1177/09721509211027402>
- [66]. IBM Institute of Business Value, Yndurain, E., Woerner, S. ve Egger, D. J. (2019). Exploring quantum computing use cases for financial services. *Copyright IBM Corporation*. (Erişim Tarihi: 03.08.2023)
- [67]. Idayani, R. W., Nadlifatin, R., Subriadi, A. P. ve Gumasing, M. J. J. (2024). A comprehensive review on how cyber risk will affect the use of Fintech. *Procedia Computer Science*, 234, 1356-1363.
- [68]. İletişim Başkanlığı: (2023), <https://www.iletisim.gov.tr/turkce/haberler/detay/turkiye-ile-birlesik-arap-emirlikleri-arasinda-507-milyar-dolarlik-anlasma> (Erişim Tarihi: 26.07.2023).
- [69]. İlhan, E. G. E., Ulaş, Ü. N. L. Ü. ve Bayrakdaroğlu, A. (2009). Hisse Senedi Endeks Getirileri Ve Temettü Verimi: İMKB 100 Ve S&P 500 Endeksleri Üzerine Bir

Uygulama. *Ankara Hacı Bayram Veli Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 11(1).

[70]. Jakšič, M. ve Marinč, M. (2019). Relationship banking and information technology: the role of artificial intelligence and FinTech. *Risk Manag* 21, 1–18 <https://doi.org/10.1057/s41283-018-0039-y>

[71]. Kahraman, M. E. (2022). Blok zincir, deepfake, avatar, kripto para, NFT ve metaverse ile yaygınlaşan sanal yaşam. *Uluslararası Kültürel ve Sosyal Araştırmalar Dergisi*, 8(1), 149-162.

[72]. Karagöz, İ. (2023). Dijital finansta yeni trendler. *Dijitalleşmenin finans sektörüne getirdiği yenilikler*, 39-56.

[73]. Karaki, B. A., Al_kasasbeh, O. ve Alsheikh, G. (2023). FinTech and FinTech ecosystem: A case of Jordan-based SWOT analysis. *Review of Economics and Finance*, 21(1), 2061-2067.

[74]. Karaömer, Y. (2021). The analysis of Fintek sector in Turkey. *Journal of Politics Economy and Management*, 4(2), 128-139.

[75]. Katz, R. L. (2017). Social and Economic Impact of Digital Transformation. International Telecommunications Union.

[76]. Kaya, H. (2024). Gartner sihirli çeyrekler yöntemi ile BİST Temettü 25 Endeksleri karşılaştırılması. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(3), 373-389.

[77]. Kaya, H. G. ve Sağbaş, A. (2024). Müşteri İlişkileri Yönetiminde Büyük Veri ve Robotik Süreç Otomasyonu ile Süreç İyileştirme. *European Journal of Engineering and Applied Sciences*, 7(1), 44-53.

[78]. Kaya, F. (2009). Türkiye'de kredi kartı uygulaması (No. 263). *İstanbul: Türkiye Bankalar Birliği*.

[79]. Kaymaz, Ö., Kaymaz, O. ve Güvemli, B. (2021). Testing Dividend Signaling Theory in Turkey As An Emerging Market: Empirical Evidence From Public Firms Listed in Borsa Istanbul. *Muhasebe Ve Finansman Dergisi*, 59-92.

[80]. Kent, E. (2018). Endüstri 4.0'dan Toplum 5.0'a, <https://www.endustri40.com/endustri-4-0dan-toplum-5-0a/> (23.03.2020)

[81]. Keskin, M. (2025). Finansal Teknoloji: Neo Bankacılık ve Gömülü Finans. *Bankacılık ve Finansal Araştırmalar Dergisi*, 12(1), 1-13.

- [82]. Kevser, M. ve Doğan, M. (2021). Bankacılık Sektöründe Veri Madenciliğine Yönelik Kuramsal Bir Değerlendirme. *Socrates Journal of Interdisciplinary Social Studies*, 10, 28-39.
- [83]. Khanboubi, F., Boulmakoul, A. ve Tabaa, M. (2019). Impact of digital trends using IoT on banking processes. *Procedia Computer Science*, 151, 77-84.
- [84]. Kırbaş, İ. (2018). Blokzinciri teknolojisi ve yakın gelecekteki uygulama alanları. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(1), 75-82.
- [85]. Kıvrak, O. ve Hatipoğlu, S. (2023). Teknolojik gelişmelerin bankacılık hizmetlerine katkısı: Türkiye'nin son yüzyılı örneği. *Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 26(49-1), 239-248.
- [86]. Kim, H. Y. ve Won, C. H. (2018). Forecasting The Volatility of Stock Price Index: A Hybrid Model Integrating Lstm With Multiple Garch-Type Models. *Expert Systems With Applications*, 103, 25-37.
- [87]. Konak, F., Bülbül, M.A. ve Türkoğlu, D. (2024). Feature Selection and Hyperparameters Optimization Employing a Hybrid Model Based on Genetic Algorithm and Artificial Neural Network: Forecasting Dividend Payout Ratio. *Comput Econ* 63, 1673–1693. <https://doi.org/10.1007/s10614-023-10530-z>
- [88]. Kömürcüoğlu, Ö. F., ve Akyazı, H. (2020). Finansal Teknolojilerdeki (Fintek) Gelişmeler: Fırsatlar ve Riskler. *Karadeniz Ekonomi Araştırmaları Dergisi*, 1(1), 35-48.
- [89]. Körpe, E. (2021). Dijital Dönüşüm İle Yeni Finans Çağı ve Gelecek Yaklaşımları. *Uluslararası Bankacılık Ekonomi ve Yönetim Araştırmaları Dergisi*, 4(2), 108-131.
- [90]. KPMG: (2021), Dijitalleşme Yolunda Türkiye Raporu.
- [91]. Küçük, G. Ş. ve Kaynar, Z. (2023). Finansal Teknoloji Literatürü Üzerine Bibliyometrik Bir Analiz. *Necmettin Erbakan Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*, 5(2), 119-131.
- [92]. Küçükvardar, M. ve Aslan, A. (2021). Dijitalleşmenin ekonomik, teknolojik, toplumsal ve etik etkilerinin uluslararası raporlar üzerinden analizi. *Intermedia International e-Journal*, 8(14), 21-38.
- [93]. Lee, I. ve Shin, Y. J. (2018). Fintek: Ecosystem, business models, investment decisions, and challenges. *Business Horizons*, 61(1), 35-46.

- [94]. Lee, S. I. ve Yoo, S. J. (2020). Multimodal deep learning for finance: integrating and forecasting international stock markets. *The Journal of Supercomputing*, 76, 8294-8312. <https://doi.org/10.1007/s11227-019-03101-3>
- [95]. Liu, Y. (2024). Discussion on the Enterprise Financial Risk Management Framework Based on AI Fintech . *Decision Making: Applications in Management and Engineering*, 7(1), 254–269. <https://doi.org/10.31181/dmame712024942>
- [96]. Lubis , E., Khaddafi, M. ve Satriawan, B. (2024). Dividend Policy as a Tool to Increase Firm Value. *Business and Investment Review*, 2(3), 20–27. <https://doi.org/10.61292/birev.109>
- [97]. Machkour, B. ve Abriane, A. (2020). Industry 4.0 and its Implications for the Financial Sector. *Procedia Computer Science*, 177, 496-502.
- [98]. Mahawar, P., Bajaj, S. ve Kashyap, S. V. (2024). Banking in the Age of Industry 5.0: Charting a Path to Technological Transformation. In *Industry 5.0 and Emerging Technologies: Transformation Through Technology and Innovations* (pp. 393-408). Cham: Springer Nature Switzerland.
- [99]. Mandal, S. ve Shill, P. C. (2024, April). Ensuring Security and Efficiency in Digital Payments using Blockchain with NFC. In *2024 International Conference on Knowledge Engineering and Communication Systems (ICKECS)* (Vol. 1, pp. 1-7). IEEE.
- [100]. Mehdiabadi, A., Shahabi, V., Shamsinejad, S., Amiri, M., Spulbar, C. ve Birau, R. (2022). Investigating Industry 5.0 and its impact on the banking industry: Requirements, approaches and communications. *Applied Sciences*, 12(10), 5126.
- [101]. Mehrban, S., Nadeem, M. W., Hussain, M., Ahmed, M. M., Hakeem, O., Saqib, S., ve Khan, M. A.: (2020), Towards secure FinTech: A survey, taxonomy, and open research challenges. *IEEE Access*, 8, 23391-23406.
- [102]. Menteş, A. (2019). Finansal tabana yayılma aracı olarak finansal teknoloji şirketleri. *Sosyal Bilimler Araştırma Dergisi*, 8(1), 168-175.
- [103]. Menteş, A. (2019). Bankacılık sektörüne bir tehdit unsuru olarak finansal teknoloji şirketleri. *Balkan ve Yakın Doğu Sosyal Bilimler Dergisi*, 5(01), 49-53.
- [104]. Mizuho Bank: (2023), https://www.mizuhogroup.com/news/2023/02/20230210release_eng.html, (Erişim Tarihi: 13.02.2024)

- [105]. Mohaghar, A., Sadeghi Moghadam, M. R., Ghourchi Beigi, R. ve Ghasemi, R. (2021). IoT-based services in banking industry using a business continuity management approach. *Journal of Information Technology Management*, 13(4), 16-38.
- [106]. Morrar, R., Arman, H. ve Mousa, S. (2017). The fourth industrial revolution (Industry 4.0): A social innovation perspective. *Technology innovation management review*, 7(11), 12-20.
- [107]. Narez-Sánchez, I. A. ve Berttolini-Díaz, G. M. (2022). Fintech, the digital age of financial services. *Journal Applied Computing*, 6(18), 32-43.
- [108]. Polat, L. ve Erkollar, A. (2020, September). Industry 4.0 vs. Society 5.0. In *The International Symposium for Production Research* (pp. 333-345). Cham: Springer International Publishing.
- [109]. Ochoa, S. F., Fortino, G. ve Di Fatta, G. (2017). Cyber-physical systems, internet of things and big data. *Future Generation Computer Systems*, 75, 82-84.
- [110]. OECD: (2018), Financial markets, insurance and private pensions: Digitalisation and finance.
- [111]. Oesterreich, T. D. ve Teuteberg, F. (2016). Understanding the implications of digitisation and automation in the context of Industry 4.0: A triangulation approach and elements of a research agenda for the construction industry, *Computers in Industry*, Cilt: 83, 121-139.
- [112]. Okuyan, H. A., Sakarya, Ş., Aydın, C. ve Deniz, D. (2020). İmalat Sanayi Ve Finansal Sektörde Temettü Dağıtımlarının Kısa Dönemli Fiyat Etkisi: BİST Uygulaması. *Muhasebe Ve Finansman Dergisi*, (85), 25-44.
- [113]. Olaiya, O. P., Adesoga, T. O., Adebayo, A. A., Sotomi, F. M., Adigun, O. A., ve Ezeliya, P. M. (2024). Encryption techniques for financial data security in fintech applications. *International Journal of Science and Research Archive*, 12(1), 2942-9.
- [114]. Ooi, K. B., Tan, G. W. H., Aw, E. C. X., Cham, T. H., Dwivedi, Y. K., Dwivedi, R., ... ve Sharma, A. (2023). Banking in the metaverse: a new frontier for financial institutions. *International Journal of Bank Marketing*, 41(7), 1829-1846.
- [115]. OVP: (2023), ORTA VADELİ PROGRAM 2024-2026, <https://www.resmigazete.gov.tr/eskiler/2023/09/20230906M1-1.pdf>, Erişim Tarihi: 12.09.2023

- [116]. Özenen C. (2023). Blok zinciri harcamaları 19 milyar dolara ulaşacak, <https://www.haberturk.com/blok-zinciri-harcamalari-19-milyar-dolara-ulasacak-3605311-teknoloji>, Erişim Tarihi: 25.07.2023
- [117]. Öznur, S. ve Gezer, Ü. (2025). Dijital Toplumun Yetkin Aktörü Yapay Zeka. *International Journal of Social and Humanities Sciences Research (JSHSR)*, 12(115), 38-45.
- [118]. Palmié, M., Wincent, J., Parida, V. ve Caglar, U. (2019). The evolution of the financial technology ecosystem: An introduction and agenda for future research on disruptive innovations in ecosystems. *Technological Forecasting and Social Change*, 151, 119779.
- [119]. Pollari, I. (2016). The rise of Fintek opportunities and challenges. *JASSA Financial Services Institute of Australasia*, 3, 15-21.
- [120]. Puschmann, T. (2017). Digitization of the Financial Services Industry. *Business ve Information Systems Engineering*, 59(1), 69-76.
- [121]. PwC Türkiye : (2022), <https://www.pwc.com.tr/tr/yayinlar/gelecek-trendleri-arastirmasi/pwc-gelecek-trendleri-arastirmasi-2022.pdf> (Erişim Tarihi: 27.07.2023)
- [122]. Ramos, C., Augusto, J. C. ve Shapiro, D. (2008). Ambient intelligence—the next step for artificial intelligence. *IEEE Intelligent Systems*, 23(2), 15-18.
- [123]. Rimer, S. (2017, May). An IoT architecture for financial services in developing countries. In *2017 IST-Africa Week Conference (IST-Africa)* (pp. 1-10). IEEE.
- [124]. Roblek, V., Meško, M. ve Krapež, A. (2016). A Complex View of Industry 4.0, *SAGE Open*, Cilt: 6, Sayı: 2, 1-11.
- [125]. Rolando, B. ve Mulyono, H. (2024). Managing Risks In Fintech: Applications And Challenges Of Artificial Intelligence-Based Risk Management . *Economics and Business Journal (ECBIS)*, 2(3), 249–268. <https://doi.org/10.47353/ecbis.v2i3.127>
- [126]. Sarıgül, H. (2020). Türkiye de Finansal Okuryazarlık Alanında Yazılan Lisansüstü Tezlerin İçerik Analizi. *Yükseköğretim ve Bilim Dergisi*, (1), 153-165.
- [127]. Serfling, M. A. ve Miljkovic, D. (2011). Time series analysis of the relationships among (macro) economic variables, the dividend yield and the price level of the SveP 500 Index. *Applied Financial Economics*, 21(15), 1117–1134. <https://doi.org/10.1080/09603107.2011.562167>
- [128]. Singh, S., Sahni, M.M. ve Kovid, R.K. (2020). "What drives FinTech adoption? A multi-method evaluation using an adapted technology acceptance

- model", *Management Decision*, Vol. 58 No. 8, pp. 1675-1697. <https://doi.org/10.1108/MD-09-2019-1318>
- [129]. Sirenko, N., Atamanyuk, I., Volosyuk, Y., Poltorak, A., Melnyk, O. ve Fenenko, P. (2020, May). Paradigm changes that strengthen the financial security of the state through FINTECH development. In *2020 IEEE 11th International Conference on Dependable Systems, Services and Technologies (DESSERT)* (pp. 110-116). IEEE.
- [130]. Şahin, C. (2024). Geleneksel Finansal Kurumlara Rakip Bir Yenilikçi Finansal Uygulama: Fintek. *Premium e-Journal of Social Sciences (PEJOSS)*, 8(38), 01-06.
- [131]. Tanrıverdi, A. (2021). Yapay zekânın kamu hizmetinin sunumuna etkileri. *Adalet Dergisi*, (66), 293-314.
- [132]. Teifurova, S. (2021). On the use of quantum cryptography in financial it systems.
- [133]. Teoman, Ö. (1996). Hukuki yönden kredi kartı uygulaması. *Beta*.
- [134]. Terzi, O. ve İşli, A. G. (2020). Dijitalleşen dünyada dijital okuryazarlık: Banka müşterileri üzerine bir araştırma. *Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (7), 50-67.
- [135]. Theflaticon : (2022), Flaticon, the largest database of free vector icons. *Flaticon*. <https://www.flaticon.com> (Erişim Tarihi: 29.07.2023)
- [136]. TOBB (2021). Dijital Dönüşüm, Ekonomik Forum Dergisi, Sayı 318, 18-25.
- [137]. TOGG : (2023), https://www.togg.com.tr/trumore?gclid=Cj0KCQjwiIOmBhDjARIsAP6YhSV4bWd9MJEEZi9SudCrqxq81KywcqrPJ7fG_yqEoP_X17_kbrB-8xAaAipCEALw_wcB (Erişim Tarihi: 27.07.2023)
- [138]. Turing, A. M. (2009). Computing machinery and intelligence, *Springer Netherlands*, 23-65.
- [139]. Turing, A. (2004). On Computable Numbers, with an Application to the Entscheidungs problem, 1936. *The essential Turing: seminal writings in computing, logic, philosophy, artificial intelligence, and artificial life, plus the secrets of Enigma*, 58.
- [140]. Türkiye Cumhuriyeti Cumhurbaşkanlığı Finans Ofisi, <https://www.cbfo.gov.tr/fintek>, Erişim: 03 Mayıs 2022.


- [141]. Tyagi, A. (2024). Risk Management in Fintech", Baker, H.K., Filbeck, G. and Black, K. (Ed.) *The Emerald Handbook of Fintech*, Emerald Publishing Limited, Leeds, pp. 157-175. <https://doi.org/10.1108/978-1-83753-608-520241015>
- [142]. Uçucu, R. (2023). Bankacılık Sektörünün Sürdürülebilirliğinde Büyük Veri Kullanımının İnovasyon Süreçlerine ve Rekabet Gücüne Etkisi. *International Journal of Sustainability*, 1(1), 78-92.
- [143]. Ustaömer, K. (2019). Türkiye'nin bankacılık sektöründe dijitalleşme olgusu. *Ekonomi İşletme ve Yönetim Dergisi*, 3(1), 1-24.
- [144]. Utami, A. F., Ekaputra, I. A. ve Japutra, A. (2021). Adoption of FinTech Products: A Systematic Literature Review. *Journal of Creative Communications*, 16(3), 233-248. <https://doi.org/10.1177/09732586211032092>
- [145]. Vijh, M., Chandola, D., Tikkiwal, V. A. ve Kumar, A. (2020). Stock Closing Price Prediction Using Machine Learning Techniques. *Procedia Computer Science*, 167, 599-606.
- [146]. Vittala, K. P., Nagarathnamma, J., Chidambaram, N. ve Tyagi, A. K. (2025). Smart Financial Services Through Smart Banking in the Era of Industry 5.0: Opportunities and Challenges. *Creating AI Synergy Through Business Technology Transformation*, 203-226.
- [147]. Vučinić, M. ve Luburić, R. (2022). Fintech, risk-based thinking and cyber risk. *Journal of Central Banking Theory and Practice*, 11(2), 27-53.
- [148]. Wirawan, P. (2023). Leveraging Predictive Analytics in Financing Decision-Making for Comparative Analysis and Optimization. *Advances in Management ve Financial Reporting*, 1(3), 157–169. <https://doi.org/10.60079/amfr.v1i3.209>
- [149]. Yağcı, M. (2018). Yükselen Finansal Teknolojilerin Ekonomi Politikası: Fintek ve Bitcoin Örnekleri. *İktisat ve Toplum*, 17-24.
- [150]. Yavuz, M. (2019). Ekonomide dijital dönüşüm: Blockchain teknolojisi ve uygulama alanları üzerine bir inceleme. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 4(1), 15-29.
- [151]. Yetiz, F., Turan, Y. ve Canpolat, İ. (2021). Bankacılık sektöründe robotik süreç otomasyonu ve verimlilik ilişkisi: bir banka örneği. *Verimlilik Dergisi*, (2), 65-80.
- [152]. Yıldız, A. (2022). Finans Alanında Yapay Zekâ Teknolojisinin Kullanımı: Sistemik Literatür İncelemesi. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (52), 47-66.

- [153]. Yıldız, B., Gökbulut, R. İ. ve Korkmaz, T. (2014). Firmalarda Temettü Politikalarını Etkileyen Unsurlar: BİST Sanayi İşletmeleri Üzerine Bir Panel Veri Uygulaması. *Ekonomik Ve Sosyal Araştırmalar Dergisi*, 10(1), 185-206.
- [154]. Yılmaz, T. ve Gül, M. (2023). Bist Temettü 25 Endeksinde Yer Alan Firmaların Finansal Performanslarının Sd Ve Waspas Yöntemiyle Analiz Edilmesi. *Dicle Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (32 (Dicle Üniversitesi'nin 50. Yılına Özel 50 Makale)), 198-221.
- [155]. Zhang, J., Li, L. ve Chen, W. (2021). Predicting stock price using two-stage machine learning techniques. *Computational Economics*, 57, 1237-1261. <https://doi.org/10.1007/s10614-020-10013-5>
- [156]. Web-1: “Updated: Coca-Cola to offer first-ever NFT collectibles in International Friendship Day charity auction,” Coca-Cola, July 28, 2021.
- [157]. Web-2: Maghan McDowell, “Inside Roblox’s metaverse opportunity,” Vogue Business, May 17, 2021.
- [158]. Web-3: “ANAM: Your multiverse platform,” AnamXR, May 31, 2022.
- [159]. Web-4: Kati Chitrakorn, Maghan McDowell, “Adidas reveals new NFT project with Bored Ape Yacht Club,” Vogue Business, December 17, 2021.
- [160]. Web-5: Garanti BBVA: (2022), Sanal Asistanlar. Bankacılık İşlemlerini Sanal Asistanlarla Nasıl Yönetirsiniz? <https://www.garantibbva.com.tr/tr/blog/islemlerini-sanal-asistanlarlayonetmek.page>, (Erişim Tarihi: 14.02.2024).
- [161]. Web-6: S. Elif Kocaoglu Ulbrich Holistic Banking: The Rise of Embedded Finance, <https://lhoft.com/insights/holistic-banking>, (Erişim Tarihi: 14.02.2024).


EKLER

EK A RMSE ANALİZİ SONUÇ GRAFİKLERİ


Şekil 47: AEFES Genel Görünüm




Şekil 48: AEFES Eğitim ve Test Veri Kümesi




Şekil 49: AEFES Naif Model Öngörülleri




Şekil 50: AEFES Basit Ortalama Öngörülleri




Şekil 51: AEFES Basit Hareketli Ortalama Öngörülleri




Şekil 52: AEFES Sarima Öngörülleri




Şekil 53: AKBNK Genel Görünüm




Şekil 54: AKBNK Eğitim ve Test Veri Kümesi




Şekil 55: AKBNK Naif Model Öngörülleri




Şekil 56: AKBNK Basit Ortalama Öngörülleri




Şekil 57: AKBNK Basit Hareketli Ortalama Öngörülleri




Şekil 58: AKBNK Sarima Öngörülleri




Şekil 59: AKSA Genel Görünüm




Şekil 60: AKSA Eğitim ve Test Veri Kümesi




Şekil 61: AKSA Naif Model Öngörülleri




Şekil 62: AKSA Basit Ortalama Öngörülleri




Şekil 63: AKSA Basit Hareketli Ortalama Öngörülleri




Şekil 64: AKSA Sarima Öngörülleri




Şekil 65: AKSEN Genel Görünüm




Şekil 66: AKSEN Eğitim ve Test Veri Kümesi




Şekil 67: AKSEN Naif Model Öngörülleri




Şekil 68: AKSEN Basit Ortalama Öngörülleri




Şekil 69: AKSEN Basit Hareketli Ortalama Öngörülleri




Şekil 70: AKSEN Sarıma Öngörülleri




Şekil 71: BIMAS Genel Görünüm




Şekil 72: BIMAS Eğitim ve Test Veri Kümesi




Şekil 73: BIMAS Naif Model Öngörülleri




Şekil 74: BIMAS Basit Ortalama Öngörülleri




Şekil 75: BIMAS Basit Hareketli Ortalama Öngörülleri




Şekil 76: BIMAS Sarima Öngörülleri




Şekil 77: BRYAT Genel Görünüm




Şekil 78: BRYAT Eğitim ve Test Veri Kümesi




Şekil 79: BRYAT Naif Model Öngörülleri




Şekil 80: BRYAT Basit Ortalama Öngörülleri




Şekil 81: BRYAT Basit Hareketli Ortalama Öngörülleri




Şekil 82: BRYAT Sarıma Öngörülleri




Şekil 83: CIMSA Genel Görünüm




Şekil 84: CIMSA Eğitim ve Test Veri Kümesi




Şekil 85: CIMSA Naif Model Öngörülleri




Şekil 86: CIMSA Basit Ortalama Öngörülleri




Şekil 87: CIMSA Basit Hareketli Ortalama Öngörülleri




Şekil 88: CIMSA Sarima Öngörülleri




Şekil 89: DOAS Genel Görünüm




Şekil 90: DOAS Eğitim ve Test Veri Kümesi




Şekil 91: DOAS Naif Model Öngörülleri




Şekil 92: DOAS Basit Ortalama Öngörülleri




Şekil 93: DOAS Basit Hareketli Ortalama Öngörülleri




Şekil 94: DOAS Sarima Öngörülleri




Şekil 95: ECILC Genel Görünüm




Şekil 96: ECILC Eğitim ve Test Veri Kümesi




Şekil 97: ECILC Naif Model Öngörülleri




Şekil 98: ECILC Basit Ortalama Öngörülleri




Şekil 99: ECILC Basit Hareketli Ortalama Öngörülleri




Şekil 100: ECILC Sarima Öngörülleri




Şekil 101: ENJSA Genel Görünüm




Şekil 102: ENJSA Eğitim ve Test Veri Kümesi




Şekil 103: ENJSA Naif Model Öngörülleri




Şekil 104: ENJSA Basit Ortalama Öngörülleri




Şekil 105: ENJSA Basit Hareketli Ortalama Öngörülleri




Şekil 106: ENJSA Sarima Öngörülleri




Şekil 107: ENKAI Genel Görünüm




Şekil 108: ENKAI Eğitim ve Test Veri Kümesi




Şekil 109: ENKAI Naif Model Öngörülleri




Şekil 110: ENKAI Basit Ortalama Öngörülleri




Şekil 111: ENKAI Basit Hareketli Ortalama Öngörülleri




Şekil 112: ENKAI Sarima Öngörülleri




Şekil 113: FROTO Genel Görünüm




Şekil 114: FROTO Eğitim ve Test Veri Kümesi




Şekil 115: FROTO Naif Model Öngörülleri




Şekil 116: FROTO Basit Ortalama Öngörülleri




Şekil 117: FROTO Basit Hareketli Ortalama Öngörülleri




Şekil 118: FROTO Sarıma Öngörülleri




Şekil 119: GARAN Genel Görünüm




Şekil 120: GARAN Eğitim ve Test Veri Kümesi




Şekil 121: GARAN Naif Model Öngörülleri




Şekil 122: GARAN Basit Ortalama Öngörülleri




Şekil 123: GARAN Basit Hareketli Ortalama Öngörülleri




Şekil 124: GARAN Sarıma Öngörülleri




Şekil 125: ISCTR Genel Görünüm




Şekil 126: ISCTR Eğitim ve Test Veri Kümesi




Şekil 127: ISCTR Naif Model Öngörülleri




Şekil 128: ISCTR Basit Ortalama Öngörülleri




Şekil 129: ISCTR Basit Hareketli Ortalama Öngörülleri




Şekil 130: ISCTR Sarima Öngörülleri




Şekil 131: ISMEN Genel Görünüm




Şekil 132: ISMEN Eğitim ve Test Veri Kümesi




Şekil 133: ISMEN Naif Model Öngörülleri




Şekil 134: ISMEN Basit Ortalama Öngörülleri




Şekil 135: ISMEN Basit Hareketli Ortalama Öngörülleri




Şekil 136: ISMEN Sarima Öngörülleri




Şekil 137: KCHOL Genel Görünüm




Şekil 138: KCHOL Eğitim ve Test Veri Kümesi




Şekil 139: KCHOL Naif Model Öngörülleri




Şekil 140: KCHOL Basit Ortalama Öngörülleri




Şekil 141: KCHOL Basit Hareketli Ortalama Öngörülleri




Şekil 142: KCHOL Sarima Öngörülleri




Şekil 143: MAVI Genel Görünüm




Şekil 144: MAVI Eğitim ve Test Veri Kümesi




Şekil 145: MAVI Naif Model Öngörülleri




Şekil 146: MAVI Basit Ortalama Öngörülleri




Şekil 147: MAVI Basit Hareketli Ortalama Öngörülleri




Şekil 148: MAVI Sarima Öngörülleri




Şekil 149: SAHOL Genel Görünüm




Şekil 150: SAHOL Eğitim ve Test Veri Kümesi




Şekil 151: SAHOL Naif Model Öngörülleri




Şekil 152: SAHOL Basit Ortalama Öngörülleri




Şekil 153: SAHOL Basit Hareketli Ortalama Öngörülleri




Şekil 154: SAHOL Sarıma Öngörülleri




Şekil 155: SISE Genel Görünüm




Şekil 156: SISE Eğitim ve Test Veri Kümesi




Şekil 157: SISE Naif Model Öngörülleri




Şekil 158: SISE Basit Ortalama Öngörülleri




Şekil 159: SISE Basit Hareketli Ortalama Öngörülleri




Şekil 160: SISE Sarima Öngörülleri




Şekil 161: TCELL Genel Görünüm




Şekil 162: TCELL Eğitim ve Test Veri Kümesi




Şekil 163: TCELL Naif Model Öngörülleri




Şekil 164: TCELL Basit Ortalama Öngörülleri




Şekil 165: TCELL Basit Hareketli Ortalama Öngörülleri




Şekil 166: TCELL Sarıma Öngörülleri




Şekil 167: TOASO Genel Görünüm




Şekil 168: TOASO Eğitim ve Test Veri Kümesi




Şekil 169: TOASO Naif Model Öngörülleri




Şekil 170: TOASO Basit Ortalama Öngörülleri




Şekil 171: TOASO Basit Hareketli Ortalama Öngörülleri




Şekil 172: TOASO Sarima Öngörülleri




Şekil 173: TTRAK Genel Görünüm




Şekil 174: TTRAK Eğitim ve Test Veri Kümesi




Şekil 175: TTRAK Naif Model Öngörülleri




Şekil 176: TTRAK Basit Ortalama Öngörülleri




Şekil 177: TTRAK Basit Hareketli Ortalama Öngörülleri




Şekil 178: TTRAK Sarıma Öngörülleri




Şekil 179: TURSG Genel Görünüm




Şekil 180: TURSG Eğitim ve Test Veri Kümesi




Şekil 181: TURSG Naif Model Öngörülleri




Şekil 182: TURSG Basit Ortalama Öngörülleri




Şekil 183: TURSG Basit Hareketli Ortalama Öngörülleri




Şekil 184: TURSG Sarima Öngörülleri




Şekil 185: VESBE Genel Görünüm




Şekil 186: VESBE Eğitim ve Test Veri Kümesi




Şekil 187: VESBE Naif Model Öngörülleri




Şekil 188: VESBE Basit Ortalama Öngörülleri




Şekil 189: VESBE Basit Hareketli Ortalama Öngörülleri




Şekil 190: VESBE Sarıma Öngörülleri




Şekil 191: YKBNK Genel Görünüm




Şekil 192: YKBNK Eğitim ve Test Veri Kümesi




Şekil 193: YKBNK Naif Model Öngörülleri



Şekil 194: YKBNK Basit Ortalama Öngörülleri



Şekil 195: YKBNK Basit Hareketli Ortalama Öngörülleri



Şekil 196: YKBNK Sarima Öngörülleri

