

T.C.
MARMARA ÜNİVERSİTESİ
BANKACILIK VE SİGORTACILIK ENSTİTÜSÜ
SERMAYE PİYASASI VE BORSA ANABİLİM DALI

**YAPAY ZEKA MODELLERİ VE BORSA İSTANBUL
ENDEKS VERİLERİYLE UYGULAMA**

BAHARE BAGHDADI

İSTANBUL, 2023

T.C.
MARMARA ÜNİVERSİTESİ
BANKACILIK VE SİGORTACILIK ENSTİTÜSÜ
SERMAYE PİYASASI VE BORSA ANABİLİM DALI

**YAPAY ZEKA MODELLERİ VE BORSA İSTANBUL
ENDEKS VERİLERİNE UYGULAMA**

BAHARE BAGHDADI

DANIŞMAN
Prof. Dr. Zeynep Dina ÇAKMUR YILDIRTAN

İSTANBUL, 2023

T.C.
MARMARAÜNİVERSİTESİ
BANKACILIK VE SİGORTACILIK ENSTİTÜSÜ

**YAPAY ZEKA MODELLERİ VE BORSA İSTANBUL
ENDEKS VERİLERİNE UYGULAMA**

Bahare BAGHDADI

YÜKSEK LİSANS TEZİ
SERMAYE PİYASASI VE BORSA ANABİLİM DALI

Tezin Enstitüye Teslim Edildiği Tarih :

Tezin Savunulduğu Tarih :

Tez Danışmanı: Prof. Dr. Z. Dina ÇAKMUR YILDIRTAN _____
(T.C. Marmara Üniversitesi)

Diğer Jüri Üyeleri : _____

İSTANBUL

İÇİNDEKİLER

ÖZET	v
ABSTRACT	vi
KISALTIMA LİSTESİ	vii
ŞEKİL VE TABLO LİSTESİ	ix
GİRİŞ	1

1. BÖLÜM

TEKNİK ANALİZ KAVRAMSAL ÇERÇEVE

1.1. ANALİZ TÜRLERİ	2
1.1.1 Temel Analiz	2
1.1.2 Teknik Analiz	2
1.1.3 Makroekonomik Analiz	2
1.1.4 Kıyaslama Analiz	2
1.1.5 Stratejik Analiz	3
1.2. TEKNİK ANALİZ TANIMI	3
1.3 TEKNİK ANALİZ TARİHÇESİ	5
1.4 TEKNİK ANALİZ GRAFİKLER	5
1.4.1. Çizgi Grafik	5
1.4.2. Çubuk Grafik	6
1.4.3. Mum Grafik	8
1.4.4. Nokta ve Şekil Grafiği	9
1.4.5. Hcim Grafiği	10
1.4.6. Grafiklerde Zaman Dilimleri	11
1.4.7. Grafiklerde Skalalar	12
1.5. TEKNİK ANALİZ FORMASYONLAR	13

1.5.1. Destek Ve Direnç Seviyeleri	13
1.5.2. Trendler	14
1.5.3 Fiyat Formasyon	15
1.5.4. Omuz-Baş-Omuz Formasyon	15
1.5.5. Ters-Omuz-Baş-Omuz Formasyon	16
1.5. 6. Çift Tepe Çift Dip Formasyon	17
1.5.7. Üçgen Formasyon	18
1.5.8. Dikdörtgen Formasyon	20
1.5.9. Elmas Formasyon	21
1.5.10. Çanak Ve Ters Çanak Formasyon	22
1.5.11. "V" Formasyon	24
1.5.12. Takoz Formasyonları	25
1.5.13. Bayrak Formasyonları	27
1.5.14. Flama Formasyonları	27
1.6. TEKNİK ANALİZ GÖSTERGELERİ	28
1.6.1.Trend Göstergeleri	28
1.6.1.1. Hareketli Ortamalar (Moving Average)	28
1.6.1.2.Ağırlıklı Hareketli Ortalama (Weighted Moving Average-WMA)	29
1.6.1.3. Aroon Göstergesi	30
1.6.1.4. Duple Üslü Hareketli Ortalama (Double Exponential Moving Average - DEMA)	31
1.6.1.5. MACD (Moving Average Convergence Divergence)	32
1.6.1.6. Parabolik SAR	34
1.6.1.7. ADX (Average Directional Index)	35
1.6.2.Momentum Göstergeleri	36
1.6.2.1. Momentum Göstergeleri (MOM)	36
1.6.2.2. Stokastik (Stochastics) Osilatör	37
1.6.2.3. RSI (Relative Strength Index) Göreceli Güç İndeksi	39
1.6.2.4. CCI (Commodity Channel Index) Emtia Kanalı İndeksi	40
1.6.2.5. ROC (Rate Of Change) Değişim OranYüzdesi	41
1.6.3. Volatilite Göstergeleri	42
1.6.3.1. Bolinger Bantlar	42
1.6.3.2. Ortalama Gerçek Aralık (Average True Range - ATR)	44
1.6.3.3. Zarflar (Envelopes)	45
1.6.3.4. İzdüşüm Osilatörü (Projection Oscillator)	45
1.6.4. Hacim Göstergeleri	46
1.6.4.1. AD (Accumulation/Distribution Index) Biriktirim/Dağıtım İndeksi	46
1.6.4.2. CO (Chaikin Oscillator) Chaikin Osilatörü	47
1.6.4.3. OBV (On Balance Volume) Hacim Dengesi	49

1.6.4.4.MFI (Money Flow Index) Para Akım İndeksi	50
--	----

2. BÖLÜM

FİNANSAL PİYASALARDA YAPAY ZEKA KAVRAMSAL ÇERÇEVE

2.1.YAPAY ZEKA TAIMI	52
2.2. YAPAY ZEKA TARİHÇESİ	55
2.3. FİNANSAL PİYASALARDA YAPAY ZEKA MODELLERİ	59
2.3.1.Zaman Serileri	59
2.3.1.1. ARIMA (AutoRegressive Integrated Moving Average)	59
2.3.1.2.SARIMA (Seasonal AutoRegressive Integrated Moving Average)	60
2.3.1.3. RNN (Recurrent Neural Network-Tekrarlayan Sinir Ağı)	61
2.3.1.4. GARCH (Generalized Autoregressive Conditional Heteroskedasticity)	61
2.3.2.Derin Öğrenme Modeller	62
2.3.2.1. Yapay Sinir Ağları (Artificial Neural Networks)	62
2.3.2.2. Evrimsel Stratejiler (Evolutionary Strategies)	
2.3.2.3. Long Short-Term Memory (LSTM - Uzun Kısa Vadeli Hafıza)	67
2.3.2.4. Evrimsel Sinir Ağları (Convolutional Neural Networks - CNN)	68
2.3.3.Makine Öğrenme Modelleri	69
2.3.3.1. Doğrusal Regresyon	73
2.3.3.2.Random Forests	75
2.3.3.3.Takviyeli Öğrenme (RL)	76
2.3.3.4.Light GBM (Light Gradient Boosting Machine):	77
2.3.3.5. Destek Vektör Makineleri (Support Vector Machines - SVM)	79
2.3.4. Genetik Algoritma (GA)	81
2.3.4.1. Genetik Programlama (Genetic Programming - GP)	85
2.3.4.2. Genetik Algoritma Tabanlı Sıralama (Genetic Algorithm for Ranking - GAR)	86
2.3.4.3. Küme Tabanlı Genetik Algoritmalar (Cluster-Based Genetic Algorithms - CBGA)	88
2.3.4.4. Çok Amaçlı Genetik Algoritmalar (Multi-Objective Genetic Algorithms - MOGA)	89
2.3.4.5.Gelişmiş Genetik Algoritmalar (Enhanced Genetic Algorithms - EGA)	90

3. BÖLÜM

YAPAY ZEKA MAKİNE ÖĞRENME MODELİ, LGBM ALGORİTMASI KULLANARAK BİST100 HİSSE SENETLERİNE UYGULAMA

3.1.ÇALIŞMANIN AMACI VE KAPSAMI	92
3.2.UYGULAMA YÖNTEMİ	94
3.3.UYGULAMADA KULLANILAN GÖSTERGELER	94
3.4.UYGULAMA ALGORİTMA SEÇİMİ	94
3.5. TEMEL VE ALT PROBLEM SORULARI	97
3.6.ANALİZ VE BULGULAR	98
SONUÇ VE ÖNERİLER	115
KAYNAKLAR	116
EKLER	116

ÖZET

YAPAY ZEKA MODELLERİ VE BORSA İSTANBUL ENDEKS VERİLERİNE UYGULAMA

Bu çalışma, finans piyasalarında yatırım araçlarının gelecekteki fiyat hareketlerini tahmin etmek amacıyla kullanılan teknik analiz yöntemini ele almaktadır. İlk olarak, birinci bölümünde teknik analizin genel bir incelemesi sunulmuş, bu kapsamda grafikler, formasyonlar ve göstergeler gibi temel konulara odaklanılmıştır. Daha sonra, yapay zeka kavramı ve finans dünyasındaki uygulama alanları hakkında bilgi verilmiş ve yapay zekanın teknik analiz sonuçlarına dayalı kombinasyon analizi için kullanılabilen modeller gözden geçirilmiştir. Bu modellerin özellikleri, teknikleri ve algoritmaları incelenmiş ve makine öğrenme tekniklerinin kullanılmasına karar verilmiştir.

Makine öğrenme tekniğinin teorik temelleri, çalışmanın ikinci bölümünde detaylı bir şekilde ele alınmıştır. Bu bölümde, makine öğrenme tekniklerinin temel özellikleri, parametreleri ve bu çalışma bağlamında nasıl uygulanabileceği üzerinde durulmuştur.

Uygulama bölümünde, Türkiye'deki finans sektöründe etkili olan ve yüksek işlem hacmine sahip olan hisse senetlerine odaklanılmıştır. Bu hisse senetleri üzerinde makine öğrenme tekniği Light GBM algoritmasının kullanılarak teknik analiz göstergelerinin kombinasyonu ile gelecekteki fiyat hareketlerini tahmin etmeye yönelik denemeler gerçekleştirilmiştir. Özellikle, RSI, MACD gibi teknik göstergelerin sonuçlarına dayalı olarak LightGBM algoritması ile bir model eğitilmiştir.

Sonuç olarak, bu çalışmanın temel amacı, yatırımcıların bilinçli kararlar alabilmeleri için teknik göstergelerin ve makine öğrenme modellerinin bir araya getirilerek sonuçlarının incelenmesidir. Çalışmanın sonuç kısmında, hangi yöntemin piyasadaki gerçek değerlere daha yakın sonuçlar verdiği karşılaştırılarak, yatırımcılara daha doğru işlem sinyalleri oluşturulmasına katkı sağlamaktır. Bu sayede finans piyasasındaki yatırım kararları daha sağlam bir temele dayandırılabilir ve yatırımcılar gelecekteki fiyat hareketleri konusunda daha iyi bilgilendirilmiş olur.

Anahtar Kelimeler: Teknik Analiz, Borsa İstanbul, Yapay Zeka

ABSTRACT

ARTIFICIAL INTELLIGENCE MODELS AND APPLICATION TO BORSA ISTANBUL INDEX DATA

This study focuses on the technical analysis method used to predict future price movements of investment instruments in financial markets. Firstly, an overview of technical analysis is provided, with a focus on fundamental concepts such as charts, patterns, and indicators. Subsequently, the concept of artificial intelligence and its applications in the financial world are discussed, and models that can be used for combination analysis based on technical analysis results are reviewed.

The features, techniques, and algorithms of these models are examined, and the decision is made to employ machine learning techniques for modeling.

The theoretical foundations of machine learning are detailed in a section of this study. In this section, the fundamental characteristics of machine learning techniques, their parameters, and how they can be applied in the context of this study are elaborated upon.

In the application section, the study concentrates on stocks that have a significant impact on the Turkish financial sector and have high trading volumes. Experiments aimed at predicting future price movements using a combination of technical analysis indicators with machine learning techniques are conducted on these stocks. Particularly, a model is trained using the LightGBM algorithm based on the results of technical indicators such as RSI and MACD.

In conclusion, the primary objective of this study is to examine the results by combining technical indicators and machine learning models to enable investors to make informed decisions. In the concluding section of the study, the comparison of which method yields results closer to real market values contributes to the creation of more accurate trading signals for investors. This, in turn, allows for investment decisions in financial markets to be based on a more solid foundation, ultimately better informing investors about future price movements.

Keywords: Technical Analysis, Borsa Istanbul, Artificial intelligence

KISALTMA LİSTESİ

A/D	: Accumulation/Distribution Index
ADX	: Average Directional Movement Index
AKBNK	: Akbank T.A.Ş.
ATR	: Average True Range
BIST	: Borsa İstanbul A.Ş.
BIST100	: Borsa İstanbul 100 Endeksi
CO	: Chaikin Osilatörü
CCI	: Commodity Channel Index
CMO	: Chande Momentum Osillator
DEMA	: Double Exponential Moving Average
DM	: Directional Movement Index
DMI	: Dynamic Momentum Index
EMA	: Exponential Moving Average
EOM	: Ease Of Movement
GA	: Genetik Algoritma
GBM	: Gradient Boosting Machine
KVHO	: Kısa Vadeli Hareketli Ortalama
LSTM	: Uzun Kısa Vadeli Hafıza Ağları
M	: İkili Tepe Formasyonu

MA	: Moving Avarage
ML	: Machine Learning
MA CROSS	: Hareketli Ortalama Kesişim
MACD	: Moving Average Convergence Divergence
MFI	: Money Flow Index
MOM	: Momentum
OBV	: On Balance Volume
RMA	: RSI Bazlı Moving Average
ROC	: Rate Of Change
RSI	: Relative Strength Index
RL	: Reinforcement Learning
SAR	: Stop and Reverse
SMA	: Simple Moving Average
TP	: Take Profit
UO	: Ultimate Oscillator
UVHO	: Uzun Vadeli Hareketli Ortalama
W	: İkili Dip Formasyonu
WMA	: Weighted Moving Average
YZ	: Yapay Zeka
YSA	: Yapay Sinir Ağları

ŞEKİL VE TABLO LİSTESİ

Şekil.2.1. Çizgi Grafiği _____	6
Şekil 2.2. Çubuk Grafiği _____	7
Şekil 2.3.MUM ve Hacim Grafiği _____	9
Şekil 2.4. Nokta ve Şekil _____	10
Şekil 2.5. Aritmetik ve logaritmik grafikleri _____	12
Şekil 2.6. USDJPY Destek ve Direnç _____	14
Şekil 2.7.EURUSD Trend Çizgi _____	15
Şekil 2.8. Omuz Ve Baş Omuz _____	16
Şekil 2.9. Ters Omuz Ve Baş Omuz _____	17
Şekil 2.10. Çift Tepe Ve Dip Formasyon _____	18
Şekil 2.11. Yükselen Üçgen _____	19
Şekil.2.12.Alçalan Üçgen _____	19
Şekil 2.13. Simetrik Üçgen _____	20
Şekil.2.14.Dikdörtgen Formasyon _____	21
Şekil.2.15. Elmas Formasyon _____	22
Şekil.2.16. Dip Çanak Formasyon _____	23
Şekil.2.17.Ters Çanak Formasyon _____	24
Şekil.2.18. “V” Formasyonu _____	25
Şekil.2.19. Takoz Formasyon _____	26
Şekil.2.20. Bayrak Formasyon _____	27
Şekil.2.21. Flama Formasyon _____	28
Şekil.2.22. Aroon Göstergesi _____	31
Şekil.2.23. EMA ve DEMA _____	32
Şekil.2.24.MACD Göstergesi _____	33
Şekil.2.25.Parabolik Göstergesi _____	35
Şekil.2.26.ADX _____	36
Şekil.2.27. MOMENTOM Göstergesi _____	37
Şekil.2.28. Stokastik Osilatör _____	38
Şekil.2.29 RSI Göstergesi _____	40
Şekil.2.30. CCI Göstergesi _____	41

Şekil.2.31. ROC Göstergesi	42
Şekil.2.32. Bolinger Bantlar	44
Tablo.2.1. Yapay Sinir Ağı Yönteminde Kullanılan Parametreler	66
Tablo.2.2. Genetik Algoritmaların Çalışma Adımları	82
Şekil 3.1. AKBANK- MA	99
Şekil.3.2. AKBANK- EMA	100
Tablo.3.1. Teknik Analiz işlem Detayları	100
Şekil.3.3. AKBANK –Teknik Analiz (RSI)	101
Şekil 3.4. AKBANK –Teknik Analiz (MACD)	101
Şekil.3.5. AKBANK- Teknik Analiz AL/SAT Sinyal grafiği	102
Şekil.3.6. AKBANK- Makine Öğrenme AL/SAT Sinyal grafiği	103
Şekil.3.7. AKBANK- TEKNİK ANALİZ VE MAKİNE ÖĞRENME SONUCU KARŞILAŞTIRMA	104
Şekil.3.8. THY- MA göstergesi	105
Şekil.3.9. THY- EMA göstergesi	105
Tablo.3.2. Teknik Analiz Detay listesi	106
Şekil.3.10. THY –Teknik Analiz (RSI) Gösterge	107
Şekil.3.11. THY – Teknik Analiz (MACD) Gösterge	107
Şekil.3.12. THY- Teknik Analiz - AL/SAT sinyalleri	108
Şekil.3.13. THY-ML- AL/SAT sinyalleri	108
Şekil.3.14. THY-Teknik Analiz ve ML sonuç Karşılaştırma	109
Şekil.3.15. SASA-MA göstergesi	110
Şekil.3.16. SASA- EMA göstergesi	111
Tablo.3.3. SASA-Teknik Analiz işlemler Detayı	111
Şekil.3.17. SASA-Teknik Analiz-RSI gösterge	112
Şekil.3.18. SASA-Teknik Analiz- MACD gösterge	113
Şekil.3.19. SASA- Teknik Analiz AL/SAT sinyalleri	113
Şekil.3.20. SASA-ML-AL/SAT Sinyalleri	114
Şekil.3.21. SASA-ML Ve Teknik Analiz Karşılaştırma	115

GİRİŞ

Sanayi devriminin ardından, ticari malların çeşitliliği arttı ve bu, finansal piyasaların oluşmasına ve yatırım araçlarının (hisse senetleri, tahviller, bonolar, kıymetli metaller, emtia vb.) bu piyasalarda işlem görmesine neden oldu. Bu gelişmelerle birlikte, piyasalardaki fiyat hareketlerini tahmin etmek ve yatırımcılara rehberlik etmek amacıyla iki temel analiz türü geliştirildi: Temel Analiz ve Teknik Analiz.

Temel analiz, bir yatırım aracının gerçek değerini ekonomik, sektörel, finansal ve mali faktörleri inceleyerek belirlemeye çalışır. Bu analiz, yatırım aracının piyasa fiyatı ile gerçek değeri arasındaki farkı değerlendirerek yatırımcılara alım veya satım kararları konusunda yol gösterir.

Diğer yandan, teknik analiz, geçmiş fiyat hareketlerini inceleyerek gelecekteki fiyat tahminleri yapmaya çalışır. Grafikler, göstergeler ve formasyonlar gibi araçlar kullanılarak, geçmiş fiyat hareketlerinden gelecekteki eğilimleri tahmin etmeye odaklanır.

Sonraki bölümde ise yapay zeka ve makine öğrenme modelleri, BIST100 hisse senetleri üzerinde uygulanarak finans ve iş dünyasındaki potansiyel kullanım alanları incelenmiştir. Bu çalışma, finansal piyasalarda daha etkili sonuçlar elde etmek amacıyla yapay zeka model ve algoritmalarına odaklanmaktadır.

Araştırma sonuçları, teknik analiz ve yapay zeka modellerinin birleştirilerek gelecekteki fiyat tahminlerinde daha faydalı olabileceğini göstermektedir. Ancak, bu tahminlerin güvenilirliği her zaman dış etkenlerin etkisi ve finansal piyasaların karmaşıklığı nedeniyle kesin olamayabilir.

Uygulama bölümünde, Borsa İstanbul'da işlem gören finans sektörüne ait hisse senetleri üzerinde gerçekleştirilen çalışma incelenmiştir. Bu çalışma, teknik analiz ve yapay zeka tabanlı makine öğrenme modeli kullanarak gelecekteki fiyat tahminlerini karşılaştırmış ve getiri-risk analizi yapmıştır.

Sonuç olarak, yatırımcıların gelecekteki fiyat hareketlerini tahmin etmek için teknik analiz tahminleri ve yapay zeka modellerinin sonuçlarını karşılaştırmak ve hangi yöntemin daha etkili ve karlı ve gerçek değerlere yakın olduğunu değerlendirmektir. Ancak her zaman ekonomik olaylar ve diğer faktörler dikkate alınmalı ve finansal piyasaların karmaşıklığı nedeniyle her tahminin kesinliği garanti edilemez.

BÖLÜM 1

TEKNİK ANALİZ KAVRAMSAL ÇERÇEVE

1.1. ANALİZ TÜRLERİ

Finansal analizler, yatırımcıların kararlarını verirken kullandıkları bir dizi araç ve tekniktir. Finansal analizler genellikle iki ana kategoriye ayrılır: temel analiz ve teknik analiz.

1.1.1 Temel Analiz

Temel analiz, bir şirketin finansal durumunu, sektör koşullarını ve ekonomik koşulları inceler. Bu tür analiz, yatırımcıların bir şirketin mali sağlığı, büyüme potansiyeli, karlılık ve risk profili gibi temel faktörleri değerlendirmelerine yardımcı olur. Bu analiz türü, finansal tablolar, şirket raporları ve ekonomik göstergeler gibi verileri kullanır.

1.1.2 Teknik Analiz

Teknik analiz, bir hisse senedi, endeks veya diğer yatırım aracının fiyat hareketlerini ve hacimlerini inceler. Bu analiz türü, bir varlığın fiyat hareketlerinin geçmişte nasıl davrandığına dayanarak gelecekteki fiyat hareketlerini tahmin etmeye çalışır. Teknik analiz, grafikler, trend çizgileri, göstergeler ve hacim analizi gibi araçlar kullanır.

1.1.3 Makroekonomik Analiz

Bu tür analiz, bir ekonominin genel durumunu, para politikasını, faiz oranlarını, enflasyonu, işsizlik oranlarını vb. inceler. Bu analiz, bir yatırımın ekonomik koşullar açısından ne kadar riskli veya avantajlı olduğunu belirlemeye yardımcı olur.

1.1.4 Kıyaslama Analiz

Bu tür analiz, bir şirketin rakipleri veya sektöründeki diğer şirketlerle karşılaştırmasını yapar. Bu analiz, bir yatırımcının bir şirketin performansını diğer şirketlerle karşılaştırmasına olanak sağlar.

1.1.5 Stratejik Analiz

Bu tür analiz, bir şirketin uzun vadeli stratejilerini, güçlü yönlerini, zayıf yönlerini, fırsatlarını ve tehditlerini inceler. Bu analiz, bir yatırımcının bir şirketin uzun vadeli büyüme potansiyelini ve piyasa konumunu değerlendirmesine yardımcı olur.

Bu analiz türleri, yatırımcıların farklı açılardan bir yatırımı değerlendirmelerine yardımcı olur ve yatırım kararlarını destekleyen bilgiler sağlar. Ancak, her tür analizin kendi avantajları ve dezavantajları vardır ve yatırımcıların birkaç analiz türünü birleştirerek kapsamlı bir değerlendirme yapmaları önemlidir.

1.2. TEKNİK ANALİZ TANIMI

Teknik analiz finansal piyasalarda kullanılan bir analiz yöntemidir. Teknik analiz, piyasalarda işlem gören varlıkların fiyatlarını, hacimlerini ve diğer istatistikleri kullanarak gelecekteki fiyat hareketlerini tahmin etmeye çalışır. Bu yöntem, geçmiş fiyat hareketlerinin gelecekteki fiyat hareketlerini etkileyeceği varsayımına dayanır.

Teknik analizde kullanılan araçlar ve yöntemler çeşitlidir. Bunlar arasında trend çizgileri, destek ve direnç seviyeleri, hareketli ortalamalar, göstergeler (RSI, MACD, vb.), hacim analizi gibi yöntemler yer alır. Bu araçlar ve yöntemler, fiyat hareketlerinin belirli bir şekilde oluştuğunu ve bunların gelecekte de aynı şekilde oluşacağını varsayar.

Teknik analiz, yatırımcılar tarafından kullanılan birçok stratejinin temelini oluşturur. Örneğin, trend takip stratejisi, piyasadaki belirli bir trendi takip ederek yatırım yapmayı içerir. Tersine çevirme stratejisi ise piyasa hareketinin tersine dönmesi beklentisiyle yatırım yapmayı içerir.

Teknik analiz, yatırımcılara piyasaları daha iyi anlamalarına ve daha bilinçli yatırım kararları almalarına yardımcı olabilir. Ancak, teknik analiz tek başına kullanılmamalıdır. Temel analiz, yani bir varlığın gerçek değerini belirleme yöntemi, teknik analiz ile birleştirilerek daha sağlıklı yatırım kararları alınabilir.

Teknik analiz, yatırımcıların piyasalarda fiyat hareketlerini takip etmelerine, olası alım-satım noktalarını belirlemelerine ve risk yönetimi stratejilerini uygulamalarına yardımcı olur. Özellikle kısa vadeli yatırımcılar arasında yaygın olarak kullanılır.

Teknik analizin temel varsayımlarından biri, piyasa davranışlarının her zaman rasgele olmadığıdır. Teknik analizde fiyat grafikleri incelenerek, geçmişte benzer şartlarda piyasanın nasıl tepki verdiği incelenir ve bundan yararlanarak gelecekteki piyasa hareketleri tahmin edilmeye çalışılır.

Teknik analizin dezavantajları arasında, piyasa hareketlerinin etkileyebileceği birçok faktörün göz ardı edilmesi ve yanıltıcı sinyallerin ortaya çıkması yer alır. Ayrıca, teknik analizde yalnızca fiyat hareketleri ve hacim gibi nicel veriler kullanıldığı için, bir varlığın gerçek değeri hakkında bilgi vermez.

Sonuç olarak, teknik analiz finansal piyasalarda yatırım kararları almak için kullanılan bir araçtır. Yatırımcılar tarafından kullanılan birçok stratejinin temelini oluşturur ve yatırımcılara piyasa hareketlerini takip etmeleri, olası alım-satım noktalarını belirlemeleri ve risk yönetimi stratejilerini uygulamaları konusunda yardımcı olur. Ancak, teknik analiz tek başına yeterli değildir ve temel analiz ile birleştirilerek daha sağlıklı yatırım kararları alınabilir.

Teknik analiz geçmiş piyasa hareketlerini temel alır ve bunlara dayanarak piyasanın gelecek eğilimlerini tahmin etmeye çalışır. Burada “Tarih tekerrürden ibarettir” mantığı yatmaktadır. Ancak geçmişte yaşananların birebir tekrarlanacağına garanti yoktur. Teknik analizin, kullanılan verilerin net ve gerçek olması, veri tabanının dağınık olmaması, analiz sonucu çıktılarının görünür olması, sonuca varmak için elektronik altyapı kullanılması gibi pek çok avantajı bulunur. (Casaretto, 2017, s. 54).

Teknik analizin dezavantajları, yatırımcı psikolojisini yok sayması, teknik bilgi ve değerlendirme için eğitim, kapasite ve deneyim gerektirmesidir.

(Casaretto, 2017, s. 54-55).

1.3 TEKNİK ANALİZ TARİHÇESİ

Teknik analiz, finansal piyasalarda fiyat hareketlerinin geçmiş performansının incelenerek gelecekteki fiyat hareketlerinin tahmin edilmesi amacıyla kullanılan bir yöntemdir. Teknik analiz, yatırımcıların fiyat hareketlerinin matematiksel ve istatistiksel modellerini kullanarak alım satım kararlarını vermesine yardımcı olur.

Teknik analizin tarihi, 17. yüzyıla kadar uzanmaktadır. Japon pirinç tüccarları, mum grafikleri kullanarak fiyat hareketlerini analiz etmişlerdir. Bu teknik, Japonya'da popüler hale gelmiştir ve daha sonra Batı ülkelerine yayılmıştır.

Teknik analiz, Charles Dow tarafından Batı'da 19. yüzyılın sonlarında geliştirilmiştir. Dow, The Wall Street Journal'ın kurucusu ve Dow Jones & Company'nin kurucu ortağı olarak tanınmaktadır. Dow, hisse senedi piyasasını analiz etmek için grafikler ve istatistikler kullanarak ilgili trendleri ve fiyat hareketlerini belirlemeye çalıştı. Dow Jones Endeksi, Dow'un piyasa analizine dayalı olarak geliştirdiği bir gösterge olarak da bilinir.

Dow, hisse senedi fiyatlarının endüstriyel ve ulaştırma sektörleri arasındaki ilişkiyi analiz etmek için endüstriyel ve ulaştırma hisse senedi endekslerini kullanmıştır. Bu ilişki, Dow Teorisi olarak bilinmektedir ve hala bugün kullanılmaktadır.

Dow Teorisi, teknik analizin birçok yönünü kapsar. Diğer teknik analiz araçları, hareketli ortalamalar, trend çizgileri, göstergeler ve formasyonlardır. Bu araçlar, fiyat hareketlerinin geçmişini analiz etmek için kullanılır ve gelecekteki fiyat hareketlerinin tahmin edilmesinde yardımcı olur.

1.4 TEKNİK ANALİZ GRAFİKLER

1.4.1. Çizgi Grafik

verilerin bir eksen üzerindeki değerlerine göre zaman içindeki değişimini göstermek için kullanılan bir grafik türüdür. Çizgi grafikler, birbirine bağlı noktaların oluşturduğu

çizgilerle verilerin görsel olarak temsil edilmesine olanak tanır. Genellikle x ve y eksenleri kullanılarak, zaman, miktar, oran veya herhangi bir niceliksel verinin değişimini yansıtan verileri göstermek için kullanılır.

Çizgi grafikleri, verilerin trendini, deseni, sezonluk değişimleri ve aykırı değerleri kolayca anlamak için kullanışlıdır. Ayrıca, birden çok veri serisini aynı grafik üzerinde karşılaştırmak için de kullanılabilir. Çizgi grafikleri, ekonomi, finans, meteoroloji, sağlık, demografi ve birçok başka alanda veri analizinde ve raporlamada yaygın olarak kullanılır.

Çizgi grafikler, genellikle bir başlık, x ve y eksen etiketleri, çizgi rengi ve stilini belirleyen bir anahtar veya lejant gibi grafik elemanları içerir. Verilerin düzenli bir çizgi ile birleştirildiği noktaların yanı sıra, çizgi grafiklerde hata çubukları, alan dolgusu veya nokta etiketleri gibi ek görsel öğeler de kullanılabilir.

Şekil.1.1. Çizgi Grafiği



Kaynak: <https://tr./charts/stocks-charts>

1.4.2. Çubuk Grafik

Kategorik verileri veya farklı kategoriler içindeki değerleri görsel olarak temsil etmek için kullanılan bir grafik türüdür. Çubuk grafikleri, dikdörtgen sütunlardan veya çubuklardan oluşur ve her bir çubuğun yüksekliği, temsil ettiği veri değerini gösterir. Çubuklar, yatay veya dikey olarak düzenlenebilir ve genellikle kategorilerin x eksenini


üzerinde yer aldığı, değerlerin ise y ekseninde gösterildiği bir koordinat düzenine sahiptir.

Grafikte açılış fiyatı çubuğun soluna, kapanış fiyatı ise çubuğun sağına küçük yatay bir çizgi gösterilmektedir. Fiyat aralığı çubuk uzunluğuna bakılarak tayin edilebilmektedir (Aksoy & Tanrıöven, 2014, s. 602-603).

Çubuk grafikleri, verileri karşılaştırmak, dağılımı anlamak, eğilimleri belirlemek ve aykırı değerleri tespit etmek için kullanılabilir. Kategorik verilerin, örneğin ürün satışları, bölgeler, demografi, zaman dilimleri gibi farklı kategorilere göre dağılımını göstermek için sıkça kullanılır.

Çubuk grafiklerinde çubukların uzunlukları, değerlerin görsel olarak karşılaştırılmasına olanak tanır. Değerleri temsil eden çubuklar, farklı renkler, dolgular veya desenler kullanılarak ayrıştırılabilir. Ayrıca, çubuk grafiklerinde çubukların üzerine değer etiketleri eklenerek daha ayrıntılı bilgiler sunulabilir. Başlık, eksen etiketleri, açıklamalar ve anahtar gibi grafik elemanları da çubuk grafiklerinde sıkça kullanılır. Çubuk grafikleri, Microsoft Excel, Google Sheets, PYTHON ve diğer veri analiz ve görselleştirme araçları gibi yaygın olarak kullanılan yazılımlar tarafından desteklenir ve geniş bir uygulama yelpazesine sahiptir.

Şekil 1.1: Çubuk Grafiği



Kaynak: <https://tr /charts/stocks-charts>

1.4.3. Mum Grafik

1600 yıllarında Japonya'da tüccarların kullandığı bu yöntem son yıllarda teknik analizde de kullanılmaya başlanmıştır (Sarı, Borsada Grafiklerle Teknik Analiz, 1998, s. 27). En sık kullanılan ve kullanımı görece kolay olan grafik türüdür. Mum grafikler sayesinde belirlenen zaman periyotundaki fiyat hareketlerinin en düşük, en yüksek, açılış ve kapanış fiyatları izlenebilir (Ekosentez,2018).

finans piyasalarında teknik analiz yapmak için kullanılan bir grafik türüdür. Japon Mum Grafikleri veya Japon Şamdanları olarak da bilinirler ve ilk olarak Japonya'da pirinç ticareti yapılırken kullanılmışlardır. Mum grafikleri, finansal varlıkların (örneğin hisse senetleri, döviz, emtialar) fiyat hareketlerini ve trendlerini görsel olarak temsil eder.

Mum grafikleri, her bir mumun belirli bir zaman diliminde (örneğin 1 dakika, 1 saat, 1 gün, 1 hafta vb.) açılış, kapanış, en düşük ve en yüksek fiyatlarını gösterir. Her bir mum, bir dikdörtgen şeklinde gösterilir ve bu dikdörtgenin üst ve alt kısımlarında çizgiler bulunur. Üst çizgi, en yüksek fiyatı gösterirken, alt çizgi en düşük fiyatı gösterir. Dikdörtgenin içi ise açılış ve kapanış fiyatlarını gösterir. Renkler ise genellikle fiyatın arttığı (boğa piyasası) ve azaldığı (ayı piyasası) dönemleri temsil eder.

Mum grafikleri, fiyat hareketlerini analiz etmek ve trendleri belirlemek için kullanılır. Özellikle, grafik desenleri, formasyonlar, mum desenleri ve mum grupları gibi belirli kalıplar, teknik analistler tarafından kullanılır. Bu grafikler, fiyat hareketleri ve piyasa duyarlılıklarını daha iyi anlamak için kullanılabilir ve yatırım kararlarına yardımcı olabilir.

Mum grafikleri, finans piyasalarında yaygın olarak kullanılan ve teknik analiz için önemli bir araç olan bir grafik türüdür. Farklı mum desenlerini, formasyonlarını ve trendleri doğru bir şekilde anlamak, finansal varlıkların fiyat hareketlerini daha etkili bir şekilde analiz etmek için önemlidir.

Şekil 1.2: Mum Grafiği



Kaynak: <https://tr. /charts/stocks-charts>

1.4.4. Nokta ve Şekil Grafiği

Nokta ve şekil grafikleri, finans piyasalarında teknik analiz yapmak için kullanılan diğer grafik türleridir. Nokta grafikleri, fiyat hareketlerini noktalar veya nokta grupları şeklinde temsil ederken, şekil grafikleri, belirli desenler ve şekiller oluşturarak fiyat hareketlerini gösterir.

Nokta Grafikleri: Nokta grafikleri, fiyatların belirli zaman dilimlerindeki (örneğin gün, hafta, ay) kapanış fiyatlarını noktalar veya nokta grupları ile temsil eder. Her nokta, kapanış fiyatını belirli bir seviyede gösterir ve noktalar, zaman içindeki fiyat hareketlerini izleyerek grafik oluşturur. Nokta grafikleri, trendleri, destek ve direnç seviyelerini ve fiyat değişimlerini belirlemek için kullanılabilir.

Şekil Grafikleri: Şekil grafikleri, belirli desenler ve şekiller oluşturarak fiyat hareketlerini gösterir. Bu desenler, finansal varlıkların trendlerini, dönüş noktalarını ve diğer teknik analiz sinyallerini belirlemek için kullanılabilir. Örnek olarak, kupa ve sap, ters kupa ve sap, çift dip, çift tepe, bayrak, flama, omuz baş omuz, ters omuz baş omuz gibi belirli desenler şekil grafiklerinde kullanılabilir. Bu grafikleri, teknik analiz yapmak için kullanılan ve finans piyasalarında fiyat hareketlerini izlemek ve trendleri belirlemek için önemli bir araçtır. Bu grafik türleri, fiyat hareketlerini daha net bir şekilde görmeyi ve potansiyel ticaret fırsatlarını tanımanızı sağlar. Ancak, teknik analizde herhangi bir tekniğin doğruluğu, başka analiz yöntemleri ve risk yönetimi ile birlikte kullanıldığında daha yüksektir.

Şekil 1.3: Nokta ve Şekil Grafığı



Kaynak: <https://charts/stocks-charts>

1.4.5. Hacim Grafığı

Hacim grafığı, finans piyasalarında işlem gören bir varlığın (örneğin hisse senedi, döviz, emtia) işlem hacmini temsil eden bir grafik türüdür. Hacim, belirli bir zaman diliminde gerçekleşen toplam işlem miktarını ifade eder ve fiyat hareketlerinin arkasındaki işlem aktivitesini yansıtır.

Hacim grafığı, genellikle bir varlığın fiyat hareketleriyle birlikte kullanılarak daha kapsamlı bir analiz sağlar. Hacim grafığı, genellikle çubuklar veya histogramlar şeklinde temsil edilir ve şekil 1,2,3 de gösterildiği gibi, dikey eksen üzerinde işlem hacmini, yatay eksen üzerinde ise zamanı gösterir.

Hacim grafığı, finans piyasalarında bir varlığın ticaret aktivitesini, likiditeyi, işlem yoğunluğunu ve potansiyel trendleri belirlemek için kullanılabilir. Özellikle, hacim grafığı ile fiyat hareketleri karşılaştırılarak, belirli bir fiyat hareketinin arkasındaki ticaret hacmi analiz edilerek, fiyat hareketinin güvenilirliği ve sürdürülebilirliği hakkında fikir edinilebilir. teknik analizde diğer analiz araçları ile birlikte kullanılarak ticaret kararlarına destek sağlar. Örneğin, fiyatların yükselmesi veya düşmesiyle birlikte artan hacim, trendin güçlü olduğunu ve daha güvenilir olduğunu düşündürebilir. Aynı şekilde, fiyatların yükselmesi veya düşmesiyle birlikte azalan hacim, trendin zayıfladığını veya tersine dönebileceğini düşündürebilir. Ancak, hacim grafığı tek başına bir analiz yöntemi olarak kullanılmamalıdır, diğer teknik analiz araçları ile birlikte değerlendirilmelidir.

1.4.6. Grafiklerde Zaman Dilimleri

Grafiklerde zaman dilimleri, zaman bazlı verilerin görselleştirildiği grafiklerde kullanılan zaman birimlerini ifade eder. Zaman dilimleri, verinin zaman içindeki değişimini anlamak, trendleri belirlemek, mevsimsel veya dönemsel değişimleri incelemek gibi analizler için önemlidir. Bazı yaygın zaman dilimleri aşağıda belirtilmiştir:

Günlük: Günlük zaman diliminde, veriler gün bazında gösterilir. Her bir çubuk, bir günü temsil eder ve genellikle günlük verilerin analizi için kullanılır.

Haftalık: Haftalık zaman diliminde, veriler haftalık periyotlara göre gösterilir. Her bir çubuk, bir haftayı temsil eder ve haftalık verilerin analizi için kullanılır.

Aylık: Aylık zaman diliminde, veriler aylık periyotlara göre gösterilir. Her bir çubuk, bir ayı temsil eder ve aylık verilerin analizi için kullanılır.

Yıllık: Yıllık zaman diliminde, veriler yıllık periyotlara göre gösterilir. Her bir çubuk, bir yılı temsil eder ve yıllık verilerin analizi için kullanılır.

Dakikalık veya saatlik: Dakikalık veya saatlik zaman dilimlerinde, veriler daha kısa zaman aralıklarında gösterilir. Özellikle finansal veriler gibi hızlı değişen verilerin analizinde kullanılabilir.

Özel zaman dilimleri: Ayrıca, özel zaman dilimleri de kullanılabilir. Örneğin, 15 dakikalık, 30 dakikalık veya 4 saatlik zaman dilimleri gibi, belirli analiz ihtiyaçlarına göre özel zaman dilimleri oluşturulabilir.

Zaman dilimleri, grafiklerdeki verilerin zaman içindeki değişimini daha iyi anlamak ve trendleri belirlemek için önemlidir. Doğru zaman dilimini seçmek, analiz süreçlerini optimize edebilir ve doğru sonuçlara ulaşmayı sağlayabilir.

1.4.7. Grafiklerde Skalalar (Aritmetik ve logaritmik)

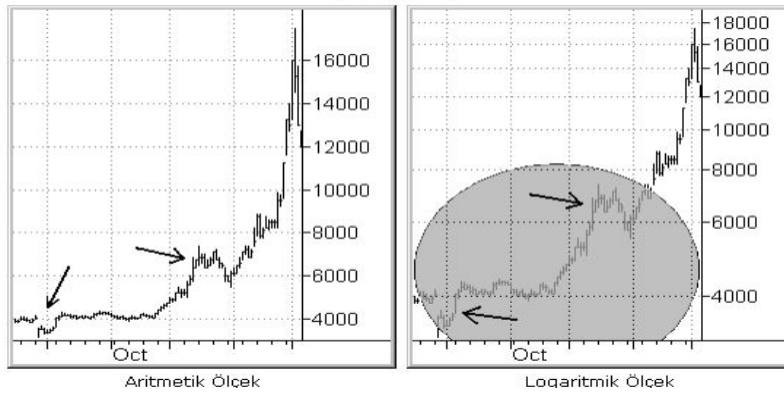
Grafiklerde kullanılan skalalar, verilerin dikey eksen üzerinde nasıl temsil edildiğini belirler. İki yaygın kullanılan skala türü aritmetik ve logaritmik skalalardır.

1.4.7.1. Aritmetik Skala: Aritmetik skala, verilerin doğrusal olarak eksen üzerinde temsil edildiği bir skala türüdür. Bu skala türünde, eksen üzerindeki her bir birim eşit büyüklükte bir değeri temsil eder. Örneğin, eksen üzerindeki her bir çizgi 1 birim, 5 birim, 10 birim gibi eşit değerlere karşılık gelebilir. Aritmetik skala, genellikle verilerin düzgün bir şekilde arttığı veya azaldığı durumlarda kullanılır.

1.4.7.2. Logaritmik Skala: Logaritmik skala, verilerin logaritmik olarak temsil edildiği bir skala türüdür. Bu skala türünde, eksen üzerindeki her bir birim, bir önceki birimin bir katı büyüklüğünde bir değeri temsil eder. Örneğin, eksen üzerindeki her bir çizgi 1, 10, 100, 1000 gibi logaritmik artışlara karşılık gelebilir. Logaritmik skala, genellikle verilerin büyük değerler veya geniş aralıklar içerdiği durumlarda kullanılır, çünkü verileri daha kolay karşılaştırmaya ve görselleştirmeye olanak tanır.

Grafiklerde kullanılan skala türü, verilerin doğası ve analiz amacına bağlı olarak seçilir. Aritmetik skala, genellikle verilerin doğrusal olarak arttığı veya azaldığı durumlarda kullanılırken, logaritmik skala, genellikle büyük değerler veya geniş aralıklar içeren verilerin daha etkili bir şekilde temsil edilmesi gerektiği durumlarda tercih edilir.

Şekil 1.4. Aritmetik ve logaritmik grafikleri



1.5. TEKNİK ANALİZ FORMASYONLAR

Teknik analiz, fiyat ve işlem hacmi gibi piyasa verileri kullanılarak gelecekteki fiyat hareketlerini tahmin etmek için kullanılan bir analiz yöntemidir. Teknik analizde kullanılan araçlar ve kavramlar, yatırımcıların fiyat hareketleri hakkında daha iyi kararlar vermelerine yardımcı olur.

Teknik analizin kavramları ve görsel yöntemleri arasında aşağıdakiler yer alır:

1.5.1. Destek Ve Direnç Seviyeleri

Fiyat grafiği üzerinde belirli fiyat seviyeleri, fiyatın yükselmesini veya düşmesini önleyebilen destek ve direnç seviyeleri olarak adlandırılır.

Destek ve direnç seviyeleri, teknik analizin en önemli kavramlarından biridir. Bu seviyeler, fiyatların yönünü belirleyen kritik noktalardır ve yatırımcıların alım-satım kararları almasında yardımcı olurlar.

Yatırım araçlarının alım-satımında, yatırımcı ve teknik analistlerin pozisyon açmadan önce ilk olarak başvurdukları ve en çok dikkat ettikleri yöntem destek ve direnç noktalarının belirlenmesidir (Münyas & Atasoy, 2019, s. 89).

Destek seviyesi, fiyatların düşmeye başladığı seviyedir ve daha düşük bir seviyeye inmesini engelleyen bir bariyer görevi görür. Bu seviye genellikle daha önce fiyatların yükseldiği bir noktadır ve fiyatların buraya geri gelmesi halinde talebin artacağı düşünülür. Destek seviyesi kırıldığı zaman fiyatlar genellikle daha düşük seviyelere doğru hareket eder.

Direnç seviyesi ise, fiyatların yükselmeye başladığı seviyedir ve daha yüksek bir seviyeye çıkmasını engelleyen bir bariyer görevi görür. Bu seviye genellikle daha önce fiyatların düştüğü bir noktadır ve fiyatların buraya geri gelmesi halinde arzın artacağı düşünülür. Direnç seviyesi kırıldığı zaman fiyatlar genellikle daha yüksek seviyelere doğru hareket eder.

Destek ve direnç seviyeleri, yatırımcıların fiyatların yönü hakkında tahminlerde bulunmalarına yardımcı olur. Fiyatların destek seviyelerinde tutunması veya direnç seviyelerini kırması durumunda, yatırımcılar alım veya satım pozisyonu açabilirler. Ancak destek ve direnç seviyeleri, her zaman kesin bir şekilde belirlenemez ve fiyatlar bu seviyelerde dalgalanabilir.

Şekil 1.5. Destek ve Direnç



Kaynak : Grafiklerin Dili; Trend, Eğitim Çizgileri, Fiyat Kanalları

1.5.2. Trendler

Fiyat grafiğinde belirgin bir yön oluşturan fiyat hareketleri trend olarak adlandırılır. Trendler, yükselen, düşen veya yatay olabilir.

Teknik analizde trend, fiyatların belli bir yönde hareket ettiği genel eğilimi ifade eder. Trendler, piyasada yönü belirlemek için kullanılan en önemli araçlardan biridir.

Bir trend genellikle üç yönde olabilir: yukarı, aşağı veya yatay. Yukarı trend, fiyatların zaman içinde arttığı anlamına gelirken, aşağı trend fiyatların zaman içinde azaldığını ifade eder. Yatay trend ise fiyatların nispeten sabit kaldığı, genellikle bir aralıkta dalgalanma gösterdiği bir durumu ifade eder.

Trendin belirlenmesi, grafiklerin analiz edilmesiyle yapılır. Teknik analizde trend çizgileri kullanılarak belirlenir. Yukarı trend için çizgi, fiyatların yükselmeye devam ettiği noktalardan başlayarak çizilir. Aşağı trend için de çizgi, fiyatların düşmeye devam ettiği noktalardan başlayarak çizilir. Yatay trendde ise destek ve direnç seviyeleri çizilerek fiyatın o seviyeler arasında dalgalanacağı belirtilir.

Şekil 1.7. Trend Çizgi



Kaynak: [Grafiklerin Dili; Trend, Eğitim Çizgileri, Fiyat Kanalları](#)

1.5.3 Fiyat Formasyon

Fiyat formasyonu, finansal grafik analizde kullanılan bir terimdir ve bir finansal enstrümanın fiyat grafiğinde belirli bir şekil veya desen olarak görünen fiyat hareketlerini ifade eder. Fiyat formasyonları, gelecekteki fiyat hareketlerini tahmin etmek için kullanılabilir ve traderlar tarafından teknik analizde sıkça kullanılır.

Fiyat formasyonları, genellikle belirli bir süre boyunca oluşan fiyat hareketlerinin tekrarlanan modelleridir. Bunlar yükselen trendlerde, düşen trendlerde veya yatay hareket eden piyasalarda ortaya çıkabilir. Fiyat formasyonları, bir finansal enstrümanın gelecekteki fiyat hareketlerini öngörmeye yardımcı olabilir, ancak tek başına bir ticaret kararı vermek için yeterli değildir. Diğer teknik analiz araçları ve temel analiz ile birlikte kullanıldığında daha güçlü ticaret sinyalleri üretebilirler.

1.5.4. Omuz-Baş-Omuz Formasyon

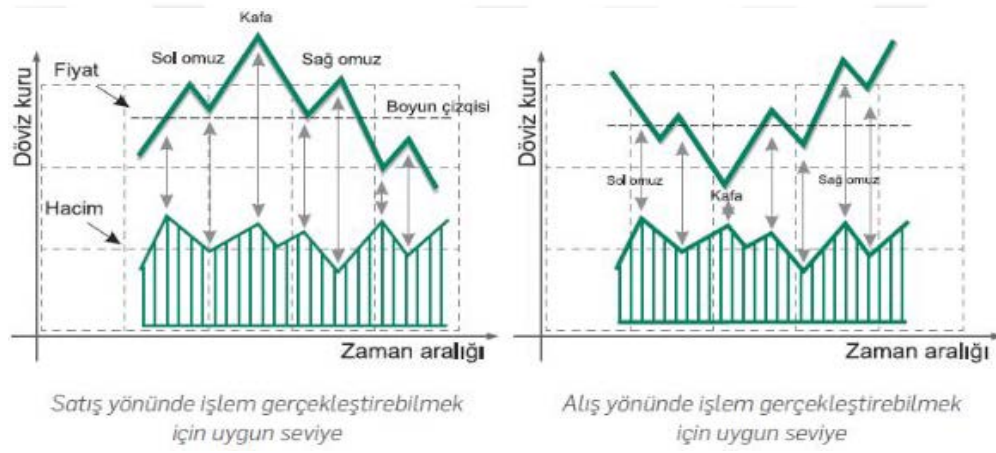
Bu formasyon, trendin yönünü değiştirebileceğine işaret eder ve trendin zirvesinde meydana gelir.

Omuz baş omuz formasyonu, omuzlar ve bir baştan oluşan bir desene sahiptir. Omuzlar, bir önceki fiyat hareketinin zirvelerini temsil ederken, baş fiyatların en yüksek noktasını temsil eder. Bu formasyon tamamlandığında, fiyatların düşeceği yönünde bir sinyal verir. Formasyon tamamlandıktan sonra fiyatlar, başın altındaki seviyeye kadar düşebilir.

” Güçlü satış sinyalleri oluşturarak devam eden yükseliş trendine son verir. Trendin negatif yönlü olarak değişeceğine işaret eden zirve görüntüsüdür” (Mergen, Grafiklerle Borsa Uygulamalı Teknik Analiz, 2005, s. 155).

Omuz baş omuz formasyonunun bitmesiyle ile yükseliş trendi sonlanmaktadır. Uzun vadeli yatırımcıların formasyonu en son kısmı tamamlanana kadar takip etmeleri gerekir. Boyun çizgisinin kırılmasıyla birlikte uzun vadeli sat sinyali netleşmektedir. (Sarı, Borsada Grafiklerle Teknik Analiz, 1998, s. 106)

Şekil 1.8. Omuz Ve Baş Omuz



Kaynak : [Omuz Baş Omuz Formasyonları | InvestAZ](#)

1.5.5. Ters-Omuz-Baş-Omuz Formasyon

Ters Omuz-Baş-Omuz formasyonu, en popüler ve güvenilir fiyat formasyonlarından biridir ve trend dönüşlerini gösteren bir formasyondur. Bu formasyon, önce yükselen bir trendin sonuna doğru baş gösterir.

Omuz baş omuz formasyonunda oluşan üç zirve görüntüsündeki gibi ters omuz baş formasyonunda da üç tane dip noktası oluşmaktadır. (Mergen, Grafiklerle Borsa Uygulamalı Teknik Analiz, 2005, s. 188).

Formasyon, sol omuz, baş ve sağ omuz olmak üzere üç tepe oluşumu ile karakterizedir. Sol omuz, fiyatların yavaşça yükselmesiyle oluşur. Baş, fiyatların sol omuzun üzerine çıktığı, zirveye ulaştığı ve daha sonra geri çekildiği bir noktada oluşur.

Sağ omuz, fiyatların tekrar yükseldiği ancak baş seviyesine ulaşamadığı, daha düşük bir zirveye ulaştığı bir noktada oluşur.

Ters Omuz-Baş-Omuz formasyonu, sol omuz ve sağ omuz seviyeleri arasında oluşan çizginin kırılması ile tamamlanır. Çizgi kırıldıktan sonra fiyatlar genellikle omuz seviyesine doğru bir düzeltme hareketi yaparlar. Bu formasyonun teyidi için, fiyatların kırılma seviyesinin altında bir süre kalması beklenir.

Bu formasyon ayrıca, sağ omuz seviyesinin sol omuz seviyesinin altına düştüğü, bir Ters Omuz-Baş-Omuz formasyonu olarak adlandırılan tersine formasyon ile de karşılaştırılabilir. Ters Omuz-Baş-Omuz formasyonunda olduğu gibi, bu formasyon da bir trend dönüş sinyali olarak yorumlanabilir.

Şekil 1.9. Ters Omuz Ve Baş Omuz



Kaynak : [Teknik Analiz Eğitim Notu — Formasyonlar | by Halk Yatırım | Medium](#)

1.5. 6. Çift Tepe Çift Dip Formasyon


Çift tepe çift dip formasyonları da trend dönüş formasyonları arasında yer almaktadır. Bu formasyonlar, fiyatların önce belirli bir seviyeye çıktuktan veya düştükten sonra geri dönerek tekrar aynı seviyeye geldiği ve bu işlemin iki defa gerçekleştiği zamanlarda oluşur.

Çift tepe formasyonunda, fiyat önce bir seviyeye yükselir ve bu seviyeden geri döner. Daha sonra tekrar aynı seviyeye çıkar ancak burada dirençle karşılaşır ve tekrar geri düşer. Bu işlem sırasında oluşan grafik şekli, çift tepe formasyonunu oluşturur. fiyat önce

bir seviyeye düşer ve burada bir destek oluşur. Fiyat daha sonra tekrar aynı seviyeye gelir ancak bu sefer destekle karşılaşır ve yükselmeye başlar. Ancak fiyat yine de dirençle karşılaşır ve tekrar düşer. Bu işlem sırasında oluşan grafik şekli, çift dip formasyonunu oluşturur.

Çift tepe ve çift dip formasyonları, destek ve direnç seviyelerinin belirlenmesi açısından oldukça önemlidir. Bu formasyonların oluşumu, trendin zayıflayabileceğine veya trend dönüşüne işaret edebilir. Ancak bu formasyonların bir trend dönüşüne işaret edip etmediği, formasyonun tamamlandığından sonra fiyatın destek veya direnç seviyelerini kırıp kırmadığına bağlıdır.

Şekil 1.10. Çift Tepe Ve Dip Formasyon



Kaynak : [İkili Zirve ve İkili Dip Formasyonları | InvestAZ](#)


1.5.7. Üçgen Formasyon

genellikle direnç çizgisinin ve destek çizgisinin kesiştiği noktada ortaya çıkar. Yükselen üçgenlerde, destek hattı yatay, direnç hattı ise yukarı doğru eğilim gösterir. Düşen üçgenlerde ise, direnç hattı yatay, destek hattı ise aşağı doğru eğilim gösterir. Üçgen formasyonlarında fiyat, destek hattı ve direnç hattı arasında gidip gelirken, genellikle hacim azalır.

Üçgen formasyonlarının genellikle birkaç türü vardır:

- **Yükselen üçgen:** Fiyatların yükseliş trendinde olduğu durumlarda ortaya çıkan bir formasyondur. Fiyatlar destek çizgisinden kalkar ve direnç çizgisine yaklaşırken, yatay seyrederek.


Şekil 1.11. Yükselen Üçgen



Kaynak : [Üçgen Formasyonları | InvestAZ](#)

- Düşen üçgen: Fiyatların düşüş trendinde olduğu durumlarda ortaya çıkan bir formasyondur. Fiyatlar direnç çizgisinden döner ve destek çizgisine yaklaşırken, yatay seyreder.

Şekil.1.12. Alçalan Üçgen




Kaynak : [Üçgen Formasyonları | InvestAZ](#)

- Simetrik üçgen: Yükselen veya düşen bir trend olmadan ortaya çıkan bir formasyondur. Fiyatlar, bir destek çizgisi ve bir direnç çizgisi arasında gidip gelirken, hacim azalır.

Üçgen formasyonları, kırılma noktalarına göre alım veya satım sinyalleri üretir. Destek çizgisinin kırılması, satış sinyali olarak yorumlanırken, direnç çizgisinin kırılması alış sinyali olarak yorumlanır. Ancak bu formasyonların güvenilirliği yüksek değildir ve mutlaka diğer teknik analiz araçları ile birlikte kullanılmalıdır.

Örneğin, bir hisse senedinin fiyat grafiğinde yatay bir direnç çizgisi ve yükselen bir destek çizgisi varsa, bu üçgen formasyonunu gösterir. Fiyatlar, destek çizgisine yakınken alıcıların piyasada olduğu, direnç seviyesine yaklaştığında ise satıcıların piyasada olduğu bir aralıkta hareket eder. Fiyatların bu iki seviye arasında gidip gelmesi, üçgen formasyonu olarak adlandırılır. Bu formasyon, yükseliş eğilimi gösteren bir trendin sonunda oluşabilir ve fiyatlar üçgenin alt sınırını kırdığında, satış baskısının artması nedeniyle fiyatlar düşebilir. Aksine, üçgenin üst sınırı kırıldığında, alıcıların güçlenmesi nedeniyle fiyatlar yükselmeye başlayabilir.

Şekil 1.13. Simetrik Üçgen



Kaynak : [Üçgen Formasyonları | InvestAZ](#)

1.5.8. Dikdörtgen Formasyon

Dikdörtgen formasyonu, fiyatların belli bir süre boyunca yatay bir seyir izlediği bir grafik modelidir. Bu formasyonda, destek ve direnç seviyeleri yatay bir çizgi ile birleştirilir ve böylece grafik dikdörtgen şeklini alır.


Dikdörtgen formasyonu, fiyatların yönü hakkında kesin bir fikir vermez, ancak piyasanın yön değiştirebileceği bir dönüm noktası olarak görülebilir. Bu formasyonun görülmesi, piyasanın genellikle bir süre daha yatay seyredeceğini ve yön değiştirmeden önce bir süre daha kararsız kalacağını gösterir. Dikdörtgen formasyonu, diğer formasyonlarla birlikte kullanılarak fiyatların yönü hakkında daha kesin bir tahminde bulunmak için kullanılabilir.

Dikdörtgen formasyonu, yükselen veya düşen bir trendin sırasında belirgin bir aralıkta işlem gören bir varlıkta gözlemlenebilir. Bu formasyonda fiyat, bir destek seviyesi olarak

kabul edilen belirli bir fiyat seviyesinde toplandığında ve bir direnç seviyesi olarak kabul edilen üst bir fiyat seviyesinde satıldığında belirli bir aralıkta işlem görür.

Dörtgen formasyonunda akımın yukarı yönlü kırılması sonucunda işlem hacmi yükselmekte, aşağı kırılması sonucu ise hacim düşmektedir. (Çağırman, 1999, s. 117)

Şekil.1.14.Dikdörtgen Formasyon



Kaynak: <https://teknik-analiz/formasyonlar/>


Örneğin, bir hisse senedinin 50 \$ ile 60 \$ arasında işlem gördüğünü ve bu aralığın destek ve direnç seviyelerini oluşturduğunu varsayalım. Fiyat bu seviyeler arasında dalgalanmaya devam ederken, yatırımcılar fiyatın bir önceki destek veya direnç seviyesine ulaşmasını bekleyerek alım satım kararları alabilirler. Bu nedenle, dikdörtgen formasyonu, yatırımcıların belirli bir aralıkta işlem gören bir varlıkta işlem yaparken fiyat hareketlerini takip etmelerine yardımcı olabilir.

1.5.9. Elmas Formasyon

Elmas formasyonu genellikle yükselen bir trendde meydana gelir ve tepe seviyelerinin giderek yükselmesiyle oluşur. Fiyatlar önce belirgin bir yükseliş trendinde hareket eder, ardından bir düzeltme hareketiyle karşılaşır ve belirli bir seviyede yatay bir seyir izler. Daha sonra fiyatlar tekrar yükselmeye başlar ve belirli bir noktada önceki tepe seviyesine ulaşır. Ancak bu sefer fiyatlar önceki tepe seviyesinde kalmaz ve tekrar geri çekilir. Bu geri çekilme sonrası yatay bir seyir izler ve ardından düşüş trendine geçer. Bu formasyon adını, grafikteki şeklinin elmasa benzemesinden almıştır.

Örnek olarak, XYZ hisse senedi belirli bir süre boyunca yükselen bir trend gösteriyor. Ancak daha sonra bir düzeltme hareketiyle karşılaşılıyor ve bir süre yatay bir seyir izliyor. Daha sonra fiyatlar tekrar yükselmeye başlıyor ve önceki tepe seviyesine kadar çıkıyor. Ancak bu sefer fiyatlar bu seviyede kalamıyor ve geri çekiliyor. Geri çekilme sonrası yatay bir seyir izleyen fiyatlar, daha sonra düşüş trendine geçiyor. Bu fiyat hareketi elmas formasyonunu oluşturuyor.

Şekil.1.15. Elmas Formasyon



Kaynak: <https://teknikanalizformasyonlar.blogspot.com/search/label/Elmas%20Formasyonu>

1.5.10. Çanak Ve Ters Çanak Formasyon

Çanak Dip Formasyon: Çanak (dip) formasyonu, fiyat grafiğinde çanak şeklinde görünen ve genellikle bir düşüş trendinin sona ermesini gösteren bir teknik analiz formasyonudur. Bu formasyon, düşüş trendindeki fiyatların düzeltme hareketine girdiğini gösterir ve genellikle yükseliş trendine dönüş sinyali olarak yorumlanır.

Çanak formasyonunun özellikleri şunlardır:

1. Formasyon, bir düşüş trendinde görülür ve fiyatlar düşerken oluşur.
2. Formasyonun oluşumu sırasında fiyatlar dip seviyelerine ulaşır ve bir süre boyunca bu seviyelerde kalır. Bu dip seviyeleri, formasyonun destek seviyelerini oluşturur.


3. Fiyatlar, dip seviyelerinde konsolide olduktan sonra yavaş yavaş yükselmeye başlar ve formasyonun üst kısmını oluşturacak şekilde tepe noktalarına doğru ilerler.
4. Formasyonun tepe noktaları, destek seviyelerinden daha yüksek bir seviyede bulunur ve çanak şeklini oluştururlar.
5. Formasyon tamamlandığında, fiyatlar tekrar düşmeye başlar ve genellikle önceki destek seviyelerine doğru geri çekilirler.
6. Fiyatlar, önceki destek seviyelerinde tutunurlarsa, çanak formasyonu tamamlanmış olur ve yükseliş trendine dönüş sinyali olarak yorumlanır.

Çanak formasyonu, yatırımcılar tarafından diğer teknik analiz araçları ile birlikte kullanılır ve alım veya satım kararı verirken birlikte değerlendirilir.

Çanak formasyonu, fiyatın birkaç kez dip yaptıktan sonra yavaş yavaş yükseldiği ve bir tavan oluşturduğu bir formasyondur. Bu formasyon, yükselen bir trendin sonunda oluşur ve fiyatlar daha sonra yine yükselişe geçerler.

Örneğin, ABC şirketinin hisse senedi fiyatları son dönemde düşüş yaşamıştır ve birkaç kez dip yapmıştır. Daha sonra, fiyatlar yavaş yavaş yükselmeye başlar ve bir tavan oluşturur. Fiyatlar daha sonra yine yükselişe geçer ve bu çanak formasyonu tamamlanır. Bu formasyon, yatırımcılara fiyatların artacağına dair bir işaret olarak görülebilir.

Şekil.1.16. Dip Çanak Formasyon




Kaynak: <https://www.investaz.com.tr/yatirim/canak-formasyonu>

Ters Çanak Formasyonu: Ters Çanak formasyonu ise, aşağı yönlü bir trendin sonunda ortaya çıkar. Fiyatlar önce düşer, daha sonra bir yere kadar geri çekilir ve bu geri çekilme, ters çanak şeklinde bir yuvarlak tepe oluşturur. Ardından fiyatlar yeniden düşmeye başlar ve önceki dip seviyesine yaklaşır.

Çanak ve Ters Çanak formasyonları, destek ve direnç seviyeleri olarak kullanılabilir ve işlem sinyalleri olarak da yorumlanabilir. Örneğin, çanak formasyonunda, fiyatlar önceki zirve seviyesini geçtiğinde, bu bir alım sinyali olarak yorumlanabilir. Ters Çanak formasyonunda ise, fiyatlar önceki dip seviyesini kırdığında, satış sinyali olarak yorumlanabilir.

Şekil.1.17.Ters Çanak Formasyonu



Kaynak: <https://trend-donus-formasyonlari-canak-ve-ters-canak>

1.5.11. "V" Formasyon


"V" formasyonu, teknik analizde bir yükseliş eğiliminin başarısızlıkla sonuçlandığını gösteren bir dönüş formasyonudur. Bu formasyon, grafikte "V" harfine benzeyen bir şekle sahiptir. Fiyatlar hızla düşer, dip noktasında bir süre konsolide olur ve daha sonra hızla yükselmeye başlar. Bu formasyon, yatırımcılar tarafından trend dönüşünün erken bir işareti olarak yorumlanır.

Bir "V" formasyonu örneği, grafikte hızlı bir düşüş eğilimi sırasında fiyatların ani bir şekilde yükselmesi ve ardından konsolidasyon süresinin ardından daha da yükselmesiyle oluşur. Bu yükseliş genellikle yavaş bir trend izleyerek gerçekleşir ve fiyatlar önceki düşüş seviyesine yaklaşıncaya kadar tekrar test edilir.

“V” formasyonu, düşüş trendindeki bir fiyat grafiğinde, fiyatların hızlı bir şekilde düştükten sonra hızlı bir şekilde yükselmeye başlaması ile oluşan bir formasyondur. Bu formasyon, yatırımcıların aşırı satış yaptığı bir piyasada, düşük fiyat seviyelerinden yararlanmak isteyen yatırımcıların piyasaya yeniden girişiyle meydana gelir.

Örneğin, bir hisse senedinin fiyatı düşüş trendinde iken, belirli bir seviyede alıcılar piyasaya girer ve fiyatların düşüşü durur. Daha sonra, piyasadaki yatırımcıların güveninin artmasıyla, fiyatlar hızlı bir şekilde yükselmeye başlar ve “V” şeklinde bir grafik oluşur.

Şekil.1.18. “V” Formasyonu



Kaynak: <https://teknikanalizformasyonlar.blogspot.com/search/label/V%20Formasyonu>

1.5.12. Takoz Formasyonları

Takoz formasyonları teknik analizde sık kullanılan fiyat formasyonlarından biridir. İki tür takoz formasyonu vardır: yükselen takoz ve alçalan takoz.

Yükselen Takoz Formasyonu : Yükselen takoz formasyonu, fiyatların genişleyen bir kanalda hareket ettiği ve bu kanalın yukarı doğru daraldığı bir teknik analiz formasyonudur. Bu formasyon, genellikle bir boğa piyasasında bulunur ve alıcıların satıcılardan daha güçlü olduğunu gösterir. Bu formasyonun bir diğer özelliği, destek ve direnç seviyelerinin giderek yaklaşmasıdır.

Örnek olarak, ABC şirketinin hisse senedi fiyatının 100 TL'den 110 TL'ye yükseldiğini varsayalım. Daha sonra fiyatlar düşüşe geçer ve 95 TL seviyesine geriler. Ardından fiyatlar tekrar yükselişe geçer ve 105 TL'ye kadar çıkar. Daha sonra fiyatlar

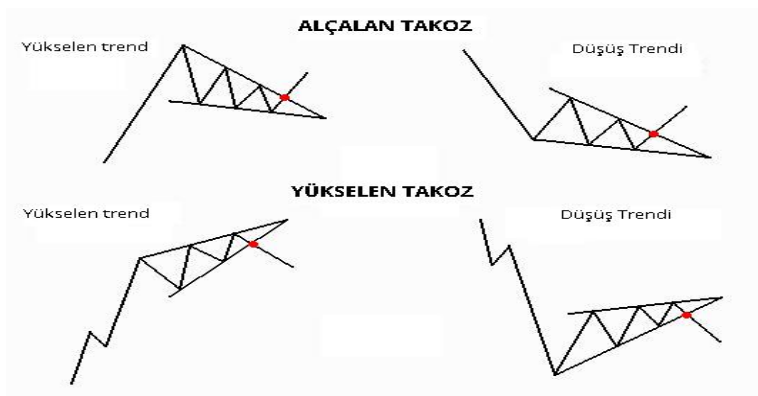
100 TL'ye kadar geriler. Bu aşamada fiyatlar yükselen bir çizgi ve alçalan bir çizgi arasında gidip gelirken bir yükselen takoz formasyonu oluşmaktadır.

Alçalan takoz formasyonu: Alçalan takoz formasyonu, üst çizginin yatay bir direnç seviyesi gibi düz bir çizgi oluşturduğu, alt çizginin ise aşağı yönlü bir eğilim gösterdiği bir fiyat formasyonudur. Formasyon, düşüş trendi sırasında oluşur ve aşağı yönlü eğilimin güç kaybettiğine ve yakın zamanda fiyatların yükselişe geçebileceğine işaret eder. Alçalan takoz formasyonunun bir örneği şöyle gösterilebilir

Yukarıdaki örnekte, alt çizgi aşağı yönlü bir trend gösterirken, üst çizgi yatay bir seviyede direnç oluşturuyor. Fiyatlar bu iki çizgi arasında gidip gelirken, yavaş yavaş sıkışarak birleşir ve takoz formasyonu oluşur. Formasyonun tamamlanması için, fiyatların alt çizginin üzerine çıkması gerekir. Bu, alçalan takoz formasyonunun tamamlandığı ve fiyatların yükselişe geçebileceği anlamına gelir.

Örneğin, bir hisse senedinin 4 saatlik grafikteki fiyat hareketi, alçalan takoz formasyonu oluşturuyor. Hisse senedi fiyatı önce belirli bir seviyede dirençle karşılaşır ve bu direncin etkisiyle fiyatlar düşüyor. Daha sonra bir dip oluşuyor ve fiyatlar yine yukarı doğru hareketleniyor. Ancak bu sefer önceki direnç seviyesinin altında kalıyor. Bu aşamadan sonra hisse senedi fiyatı birkaç kez yükseliş ve düşüşlerle hareket ederken, hem yukarı yönlü hem de aşağı yönlü hareketlerde direnç ve destek seviyeleri giderek birbirine yaklaşıyor. En sonunda hisse senedi fiyatı bu daralan takozun içinde bir noktada kırılıyor ve yönünü belirleyerek güçlü bir hareket başlatıyor.

Şekil.1.19. Takoz Formasyon



Kaynak:

<https://teknikanalizformasyonlar.blogspot.com/search/label/Takoz%20Kama%20Formasyonlar%C4%B1>

1.5.13. Bayrak Formasyonları

Fiyatların hızlı bir şekilde yükselmesi veya düşmesi sonrası belirgin bir düzeltme hareketi yaptıktan sonra tekrar ana trend doğrultusunda hareket etmeye devam etmesi sonucu oluşan grafik desenleridir. Bayrak formasyonları genellikle yatay bir şekilde hareket eden iki paralel trend çizgisi arasında meydana gelir ve düzeltme hareketi sırasında hacimler azalır. Bayrak formasyonları, yükselen bir trendde yükselen bayrak ve düşen bir trendde düşen bayrak olarak adlandırılır.

Örnek olarak, yükselen bir trendde fiyatların hızlı bir şekilde yükseldiği ve ardından bir düzeltme hareketi yaptığı bir grafik düşünelim. Bu düzeltme hareketi sırasında fiyatlar yatay bir şekilde hareket ederken işlem hacmi de azalmaktadır. Daha sonra fiyatlar tekrar yükselmeye başlayarak ana trend doğrultusunda hareket etmeye devam ederler ve bu hareket sırasında yatay bir direnç seviyesi oluşur. Bu direnç seviyesi ile destek seviyesi arasında meydana gelen yatay hareket, bayrak formasyonu olarak adlandırılır.

Şekil.1.20. Bayrak Formasyon



Kaynak: <https://teknik-analiz/formasyonlar/>

1.5.14. Flama Formasyonları

Flag (Flama) formasyonu, yükseliş trendinde oluşan kısa bir ara verme dönemini ifade eder. Fiyat grafiğinde bayrak formasyonuna benzer bir yapıdadır ancak bayrak formasyonundan farklı olarak flama formasyonu daha kısa bir sürede oluşur.

Flama formasyonu, yükselen bir trendde fiyatların belirli bir süre boyunca yatay seyretmesi sonucu oluşur. Bu süre zarfında hacimler genellikle düşüktür. Flama formasyonunda direnç ve destek seviyeleri birbirine paralel çizgiler şeklinde bulunur. Formasyon tamamlandığında, fiyatlar tekrar yükselmeye başlar ve trend devam eder.

Örneğin, bir hisse senedi fiyatı uzun süredir yükselen bir trend içerisinde seyrediyorsa ve belirli bir süre yatay bir seyir izliyorsa, bu durumda fiyat grafiğinde flama formasyonu oluşabilir. Flama formasyonu tamamlandığında, hisse senedi fiyatı tekrar yükselmeye başlayarak trendini sürdürür.

İşlem hacmi, formasyon başlangıcında yüksek olmasına karşın giderek azalmakta ve kırılma noktasından itibaren yükselmeye başlamaktadır. Çoğunlukla boğa piyasasının sonlarında ve ayı piyasasının ikinci kısmında ortaya çıkmaktadır. (Ulusoy, 1994, s. 48)

Şekil.1.21. Flama Formasyon



Kaynak: <http://www.yeniisfikirleri.net/teknik-analizde-formasyonlar/>

1.6. TEKNİK ANALİZ GÖSTERGELERİ

1.6.1.Trend Göstergeleri

1.6.1.1. Hareketli Ortamalar (Moving Average)

Hareketli ortalama (MA), belirli bir zaman dilimi boyunca fiyatların ortalamasını gösteren bir göstergedir. Hareketli ortalamalar, teknik analizde sıklıkla kullanılır ve trendin yönünü belirlemek için kullanılan basit ancak etkili bir araçtır.

Hareketli ortalamalar, kısa vadede belirsiz şekildeki fiyat dalgalanmalarını yumuşatarak teknik analistlerin trendleri takip etmelerini sağlamak amacıyla geliştirilmiştir. Zig zag görünümündedirler ve inişli çıkışlı fiyat hareketlerini yumuşatırlar. Seçilen zaman periyotunun uzunluğuna bağlı farklı boyutlardaki dalgaları düzeltebilirler (Sarı, Borsada Göstergelerle Teknik Analiz, 1998, s. 4).

Hareketli ortalamalar, yumuşatılması istenen gün sayısı kadar fiyatların toplanması ve gün sayısına bölünmesi şeklinde hesaplanır. Bulunan ortalamanın fiyat ile beraber hareket edebilmesi için ortalamanın bulunmasının ardından ilk gün fiyatı toplamdan çıkarılır ve yeni günün fiyatı eklenip, tekrar gün sayısına bölünür (Sarı, Borsada Göstergelerle Teknik Analiz, 1998, s. 5).

Hareketli ortalamaların farklı türleri vardır, örneğin:

1.6.1.1.1. Basit Hareketli Ortalama (Simple Moving Average-SMA)

Belirli bir zaman dilimindeki fiyatların toplamının, bu zaman dilimindeki bar sayısına bölünmesiyle hesaplanır. Bu, fiyat hareketlerindeki kısa vadeli dalgalanmaları azaltır.

1.6.1.3. Ağırlıklı Hareketli Ortalama (Weighted Moving Average-WMA)

SMA'nın aksine, WMA daha yeni fiyatlara daha fazla ağırlık verir. Bu, son fiyatların daha önemli olduğu zamanlarda daha duyarlı bir hareketli ortalama sağlar.

$$AHO_t = \frac{((n)F_t + (n - 1)F_{t-1} + (n - 2)F_{t-2} + \dots + F_n)}{(n + (n - 1) + (n - 2) + \dots + 1)}$$

F = Fiyat

t = Şimdiki tarih

n = Ortalaması alınan süre

(Perşembe, Teknik analiz mi dedin? Hadi canım sen de! 3. Kitap, 2017, s. 38).

1.6.1.1.2.Üstel Hareketli Ortalama (Exponential Moving Average-EMA)

Bu hareketli ortalama, daha yeni fiyat hareketlerine daha fazla ağırlık vererek, daha hızlı bir tepki süresi sağlar. Bu, son fiyatların daha önemli olduğu zamanlarda daha hassas bir hareketli ortalama sağlar.

$$\dot{I}HO_t = \dot{I}HO_{t-1} + (DF \times (F_t - \dot{I}HO_{t-1}))$$

$\dot{I}HO_t$ = Üslü Hareketli Ortalama

F = Fiyat

t = Şimdiki tarih

n = Ortalaması alınan süre

DF = Düzenleme Faktörü (2 / (n+ 1))

(Perşembe, Teknik analiz mi dedin? Hadi canım sen de! 3. Kitap, 2017, s. 39)

1.6.1.1.3.Değişken Hareketli Ortalama (VMA)

Bu hareketli ortalama, fiyat hareketlerindeki volatiliteye dayalı olarak değişen ağırlıklar kullanır. Bu, piyasanın hareketliliğine uyum sağlamak için daha hassas bir hareketli ortalama sağlar.

1.6.1.3. Aroon Göstergesi

Aroon göstergesi, trendin gücünü ve yönünü ölçmek için kullanılan bir teknik analiz aracıdır. Aroon göstergesi, bir varlığın en yüksek ve en düşük fiyatlarının zaman içindeki değişimlerini takip eder.

Aroon göstergesi, iki ayrı çizgiden oluşur: Aroon Up ve Aroon Down. Aroon Up, en yüksek fiyatın ne kadar süre önce oluştuğunu gösterirken, Aroon Down, en düşük fiyatın ne kadar süre önce oluştuğunu gösterir. Her iki çizgi de 0 ila 100 arasında bir değer alır ve 100'e yakın bir değer, trendin güçlü olduğunu gösterirken, 50'nin altındaki bir değer, trendin zayıf olduğunu gösterir.

Aroon göstergesi, genellikle bir varlığın trendinin ne kadar güçlü olduğunu belirlemek için kullanılır. Ayrıca, fiyatın kırılma noktalarını ve trend dönüşlerini tespit etmek için de kullanılabilir. Ancak, herhangi bir teknik analiz aracı gibi, Aroon göstergesi de yanlış sinyaller verebilir ve diğer analiz yöntemleriyle birlikte kullanılması önerilir, Aroon Down, Aroon Up değerini aşağıdan yukarı doğru kesiyor ve üzerine çıkıyor ise fiyatlarda düşüş ve aşağı yönlü trend beklentisi oluşmaktadır. Aroon Up aşağıdan gelip Aroon Down değerini yukarı doğru kesiyor ve üzerine çıkıyor ise fiyatlarda artış ve yukarı yönlü trend beklentisi oluşmaktadır (Mergen, 2005, s. 351).

Şekil.1.22.Aroon Göstergesi



Kaynak: trade.isbank.com.tr

1.6.1.4. Duple Üslü Hareketli Ortalama (Double Exponential Moving Average - DEMA)

Patrick Mulloy tarafından geliştirilen ve Şubat 1994'te "Technical Analysis of Stocks and Commodities" dergisinde yayınlanan DEMA, basit üslü ve duple üslü hareketli ortalamaların kombinasyonundan oluşur. Fiyat ve zaman serilerini yumuşatmak, gecikmeyi azaltmak ve diğer teknik gösterge değerlerinin düzeltilmesi amacı ile kullanılır. Bu ortalama dönüş sinyallerinin hızla tespit edilmesini sağlar.

DEMA EMA'ya göre fiyatları daha önceden takip eder. Hareketli ortalama kullanıcılarına zamanlama bakımından fayda sağlayabilir (Mergen, 2005, s. 365).

Şekil.1.23. EMA ve DEMA



Kaynak: trade.isbank.com.tr

1.6.1.5. MACD (Moving Average Convergence Divergence)

MACD, Moving Average Convergence/Divergence (Hareketli Ortalama Yakınsama / Ayrışma) kısaltmasıdır. Bu teknik analiz göstergesi, iki hareketli ortalama çizgisinin arasındaki farkın alınmasıyla oluşur.

Bu iki hareketli ortalama genellikle 12 ve 26 günlük periyotlarda hesaplanır. Bu iki çizginin arasındaki farkın hareketli ortalaması MACD çizgisini oluşturur. MACD çizgisinin bir sinyal çizgisi ile kesimi, alım veya satım sinyali olarak yorumlanabilir. Sinyal çizgisi genellikle 9 günlük bir hareketli ortalamadan oluşur.

MACD, trend takibi ve trend değişikliklerini tespit etmek için kullanılır. Pozitif veya negatif sapmalar, yani fiyatlarla MACD arasındaki farkın artması veya azalması, trend değişimlerinin işaretçisi olabilir. trend ve momentum göstergesi olarak kullanılan bir teknik analiz aracıdır. Hareketli ortalamaları kullanarak oluşturulur ve trendlerin yönü hakkında bilgi sağlar. Ayrıca, fiyatın hızı ve momentumu hakkında da fikir verir.

26 günlük üssel hareketli ortalama (EMA) ile 12 günlük EMA arasındaki farkı hesaplayarak oluşturulur. Bu fark, MACD hattı olarak adlandırılır. MACD hattının 9 günlük üssel hareketli ortalaması, sinyal çizgisi olarak adlandırılır. MACD hattı, sinyal

çizgisini yukarı yönde keserse, alım sinyali olarak yorumlanır. Sinyal çizgisi, MACD hattının altına düşerse, satım sinyali olarak yorumlanır.

MACD göstergesi ayrıca histogram olarak da görüntülenebilir. Histogram, MACD hattının sinyal çizgisinden çıkarılmasıyla oluşur. Histogramın yükselişi, fiyatın yükseliş momentumu arttığını gösterirken, düşüşü fiyatın düşüş momentumunun arttığını gösterir.

Yatırımcıların trendleri belirlemesine, potansiyel trend dönüşlerini tespit etmesine ve alım satım sinyalleri oluşturmasına yardımcı olabilir. Ancak, her teknik analiz aracı gibi, tek başına kullanılmamalı ve diğer analiz yöntemleriyle birlikte kullanılmalıdır.

Örneğin, bir hissenin 12 günlük EMA'sı 50 günlük EMA'sını yukarı yönlü kestiğinde, bu bir alım sinyali olarak yorumlanabilir. Bu durum, MACD hattının sıfır çizgisini yukarı yönlü kestiği ve histogramın pozitif bölgede yer aldığı bir MACD grafiğinde de görülebilir. Bu, fiyatın bir yükseliş eğiliminde olduğunu ve potansiyel bir yükseliş trendinin başladığını gösterir.

MACD çizgisi, tetik çizgisini aşağıdan yukarı doğru keser ve tetik çizgisinin üzerine çıkarsa AL, MACD çizgisi tetik çizgisini yukarıdan aşağıya doğru keserek tetik çizgisinin altına düşerse SAT sinyali oluşur. Kesişimler merkez bölge yani 0 çizgisine negatif olarak çok uzakta oluşuyorsa alım sinyali güçlü ve uzun süreli olabilir (Mergen, Kurtlarla Tango Göstergelerle Borsa Süper Teknik Analiz, 2005, s. 143).

Şekil.1.24.MACD Göstergesi



Kaynak: <https://tr.tradingview.com/>

1.6.1.6. Parabolik SAR

Parabolic SAR (Stop and Reverse), teknik analizde bir trend takip göstergesidir. SAR, "dur ve tersine dön" anlamına gelir. Gösterge, bir varlığın fiyatı yükseldiğinde veya düştüğünde, varlığın trend yönünü takip etmek için kullanılır. fiyat hareketlerine dayalı olarak bir dizi nokta oluşturur. Bu noktalar, fiyatın altında veya üstünde bulunur. Bir trendin yönü değiştiğinde, SAR noktaları fiyat hareketi tarafından kesilir ve pozisyon tersine çevrilir.

Bir varlığın fiyatı yükselmeye başladığında, Parabolic SAR noktaları altında bulunur ve fiyatın yükselmeye devam etmesi beklenir. Fiyatın düşmeye başlamasıyla birlikte, noktalar fiyatın üstüne çıkar ve fiyatın düşmesi beklenir. Bu nedenle, SAR noktaları, trendin yönünü takip etmek için kullanılan bir gösterge olarak kabul edilir.

Parabolic SAR, bir varlığın fiyat hareketlerinde meydana gelen trend değişikliklerini tanımlamaya yardımcı olabilir. Gösterge, yatırımcıların bir varlık üzerinde ne zaman alım veya satım yapacaklarına karar vermelerine yardımcı olabilir. Ancak, yalnızca tek başına Parabolic SAR kullanarak işlem yapmak tavsiye edilmez. Diğer göstergelerle birlikte kullanıldığında daha etkili olabilir.

“Parabolik SAR göstergesi, fiyatların olduğu yeri ve alış satış noktaları için iyi sinyaller verir. Ama verdiği sinyaller gecikmelidir. Diğer göstergelerle birlikte destekleyici olacak şekilde kullanılması tavsiye edilebilir. Yatırımcılar tarafından açığa satış, stop loss düzeylerinin tespit edilmesi işlemleri için kullanılmaktadır.”

(Aksoy & Tanrıöven, 2014, s. 624).

Parabolik SAR HESAPLAMA FORMULU

Parabolik SAR hesaplama formülü şöyledir:

AF = başlangıçtan sonraki her adımda artırılan hız faktörü E_{Pt} = t-barının en yüksek fiyatı
 A_{Ft-1} = t-1-barında kullanılan hız faktörü SAR_{t-1} = t-1-barındaki SAR değeri LONG
veya SHORT = uzun veya kısa pozisyon

İlk SAR değeri, ilk EP değerine eşittir:

$$SAR = EP1$$

İkinci adımdan itibaren, SAR değeri şu şekilde hesaplanır:

$$SAR_t = SAR_{t-1} + AF_{t-1} \times (EP_{t-1} - SAR_{t-1})$$

Burada SAR_t, t-barındaki SAR değerini, AF_{t-1}, t-1-barında kullanılan hız faktörünü, EP_{t-1}, t-1-barındaki en yüksek fiyatı ve SAR_{t-1}, t-1-barındaki SAR değerini ifade eder.

EP değeri, LONG veya SHORT pozisyona bağlı olarak şu şekilde hesaplanır:

LONG pozisyonu için EP_t = maksimum yükseklik değeri (yani, günün en yüksek değeri)

SHORT pozisyonu için EP_t = minimum düşük değer (yani, günün en düşük değeri)

Hız faktörü (AF) başlangıçta 0,02'dir ve 0,02'lik bir artışla maksimum 0,20'ye kadar artırılabilir.

Şekil.1.25.Parabolik Göstergesi



Kaynak: <https://tr.tradingview.com/>

1.6.1.7. ADX (Average Directional Index)

ADX (Average Directional Index), bir varlığın trendin ne kadar güçlü olduğunu ölçmek için kullanılan bir teknik analiz göstergesidir. Bu gösterge, trendin gücünü ve yönünü belirlemek için kullanılan diğer teknik göstergelerle birlikte kullanılabilir. Bir varlığın yön değiştirdiği veya trendin zayıfladığı dönemleri belirlemek için de kullanılır.

Genellikle, ADX değeri 25'ten büyük olduğunda, bir trendin güçlü olduğu kabul edilir. ADX değeri 25'in altındaysa, bir trendin zayıf olduğu veya yok olduğu kabul edilir.

ADX, bir dizi doğrusal hareketli ortalama ve pozitif yönlü hareketli ortalama arasındaki farkın mutlak değerinin hareketli ortalaması olarak hesaplanır. Sonuç, bir aralıkta yer alır ve genellikle 0 ila 100 arasında değişir. ADX, J. Welles Wilder Jr. tarafından geliştirilmiştir ve birçok teknik analist tarafından kullanılmaktadır. Bu gösterge, özellikle trend takibi stratejilerinde kullanılan birçok başka teknik göstergeyle birlikte kullanılabilir çok yönlü bir araçtır.

ADX var olan piyasadaki en uygun göstergenin bulunmasına yardımcı olması için bir süzgeç olarak kullanılmalıdır (Murphy, 1998, s. 143).

Şekil.1.26.ADX GÖSTERGESİ



Kaynak: <https://tr.tradingview.com>

1.6.2.Momentom Göstergeleri

1.6.2.1. Momentom Göstergeleri (MOM)

Momentum, fiyatların hızını ve değişim oranını ölçen bir göstergedir. Fiyatların artış veya düşüş yönündeki ivmelerini ölçerek trend değişimlerinin olası olduğu noktaları tespit etmede kullanılır,kapanış fiyatının belirli bir dönem öncesine göre yüzdelik değişimini hesaplar. Genellikle 10, 14 veya 20 günlük dönemler kullanılır. Pozitif momentum, kapanış fiyatının belirli bir dönem öncesine göre arttığını gösterirken, negatif momentum ise kapanış fiyatının azaldığını gösterir.

ayrıca bir referans çizgisi olan sıfır çizgisi ile birlikte kullanılır. Pozitif bir momentum göstergesi, sıfır çizgisinin üzerinde yer alırken, negatif bir momentum göstergesi sıfır çizgisinin altında yer alır. Momentum göstergesi, ayrıca hareketli ortalamalar ve diğer göstergelerle birlikte kullanılarak daha doğru sinyaller üretilebilir.

Örneğin, bir hisse senedinin fiyatı sürekli olarak artarken, momentum göstergesi de pozitif olacaktır. Ancak hisse senedi fiyatı düşmeye başlarsa, momentum göstergesi de negatife dönecektir. Bu, trendin zayıfladığını ve olası bir trend değişikliğinin olabileceğini gösterir.

Kısaca, yükselen momentum endeksi, fiyatların momentumunun yükselişi (trendin sağlamlığını) alçalan momentum ise fiyatların yükseliş hızını yitirdiğini, yani piyasanın zayıfladığını gösterir. Yükselen momentum piyasanın yükselişine (boğa piyasası) alçalan momentum ise düşüşüne (ayı piyasası) işaret etmektedir.

(ANON., 2009, İMKB Eğitim Seti: Hisse Senetleri Piyasası - Grafikler ve Teknik Analiz)

Şekil.1.27. MOMENTOM Göstergesi



Kaynak: <https://tr.tradingview.com/script/cYl84KJB-Momentum-Ratio-Oscillator-Loxx/>

1.6.2.2. Stokastik (Stochastics) Osilatör

Stokastik, bir yatırım aracının kapanış fiyatlarını en düşük ve en yüksek düzeylere göre ölçer, dönüş sinyali üretir. Aynı zamanda aşırı alış ve satış bölgelerinin tespit edilebilmesini sağlar (Münyas & Atasoy, 2019, s. 156).


Stokastik Osilatörü, fiyatın son kapanış fiyatının, belirli bir zaman dilimi boyunca gözlemlenen en yüksek ve en düşük fiyatlar arasındaki ilişkiyi ölçen bir göstergedir. Bu gösterge, kısa vadeli aşırı alım ve aşırı satım durumlarını tespit etmek için kullanılır.

Genellikle 0 ile 100 arasında bir aralıkta hareket eder. Gösterge, genellikle %K ve %D olmak üzere iki satırdan oluşur. %K satırı, günün kapanış fiyatı ile en düşük fiyat arasındaki farkı en yüksek fiyat ile en düşük fiyat arasındaki farka bölerek hesaplanır. %D satırı, %K satırının hareketli ortalamasını temsil eder.

Stokastik osilatörü, aşırı alım veya aşırı satım sinyalleri verdiğinde kullanışlıdır. %K çizgisi %D çizgisinin üzerindeyken, varlık aşırı alım bölgesinde olabilir ve fiyatın düşmesi beklenebilir. %K çizgisi %D çizgisinin altındaysa, varlık aşırı satım bölgesinde olabilir ve fiyatın yükselebileceği düşünülebilir.

Stokastik Osilatörü, bir finansal varlığın kapanış fiyatlarının son dönemdeki değişim hızını ölçen bir momentum göstergesidir. Gösterge, %K ve %D olmak üzere iki çizgiden oluşur. %K çizgisi, son fiyatın belirli bir zaman dilimindeki en yüksek ve en düşük değerleri ile birlikte hesaplanan bir formül kullanılarak bulunur. Bu çizgi, genellikle 14 periyot kullanılarak hesaplanır. %D çizgisi ise %K çizgisinin hareketli ortalamasıdır ve genellikle 3 periyotlu bir hareketli ortalamadır.

Şekil.1.28.Stokastik Osilatör



Kaynak: <https://www.investaz.com.tr/blog/stokastik-gostergesi-kullanimi/>

1.6.2.3. RSI (Relative Strength Index) Göreceli Güç İndeksi

RSI (Relative Strength Index) Göreceli Güç İndeksi, teknik analizde sıkça kullanılan bir momentum osilatörüdür. RSI, bir finansal enstrümanın güçlü yanını ölçer ve bu gücü yüzdesel olarak ifade eder. Bu gösterge, özellikle aşırı alım veya aşırı satım koşullarını belirlemek için kullanılır.

RSI genellikle 14 periyodluk bir süre boyunca hesaplanır. Bu hesaplama, fiyatların yükselişleri ve düşüşleri arasındaki farkları toplar ve sonucu 14 ile böler. Sonuç, 0 ile 100 arasında bir sayıdır. 70 ve üstü RSI değerleri, aşırı alım koşullarını gösterirken, 30 ve altındaki değerler aşırı satım koşullarını gösterir.


RSI ayrıca, fiyat hareketleri ile uyumsuzluklar veya trend dönüşleri ile ilgili sinyaller veren "uyumsuzluklar" için de kullanılır. Bu, fiyatların yükselirken RSI'nin düşmesi veya fiyatların düşerken RSI'nin yükselmesi durumunda oluşur.

Örneğin, bir finansal enstrümanın fiyatı yükselirken RSI değeri 70'in üzerindeyse, aşırı alım koşulları olduğu ve fiyatın düşebileceği konusunda bir uyarı sinyali verebilir. Tam tersi durumda, fiyatlar düşerken RSI değeri 30'un altına inerse, aşırı satım koşulları olduğu ve fiyatın yükselebileceği konusunda bir uyarı sinyali verebilir.

Wilder, RSI için 14 günlük periyot kullanmıştır. Göstergenin fiyat akımlarına gösterdiği tepki ne kadar duyarlıysa o kadar çok sinyal alınır. Bu durum hem riskin hem de işlem maliyetlerinin artmasına neden olur. Diğer taraftan, seçilen işlem süresi ne kadar uzunsa RSI fiyatlara o denli düşük tepki gösterir, sinyal sayısı azalır. Kısaca düşük sinyal, az pozisyon ve daha az riske neden olur. Ancak fiyatların tepe ve dip hareketleri de geç yakalanacaktır.

(Perşembe, Teknik analiz mi dedin? Hadi canım sen de! 3. Kitap, 2017, s. 134).

Şekil.1.29. RSI Göstergesi



Kaynak: <https://teknikanalizformasyonlar.blogspot.com/search/label/RSI%20%C4%B0ndikat%C3%B6r%C3%BC>

1.6.2.4. CCI (Commodity Channel Index) Emtia Kanalı İndeksi

Donald Lambert'in 1980'lerde mal piyasaları için geliştirdiği gösterge yatırımcılara, kısa vadeli fiyat dalgalanmalarının aşırı alıŖ ve satıŖ bölgelerine ulaŖtığını göstermektedir. Pay senetlerinin alım satım iŖlemleri için de kullanılmaktadır. Hesaplamalar günlük ortalama fiyatlar veya kapanıŖ fiyatları ile yapılabilir. (Mergen, Kurtlarla Tango Göstergelerle Borsa Süper Teknik Analiz, 2005, s. 254).

Formülü;

$$CCI: \frac{(Ortalama Fiyat) - (Ortalama Fiyatın Hareketli Ortalaması)}{(Elde Edilen Farkın Hareketli Ortalaması) \times (Sabit Katsayı)}$$

Gösterge eksenini +100 ve -100 ile sınırlandırılmıştır. Yatay gelişen trendlerde isabetli sonuçlar vermektedir. Lambert göstergeninin pay senetlerinde 5 ile 25 gün arasındaki periyotların kullanımını tavsiye etmektedir. (Sarı, Borsada Göstergelerle Teknik Analiz, 1998, s. 51).

emtia piyasalarında fiyatların aşırı alım veya satım seviyelerini belirlemek için kullanılan bir momentum göstergesidir. CCI, genellikle +100 ile -100 arasındaki

değerlerle ifade edilir ve bu değerler üzerindeki seviyeler aşırı alım, altındaki seviyeler ise aşırı satım sinyali olarak yorumlanır.

Örnek olarak, ABC hisse senedi için 14 günlük CCI hesaplanmış ve sonuç +120 çıkmıştır. Bu değer, +100 seviyesinin üzerinde olduğu için aşırı alım sinyali olarak yorumlanabilir. Bu durumda, yatırımcılar hisse senedinin fiyatının kısa süre içinde düşebileceğini ve bu nedenle hisse senedini satmayı veya kısa pozisyon açmayı düşünebilirler.

Şekil.1.30. CCI Göstergesi



Kaynak: <https://tr.tradingview.com>

1.6.2.5. ROC (Rate Of Change) Değişim Oran Yüzdesi

ROC (Rate of Change), Türkçe anlamıyla değişim oranı yüzdesi, fiyatların ne kadar hızlı veya yavaş değiştiğini ölçmek için kullanılan bir teknik analiz göstergesidir. ROC göstergesi, bir varlığın fiyatındaki değişimin yüzdesini hesaplar ve gösterir. genellikle 14 periyotluk bir zaman diliminde kullanılır. Bu, son 14 periyotta fiyatların ne kadar değiştiğini ölçmek için yapılır. ROC, pozitif veya negatif olabilir. Pozitif ROC, fiyatların arttığını gösterirken, negatif ROC, fiyatların düştüğünü gösterir. ROC göstergesi, fiyat eğilimlerini belirlemek, trendleri doğrulamak ve aşırı alım/satım koşullarını tespit etmek için kullanılır.

Örnek olarak, bir hisse senedinin fiyatı son 14 periyotta 10 TL'den 12 TL'ye yükseldiğinde, ROC göstergesi 20 olur. Bu da fiyatın son 14 periyotta %20 arttığını gösterir. Tam tersi durumda, hisse senedinin fiyatı son 14 periyotta 12 TL'den 10 TL'ye düştüğünde, ROC göstergesi -16.67 olur. Bu da fiyatın son 14 periyotta %16.67 oranında düştüğünü gösterir.

Momentum ile aynı sinyalleri üretir ve aynı şekilde yorumlanır. Formülü;

$$ROC = (F_t / F_{t-n}) \times 100$$

F_t = En son fiyat

F_{t-n} = n periyot önceki fiyat

(Perşembe, Teknik analiz mi dedin? Hadi canım sen de! 3. Kitap, 2017, s. 158).

Şekil.1.31. ROC Göstergesi



Kaynak : <https://.com/tr/roc-indicator-for-metatrader-4/>

1.6.3. Volatilite Göstergeleri

1.6.3.1. Bolinger Bantlar

Bollinger Bantları, teknik analizde sıklıkla kullanılan bir göstergedir ve fiyatın belirli bir periyotta aldığı hareketlerin standart sapmasına dayalı olarak hesaplanır. Bu gösterge, fiyatların olası destek ve direnç seviyelerini tespit etmek için kullanılabilir.

Bollinger Bantları, 3 çizgiden oluşur: orta çizgi, üst bant ve alt bant. Ortalama fiyat hareketi için hareketli bir ortalama kullanılarak hesaplanan orta çizgi, üst bant ve alt bant ise bu hareketli ortalamanın belirli bir standart sapma değeri kadar üstünde ve altında yer alan iki çizgidir. Bu standart sapma değeri genellikle 2 olarak belirlenir, ancak kullanıcılar farklı değerler de seçebilirler. volatilité arttığında genişler ve volatilité azaldığında daralır. Bu nedenle, bantlar sıkıştığında, piyasanın yön deęiştireceğine dair bir işaret olabilir.


Örneğin, Bollinger Bantları göstergesi, bir hisse senedinin fiyat hareketlerini analiz etmek için kullanılabilir. Eđer fiyatlar üst banttán geçerse, hisse senedi aşırı alım bölgesine girmiş olarak deęerlendirilebilir ve düşüş olasılıęı artar. Öte yandan, eđer fiyatlar alt banda dokunursa, hisse senedi aşırı satım bölgesine girmiş olarak deęerlendirilebilir ve yükseliş olasılıęı artar.

Hesaplama da kapanış fiyatları kullanılmaktadır. Eđer bant çizgileri keskin bir şekilde yukarı veya aşağı yönde hareket etmiyorlarsa fiyatlar çizgilerin dışına çıktığında akımın devam ettięi varsayılmaktadır. Bollinger, hareketli ortalamanın etrafındaki iki standart sapmanın kullanılmasını tavsiye etmektedir. Teoride 2 standart sapma genellikle bütün fiyat verilerini içermektedir. Belirttięi kadarı ile de 2 standart sapma hesaplamasındaki kareye alma işle mi kısa dönem fiyat hareketlerini oldukça iyi takip edebilmektedir (Mergen, Kurtlarla Tango Göstergelerle Borsa Süper Teknik Analiz, 2005, s. 107).

Fiyatların üst bant sınırına yaklaşması satış, alt bant sınırına yaklaşması alış sinyali oluşturur. Fiyatlar bazen orta banda çarparak ters yönde hareket edebilmektedir.

(Aksoy & Tanrıöven, 2014, s. 614).

Şekil.1.32. Bolinger Bantlar



Kaynak : [https:// bollinger-bantlari/](https://bollinger-bantlari/)

1.6.3.2. Ortalama Gerçek Aralık (Average True Range - ATR)

Finansal piyasalarda kullanılan bir teknik analiz göstergesidir. ATR, bir varlığın fiyatındaki oynaklığı ölçmek ve potansiyel trend değişikliklerini belirlemek için kullanılır.

ATR, belirli bir zaman diliminde (genellikle 14 periyot) varlık fiyatındaki gerçek aralıkların ortalamasını hesaplar. Gerçek aralık, o günün en yüksek ile en düşük fiyatı arasındaki farkı ifade eder. ATR, fiyat hareketlerindeki oynaklıkla ilgilenir, yani fiyatın ne kadar değişebileceğini ölçmeye çalışır.

ATR, volatilitiyi ölçmek için kullanıldığından, özellikle trend takibi ve stop-loss seviyelerinin belirlenmesi gibi stratejik kararlar almak için yatırımcılar tarafından sıklıkla kullanılır. Yüksek ATR değerleri, genellikle artan volatiliteye işaret ederken, düşük ATR değerleri düşük volatilitiyi gösterir. ATR'nin yönü veya eğimi, fiyat trendindeki değişikliklerin bir işareti olarak yorumlanabilir. birçok teknik analiz göstergesi ve stratejiyle birlikte kullanılabilir. Örneğin, hareketli ortalamalarla birlikte kullanıldığında, ATR, stop-loss seviyelerinin belirlenmesine yardımcı olabilir. ATR'nin değeri, yatırımcıya bir varlık için uygun bir stop-loss seviyesi belirlemede yardımcı olurken, aynı zamanda potansiyel kar hedeflerini de belirlemesine yardımcı olabilir.

ATR, volatiliteye dayalı kararlar alırken kullanılan önemli bir araçtır, ancak tek başına yeterli değildir. Diğer teknik analiz araçları ve piyasa koşullarının tam bir analizi ile birlikte kullanıldığında daha etkili sonuçlar elde edilebilir.

1.6.3.3. Zarflar (Envelopes)

teknik analizde kullanılan bir göstergedir. Zarflar, bir varlık fiyatının üst ve alt bantlarını tanımlayan ve fiyatın bu bantlar içinde hareket ettiği durumları belirlemeye yardımcı olan bir göstergedir.

Zarflar yapı bakımından Bollinger bantlarına benzemektedir. Fiyatların üst ve alt limitler içinde hareket etmesi için iki ayrı eğri çizilir (Erdoğan, 2004, s. 357).

Zarflar, bir hareketli ortalamanın belirli bir yüzdesiyle üst ve alt bantlar oluşturur. Genellikle hareketli ortalama olarak Basit Hareketli Ortalama (Simple Moving Average - SMA) veya Üstel Hareketli Ortalama (Exponential Moving Average - EMA) kullanılır. Örneğin, %5 zarflar kullanılıyorsa, üst bant, hareketli ortalamanın %5 yukarısında ve alt bant, hareketli ortalamanın %5 aşağısında olacaktır. fiyatın bantlar içinde nasıl hareket ettiğini değerlendirmek ve potansiyel alım-satım sinyalleri üretmek için kullanılır. Örneğin, fiyat alt banda ulaştığında, varlık aşırı satım bölgesinde olabilir ve alım fırsatı olabilir. Benzer şekilde, fiyat üst banda ulaştığında, varlık aşırı alım bölgesinde olabilir ve satış fırsatı olabilir.

volatiliteye dayalı bir gösterge olduğundan, volatilitenin arttıkça bant genişlerken, volatilitenin azaldıkça bant daralır. Bu nedenle, zarflar aynı zamanda volatilitenin değişimlerini takip etmek için de kullanılabilir.

Zarflar, diğer teknik analiz araçları ve göstergelerle birlikte kullanılarak daha sağlam sonuçlar üretebilir. Ayrıca, her yatırımcının kendi stratejilerine ve tercihlerine göre ayarlamalar yapabileceği birçok farklı zarf türü ve parametreleri mevcuttur.

1.6.3.4. İzdüşüm Osilatörü (Projection Oscillator)

İzdüşüm Osilatörü (Projection Oscillator), teknik analizde kullanılan bir göstergedir. Bu osilatör, bir varlığın trendini tahmin etmek ve potansiyel dönüş noktalarını belirlemek amacıyla kullanılır. İzdüşüm Osilatörü, hareketli ortalamaların ilişkisine dayanır.

Genellikle üç hareketli ortalama kullanılır: kısa vadeli (genellikle 10 periyot), orta vadeli (genellikle 20 periyot) ve uzun vadeli (genellikle 30 periyot) hareketli ortalamalar.

Bu osilatör, kısa vadeli hareketli ortalamanın, orta vadeli hareketli ortalama üzerine yükseldiği durumlarda pozitif değerler üretir ve aşağı indiği durumlarda negatif değerler üretir. Benzer şekilde, orta vadeli hareketli ortalama, uzun vadeli hareketli ortalamanın üzerine yükseldiğinde pozitif değerler üretirken, aşağı indiğinde negatif değerler üretir. bu hareketli ortalama ilişkisini kullanarak trendin gücünü ve potansiyel dönüş noktalarını göstermeye çalışır. Pozitif değerler yükseliş trendini, negatif değerler ise düşüş trendini gösterir. Osilatör, sıfır çizgisi üzerinde dalgalanır ve yön değişikliklerine tepki verir.

Izdüşüm Osilatörü, diğer osilatörler gibi aşırı alım ve aşırı satım bölgelerini belirleme amacıyla kullanılmaz. Bunun yerine, trendin gücünü ve trendin zayıflayabileceği noktaları görmek için kullanılır. Örneğin, osilatörün pozitif değerlerden negatif değerlere dönmesi, yükseliş trendinin zayıflayabileceği veya dönüş sinyali olabileceği anlamına gelebilir. farklı yatırımcıların tercihlerine ve stratejilerine bağlı olarak ayarlanabilir. Periyotlar ve hareketli ortalamaların değerleri özelleştirilebilir. Ayrıca, diğer teknik analiz araçları ve göstergelerle birlikte kullanılarak daha sağlam sonuçlar elde edilebilir.

Gösterge, 80 düzeyinin üzerine çıkıp bu seviyeden düşüyorsa satış, 20 seviyesinin altına inip bu seviyeden yükseliyorsa alış sinyali vermektedir. Fiyatlar bant dışına çıkamazlar (Erdinç, 2004, s. 491).

1.6.4. Hacim Göstergeleri

1.6.4.1. AD (Accumulation/Distribution Index) Biriktirim/Dağıtım İndeksi

Accumulation/Distribution Index (AD), hisse senedi fiyatlarındaki değişimleri ve hacimleri birlikte değerlendirerek trendin gücünü ve hacmin yönünü gösteren bir teknik analiz göstergesidir. Hacim verilerini kullanarak bir hisse senedinin birikim veya dağıtım aşamasında olup olmadığını belirlemeye yardımcı olur ,birikim veya dağıtım sürecindeki bir hisse senedinin fiyat trendinin değişeceği veya devam edeceği konusunda sinyal verir. Pozitif AD değerleri birikimi, negatif AD değerleri ise dağıtımı temsil eder.

AD değeri, günlük kapanış fiyatının önceki günün kapanış fiyatına göre değişim yüzdesine ve o günkü hacme bağlı olarak hesaplanır.

$$AD = \text{Önceki Günün AD} + \frac{[(\text{Kapanış Fiyatı} - \text{Bir Önceki Günün En Düşük Fiyatı}) - (\text{Bir Önceki Günün, En Yüksek Fiyatı} - \text{Kapanış Fiyatı})]}{(\text{Bir Önceki Günün, En Yüksek Fiyatı} - \text{Önceki Günün En Düşük Fiyatı})} \times \text{Hacim}$$

AD göstergesi, hisse senedi fiyatlarındaki değişimleri ve hacimleri analiz ederek alım ve satım kararları almak için kullanılabilir. Pozitif AD değerleri birikimi, negatif AD değerleri ise dağıtımı temsil eder. Gösterge, piyasada hisse senedinin nereye gidebileceği hakkında ipuçları sağlamak için diğer teknik analiz araçları ile birlikte kullanılabilir.

1.6.4.2. CO (Chaikin Oscillator) Chaikin Osilatörü

Chaikin Osilatörü (CO), bir varlığın fiyatındaki değişimleri ve hacim değişikliklerini analiz etmek için kullanılan bir momentum göstergesidir. Bu gösterge, bir varlığın fiyat hareketinin yönü ve gücü hakkında bilgi sağlar. CO göstergesi, bir varlığın alım veya satım baskısının ne kadar güçlü olduğunu gösteren bir osilatördür.

CO göstergesi, bir varlığın fiyat hareketi ve hacim verilerini kullanarak hesaplanır. Gösterge, bir varlığın kapanış fiyatının ve fiyat aralığının ortalaması (en yüksek fiyat - en düşük fiyat) arasındaki farkın, belirli bir süre boyunca (genellikle 3 ve 10 gün) hesaplanan hacim ağırlıklı ortalamasının çıkarılmasıyla elde edilir. sıfır çizgisinin üzerinde veya altında dalgalanır. Pozitif bir değer, bir varlığın fiyatındaki artışa işaret ederken, negatif bir değer, bir varlığın fiyatındaki düşüşe işaret eder. CO göstergesi, alım veya satım sinyalleri üretebilir ve trendin devam edip etmeyeceği hakkında da bilgi sağlayabilir.

Chaikin Osilatörü (CO), kısa vadeli bir momentum göstergesi olarak kullanılan bir osilatördür. Akım hacimleri ve hareketli ortalamalar kullanarak fiyat ve hacim arasındaki uyumsuzluğu ölçer. CO, akım hacmi göstergesi (AC) ve Hareketli Ortalama Yakınsama / Iraksama (MACD) göstergelerinin bir kombinasyonudur. Bu gösterge, piyasanın yönünü belirlemek ve ticaret fırsatlarını belirlemek için kullanılabilir.

CO'nun hesaplanması için, 3 ve 10 periyotluk hareketli ortalamalar kullanılarak Akım Hacmi Göstergesi (AC) hesaplanır. Sonra, 10 periyotluk AC'den 3 periyotluk AC

çıkarılır. Elde edilen sonuç, Chaikin Osilatörü olarak adlandırılır. pozitif veya negatif değerlerle ifade edilir. Pozitif bir değer, piyasanın yükseliş eğiliminde olduğunu gösterirken, negatif bir değer, piyasanın düşüş eğiliminde olduğunu gösterir.

özellikle hisse senetleri piyasalarında kullanılan bir göstergedir.

Örneğin, bir hisse senedinin kapanış fiyatları ve hacimleri şu şekildedir:

1. gün: Kapanış fiyatı 10 TL, hacim 100.000
2. gün: Kapanış fiyatı 11 TL, hacim 150.000
3. gün: Kapanış fiyatı 12 TL, hacim 200.000
4. gün: Kapanış fiyatı 10 TL, hacim 180.000
5. gün: Kapanış fiyatı 9 TL, hacim 120.000

MFI hesaplamak için önce tipik fiyatlar (TP) bulunmalıdır. TP, her günün en yüksek, en düşük ve kapanış fiyatlarının toplamının 3'e bölünmesiyle bulunur. Örneğin:

1. gün: $TP = (10 + 10 + 10) / 3 = 10$
2. gün: $TP = (11 + 11 + 10) / 3 = 10.67$
3. gün: $TP = (12 + 12 + 12) / 3 = 12$
4. gün: $TP = (10 + 10 + 10) / 3 = 10$
5. gün: $TP = (9 + 9 + 9) / 3 = 9$

Daha sonra para akışı (MF) bulunmalıdır. Pozitif para akışı, o günün TP'sinin önceki günün TP'sinden büyük olduğu günlerde hacmin çarpımıdır. Negatif para akışı, o günün TP'sinin önceki günün TP'sinden küçük olduğu günlerde hacmin çarpımıdır. Eşitse, para akışı sıfırdır. Örneğin:

1. gün: Pozitif para akışı $= 10 * 100.000 = 1.000.000$, negatif para akışı $= 0$

2. gün: Pozitif para akışı = $10.67 * 150.000 = 1.600.500$, negatif para akışı = 0
3. gün: Pozitif para akışı = $12 * 200.000 = 2.400.000$, negatif para akışı = 0
4. gün: Pozitif para akışı = 0, negatif para akışı = $10 * 180.000 = 1.800.000$
5. gün: Pozitif para akışı = 0, negatif para akışı = $9 * 120.000 = 1.080.000$

Son olarak, MFI hesaplanır. MFI, pozitif para akışının n günlük (genellikle 14 günlük) tipik fiyat ortalamasına bölünmesi, negatif para akışının n günlük tipik fiyat ortalamasına bölünmesi ve bu iki değer toplamının 100'e bölünmesiyle bulunur. Bu işlem, gün gün yapılır ve sonuçlar bir grafik üzerinde gösterilir.

1.6.4.3. OBV (On Balance Volume) Hacim Dengesi

OBV (On Balance Volume) göstergesi, bir varlığın fiyatının ve işlem hacminin değişimlerinin birlikte ele alınarak, piyasa trendlerini ölçmeye yarayan bir momentum göstergesidir. , belirli bir dönemdeki (genellikle bir gün) işlem hacminin artış ya da azalışını değil, fiyat hareketlerinin hacimle birlikte göz önüne alınmasını amaçlar. Bu gösterge, fiyat değişimlerinin hacimle birlikte analiz edilmesi sayesinde, belirli bir varlıkta artan veya azalan talebi ölçmek için kullanılır.

OBV hesaplaması, bir varlık için gün içindeki işlem hacimleri ile fiyat hareketlerinin çarpılması ile yapılır. Hacimlerin artış veya azalışına göre hesaplanan farklar, sonuç olarak pozitif veya negatif bir değer oluşturur. Bu değerlerin toplanması sonucunda OBV göstergesi oluşur.

$OBV = OBV (\text{Önceki}) + (\text{Hacim} \times \text{Değişim})$ Burada,

- Önceki, önceki günün OBV değeridir.
- Hacim, gün içindeki işlem hacmidir.
- Değişim, fiyat değişim yüzdesidir.

OBV deęeri, belirli bir dönemdeki toplam işlem hacmi ile fiyat hareketlerinin yönünü gösterir. Pozitif OBV, fiyatların arttığı ve hacmin de arttığı bir dönemi gösterirken, negatif OBV, fiyatların düřtüęü ve hacmin de azaldığı bir dönemi gösterir.

OBV'nin genellikle fiyat grafięi ile birlikte hareket etmesi gerekir. Fiyatlar ile birlikte yükselip düşmesi trendi onar. Fiyat yükselirken OBV düşüyor ise dağıtım işaret eder. Fiyatların düşüş beklentisini oluşturur. Fiyatlar düşerken OBV yükseliyorsa fiyatların da yükselmesi beklenir (Sarı, Borsada Göstergelerle Teknik Analiz, 1998, s. 159).

1.6.4.4.MFI (Money Flow Index) Para Akım İndeksi

Mark Chaikin tarafından geliştirilen MFI, hesaplamasında günün ortalama fiyatını esas alır. MFI hesaplamasında günün en yüksek, en düşük ve kapanış fiyatlarının toplamı üçe bölünerek ortalama fiyat bulunur. İşlem miktarı ile çarpılarak bugünün para giriři bulunur. Daha sonra dünün ortalama fiyatıyla bugünün ortalama fiyatları karşılaştırılır (Ekosentez, 2018, s. 02.01.2020).

MFI (Money Flow Index), para akışını ölçmek ve fiyat hareketlerini doğrulamak için kullanılan bir göstergedir. Bu gösterge, fiyat hareketlerindeki hacim deęişikliklerini hesaba katarak para akışını belirler. fiyat ve hacim verilerini birleştirir ve sonuçta bir gösterge çıkarır. Bu gösterge 0 ila 100 arasında bir deęere sahip olur ve genellikle 20 ve 80 seviyeleri önemli direnç ve destek seviyeleri olarak kabul edilir. , aşırı alım veya satım koşullarını belirlemek için kullanılabilir. Gösterge 80 üzerinde olduęunda aşırı alım, 20'nin altında olduęunda ise aşırı satım koşulları mevcut olarak kabul edilir.

MFI'nin hesaplanması için ařağıdaki adımlar izlenir:

1. Tipik Fiyat (TP) hesaplanır. TP, bir dönemin (genellikle bir gün) en yüksek, en düşük ve kapanış fiyatlarının toplamının 3'e bölünmesiyle elde edilir.

$$TP = (\text{En Yüksek Fiyat} + \text{En Düşük Fiyat} + \text{Kapanış Fiyatı}) / 3$$

2. Para Akışı (MF) hesaplanır. MF, TP ile aynı yönde olan hacim ile çarpılır. TP yükseldięinde, hacim de artarsa, MF daha yüksek olacaktır. Aynı şekilde, TP düřtüęünde, hacim de azaldığında, MF daha düşük olacaktır.

$$MF = TP \times \text{Hacim}$$

3. Pozitif ve Negatif Para Akışı (PMF ve NMF) hesaplanır. PMF, günün TP'si önceki günden daha yüksek olduğunda MF'nin değeridir. NMF, günün TP'si önceki günden daha düşük olduğunda MF'nin değeridir.

PMF = Toplam MF Miktarı (TP artışları olan günlerde) NMF = Toplam MF Miktarı (TP düşüşleri olan günlerde)

4. Para Akım İndeksi (MFI) hesaplanır. MFI, PMF ve NMF'nin birbirine oranıdır.

$$MFI = 100 - (100 / (1 + PMF / NMF))$$

MFI hesaplamaları genellikle 14 periyot için yapılır ve sonuçlar çizgi grafikte gösterilir.

BÖLÜM 2

FİNANSAL PİYASALARDA YAPAY ZEKA KAVRAMSAL ÇERÇEVE

2.1.YAPAY ZEKA TAIMI

Yapay zeka, bilgisayarların insan benzeri düşünme ve davranış sergilemesine izin veren bir bilim dalıdır. Yapay zeka teknolojileri, bilgisayarların öğrenme, problem çözme, dil anlama, görüntü işleme, karar verme ve daha birçok görevi yerine getirmelerini sağlar. Bu teknolojiler, özellikle büyük veri analizi, nesnelerin interneti, robotik, otonom araçlar, sağlık, finans, eğitim, tarım gibi birçok sektörde kullanılmaktadır.

Yapay Zeka için geliştirilen temel program John McCarthy tarafından 1957'de geliştirilen LISP programıdır. Basic, Fortran, Cobol ve Pascal gibi programların aksine, LISP cümle, kural, isim gibi diğer ayrıntılı konularla da ilgilidir. LISP kullanıcıları için esas teçhizat, LISP makinesi veya sembolik işlemci diye adlandırılan düzenektir. Bu sembolik işlemci, bir çeşit bilgisayar sistemi ve yapay zeka programlarının geliştirilmesi ve uygulanmasını etkili ve verimli şekilde desteklemek için dizayn edilmiş mantıksal bir sistemdir. (HARP Akademi, 1996, S.49-51)

2.1.1. Yapay zeka kullanım alanları

Yapay zeka, birçok farklı uygulama alanında kullanılmaktadır. Bunlar arasında şunlar yer almaktadır:

1. Otomotiv: Yapay zeka, otonom araçların geliştirilmesi için kullanılmaktadır. Bu teknoloji, araçların çevresindeki nesnelere tanınmasına, yolları takip etmesine ve sürücüsüz olarak ilerlemesine yardımcı olmaktadır.
2. Sağlık: Yapay zeka, tıp alanında hastalıkların teşhis ve tedavisi için kullanılmaktadır. Bu teknoloji, hastalıkların erken teşhis edilmesine yardımcı

olmakta ve tedavi süreçlerinde daha etkili sonuçlar elde edilmesine katkıda bulunmaktadır.

3. Bankacılık ve Finans: Yapay zeka, bankacılık ve finans sektöründe müşteri verilerinin analiz edilmesi, dolandırıcılık faaliyetlerinin tespit edilmesi ve yatırım stratejilerinin geliştirilmesi için kullanılmaktadır.
4. Perakende: Yapay zeka, perakende sektöründe müşteri davranışları hakkında veri analizi yapmakta ve ürünlerin stok düzeylerinin yönetilmesine yardımcı olmaktadır.
5. Üretim: Yapay zeka, üretim süreçlerinde kullanılarak işletmelerin verimliliğini artırmakta ve ürün kalitesini iyileştirmektedir.
6. Enerji: Yapay zeka, enerji sektöründe kullanılarak enerji tüketimini optimize etmekte ve enerji verimliliğini artırmaktadır.
7. Medya ve Eğlence: Yapay zeka, medya ve eğlence sektöründe kişiselleştirilmiş içeriklerin üretilmesine yardımcı olmaktadır.
8. Tarım: Yapay zeka, tarım sektöründe kullanılarak ürün verimliliğinin artırılması ve hasat sürecinin optimize edilmesi sağlanmaktadır.

Yukarıda bahsedilen uygulama alanlarının yanı sıra, yapay zeka birçok farklı alanda kullanılmaktadır. Bu teknolojinin kullanım alanları sürekli olarak genişlemekte ve gelişmektedir.

Yapay zeka (YZ) teknolojileri, insan zekasına benzer bir şekilde karar vermeyi ve öğrenmeyi sağlayan, bilgisayar sistemleri için geliştirilmiş tekniklerdir. Yapay zeka teknikleri, verilerin toplanması, analizi, yorumlanması ve işlenmesi gibi işlevleri yerine getirmek için kullanılır.

Yapay zeka teknikleri arasında makine öğrenmesi, derin öğrenme, doğal dil işleme, veri madenciliği, genetik algoritmalar, uzman sistemler, bulanık mantık, evrimsel

algoritmalar, unsupervised learning, supervised learning ve reinforcement learning gibi teknikler yer alır.

Bu teknikler, iş ve finans dünyasında birçok uygulama alanı bulur. Örneğin, finans sektöründe, müşterilerin kredi riski analizi, hisse senedi fiyatlarının tahmin edilmesi, trend analizi ve sahtecilik tespiti gibi birçok konuda yapay zeka teknikleri kullanılır. Portföy Yönetimi: Yapay Zeka Uzman Sistemleri, portföy yönetimi konusunda da kullanılabilir. Veri analizi ve makine öğrenme yöntemleriyle, yatırımcılara portföylerini optimize etme ve risk-getiri dengesini iyileştirme konusunda rehberlik edebilir.

1. Otomatik Ticaret: Yapay Zeka Uzman Sistemleri, finansal piyasalarda otomatik ticaret stratejileri geliştirmek için kullanılabilir. Piyasa verilerini izleyerek, trendleri ve desenleri tanıyabilir, alım-satım kararlarını otomatik olarak gerçekleştirebilir ve ticaret performansını analiz edebilir.
2. Dolandırıcılık Tespiti: Finans sektöründe dolandırıcılık tespiti büyük bir öneme sahiptir. Yapay Zeka Uzman Sistemleri, büyük miktarda finansal veriyi analiz ederek, dolandırıcılık işaretlerini tespit edebilir ve dolandırıcılık olaylarını engellemeye yardımcı olabilir.
3. Müşteri Hizmetleri: Finansal kuruluşlar için müşteri hizmetleri alanında Yapay Zeka Uzman Sistemleri kullanılabilir. Doğal dil işleme ve chatbot teknolojileriyle, müşteri sorularını yanıtlayabilir, hesap bilgilerini sağlayabilir ve müşteri deneyimini iyileştirebilir.

Yapay Zeka Uzman Sistemleri, finans sektöründe veri analizi, risk yönetimi, portföy yönetimi, ticaret stratejileri, dolandırıcılık tespiti gibi birçok alanda kullanılabilir. Bu sistemler, hassas finansal verileri analiz ederek daha iyi kararlar almayı sağlar ve süreçleri otomatikleştirerek verimliliği artırır.

Uzman sistemler, bilgi tabanı ve kurallar kümesine dayanan, belirli bir uzmanlık alanında insan benzeri kararlar alabilen sistemlerdir. Finansal alanda, uzman sistemler, karar destek sistemleri olarak kullanılabilir ve karmaşık finansal analizlerde, portföy yönetiminde ve risk değerlendirmesinde yardımcı olabilirler. (Yves Hilpisch,2019).

2.2. YAPAY ZEKA TARİHÇESİ

Yapay zeka kavramı ve teknolojisi, 1950'li yıllarda ortaya çıkmıştır. O dönemlerde, IBM gibi büyük şirketler ve araştırma kurumları yapay zeka araştırmaları yapmaya başlamıştır. 1956 yılında, Dartmouth Konferansı adı verilen bir konferansta, yapay zeka alanının resmi olarak tanımlanması yapılmış ve yapay zeka çalışmalarına ivme kazandırılmıştır, 1960'lı yıllarda, yapay zeka alanındaki araştırmaların odak noktası, bilgisayarların insan benzeri düşünme süreçlerini nasıl gerçekleştirebileceği konusuydu. Bu dönemde, dil işleme, resim tanıma ve el yazısı tanıma gibi alanlarda ilk yapay zeka uygulamaları geliştirildi. 1970'li yıllarda, yapay zeka alanındaki araştırmalar hız kazandı ve uzman sistemler, bulanık mantık ve doğal dil işleme teknikleri geliştirildi.

1980'li yıllarda, yapay sinir ağları ve genetik algoritmalar gibi yeni yapay zeka teknikleri ortaya çıktı. Bu dönemde ayrıca, uzman sistemlerin ticari uygulamaları da yaygınlaşmaya başladı, 1990'lı yıllarda, yapay zeka teknolojisi hızla gelişti ve makine öğrenimi, doğal dil işleme ve görüntü işleme gibi alanlarda önemli ilerlemeler kaydedildi. 2000'li yıllarda, yapay zeka teknolojisi hızla yaygınlaşmaya başladı ve birçok sektörde kullanılmaya başlandı. Günümüzde, yapay zeka teknolojileri, sağlık, finans, lojistik, üretim, otomotiv, perakende gibi birçok sektörde yaygın olarak kullanılmaktadır.

Yapay Zeka için geliştirilen temel program John McCarthy tarafından 1957'de geliştirilen LISP programıdır. Basic, Fortran, Cobol ve Pascal gibi programların aksine , LISP cümle , kural, isim gibi diğer ayrıntılı konularla da ilgilidir. LISP kullanıcıları için esas teçhizat, LISP makinesi veya sembolik işlemci diye adlandırılan düzenektir. Bu sembolik işlemci, bir çeşit bilgisayar sistemi ve yapay zeka programlarının geliştirilmesi ve uygulanmasını etkili ve verimli şekilde desteklemek için dizayn edilmiş mantıksal bir sistemdir. (Geçen Eser, S. 49-51)

2.2.1.Yapay zeka ile Doğal zeka Karşılaştırılması

Yapay zeka ve doğal zeka, farklı yollarla bilgi işleme ve problem çözme konusunda benzerlikler ve farklılıklar gösterirler. Bazı uzmanlar, yapay zekanın doğal zekaya benzer özelliklerinin olduğunu, ancak bazı yönlerde de doğal zekadan daha avantajlı olduğunu savunurken, bazıları ise yapay zekanın sadece belirli alanlarda işlevsel olduğunu ve doğal zekanın hala birçok alanda üstünlüğü koruduğunu düşünür.

Doğal zeka, insan beyninin bilişsel yeteneklerinden kaynaklanır ve geniş bir yelpazede görevleri yerine getirir. Doğal zeka, öğrenme, anlama, muhakeme, analiz, sentez, problem çözme, yaratıcılık, iletişim, sosyal etkileşim, duygusal zeka gibi birçok beceriyi içerir. Doğal zeka, öğrenme yoluyla geliştirilebilir ve yaşa ve deneyime bağlı olarak değişebilir.

Yapay zeka, bilgisayar sistemlerinin insan benzeri zeka işlevleri yerine getirmesi için tasarlanmış bir dizi teknolojidir. Yapay zeka, veri madenciliği, makine öğrenimi, derin öğrenme, doğal dil işleme, robotik, otonom araçlar gibi birçok alanda uygulanabilir. Yapay zeka, önceden programlanmış kurallara veya örüntülere dayanarak, öğrenme yoluyla veya öz yinelemeli olarak verileri analiz ederek ve çıkarımlar yaparak işlev görür.

Yapay zeka ve doğal zeka arasındaki farklılıklar, yapay zekanın belirli alanlarda insanlardan daha hızlı ve etkili olabilmesi, ancak yaratıcılık, duygusal zeka, sosyal etkileşim, insan becerileri ve esneklik gibi alanlarda hala sınırlı olmasıdır. Ancak yapay zeka teknolojileri geliştikçe, insanların yapabileceği birçok işlevi yerine getirme yetenekleri de artacaktır.

2.3. İŞ VE FİNANS DÜNYASINDA AKILLI SİSTEMLERE GENEL BAKIŞ

İş ve finans dünyası, akıllı sistemlerin kullanımını giderek artırmaktadır. Akıllı sistemler, bir dizi algoritma, makine öğrenimi, yapay sinir ağları ve benzeri teknolojileri içeren karmaşık bir dizi teknolojik araçtır. Bu araçlar, büyük veri kütlelerini analiz etmek, öngörülemeyen trendleri ve fırsatları belirlemek, iş süreçlerini otomatikleştirmek ve finansal riski azaltmak için kullanılabilir.

Örneğin, yatırım firmaları ve bankalar, piyasa verilerini analiz etmek ve otomatik ticaret stratejileri oluşturmak için yapay zeka ve makine öğrenimi tekniklerini kullanırlar. Bu teknikler, yatırımcıların karar verme sürecinde daha hızlı ve daha verimli olmalarına yardımcı olabilir.

Akıllı sistemler, finansal hizmetler sektöründe müşteri hizmetlerini geliştirmek için de kullanılabilir. Örneğin, müşteri şikayetlerini ve yorumlarını analiz etmek için doğal dil işleme algoritmaları kullanılabilir. Bu sayede, finansal kuruluşlar müşteri deneyimini iyileştirebilir ve müşteri memnuniyetini artırabilir.

Bunun yanı sıra, akıllı sistemler, finansal dolandırıcılık, para aklama ve yasa dışı faaliyetlerin tespiti ve önlenmesinde de kullanılabilir. Makine öğrenimi algoritmaları, büyük veri kütlelerinde anormallikleri ve belirli kalıpları tespit edebilir, bu sayede finansal suçların önlenmesine yardımcı olabilir.

Sonuç olarak, iş ve finans dünyası, yapay zeka ve akıllı sistemlerin kullanımı ile büyük bir değişim yaşamaktadır. Bu teknolojiler, veri analizi, karar verme süreci, müşteri hizmetleri ve risk yönetimi gibi alanlarda büyük faydalar sağlayabilir.

2.3.1.Yapay Zeka Akıllı Sistemlerin Karakteristik Özellikleri

Akıllı Sistemlerin Öğrenme Özelliği

Akıllı sistemlerin en önemli özelliklerinden biri öğrenme yeteneğidir. Bu sistemler, verileri analiz ederek kendi başına öğrenebilir ve gelecekteki kararlarını bu öğrenme sürecinde elde ettiği bilgilere dayandırabilir.

Öğrenme özelliği sayesinde, akıllı sistemler daha doğru ve verimli kararlar alabilirler. Örneğin, bir finansal akıllı sistem, piyasadaki değişimleri takip ederek, belirli bir yatırım stratejisine göre kendisini güncelleyebilir ve gelecekteki kararlarını bu stratejiye göre alabilir.

Bu özellik ayrıca, akıllı sistemlerin sürekli olarak gelişmesine ve kendisini güncellemesine de olanak tanır. Öğrenme süreci devam ettikçe, sistem daha fazla veri toplar ve daha doğru sonuçlar elde etmek için kendisini sürekli olarak iyileştirir.

Akıllı Sistemlerin Adaptasyon :

Akıllı sistemlerin adaptasyon özelliği, sistemin dış dünyadaki değişiklikleri algılaması ve buna uygun şekilde kendini güncelleyebilmesidir. Bu özellik, akıllı sistemlerin esnekliğini ve performansını artırır. Adaptasyon özelliği sayesinde, sistemlerin sürekli olarak yeni verilerle öğrenerek ve değişen koşullara uyum sağlayarak daha doğru sonuçlar üretmesi mümkün olur.

Örneğin, bir finansal işlem robotu, piyasadaki değişikliklere uyum sağlamak için düzenli olarak güncellenir ve yeniden eğitilir. Ayrıca, bir üretim hattı için kullanılan bir yapay zeka sistemi, üretim sürecindeki değişiklikleri otomatik olarak algılar ve üretim hattının ayarlarını buna göre otomatik olarak ayarlar. Bu şekilde, adaptasyon özelliği sayesinde, sistemlerin performansı ve verimliliği artırılır.

Akıllı Sistemlerin Esneklik :

Akıllı sistemlerin bir diğer karakteristik özelliği esnekliktir. Bu sistemler, değişen iş koşullarına hızla uyum sağlayabilen ve yeni verileri hızlı bir şekilde işleyebilen yapılardır. Esneklik, işletmelerin değişen pazar koşullarına uyum sağlamasına ve daha hızlı kararlar almasına yardımcı olabilir. Ayrıca, esnek sistemler, özellikle veri madenciliği, trend analizi ve kestirim gibi finansal analizlerde oldukça yararlıdır.

Akıllı Sistemlerin Açıklanabilirlik :

Akıllı sistemlerin açıklanabilirliği, bu sistemlerin kararlarını nasıl aldıklarını ve sonuçlarının nasıl üretildiğini anlama yeteneği ile ilgilidir. Bu özellik, özellikle finans dünyasında, bu kararların neye dayandığını ve nasıl alındığını anlamak isteyen yatırımcılar ve düzenleyiciler tarafından talep edilmektedir.

Açıklanabilirlik, özellikle yapay zeka ve derin öğrenme sistemleri gibi karmaşık akıllı sistemlerde zor bir sorundur. Bu sistemler, genellikle büyük veri kümeleri üzerinde öğrenir ve karar verirler ve bu nedenle, sonuçlarının nasıl üretildiğini anlamak için geleneksel yöntemler genellikle yetersiz kalır.

Bu nedenle, açıklanabilirliği artırmak için yeni teknikler ve yöntemler geliştirilmektedir. Örneğin, bazı araştırmacılar, derin öğrenme algoritmalarını daha açıklanabilir hale getirmek için farklı yaklaşımlar geliştirmişlerdir. Ayrıca,

düzenleyicilerin de yapay zeka ve diğer akıllı sistemlerin kullanımını düzenlemek için yeni politikalar ve yönergeler geliştirdiği görülmektedir.

Akıllı Sistemlerin Keşif :

Akıllı sistemlerin keşif (discovery) özelliği, veri madenciliği (data mining) ve makine öğrenmesi (machine learning) teknikleri ile ilişkilidir. Bu özellik, akıllı sistemlerin büyük veri setleri içinde belirli kalıpları, trendleri veya farklılıkları keşfetmelerini ve bu bilgiyi işletmelerin veya finans kurumlarının karar alma süreçlerinde kullanmalarını sağlar.

Örneğin, bir banka, müşterilerinin kredi geçmişi ve diğer finansal verileri gibi büyük veri setleri ile çalışarak, kredi riski değerlendirmesi yapabilir. Bu verileri kullanarak, akıllı sistemler belirli bir müşterinin kredi geri ödeme olasılığını tahmin edebilir ve bankanın karar verme sürecinde kullanabileceği farklı senaryoları keşfedebilir.

Benzer şekilde, bir perakende şirketi, müşteri davranışları ve satış verileri gibi büyük veri setleriyle çalışarak, hangi ürünlerin en çok talep gördüğünü ve müşterilerin hangi ürünlere daha fazla ilgi gösterdiğini keşfedebilir. Bu bilgiyi kullanarak, şirket daha iyi bir stok yönetimi yapabilir ve müşterilere daha uygun ürünler sunabilir.

2.3. FİNANSAL PİYASALARDA YAPAY ZEKA MODELLERİ

2.3.1.Zaman Serileri

2.3.1.1. ARIMA (AutoRegressive Integrated Moving Average)

Zaman serileri analizi için kullanılan bir istatistiksel modeldir. Bu model, zaman serilerindeki yapıları ve desenleri tanımak, verileri durağan hale getirmek ve gelecekteki değerleri tahmin etmek amacıyla kullanılır. İşte ARIMA modelinin temel bileşenleri ve işleyişi:

1. **AutoRegressive (AR) Terimi:** ARIMA'nın "AR" kısmı, otokorelasyonu ifade eder. Otopregresyon, bir değişkenin geçmiş değerleri ile ilişkilendirilmiş olma eğilimini temsil eder. AR kısmı, şu anki değeri, geçmiş zamanlardaki değerlerle

açıklar. "p" parametresi, kaç adet geçmiş zaman değerinin kullanılacağını belirler.

2. **Integrated (I) Terimi:** ARIMA'nın "I" kısmı, verinin durağan hale getirilmesini ifade eder. Durağanlık, zaman serisinin istatistiksel özelliklerinin zaman içinde sabit kalması anlamına gelir. Bu terim, veriyi fark alarak durağan hale getirir. "d" parametresi, fark derecesini belirler.
3. **Moving Average (MA) Terimi:** ARIMA'nın "MA" kısmı, hareketli ortalama terimini ifade eder. Hareketli ortalama, geçmiş hataların bir lineer kombinasyonu ile şu anki değeri açıklar. "q" parametresi, kullanılacak hataların sayısını belirler.

ARIMA modeli, genellikle "p," "d," ve "q" olmak üzere üç ana parametre ile tanımlanır ve "ARIMA(p, d, q)" olarak yazılır. Modelin bu parametrelerini doğru bir şekilde belirlemek, modelin zaman serisi verilerini iyi bir şekilde uyumlaştırmasını ve gelecekteki değerleri daha iyi tahmin etmesini sağlar.

ARIMA modeli, zaman serileri analizi için oldukça yaygın olarak kullanılır ve birçok istatistiksel yazılım paketi ve programlama dilinde uygulanabilir. Finansal piyasalar, ekonomi, hava durumu tahmini, talep tahmini ve birçok diğer uygulama alanında ARIMA modeli etkili bir araç olarak kullanılır.

2.3.1.2. SARIMA (Seasonal AutoRegressive Integrated Moving Average)

ARIMA modelinin mevsimsel bileşenlerle genişletilmiş bir versiyonudur. SARIMA modeli, zaman serileri verilerindeki hem genel hem de mevsimsel desenleri yakalamak ve gelecekteki değerleri tahmin etmek için kullanılır.

SARIMA modeli, temel olarak üç ana bileşeni içerir:

1. **Seasonal Component (Mevsimsel Bileşen):** SARIMA modeli, verinin mevsimsel desenlerini yakalamak için bir mevsimsel bileşen içerir. Bu bileşen, genellikle belirli bir periyotta (örneğin, her yılın aynı dönemi) gözlemlenen desenleri ifade eder. Bu mevsimsel bileşeni tanımlamak için bir dizi parametre kullanılır.
2. **AutoRegressive (AR) Terimi:** SARIMA modelinin AR kısmı, otokorelasyonu ifade eder ve genel zaman serisi desenlerini yakalamak için kullanılır. Bu bileşen, verinin geçmiş değerleri ile ilişkilendirilmiş olma eğilimini temsil eder.
3. **Integrated (I) Terimi:** SARIMA modelinin I kısmı, veriyi durağan hale getirir. Bu, veriyi fark alarak yapılır ve mevsimsel desenlerin durağan olmayan bileşenleri düzeltilir.

SARIMA modeli, genellikle "p," "d," "q," "P," "D," ve "Q" olmak üzere altı ana parametre ile tanımlanır:

- "p" ve "P" parametreleri, AR bileşeninin genel ve mevsimsel otokorelasyon derecesini belirler.
- "d" ve "D" parametreleri, veriyi durağan hale getirme derecesini belirler.
- "q" ve "Q" parametreleri, MA bileşeninin genel ve mevsimsel hareketli ortalama derecesini belirler.

SARIMA modeli, zaman serileri analizi ve tahmininde kullanılırken, özellikle veride mevsimsel desenlerin bulunduğu durumlarda oldukça etkilidir. Finansal piyasa verileri, periyodik mevsimsel desenlere sahip olabilir (örneğin, yıllık sezonluk dalgalanmalar), bu nedenle SARIMA modeli bu tür verilerin analizi için sıkça tercih edilen bir araçtır.

2.3.1.3. Recurrent Neural Network (RNN - Tekrarlayan Sinir Ağı):

RNN, zaman serileri gibi ardışık verileri işlemek için tasarlanmış bir yapay sinir ağı türüdür. RNN'ler, önceki zaman adımlarındaki bilgileri mevcut hesaplamalarına dahil edebilirler, bu nedenle zaman serileri gibi sıralı verileri modellemek için uygundur. Ancak, geleneksel RNN'lerin, uzun vadeli bağımlılıkları etkili bir şekilde modelleyemediği bir dezavantajı vardır. Bu, "gradients vanish" (gradyan kaybolması) veya "gradients explode" (gradyan patlaması) sorunlarına yol açar.

2.3.1.4. GARCH (Generalized Autoregressive Conditional Heteroskedasticity):

Finansal verilerin volatilitelerini (oyunaklık) modellemek için kullanılan bir istatistiksel modeldir. Özellikle finansal piyasalardaki fiyat dalgalanmalarını ve riski analiz etmek için yaygın olarak kullanılır.

GARCH modeli, özellikle şu amaçlarla kullanılır:

1. **Volatilité Tahmini:** GARCH modeli, finansal varlıkların fiyat volatilitelerini tahmin etmek için kullanılır. Bu, risk yönetimi ve portföy yönetimi için önemlidir. Yatırımcılar ve finansal analistler, bir varlığın gelecekteki volatilitelerini tahmin ederek risklerini değerlendirebilirler.
2. **Opsiyon Fiyatlandırma:** Opsiyonlar, finansal piyasalarda önemli bir türev ürünüdür. GARCH modelleri, opsiyonların fiyatlandırılması için kullanılabilir çünkü opsiyonların değeri volatiliteye bağlıdır. Bu nedenle GARCH modelleri, opsiyon fiyatlarını tahmin etmek ve risk analizi yapmak için kullanılır.

GARCH modeli, aşağıdaki temel bileşenlere sahiptir:

1. **ARCH (Autoregressive Conditional Heteroskedasticity):** GARCH'ın temelini oluşturan ARCH modeli, volatilitenin zaman içinde değişebileceğini kabul eder.

2.3.2. Derin Öğrenme Modeller

2.3.2.1. Yapay Sinir Ağları (Artificial Neural Networks): Beyindeki sinir hücrelerinin çalışma prensiplerinden esinlenen bir modeldir. İleri yayılım ve geri yayılım gibi algoritmalar kullanılarak öğrenme gerçekleştirir.

Yapay Sinir Ağları (YSA), insan beyninin çalışma prensiplerine benzer bir şekilde tasarlanmış, çok katmanlı matematiksel yapıları ifade eder. Yapay sinir ağları, karmaşık verileri işleme, öğrenme ve sınıflandırma gibi işlemleri gerçekleştirebilir.

Yapay sinir ağları, birçok katmandan oluşur ve her katman belirli bir işlevi yerine getirir. İlk katman, girdi verilerini kabul eder ve diğer katmanlara iletmek için işler. Diğer katmanlar, girdi katmanından gelen verileri işleyerek son katmana kadar sinyalleri taşırlar. Yapay sinir ağları, öğrenme adı verilen bir süreçte, veri kümesi üzerinde eğitilir. Bu eğitim, ağı örnek verileri üzerinde eğitmek ve daha sonra yeni verileri sınıflandırmak için kullanmak için ağırlıkları ayarlamak suretiyle gerçekleştirilir.

Yapay sinir ağları, çeşitli endüstrilerde kullanılır. Örneğin, finans sektöründe, hisse senedi fiyatları ve para birimi kurları gibi pazar verilerini analiz etmek için kullanılırlar. Tıp alanında, kanser tarama ve teşhis için kullanılırlar. Ayrıca, yapay sinir ağları, ses ve görüntü tanıma, doğal dil işleme ve robotik gibi diğer alanlarda da kullanılır.

Günümüzde yapay sinir ağları artık teorik ve laboratuvar çalışmaları olmaktan çıkmış ve günlük hayatta kullanılan sistemler oluşturmaya ve Pratik olarak insanlara faydalı olmaya başlamıştır (Öztemel, 2012, s. 40).

Yapay Sinir Ağı (YSA) modelleri, insan beyninin sinir hücrelerinin işleyişini taklit ederek bilgi işleme ve desen tanıma yeteneklerini kullanır. Finans sektöründe YSA modellerinin kullanımı oldukça yaygındır. İşte Yapay Sinir Ağı modellerinin finansa çıkarılma tarihçesi, kullanım alanları ve avantajları:

Yapay Sinir Ağların Tarihçe:

- 1940'lar ve 1950'ler: Yapay Sinir Ağı kavramının temelleri, sinir hücrelerinin matematiksel modellenmesi üzerine çalışmalarla atıldı.
- 1980'ler: Yapay Sinir Ağları, finansal piyasa analizinde kullanılmaya başlandı. Özellikle hisse senedi fiyat tahminlemesi ve döviz kuru tahminlemesi gibi alanlarda kullanıldı.
- 1990'lar: Yapay Sinir Ağları, finansal risk yönetimi, kredi değerlendirmesi, müşteri segmentasyonu ve dolandırıcılık tespiti gibi birçok finansal uygulamada kullanılmaya başlandı.
- 2000'lerden günümüze: Yapay Sinir Ağı modelleri, büyük veri analizi, yatırım stratejileri oluşturma, portföy yönetimi ve finansal karar destek sistemleri gibi alanlarda giderek daha fazla kullanılmaktadır.

Yapay Sinir Ağların Kullanım Alanları:

Hisse Senedi Fiyat Tahmini: Yapay Sinir Ağları, hisse senedi fiyatlarının gelecekteki hareketlerini tahmin etmek için kullanılabilir. Geçmiş fiyat verileri, teknik göstergeler ve temel analiz verileri gibi girişlerle model eğitilir ve gelecekteki fiyat trendlerini tahmin eder.

Kredi Değerlendirmesi: Yapay Sinir Ağları, kredi başvurularını değerlendirmek ve kredi riskini tahmin etmek için kullanılabilir. Müşteri bilgileri, finansal geçmiş ve diğer değişkenlerle eğitilen bir model, kredi başvurusunun onaylanıp onaylanmayacağını veya müşterinin kredi riskini belirleyebilir.

Piyasa Analizi: Yapay Sinir Ağları, finansal piyasalardaki trendleri, desenleri ve ilişkileri analiz etmek için kullanılabilir. Bu, alım-satım sinyalleri üretmek, risk yönetimi stratejileri geliştirmek ve portföy yönetimi için yardımcı olabilir.

Dolandırıcılık Tespiti: Yapay Sinir Ağları, finansal işlemlerde dolandırıcılık tespiti yapmak için kullanılabilir. Özellikle kredi kartı dolandırıcılığı, kimlik hırsızlığı ve sahtecilik gibi konularda riskli işlemleri

Yapay Zeka'nın diğer modellere göre avantajları şunlardır:

1. **Öğrenme Yeteneği:** Yapay Zeka modelleri, verilere dayalı olarak öğrenme ve deneyim kazanma yeteneğine sahiptir. Bu sayede, veriler üzerinden desenleri, ilişkileri ve trendleri algılayabilir ve gelecekteki tahminlerde bulunabilir. Diğer modellere göre daha esnek ve adapte olabilme yetenekleri vardır.
2. **Büyük Veri İşleme:** Yapay Zeka modelleri, büyük veri setlerini hızlı ve etkili bir şekilde işleyebilme kabiliyetine sahiptir. Büyük miktarda veri içerisindeki desenleri ve ilişkileri bulmak için özel olarak tasarlanmış algoritmaları kullanır. Bu da daha kapsamlı analizler yapabilme ve daha doğru sonuçlar elde etme
3. **Öznitelik Çıkarımı:** Yapay Zeka modelleri, verilerden anlamlı öznitelikler çıkarabilir. Otomatik olarak verileri analiz ederek, önemli özellikleri belirleyebilir ve modelin performansını artıracak şekilde veriye odaklanabilir. Bu, eldeki veri setlerinin daha etkin bir şekilde kullanılabilmesini sağlar.
4. **Karar Verme Yeteneği:** Yapay Zeka modelleri, karmaşık karar verme süreçlerinde kullanılabilir. Büyük miktarda veriyi değerlendirebilir, farklı faktörleri göz önünde bulundurabilir ve optimize edilmiş kararlar verebilir. Bu sayede, işletmeler ve kuruluşlar için daha iyi stratejiler oluşturabilir ve daha iyi sonuçlar elde edebilir.
5. **Otomatikleştirme ve Verimlilik:** Yapay Zeka modelleri, birçok tekrarlayan veya karmaşık işi otomatikleştirebilir. İnsan gücüne dayalı işleri daha hızlı ve daha verimli bir şekilde yapabilir, zaman ve maliyet tasarrufu sağlayabilir. Aynı zamanda süreçleri daha az hata ile gerçekleştirme avantajına sahiptir.

Yapay Zeka modellerinin avantajları, farklı endüstrilerde ve uygulama alanlarında kullanımlarını artırmaktadır. Özellikle veri yoğun sektörlerde, tahminleme,

optimizasyon, iş süreçlerinin iyileştirilmesi gibi birçok alanda büyük bir potansiyele sahiptirler.

Yapay sinir ağı (YSA), finans alanında da yaygın olarak kullanılan bir makine öğrenme yöntemidir. Finansda, yapay sinir ağları genellikle risk analizi, tahmin, portföy yönetimi ve alım-satım stratejileri gibi birçok farklı uygulamada kullanılır.

Yapay sinir ağı temel olarak birçok bağlantılı nöronun katmanlar halinde düzenlenmesinden oluşur. Her bir nöron, girdi değerlerini alır, bunları ağırlıklarla çarpar ve ardından bir aktivasyon fonksiyonu ile çıktı üretir. Bu işlem, verilerin ağdan geçerek sonuç çıktısının üretilmesini sağlar.

Finansda yapay sinir ağlarının parametreleri ve formülü, ağın yapısına ve kullanılan öğrenme algoritmasına bağlıdır. İşte yaygın olarak kullanılan bazı parametreler ve formüller:

1. Katman Sayısı: Yapay sinir ağlarında, genellikle giriş katmanı, en az bir gizli katman ve çıktı katmanı bulunur. Daha karmaşık problemlerde, birden fazla gizli katman kullanılabilir. Katman sayısı, ağın karmaşıklığını ve kapasitesini belirler.
2. Nöron Sayısı: Her bir katmanda bulunan nöron sayısı ağın kapasitesini belirler. Daha fazla nöron, daha karmaşık ilişkileri ve desenleri modelleme yeteneğini artırır, ancak aşırı öğrenme riskini de beraberinde getirebilir. Optimal nöron sayısı, deneme yanılma yöntemleri veya optimizasyon teknikleriyle belirlenebilir.
3. Ağırlıklar ve Bias Değerleri: Her bir nöronun girdi değerleri ile çarptığı ağırlıklar ve aktivasyon fonksiyonuna eklenen bias değerleri, ağın çıktısını belirleyen önemli parametrelerdir. Bu değerler, ağın öğrenme süreci boyunca güncellenir.
4. Aktivasyon Fonksiyonları: Her bir nöronun çıktısını belirlemek için kullanılan aktivasyon fonksiyonları, finansda farklı tipte problemlere uygun şekilde seçilebilir. Sigmoid, ReLU, tanh gibi yaygın aktivasyon fonksiyonları kullanılabilir.

5. Öğrenme Algoritması: Yapay sinir ağının parametrelerini güncellemek ve öğrenme sürecini yönetmek için kullanılan bir öğrenme algoritması seçilir. Geri yayılım (backpropagation) algoritması, genellikle yapay sinir ağlarında kullanılan yaygın bir öğrenme algoritmasıdır.

Tablo.2.1. Yapay Sinir Ağı Yönteminde Kullanılan Parametreler

Parametre Sembolleri	Tanım
L	Öğrenme Hızı
M	Momentum
N	Eğitim Tur Sayısı
V	Test verisinin yüzdelik değeri
S	Tekrar edilebilirlik için üretilmiş rastgele sayı
E	Hata eşik değeri.

Formülasyon, genellikle matematiksel ifadelerle açıklanır ve ağın yapısına, aktivasyon fonksiyonlarına ve öğrenme algoritmasına dayanır. Bununla birlikte, finansda kullanılan yapay sinir ağı modelleri, özel finansal verilere ve analiz hedeflerine göre değişiklik gösterebilir. Bu nedenle, spesifik bir finansal probleme odaklanırsanız, daha spesifik bir formülasyon sağlayabilirim.

2.3.2.2. Evrimsel Stratejiler (Evolutionary Strategies) : yapay zeka ve optimizasyon alanında kullanılan bir tür evrimsel hesaplama yaklaşımıdır. Bu yöntem, doğal evrim süreçlerini taklit ederek problemleri çözmeyi amaçlar. Evrimsel stratejiler, genetik algoritmalar ve diğer evrimsel hesaplama teknikleriyle benzerlikler taşır, ancak farklılıkları da bulunur.

Evrimsel Stratejilerin Temel İşleyişi:

1. Popülasyon Oluşturma: İlk adım, rastgele veya belirli bir kurala göre oluşturulan bir popülasyonun tanımlanmasıdır. Bu popülasyon, problemin çözümünü temsil eden bireylerden oluşur.
2. Uygunluk Fonksiyonu (Fitness Function): Her bireyin ne kadar iyi veya kötü performans gösterdiğini değerlendiren bir uygunluk fonksiyonu tanımlanır. Bu fonksiyon, problemin optimize edilmesi gereken hedefi veya kriteri temsil eder.
3. Seçim ve Üreme: Evrimsel stratejiler, uygunluk fonksiyonuna dayanarak bireyleri seçer ve üretir. Daha iyi performans gösteren bireyler, daha yüksek

olasılıkla seçilir ve çoğaltılır. Bu, daha iyi çözümlerin nesilden nesile geçmesini sağlar.

4. Çaprazlama ve Mutasyon: Üreme sırasında, seçilen bireyler çaprazlama ve mutasyon operatörleri kullanılarak yeni bireyler oluşturur. Çaprazlama, iki bireyin özelliklerini birleştirerek yeni bireyler üretirken, mutasyon rastgele değişiklikler ekler.
5. Yeni Nesil Oluşturma: Üretilen yeni bireylerle bir sonraki nesil oluşturulur. Bu nesil, daha iyi çözümleri teşvik etmek ve kötü çözümleri elemek için kullanılır.
6. Sonlandırma Koşulu: Bir sonlandırma koşulu karşılandığında (örneğin, belirli bir uygunluk seviyesine ulaşıldığında veya belirli bir iterasyon sayısına ulaşıldığında) evrimsel süreç sona erer ve en iyi çözüm veya yaklaşık bir çözüm elde edilir.

Evrimsel Stratejilerin Kullanım Alanları:

1. Optimizasyon Problemleri: Evrimsel stratejiler, karmaşık optimizasyon problemlerini çözmek için kullanılır. Özellikle çok sayıda değişkeni olan, karmaşık ve çok boyutlu problemler bu yöntemle ele alınabilir.
2. Parametre Ayarlama: Yapay sinir ağları, öğrenme algoritmaları ve diğer makine öğrenimi modelleri için en iyi parametreleri bulmak için evrimsel stratejiler kullanılabilir.
3. Robotik Kontrol: Robotların ve otonom sistemlerin hareket planlaması ve kontrolünde evrimsel stratejiler kullanılabilir.
4. Oyun Stratejileri: Evrimsel stratejiler, oyun stratejilerinin geliştirilmesi ve oyun yapay zekası için kullanılabilir.

Evrimsel stratejiler, genetik algoritmalar gibi evrimsel hesaplama yöntemlerinin bir alternatifi olarak kullanılır ve problemin doğası ve gereksinimlerine bağlı olarak tercih edilir. Bu yöntem, geniş bir uygulama yelpazesi sunar ve özellikle karmaşık ve çok boyutlu optimizasyon problemleri için etkilidir.

2.3.2.3. Long Short-Term Memory (LSTM - Uzun Kısa Vadeli Hafıza):

LSTM, bu RNN sorununu ele alan özel bir RNN çeşididir. LSTM, uzun vadeli bağımlılıkları daha iyi yakalayabilen bir hücre yapısına sahiptir. LSTM hücreleri, geçmiş bilgileri hafızada saklayabilir ve gerektiğinde bu bilgilere erişebilir. Bu, zaman serileri analizinde uzun vadeli desenleri ve bağımlılıkları daha iyi modellemek için kullanışlıdır.

LSTM ve RNN'nin zaman serileri analizi için kullanılmasının bazı avantajları şunlar olabilir:

1. **Dinamik Desenleri Yakalama:** LSTM ve RNN, karmaşık ve değişken desenleri yakalamak için yeteneklidir. Bu, finansal piyasa verileri gibi karmaşık zaman serileri üzerinde çalışırken önemlidir.
2. **Uzun Vadeli Bağımlılıkları Yakalama:** LSTM, uzun vadeli bağımlılıkları daha etkili bir şekilde modelleyebilir ve bu da gelecekteki değerlerin tahminini iyileştirebilir.
3. **Çoklu Girişler ve Çıktılar:** LSTM ve RNN, birden fazla giriş ve çıkış değişkenini ele alabilir, bu nedenle çoklu boyutlu zaman serileri analizlerine uygundur.

Ancak, LSTM ve RNN'nin kullanımını bazı zorluklar da içerebilir:

1. **Eğitim Zorlukları:** LSTM ve RNN'nin eğitimi, doğru hiperparametre ayarlarına ve yeterli veri miktarına ihtiyaç duyar.
2. **Hesaplama Gücü:** Özellikle büyük ve karmaşık ağlar için yüksek hesaplama gücü gerektirebilirler.

LSTM ve RNN, finansal piyasalardaki fiyat tahmini, hisse senedi fiyat analizi, zaman serileri sınıflandırma ve talep tahmini gibi birçok zaman serileri analizi uygulamasında başarıyla kullanılmıştır.

2.3.2.4. Evrimsel Sinir Ağları (Convolutional Neural Networks - CNN) : Özellikle görüntü işleme ve tanıma alanında çok etkili bir derin öğrenme modelidir. CNN'ler, görüntü verilerini işlemek ve özelliklerini otomatik olarak çıkarmak için tasarlanmıştır. İşte CNN modelinin ana bileşenlerini ve işleyişini ayrıntılı bir şekilde açıklayan bir rehber.

1. Giriş Katmanı (Input Layer): CNN modelinin ilk katmanı, işlem yapılacak olan verinin giriş katmanıdır. Genellikle bu katman, renkli görüntülerde üç kanal (RGB) veya siyah-beyaz görüntülerde tek kanal içerir. Örneğin, 224x224 piksel çözünürlüğündeki bir görüntü, 224x224x3 şeklinde bir girişe sahip olabilir.

2. Evrişim Katmanları (Convolutional Layers): CNN'nin en önemli bileşenlerinden biri evrişim katmanlarıdır. Bu katmanlar, görüntünün özelliklerini çıkarmak için kullanılır. Evrişim katmanı, küçük bir pencere (filtre veya kernel) kullanarak görüntüyü tarama işlemi gerçekleştirir. Her pencere, giriş verisinin bir bölümünü işler ve bu bölüme özgü özellikleri çıkarır. Ardından bu pencereyi kaydırarak tüm görüntüyü işler. Bu, görüntünün belirli özelliklerini (örneğin, kenarlar, köşeler, dairesel yapılar) tanımak için kullanışlıdır.

3. Evrişim Katmanlarının Aktivasyon Fonksiyonları (Activation Functions): Her evrişim katmanının sonunda, özellik haritası üzerinde belirli bir aktivasyon fonksiyonu

uygulanır. Genellikle ReLU (Rectified Linear Activation) kullanılır. Bu aktivasyon fonksiyonu, negatif değerleri sıfır yapar ve pozitif değerleri bırakır. Bu, ağın daha hızlı öğrenmesini sağlar.

4. Havuzlama Katmanları (Pooling Layers): Havuzlama katmanları, evrişim katmanlarının çıkardığı özellik haritasını küçültmek ve önemli bilgileri korumak için kullanılır. Genellikle maksimum havuzlama veya ortalama havuzlama kullanılır. Bu işlem, hesaplama maliyetini düşürür ve aşırı uydurmayı (overfitting) önler.

5. Tam Bağlantılı Katmanlar (Fully Connected Layers): CNN'nin sonunda, tam bağlantılı katmanlar bulunur. Bu katmanlar, özellik haritasındaki bilgileri düzleştirir ve sınıflandırma veya regresyon gibi nihai çıktıları hesaplar. Genellikle bu katmanların sonunda bir softmax aktivasyonu kullanılır, bu da çıktının olasılık dağılımını verir.

6. Çıkış Katmanı (Output Layer): CNN'nin çıkış katmanı, spesifik bir görev için tasarlanır. Sınıflandırma yapılıyorsa, bu katmanda sınıf etiketlerine karşılık gelen olasılıklar üretilir. Regresyon yapılıyorsa, bu katman nümerik bir değer üretir.

7. Eğitim ve Geri Yayılım (Training and Backpropagation): CNN, büyük bir veri kümesi üzerinde eğitilir. Eğitim süreci, modelin ağırlıklarını ve öğrenme matrislerini optimize ederek uygun bir uygunluk fonksiyonunu minimize etmeye çalışır. Geri yayılım algoritması kullanılarak, her ağırlık güncellemesi için türevler hesaplanır.

8. Uygunluk Fonksiyonu (Loss Function): Eğitim sırasında, CNN'nin performansını ölçmek için bir uygunluk fonksiyonu kullanılır. Sınıflandırma problemleri için çapraz entropi, regresyon problemleri için ortalama kare hatası gibi uygunluk fonksiyonları kullanılabilir.

9. Optimizasyon Algoritması: Ağırlıkların ve öğrenme matrislerinin güncellenmesi için bir optimizasyon algoritması kullanılır. Stokastik gradyan inişi (SGD), Adam, RMSProp gibi optimizasyon algoritmaları yaygın olarak kullanılır.

CNN'ler, özellikle görüntü işleme, nesne tanıma, yüz tanıma, otonom sürüş, tıbbi görüntüleme ve daha birçok alanda büyük başarı elde etmiştir. Bu model, özellikle büyük ve karmaşık veri kümesi ile çalışıldığında, bilgisayarlı görüş ve yapay zeka uygulamalarında olağanüstü sonuçlar üretebilir.

2.3.3.Makine Öğrenme Modeller

Makine öğrenmesi, bir yapay zeka modelinin belirli bir algoritma ile verilerden öğrenerek, gelecekteki olayları tahmin etme yeteneğini kazanmasını sağlar. Finansal tahminler, pazar analizi, portföy yönetimi gibi alanlarda makine öğrenmesi teknikleri sıkça kullanılır.

makine öğrenmesinin finans dünyasında nasıl çalıştığına dair bir genel bakış:

1. Veri Toplama: Makine öğrenmesi için ilk adım, finansal verilerin toplanmasıdır. Bu veriler, hisse senedi fiyatları, ekonomik göstergeler, şirket bilançoları, piyasa haberleri ve sosyal medya verileri gibi çeşitli kaynaklardan elde edilebilir.
2. Veri Ön İşleme: Toplanan veriler, makine öğrenmesi algoritmasına uygun hale getirilir. Bu adımda, veri temizleme, eksik değerlerin doldurulması, özellik mühendisliği ve veri normalizasyonu gibi teknikler kullanılır.
3. Model Seçimi: Makine öğrenmesi için uygun bir model seçilir. Bu seçim, finansal problemin karmaşıklığına, kullanılabilir veri miktarına ve tahmin hedefine bağlı olarak yapılır. Örneğin, regresyon analizi, sınıflandırma modelleri veya derin öğrenme yöntemleri gibi farklı modeller kullanılabilir.
4. Eğitim Verisi: Modelin eğitimi için veriler kullanılır. Eğitim veri seti, geçmiş finansal verilere ve sonuçlara dayanarak modelin öğrenmesini sağlar. Model, giriş verilerini analiz eder, desenleri tanır ve çıktıyı tahmin etmek için uygun parametreleri öğrenir.
5. Model Eğitimi: Eğitim veri seti kullanılarak seçilen modelin parametreleri optimize edilir. Bu süreçte, modelin hedef metrikleri (örneğin, ortalama karesel hata veya doğruluk oranı) en iyi şekilde karşılaması için iteratif olarak modelin ayarlamaları yapılır.
6. Model Değerlendirme: Eğitim süreci tamamlandıktan sonra, modelin performansı değerlendirilir. Değerlendirme, modelin doğruluğunu, hassasiyetini ve öngörü yeteneğini test veri seti üzerinde kontrol ederek gerçekleştirilir.
7. Tahmin ve Uygulama: Eğitilmiş model, yeni verileri analiz ederek tahminlerde bulunabilir veya kararlar verebilir. Örneğin, hisse senedi fiyat tahminleri yapmak veya riskli kredi başvurularını sınıflandırmak gibi görevlerde kullanılabilir.

Makine öğrenme Yapay zekâ (AI), bilgisayar bilimlerinin bir alt dalı olan ve bilgisayarların akıllıca davranmasını sağlayarak akademi ve endüstride kendine yer bulan bir araştırma alanıdır (Nilsson, 2014). Bu macera ve yapay zekaya yönelik eğilim 2016

yılında, Google DeepMind'a ait bir yazılım şirketinin DeepMind tarafından üretilen bir yazılım olan AlphaGo ile 9-dan rakibini avantajsız bir şekilde yenmesiyle başlamıştır (Siau ve Wang, 2018). Yapay zekâ, makine öğrenmesi ve derin öğrenme birbiriyle çok karıştırılan kavramlardır. Yapay zekâ ile makine öğrenmesinin ilişkisi Şekil 3.4'de verilmiştir. Yapay zekâ, programların insanlar gibi öğrenebilmesi ve davranabilmesi iken makine öğrenmesi ise aynı amaç için yazılan algoritmalarıdır.

Makine Öğrenme Özellik ve Avantajları

Makine öğrenmesi, bilgisayarların insanlara benzer şekilde öğrenmesini sağlamak için çeşitli algoritma ve tekniklerin geliştirilmesi için çalışan bilimsel bir çalışma alanıdır. Bilgisayarların deneyim yoluyla otomatik olarak gelişmesini sağlayarak en hızlı büyüyen alanlardan biri olmuştur. (Jordan ve Mitchell, 2015).

Yapay zeka ve makine öğrenme tekniklerinin gerçek zamanlı ticaret stratejileri üzerindeki etkisi vardır ve Piyasa verilerinin analizi, ticaret sinyallerinin üretilmesi ve otomatik ticaret sistemleri kurar,yapay zeka ve makine öğrenme tekniklerini kullanarak finansal piyasalarda rekabetçi bir avantaj elde etme potansiyelini gösterir.

(Christian L.Dunis,Peter W.Middleton, "Artificial Intelligence for Financial Markets: Cutting Edge Applications for Investment Management, Real-Time Trading and Risk Management",London: *Palgrave Macmillan*,2016)

Makine öğrenimi portföy Yönetiminde Modeller, belirli risk seviyelerine dayanarak en yüksek getiriyi sağlayabilecek varlıkları belirleyebilir.

(Sebastian RASCHAKA ve Vahid MİRJALİLİ, Python Machine Learning: Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2, Third Edition" , Birmingham, UK:*Packt Publishing*,2017).

Yapay zeka (YZ) ve makine öğrenmesi (MO) birçok özellik ve avantaj sunar. İşte bazıları:

1. Veri analizi ve örüntü tanıma: Yapay zeka ve makine öğrenmesi, büyük miktarda veriyi analiz edebilir ve içindeki örüntüleri tanımlayabilir. Bu sayede, karmaşık problemlerin çözümünde etkili olabilir.
2. Otomatik karar verme: Yapay zeka, karar verme süreçlerini otomatikleştirebilir. Makine öğrenmesi algoritmaları, veri analizine dayalı olarak doğru ve hızlı kararlar verebilir.
3. Hız ve verimlilik: Yapay zeka ve makine öğrenmesi, hızlı veri işleme ve analiz yetenekleri sayesinde görevleri insanlardan daha hızlı ve verimli bir şekilde gerçekleştirebilir.
4. Ölçeklenebilirlik: Yapay zeka sistemleri, büyük miktarda veriyi işleme kapasitesine sahiptir. Veri miktarı arttıkça, yapay zeka sistemleri daha da güçlü hale gelebilir ve daha doğru sonuçlar üretebilir.
5. Sürekli öğrenme ve iyileştirme: Makine öğrenmesi algoritmaları, deneyimlerinden öğrenme yeteneğine sahiptir. Bu sayede, sürekli olarak yeni verilerle beslenerek performanslarını iyileştirebilirler.
6. Aykırı değer tespiti : Yapay zeka ve makine öğrenmesi, tehlikeli veya riskli görevleri üstlenebilir. Örneğin, uzay keşfi, nükleer enerji santralleri veya derin deniz sondajı gibi alanlarda insana zarar verebilecek görevleri yerine getirebilir. "Analitik korunma, işlem maliyetleri, piyasa etkisi, likidite kısıtlamaları, risk limitleri gibi piyasada meydana gelebilecek olumsuzluklarda makine öğrenmesi riskten korunma kararları verirken daha yüksek hızda hassas korunmalar üretebilir" (de Prado, 2018).
7. Kişiselleştirilmiş deneyimler: Yapay zeka ve makine öğrenmesi, kullanıcılara kişiselleştirilmiş deneyimler sunabilir. Örneğin, müşteri tercihlerine dayalı öneriler yapabilir veya kişisel dijital asistanlar aracılığıyla kullanıcılara daha iyi hizmet sağlayabilir. " Makine öğrenimi algoritmaları, yüksek boyutlu bir uzayda kalıpları tanımlar. Bu özellikler sonuçlar ile ilişkilendirilir. İlişkilerin

niteliği aşırı karmaşık olabilir. Ama hangi özelliklerin önemli olduğu makine öğrenmesinde her zaman incelenebilir’’(de Prado, 2018).

8. Hata düzeltme ve tahmin: Yapay zeka ve makine öğrenmesi, hataları tespit edebilir ve düzeltebilir. Ayrıca, gelecekteki olayları tahmin edebilir ve risk analizi yapabilir.
9. Rutin görevlerin otomasyonu: Yapay zeka ve makine öğrenmesi, tekrarlanan ve sıkıcı rutin görevleri otomatikleştirerek insanların daha stratejik ve yaratıcı işlere odaklanmasını sağlar.

Makine Öğrenmesi Modeller

Finansal piyasalar için makine öğrenme modelini eğiterek ve optimize ederek Temel makine öğrenme algoritmalarını finansal verileri entegre edilebileceğimiz ve eğitilen modelleri kullanarak ticaret stratejileri geliştirilebilir ve uygulanabilir. Gerçek zamanlı veri akışı, portföy yönetimi ve risk kontrolü gibi konulara yardımcı olur.(Stefan Zohren, Stephen Roberts, Training, Testing and Implementing Strategies, **Financial Machine Learning**, Ithaca: Cornell university, 2019).

Yüksek frekanslı işlem algoritmaları, çoklu faktörlere dayanarak en karlı işlemleri tahmin etmek için ML modellerini kullanır.(Jannes KIAAS. "**Machine Learning for Finance:Principles and practice for financial insiders**" ,Birmingham,UK:*Packt Publishing; 1st edition*, 2019).

Finansal problemleri çözmek için makine öğrenmesi ve yapay zeka tekniklerinin birçok farklı algoritması kullanılmaktadır. Ancak, hangi algoritmanın daha çok kullanıldığı spesifik problemlere ve gereksinimlere bağlıdır. Finansal alanda yaygın olarak kullanılan bazı makine öğrenmesi algoritmaları şunlardır:

2.3.3.1. Doğrusal Regresyon: Finansal verilerde fiyat tahmini, talep tahmini veya risk analizi gibi problemlerde doğrusal regresyon kullanılabilir.

Basit doğrusal regresyon analizi (Neter, Wasserman, & Kutner, 1989), iki sürekli değişken arasındaki ilişkiyi nicelendiren istatistiksel bir tekniktir. Bu değişkenler, bağımlı değişken veya tahmin etmeye çalıştığınız değişken ve bağımsız veya tahmin

edici deęişken olarak ifade edilebilir. Her noktadan kareli hatayı asgariye indiren verilerle bir doęru bularak alıřır.

Doęrusal regresyon tahmin edilen deęerlerle gerek deęerler arasındaki hatayı minimum seviyede tutmak uzere alıřır.

Doęrusal regresyon, makine ęrenme ve istatistik alanında yaygın olarak kullanılan bir regresyon teknięidir. Bu yntem, baęımlı bir deęişkenin (sonu deęişkeni) baęımsız deęişkenlerle (aıklayıcı deęişkenler) olan iliřkisini modellemek iin kullanılır. Doęrusal regresyon, bu iliřkiyi bir doęru izgi (lineer fonksiyon) ile temsil eder. İřte doęrusal regresyonun temel bileřenleri ve alıřma prensibi:

1. Temel Model: Doęrusal regresyon, temel olarak ařaęıdaki matematiksel modeli kullanır:

$$Y = b_0 + b_1 * X_1 + b_2 * X_2 + \dots + b_n * X_n$$

- Y, baęımlı deęişkendir (sonu deęişkeni) ve tahmin edilmek istenen deęişkendir.
- X_1, X_2, \dots, X_n , baęımsız deęişkenlerdir (aıklayıcı deęişkenler) ve sonucu etkileyen faktrlerdir.
- $b_0, b_1, b_2, \dots, b_n$, regresyon katsayılarıdır. Bu katsayılar, baęımsız deęişkenlerin etkilerini gsterir.

2. Ama: Doęrusal regresyonun temel amacı, baęımlı deęişkenin (Y) baęımsız deęişkenler (X_1, X_2, \dots, X_n) aracılıęıyla tahmin edilmesini saęlamaktır. Regresyon katsayıları ($b_0, b_1, b_2, \dots, b_n$), bu tahminin yapılmasına yardımcı olur.

3. Katsayıların Tahmini: Doęrusal regresyon, en uygun regresyon katsayılarını ($b_0, b_1, b_2, \dots, b_n$) veriye dayalı olarak hesaplar. Genellikle en kuk kareler yntemi kullanılır. Bu yntem, hataların karelerinin toplamını (ortalama kare hatası) minimize eden katsayıları bulmaya alıřır.

4. Modelin Deęerlendirilmesi: Doęrusal regresyon modelinin bařarısını deęerlendirmek iin farklı metrikler kullanılabilir. Bu metrikler arasında ortalama kare hata (Mean Squared Error - MSE), belirli bir hedef fonksiyonun minimize edilmesine dayalı olan R-kare (R-squared) gibi metrikler bulunur. Bu metrikler, modelin tahmin yeteneęini ler.

5. oklu Doęrusal Regresyon: Eęer birden fazla baęımsız deęişken (X_1, X_2, \dots, X_n) kullanılıyorsa, bu durumda "oklu doęrusal regresyon" olarak adlandırılır. oklu

doğrusal regresyon, birden fazla faktörün sonucu nasıl etkilediğini modellemek için kullanılır.

Doğrusal regresyon, temel ve anlaşılır bir model olması nedeniyle sıkça kullanılır. Özellikle, değişkenler arasındaki ilişkiyi anlamak, bağımsız değişkenlerin sonucu nasıl etkilediğini öğrenmek ve tahminler yapmak için kullanışlıdır. Ancak, bağımsız değişkenler ve sonuç değişkeni arasında doğrusal bir ilişki varsayımı gerektirir ve bazı durumlarda bu varsayım geçerli olmayabilir. Bu nedenle, veriye dikkatli bir şekilde yaklaşmak ve uygun model seçimini yapmak önemlidir.

2.3.3.2. Random Forests :

Random Forests, finansal veri analizi ve sınıflandırma problemleri için kullanılan yaygın bir algoritmadır. Özellikle kredi değerlendirmesi, dolandırıcılık tespiti ve portföy optimizasyonu gibi alanlarda kullanılır.

Random Forests, ensemble (kombinasyon) öğrenme yöntemlerinden biridir ve bir dizi karar ağacını kullanarak bir tahmin yapar. Random Forests, her bir karar ağacını rastgele örnekleme (bootstrap) ve rastgele özellik seçimi yaparak oluşturur.

Random Forests'ın matematiksel formülasyonu karmaşıktır ve her bir ağacın oluşturulma sürecindeki rastgelelik üzerine kuruludur. Ancak, genel olarak Random Forests'ın tahmin yapma süreci şu şekilde ifade edilebilir:

Random Forests, kullanılacak ağaç sayısını ($n_estimators$) ve özelliklerin rastgele seçilmesi için kullanılacak alt küme boyutunu ($max_features$) belirleyerek başlar.

Her bir ağaç için aşağıdaki adımlar tekrarlanır:

1. Veri setinden, rastgele örnekleme yöntemiyle (bootstrap) bir alt küme oluşturulur.
2. Rastgele seçilen özellikler kullanılarak alt kümenin en iyi bölmelerini yapacak şekilde bir karar ağacı oluşturulur.
3. Ağacın yaprak düğümlerindeki etiketler (sınıflandırma için) veya tahmin edilen değerler (regresyon için) kullanılarak tahmin yapılır.

Random Forests, ağaçların tahminlerini birleştirerek final tahmini yapar. Sınıflandırma problemlerinde genellikle oybirliği prensibi kullanılır, yani en çok oylanmış sınıf tahmini alınır. Regresyon problemlerinde ise ağaçların tahminlerinin ortalaması alınır.

Random Forests, her bir ağacın bağımsız olarak eğitilmesi ve sonuçlarının birleştirilmesi sayesinde overfitting'e karşı dirençlidir. Ayrıca, rastgele örnekleme ve özellik seçimi ile genelleme yetenekleri artırırken çeşitlilik sağlar.

Random Forests, sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılır. Veri setinin büyüklüğüne, özellik sayısına ve karmaşıklığına bağlı olarak hiperparametrelerin ayarlanması gerekebilir, ancak yukarıdaki formülasyon Random Forests'ın temelini oluşturur.

2.3.3.3. Takviyeli Öğrenme (RL) : Reinforcement Learning (Takviyeli Öğrenme), finansal piyasalarda karar verme ve portföy yönetimi gibi dinamik ve karar odaklı problemlerin çözümünde kullanılmaktadır. Örneğin, kararların algoritmik olarak optimize edildiği ticaret stratejileri geliştirmede kullanılabilir.

Reinforcement Learning (RL), bir ajanın çevresiyle etkileşime geçerek deneyim yoluyla öğrenmeyi amaçlayan bir makine öğrenme yöntemidir. RL, bir ajanın belirli bir durumda ne yapması gerektiğini öğrenmek için çevresel geribildirim (reward) kullanır.

Reinforcement Learning'de kullanılan temel matematiksel formül, Q-learning algoritmasına dayanır ve Q değerini hesaplamak için Bellman denklemini kullanır. Bellman denklemi, bir durumun değerini o durumun hemen sonraki durumlarıyla ilişkilendirir.

Q-learning algoritmasının formülü şu şekildedir:

$$Q(s, a) = (1 - \alpha) * Q(s, a) + \alpha * (r + \gamma * \max_{a'} Q(s', a'))$$

Burada:

- $Q(s, a)$, durum (state) s 'de aksiyon (action) a 'nın Q değerini temsil eder. Q değeri, durum-açıklama çiftine dayalı olarak bir aksiyonun ne kadar iyi olduğunu gösterir.

- α (alpha), öğrenme hızını (learning rate) temsil eder. Yeni bilgiyi eski bilgiyle ne kadar ağırlıklı bir şekilde birleştirmek gerektiğini belirler.
- r (reward), ajanın bir durumda aldığı anlık ödülü temsil eder.
- γ (gamma), indirim faktörünü (discount factor) temsil eder. Gelecekteki ödüllerin değerini azaltarak anlık ödüre daha fazla ağırlık vermek için kullanılır.
- s' (prime), bir sonraki durumu temsil eder.
- a' (prime), bir sonraki durumda alınabilecek aksiyonları temsil eder.
- $\max Q(s', a')$, bir sonraki durumda alınabilecek en yüksek Q değerini temsil eder.

Q-learning algoritması, ajanın Q değerlerini güncelleyerek aksiyonları öğrenmesini sağlar. Ajan, çevreden aldığı geribildirimleri kullanarak en yüksek Q değerine sahip aksiyonları seçer ve bu şekilde zamanla daha iyi performans sergiler.

Reinforcement Learning, oyun teorisi, robot kontrolü, trafik yönetimi ve birçok diğer alanlarda kullanılan bir yöntemdir. Farklı algoritmalarda farklı formüller ve yaklaşımlar kullanılabilir, ancak Q-learning, RL alanında yaygın olarak kullanılan bir formülasyondur.

2.3.3.4.Light GBM (Light Gradient Boosting Machine):

Finansal verilerin analizi ve tahmini için başarılı bir şekilde kullanılan bir algoritmadır. Light GBM, Gradient Boosting yöntemlerinden biridir ve ağaç tabanlı bir modelleme tekniği olarak çalışır.

Light GBM (Light Gradient Boosting Machine), gradyan artırma (gradient boosting) yöntemiyle çalışan bir makine öğrenmesi algoritmasıdır. Light GBM, özellikle büyük veri setleriyle çalışırken yüksek performans ve hızlı öğrenme sağlayan bir modeldir.

LightGBM, geçmiş verilere dayanarak finansal piyasaları tahmin etmek için kullanılabilir. Hisse senedi fiyatlarını, döviz kurlarını veya piyasa eğilimlerini tahmin etmek için kullanılır.(Marcos Lopez de Prado, "**Advances in Financial Machine Learning**", Manhattan.usa, Wiley; 1st edition,2018).

Light GBM'nin matematiksel formülasyonu aşağıdaki gibi ifade edilebilir:

$$F_m(x) = F_{m-1}(x) + \eta * h_m(x) \quad \text{Burada:}$$

- $F_m(x)$, m. aşamadaki (iteration) modelin tahminini temsil eder.
- $F_{m-1}(x)$, m-1. aşamadaki modelin tahminini temsil eder.
- η (learning rate), öğrenme hızını kontrol eden bir hiperparametredir. Yeni tahmini eski tahminlere ne kadar ağırlıklı eklemek gerektiğini belirler.
- $h_m(x)$, m. aşamada eklenen yeni modelin tahminini temsil eder.

Light GBM, gradient boosting yöntemini kullanarak aşama aşama bir ensemble (kombinasyon) modeli oluşturur. Her aşamada, $h_m(x)$ olarak adlandırılan yeni bir model eklenir ve bu modelin tahminleri $F_m(x)$ üzerine eklenir. Bu şekilde, hataları en aza indirerek tahmin gücü artırılır.

Light GBM'nin ayrıca ağaç tabanlı bir algoritma olduğunu belirtmek önemlidir. Her bir aşamada, ağaç yapısı kullanılarak yeni bir model oluşturulur. Ağaç yapısı, veri setini bölerek ve özneliklerin en iyi bölmeyi yapacak şekilde seçerek tahminleri iyileştirir.

Light GBM, hızlı eğitim süresi, verimli bellek kullanımı ve yüksek performansı ile bilinir. Özellikle büyük veri setleriyle çalışırken avantaj sağlar. Hiperparametrelerin ayarlanması ve modelin eğitilmesi sırasında çeşitli parametreler kullanılabilir, ancak yukarıdaki formül Light GBM'nin temelini oluşturur.

Light GBM'nin finansal uygulamaları şunları içerebilir:

1. **Sınıflandırma:** Light GBM, finansal verilerde sınıflandırma problemleri için kullanılabilir. Örneğin, kredi değerlendirmesi, dolandırıcılık tespiti veya hisse senedi fiyatlarının yönünün tahmini gibi alanlarda kullanılabilir.
2. **Regresyon:** Light GBM, finansal verilerde regresyon problemleri için de kullanılabilir. Örneğin, bir varlık fiyatının tahmini veya talep tahmini gibi problemlerde kullanılabilir.

3. **Portföy Optimizasyonu:** Light GBM, portföy yönetimi ve optimizasyonunda kullanılabilir. Portföy oluşturma ve varlık tahminlerine dayalı olarak optimize edilmiş ticaret stratejileri geliştirmede yardımcı olabilir.

Light GBM, hızlı eğitim süreleri ve yüksek performansı ile bilinir. Büyük veri kümeleri ve yüksek boyutlu özelliklerle çalışma yeteneği, finansal verilerin karmaşıklığını ele almada avantaj sağlayabilir. Ayrıca, Light GBM, düşük bellek kullanımı ve paralel hesaplama yetenekleriyle de dikkat çeker.

Ancak, her problemde olduğu gibi, Light GBM'nin kullanılması gereken spesifik bir veri seti ve problem bağlamı vardır. Veri setinizin boyutu, özelliklerin sayısı, hedefin doğası ve diğer faktörler, hangi makine öğrenmesi algoritmasının en uygun olduğunu belirlemek için dikkate alınması gereken önemli faktörlerdir.

LightGBM, histogram tabanlı çalışan bir algoritmadır. Sürekli değere sahip olan değişkenleri kesikli(discrete bin) hale getirerek hesaplama maliyetini azaltır. Karar ağaçlarının eğitim süresi yapılan hesaplama ve dolayısıyla bölünme sayısı ile doğru orantılıdır. Bu yöntem sayesinde hem eğitim süresi kısaltılmakta hem de kaynak kullanımı düşmektedir.

Karar ağaçlarında öğreniminde seviye odaklı (level-wise or depth-wise) veya yaprak odaklı(leaf-wise) olarak iki strateji kullanılabilir. Seviye odaklı stratejide ağaç büyürken ağacın dengesi korunur. Yaprak odaklı stratejide ise kaybı azaltan yapraklardan bölünme işlemi devam eder.

LightGBM bu özelliği sayesinde diğer boosting algoritmalarından ayrılmaktadır. Model yaprak odaklı strateji ile daha az hata oranına sahip olur ve daha hızlı öğrenir. Ancak yaprak odaklı büyüme stratejisi veri sayısının az olduğu durumlarda modelin aşırı öğrenmeye yatkın olmasına sebebiyet verir. Bu nedenle algoritma büyük verilerde kullanılmak için daha uygundur. Ayrıca ağaç derinliği, yaprak sayısı gibi parametreler optimize edilip aşırı öğrenmenin önüne geçmeye çalışılabilir.’’

2.3.3.5. Destek Vektör Makineleri (Support Vector Machines - SVM):Sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenme modelidir. SVM,

özellikle sınıflandırma görevlerinde kullanılmak üzere tasarlanmıştır, ancak regresyon problemlerine de uyarlanabilir. İşte SVM'nin temel bileşenleri ve çalışma prensipleri:

1. Veri Kümesi ve Özellikler: SVM, bir veri kümesini kullanarak öğrenme işlemi gerçekleştirir. Veri kümesi, sınıflandırma yapmak veya bir regresyon problemini çözmek için kullanılan özellik vektörlerini içerir. Bu özellikler, girdi verilerinin temelini oluşturur.

2. Sınıflandırma: SVM, veri noktalarını iki sınıf arasında (örneğin, pozitif ve negatif) ayırmak için kullanılır. SVM'nin temel amacı, veri noktalarını bir karar sınırı (hiper düzlem) ile bölmektir.

3. Destek Vektörler: SVM'nin önemli bir bileşeni "destek vektörleridir". Bunlar, karar sınırına en yakın olan ve sınıflar arasındaki marjı (mesafe) maksimize eden veri noktalarıdır. Destek vektörlerinin kullanılması, SVM'nin genelleme yeteneğini artırır ve modelin aşırı uydurmayı önler.

4. Marj: SVM, sınıflar arasındaki marjı maksimize etmeye çalışır. Marj, karar sınırı ile en yakın destek vektörü arasındaki mesafeyi ifade eder. Bu, modelin daha iyi genelleme yapmasını sağlar ve sınıfları daha iyi ayırır.

5. Kernel Fonksiyonları: SVM, doğrusal ve doğrusal olmayan problemleri ele alabilir. Doğrusal SVM, doğrusal ayrılabilir problemler için uygundurken, doğrusal olmayan problemler için çeşitli kernel fonksiyonları (örneğin, Radyal Temel Fonksiyon - Radial Basis Function, Polinomiyel) kullanılır. Kernel fonksiyonları, veri noktalarını yüksek boyutlu özellik uzayına taşıyarak sınıfları daha iyi ayrılabilir hale getirir.

6. Karar Sınırı ve Karar Fonksiyonu: SVM'nin sonucu, karar sınırını ve karar fonksiyonunu içerir. Karar sınırı, sınıflar arasındaki ayrımı gösterirken, karar fonksiyonu, yeni veri noktalarını sınıflandırmak için kullanılır.

7. Optimizasyon: SVM, veri noktalarını en iyi şekilde ayıran bir karar sınırını bulmak için bir optimizasyon problemi olarak formüle edilir. Bu, marjı maksimize etmek ve ayrımı en iyi şekilde yapmak için bir denge sağlar.

SVM'nin avantajları şunlardır:

- Yüksek boyutlu özellik uzaylarında iyi performans gösterir.
- Destek vektörlerini kullanarak aşırı uydurmayı önler.
- Farklı kernel fonksiyonları kullanarak çeşitli problemler için uyarlanabilir.
- İyi genelleme yeteneği sağlar.

SVM, sınıflandırma ve regresyon gibi birçok uygulama alanında başarıyla kullanılmıştır. Özellikle veri madenciliği, görüntü işleme, biyoinformatik, tıp, finans ve daha birçok alanda tercih edilen bir makine öğrenme modelidir.

2.3.4. Genetik Algoritma (GA)

Genetik algoritmalar, doğal seleksiyon ve genetik çaprazlama gibi biyolojik prensipleri kullanarak, optimizasyon problemlerinin çözümü için kullanılan bir tür yapay zeka yöntemidir. Genetik algoritmalar, bir problemi çözmek için bir dizi aday çözümünü oluşturur, bu adayların her biri bir "birey" olarak adlandırılır ve bunlar bir "popülasyon" oluşturur. Bu bireyler, genetik operatörler (seleksiyon, çaprazlama, mutasyon) ile bir sonraki nesle aktarılır ve bir dizi iterasyon sonunda, en iyi aday çözüm bulunur.

Genetik algoritmaların kullanıldığı alanlar arasında optimizasyon problemleri, makine öğrenimi, veri madenciliği, yapay hayat ve robotik yer alır. Bu algoritmaların avantajları arasında çok boyutlu problemleri çözebilme, global optimumlara ulaşabilme, kullanım kolaylığı, paralelleştirilebilirlik ve herhangi bir probleme uyarlanabilme özellikleri bulunur. Bununla birlikte, dezavantajları arasında algoritmanın bazı durumlarda yavaş olabilmesi, doğru parametrelerin ayarlanması gerekliliği ve sonuçların yeterince açıklanamaması yer alır.

Elde edilen sonuçların değerlendirilmesi, daha fazla geliştirme yapılması ve uygulamalarda kullanılması önemlidir. Ancak, yapay zeka sistemlerinin doğru bir şekilde tasarlanması ve uygulanması konusunda bazı zorluklar vardır. Bunlar arasında veri güvenliği ve gizliliği, yapay zeka modellerinin yeterince açıklanabilir olmaması, karar verme süreçlerinde insan faktörünün yetersizliği, yapay zeka sistemlerinin yeterli eğitim verilerine sahip olmaması, etik ve sosyal sorunlar, ve veri önyargısı gibi konular yer alır.

Bununla birlikte, iş ve finans dünyasında yapay zeka sistemleri, verimliliği arttırmak, maliyetleri azaltmak, müşteri deneyimini iyileştirmek, doğru kararlar almak ve rekabet avantajı sağlamak gibi birçok fayda sağlayabilir. Bu nedenle, yapay zeka teknolojilerinin kullanımı her geçen gün artmaktadır.

Bilim adamlarının evrimsel yaklaşımı bilgisayar teknolojilerinde kullanmaya çalışması oldukça eskiye dayanmaktadır. Bilgisayar teknolojileri ve evrim yaklaşımının birleştirilmesi için ilk denemeler 1950'lerin sonunda ve 1960'ların başında yapılmıştır. Ancak, ilk denemeler o günlerdeki biyolojik evrim yaklaşımına

uygun olarak mutasyon işlemine çok fazla bağımlı olmaları nedeniyle çok fazla başarılı olmamıştır.(Holland, 1992, s. 44)

Tablo.2.2. Genetik Algoritmaların Çalışma Adımları

Adım	Yapılan İşlem
1	Gösterim (kodlama) yönteminin belirlenmesi
2	Başlangıç popülasyonunun (ilk nesil) oluşturulması
3	Başlangıç popülasyonundaki her bireyin performansının amaç fonksiyonuna göre hesaplanması
4	Yeni neslin oluşturulmasında kullanılacak bireylerin seçilmesi
5	Seçilmiş bireylere genetik işlemlerin uygulanarak yeni neslin elde edilmesi
6	Yeni neslin bireylerinin performanslarının uygunluk fonksiyonuna göre hesaplanması
7	Bitiş koşulu sağlanmamışsa 4. adıma dönülmesi
8	Bitiş koşulu sağlanmışsa en iyi bireyin sonuç olarak dönülmesi

Tabloda gösterilen genetik algoritma adımları genel olarak verilmiştir. Bu adımlar değişik problemler için değişik şekilde uygulanabilir. Ancak her durumda, bu adımlar genetik algoritmaların temel bileşenlerine dayanmaktadır.

(Michalewicz, 1995, s. 177)

Genetik algoritma, portföy optimizasyonunda kullanılacak etkili bir araçtır. Bu yöntem, yatırımcıların portföylerindeki varlıkların ağırlıklarını optimize etmelerine yardımcı olabilir. Bu, her bir varlık için bir ağırlık belirleyerek yapılabilir.

Genetik algoritmanın uygulanması için öncelikle, portföyün bir matematiksel formülle ifade edilmesi gerekmektedir. Bu formülde, her bir varlık için belirlenmiş bir getiri ve risk oranı kullanılabilir. Daha sonra, genetik algoritma, portföy ağırlıklarını belirlemek için kullanılabilir.

Genetik algoritmayı çalıştırmak için aşağıdaki adımları takip edebilirsiniz:

Başlangıç popülasyonunu oluşturun: Rastgele oluşturulmuş gen dizileri (kromozomlar) kullanarak bir başlangıç popülasyonu oluşturun. Bu gen dizileri, çözülecek probleme bağlıdır. Genetik operatörlerin uygulanmasından sonra popülasyonda bozulmalar oluşabilir. Uygun olmayan kromozomlar tamir operatörü (düzenleyici algoritma) adı verilen ve başlangıç popülasyonunun bilgilerini esas alarak geliştirilen bir algoritma yardımıyla tamir edilir. Kromozomlar, tamir edildikten sonra bir sonraki nesle aktarılarak GA çalışmasına devam eder. (Çetin Elmas, 2007, s.398)

1. Uygunluk fonksiyonunu hesaplama: Her aday çözüm için uygunluk fonksiyonunu hesaplayın. Bu, aday çözümlerin ne kadar iyi olduğunu belirlemeye yardımcı olur. Genetik algoritmaların kullanmanın nihai amacı karmaşık biyoptimizasyonuna problemine en iyi veya en iyiye yakın bir çözümü en kısa sürede ve en kolay şekilde bulabilmektir. (Pereira:2000, s. 4)
2. Seçim operatörünü kullanarak yeni bir popülasyon oluşturma: Seçim operatörünü kullanarak uygunluk fonksiyonuna göre en iyi aday çözümleri seçin ve yeni bir popülasyon oluşturun. Seçim sırasında, çözüme daha yakın bireylerin daha yüksek olasılıkla seçilmesi hedeflenir. Ancak, seçim algoritması sadece en iyi bireyleri seçerse, popülasyon kısa bir sürede bu bireye yakınsayacaktır. Bu nedenle, seçim algoritması en iyileri seçmeye yönlendirilmeli, ancak, en iyi olmayıp da genetik açıdan faydalı olabilecek bilgi taşıyan bireyleri de seçebilmelidir. (Pereira, a.g.e, s. 16)
3. Çaprazlama operatörünü kullanarak genleri birleştirme: Yeni popülasyon için çaprazlama operatörünü kullanarak seçilen aday çözümlerin genlerini birleştirin. Bu, genetik materyalin karışmasını sağlar.
4. Mutasyon operatörünü kullanarak yeni gen dizileri oluşturma: Yeni popülasyon için mutasyon operatörünü kullanarak gen dizilerini rastgele değiştirin. Bu, genetik çeşitliliği artırır. Mutasyon ile var olan popülasyona yeni genetik bilgi eklenmiş olur. Bu popülasyonun çeşitliliğini arttırarak, çaprazlamanın tersine, algoritmanın çalışma sürecini rasgele bir şekilde çözüm uzayının yeni alanlarına yönlendirir. Mutasyon işlemi, genetik algoritmalara yerel alt optimumlarda

takılıp kalmama ve yeni ve daha önceden fark edilmemiş çözümlere ulaşabilme özelliği kazandırmaktadır. (Pareria, a.g.e., s. 7)

5. Yeni popülasyon için uygunluk fonksiyonunu hesaplama: Yeni popülasyon için uygunluk fonksiyonunu hesaplayın.
6. Sonlandırma kriterini kontrol etme: Belirli bir durum gerçekleşene kadar, örneğin belirli bir iterasyon sayısı veya uygunluk değerine ulaşına kadar işlemi tekrarlayın.
7. En iyi çözümü seçme: Son popülasyonda en iyi uygunluk değerine sahip aday çözümü seçme. Bu, problemin çözümüne karşılık gelen en iyi sonuçtur.

Genetik algoritmaların performansı, popülasyon boyutuna, seçim, çaprazlama ve mutasyon operatörlerine bağlıdır. İyi bir performans elde etmek için, bu parametreleri dikkatlice seçmek önemlidir.

Genetik algoritmanın portföy optimizasyonunda kullanımı, manuel olarak yapılan portföy yönetimine göre daha hızlı ve verimli bir çözüm sunabilir. Ayrıca, genetik algoritmanın sonuçlarına dayalı olarak daha sağlam kararlar alınabilir, çünkü portföy ağırlıkları, yalnızca geçmiş performansa değil, aynı zamanda gelecekteki olası değişimlere de duyarlı olan bir yapıya sahip olacaktır.

Genetik algoritmalar, klasik yöntemlerle çözümü elde edilemeyen karmaşık problemlere, en iyi ya da en iyiye yakın sonuçların, hızlı bir şekilde elde edilmesi için kullanılabilen kolay uygulanabilir, güçlü bir optimizasyon tekniğidir. Genetik algoritmaların bu avantajları aşağıda anlatılmıştır. (Pereira, a.g.e., s. 15)

- Çok geniş bir çözüm uzayı
- Birden fazla optimum noktası
- Amaç fonksiyonunun türevinin alınamıyor olması
- Amaç fonksiyonundaki süreksizlikler
- Verilerin doğrusal (lineer) olmaması

- Verilerde önemli oranda hata payı (noise) olması
- Verilerin istikrarsız (nonstationary) olması

Ancak, genetik algoritmanın kullanımı sırasında dikkat edilmesi gereken bazı faktörler vardır. Örneğin, fitness fonksiyonunun doğru şekilde tanımlanması ve genetik operatörlerin uygun bir şekilde uygulanması, sonuçların doğruluğunu ve optimizasyonun etkililiğini etkileyebilir.

Ayrıca, portföy optimizasyonunda genetik algoritmanın kullanımı, birçok değişkenin bulunduğu karmaşık bir problem olduğundan, genetik algoritmanın sonuçlarına güvenmek, başka risk faktörlerinin de dikkate alınması gerektiği anlamına gelir. Bu nedenle, yatırımcıların, genetik algoritma sonuçlarına dayanarak portföy yönetim kararlarını tek başlarına vermek yerine, bu sonuçları diğer analiz yöntemleriyle birleştirmeleri tavsiye edilir.

Genetik algoritmalar nitelikleri gereği niceldirler, dolayısıyla da parametre optimizasyonu için çok uygundur. Genetik algoritmaların en yaygın kullanım alanı çok parametrelili fonksiyon optimizasyonudur. (Forrest, 1996, s. 79)

2.3.4.1. Genetik Programlama (Genetic Programming - GP)

Genetik Programlama (Genetic Programming - GP), genetik algoritmaların bir türüdür ve özellikle sembolik regresyon ve otomatik kod üretimi problemlerini çözmek için kullanılır. GP, bir popülasyon içinde sembolik ifadeler veya programlar oluşturur ve bu programları optimize etmek için genetik operatörler kullanır. İşte Genetik Programlama'nın temel bileşenleri ve nasıl çalıştığına dair ayrıntılar:

1. Popülasyon Oluşturma: İlk olarak, GP bir popülasyon oluşturur. Bu popülasyon, sembolik ifadeler veya programlar içerir. Her bir program, potansiyel bir çözüm adayını temsil eder.

2. Uygunluk Fonksiyonu (Fitness Function): Her programın bir uygunluk değeri vardır, bu uygunluk değeri programın ne kadar iyi veya kötü bir çözüm adayı olduğunu

belirtir. Uygunluk fonksiyonu, optimize edilmek istenen hedefi veya kriteri temsil eder. Genellikle bu fonksiyon, programın çıktısı ile gerçek veriler arasındaki farkı ölçer.

3. Evrimsel Operatörler:

- **Çaprazlama (Crossover):** İki programın belirli bir noktasını kesip birleştirerek yeni programlar oluşturur. Bu, ebeveynlerin genetik materyallerini birleştirerek yeni çözümler üretme işlemidir.
- **Mutasyon:** Bir programın sembolik ifadesini rastgele değiştirerek yeni programlar oluşturur. Mutasyon, genetik çeşitliliği artırır ve yeni çözümler keşfetmeye yardımcı olur.

4. Seçilim: Programların uygunluk düzeyine dayalı olarak seçildiği bir işlem. Daha yüksek uygunluk değerine sahip programlar, bir sonraki nesilde daha fazla temsil edilme olasılığına sahiptir.

5. Elitizm: En iyi birkaç programın her nesilde korunduğu bir işlem. Bu, en iyi çözümlerin kaybolmasını önler ve daha hızlı yakınsamayı sağlar.

6. Jenerasyonlar: GP, belirli bir sayıda jenerasyon veya belirli bir uygunluk seviyesi elde edene kadar nesilleri sırayla oluşturur ve geliştirir.

7. İzlem ve Analiz: GP çalışırken, her neslin en iyi programları izlenir ve sonuçları analiz edilir. Bu, GP'nin ilerlemesini değerlendirmenize ve çözümün optimize edilip edilmediğini kontrol etmenize yardımcı olur.

Genetik Programlama, sembolik ifadeler veya programlar kullanarak karmaşık problemleri çözmek için güçlü bir araçtır. Özellikle matematiksel ifadelerin otomatik olarak oluşturulması, işlevlerin yaklaşılaştırılması, kod üretimi, sembolik regresyon ve sembolik veri analizi gibi alanlarda kullanılır. GP'nin gücü, problemi modellemek için esnek sembolik yapıların kullanılabilmesi ve optimize edilmesi gereken karmaşık problemlerde etkili bir şekilde çalışabilmesidir.

2.3.4.2. Genetik Algoritma Tabanlı Sıralama (Genetic Algorithm for Ranking - GAR)

Genetik Algoritma Tabanlı Sıralama (Genetic Algorithm for Ranking - GAR), özellikle sıralama problemlerini çözmek için tasarlanmış bir genetik algoritma türüdür. Bu tür genetik algoritma, öğeleri belirli bir sıraya göre sıralamak veya sıralama işlemini optimize etmek için kullanılır. Sıralama problemleri, birçok uygulama alanında karşımıza çıkar, örneğin sıralama tabloları oluşturma, turnuvaların sıralanması veya sıralı veri çıkarma gibi alanlarda kullanılır.

İşte Genetik Algoritma Tabanlı Sıralama'nın temel bileşenleri ve nasıl çalıştığına dair ayrıntılar:

1. Popülasyon Oluşturma: İlk olarak, GAR bir popülasyon oluşturur. Bu popülasyon, sıralama probleminin çözüm adaylarını temsil eder. Her bir aday, sıralamanın bir varyasyonunu içerir.

2. Uygunluk Fonksiyonu (Fitness Function): Her sıralama adayının bir uygunluk değeri vardır. Bu uygunluk değeri, sıralamanın ne kadar iyi veya kötü olduğunu ölçer. Genellikle, uygunluk fonksiyonu, sıralamanın hedef kriterlere ne kadar yakın olduğunu belirtir.

3. Evrimsel Operatörler:

- **Çaprazlama (Crossover):** İki sıralama adayının sıralama sıralarını birleştirerek yeni sıralama adayları oluşturur. Bu, iki ebeveynin sıralamalarını birleştirerek daha iyi sıralamalar üretme işlemidir.
- **Mutasyon:** Bir sıralama adayının sıralama sıralarını rastgele değiştirerek yeni sıralama adayları oluşturur. Mutasyon, genetik çeşitliliği artırır ve yeni sıralama varyasyonları keşfetmeye yardımcı olur.

4. Seçim: Sıralama adaylarının uygunluk düzeyine dayalı olarak seçildiği bir işlem. Daha yüksek uygunluk değerine sahip adaylar, bir sonraki nesilde daha fazla temsil edilme olasılığına sahiptir.

5. Elitizm: En iyi birkaç sıralama adayının her nesilde korunduğu bir işlem. Bu, en iyi sıralamaların kaybolmasını önler ve daha hızlı yakınsamayı sağlar.

6. Jenerasyonlar: GAR, belirli bir sayıda jenerasyon veya belirli bir uygunluk seviyesi elde edene kadar nesilleri sırayla oluşturur ve geliştirir.

7. İzlem ve Analiz: GAR çalışırken, her neslin en iyi sıralama adayları izlenir ve sonuçları analiz edilir. Bu, GAR'nin ilerlemesini değerlendirmenize ve sıralamanın optimize edilip edilmediğini kontrol etmenize yardımcı olur.

Genetik Algoritma Tabanlı Sıralama, sıralama problemlerini çözmek için güçlü bir araçtır ve sıralama sıralarının optimize edilmesi gereken birçok uygulama alanında kullanılır. Bu tür bir genetik algoritma, farklı sıralama kuralları ve ölçütler için uyarlanabilir ve birçok çeşitli sıralama problemini ele alabilir. GAR'nin gücü, sıralama probleminin doğasına uygun olarak farklı uygunluk fonksiyonları ve sıralama stratejileri kullanabilmesidir.

2.3.4.3. Küme Tabanlı Genetik Algoritmalar (Cluster-Based Genetic Algorithms - CBGA)

Küme Tabanlı Genetik Algoritmalar (Cluster-Based Genetic Algorithms - CBGA), kümeleme problemlerini çözmek için tasarlanmış bir genetik algoritma türüdür. Bu tür genetik algoritma, bir veri kümesindeki benzer öğeleri gruplayarak veya kümelemeyi optimize ederek kullanılır. Kümeleme, özellikle veri analizi ve veri madenciliği alanlarında sıkça kullanılan bir tekniktir.

CBGA'nın temel amacı, veri kümesini homojen kümelere bölmek veya kümelemeyi optimize etmek için uygun küme merkezlerini ve sınırlarını bulmaktır. İşte CBGA'nın temel bileşenleri ve nasıl çalıştığına dair ayrıntılar:

- 1. Popülasyon Oluşturma:** İlk olarak, CBGA bir popülasyon oluşturur. Bu popülasyon, veri kümesindeki küme merkezi ve sınırları temsil eden çözüm adaylarını içerir. Her bir aday, bir kümeleme çözümünü temsil eder.
- 2. Uygunluk Fonksiyonu (Fitness Function):** Her kümeleme çözümünün bir uygunluk değeri vardır, bu uygunluk değeri kümelemeyi ne kadar iyi veya kötü optimize ettiğini ölçer. Uygunluk fonksiyonu, küme merkezlerinin ve sınırlarının veriye ne kadar iyi uyarlandığını değerlendirir.
- 3. Evrimsel Operatörler:**
 - **Çaprazlama (Crossover):** İki kümeleme çözümünün küme merkezlerini ve sınırlarını birleştirerek yeni kümeleme çözümleri oluşturur. Bu, iki ebeveynin kümeleme yapısını birleştirerek daha iyi kümeleme çözümleri üretme işlemidir.
 - **Mutasyon:** Bir kümeleme çözümünün küme merkezlerini ve sınırlarını rastgele değiştirerek yeni kümeleme çözümleri oluşturur. Mutasyon, genetik çeşitliliği artırır ve yeni kümeleme varyasyonları keşfetmeye yardımcı olur.
- 4. Seçim:** Kümeleme çözümlerinin uygunluk düzeyine dayalı olarak seçildiği bir işlem. Daha yüksek uygunluk değerine sahip çözümler, bir sonraki nesilde daha fazla temsil edilme olasılığına sahiptir.
- 5. Elitizm:** En iyi birkaç kümeleme çözümünün her nesilde korunduğu bir işlem. Bu, en iyi kümelemelerin kaybolmasını önler ve daha hızlı yakınsamayı sağlar.
- 6. Jenerasyonlar:** CBGA, belirli bir sayıda jenerasyon veya belirli bir uygunluk seviyesi elde edene kadar nesilleri sırayla oluşturur ve geliştirir.
- 7. İzlem ve Analiz:** CBGA çalışırken, her neslin en iyi kümeleme çözümleri izlenir ve sonuçları analiz edilir. Bu, CBGA'nin ilerlemesini değerlendirmenize ve kümelemeyi optimize edip etmediğini kontrol etmenize yardımcı olur.

CBGA, veri kümeleme problemlerini çözmek için güçlü bir araçtır. Özellikle büyük veri setlerini kümelendirmek veya veri analizi yapmak gerektiğinde kullanılır. CBGA'nın gücü, farklı kümeleme yapısı ve kriterleri için uygunluk fonksiyonları ve genetik operatörler kullanabilmesidir. Bu sayede verileri anlamak ve gruplandırmak için optimize edilmiş kümelemeler elde edilebilir.

2.3.4.4. Çok Amaçlı Genetik Algoritmalar (Multi-Objective Genetic Algorithms - MOGA)

Çok Amaçlı Genetik Algoritmalar (Multi-Objective Genetic Algorithms - MOGA), birden fazla amaç veya kritere sahip olan optimizasyon problemlerini çözmek için tasarlanmış bir genetik algoritma türüdür. Bu tür genetik algoritma, her biri farklı amaçları temsil eden çok sayıda uygunluk fonksiyonu kullanır ve bu amaçları optimize etmek için çalışır. MOGA, çok amaçlı optimizasyon problemlerini ele alır ve tipik olarak bir çözümün "Pareto ön sahil" adı verilen bir ön sahilde bulunması gerektiği bir yaklaşımı benimser.

MOGA'nın temel amacı, bir çözümün birçok farklı amaç veya kritere karşı nasıl performans gösterdiğini değerlendirmektir. Bu tür problemler genellikle çelişen hedeflere sahiptir, yani bir amaçın iyileştirilmesi diğerlerini kötüleştirir. MOGA, bu çelişkili hedefleri dengelemeye çalışır ve birçok farklı optimum çözümün bulunduğu bir çözüm setini üretir.

MOGA'nın temel bileşenleri ve nasıl çalıştığına dair ayrıntılar şunları içerir:

1. Popülasyon Oluşturma: İlk olarak, MOGA bir popülasyon oluşturur. Bu popülasyon, farklı çözüm adaylarını temsil eder. Her bir aday, çok amaçlı optimizasyon probleminin bir çözümünü temsil eder.

2. Çok Amaçlı Uygunluk Fonksiyonları: MOGA, her bir çözümün her bir amaç veya kritere karşı nasıl performans gösterdiğini değerlendirmek için çok amaçlı uygunluk fonksiyonlarını kullanır. Bu fonksiyonlar, her bir amaç için bir uygunluk değeri üretir.

3. Pareto Ön Sahil: MOGA, çözüm adaylarını değerlendirirken, bu adayların Pareto ön sahilde olup olmadığını kontrol eder. Pareto ön sahil, hiçbir amaç fonksiyonunu kötüleştirmeyen ve diğerlerini iyileştiren çözüm adaylarının oluşturduğu bir ön sahtir.

4. Evrimsel Operatörler:

- **Çaprazlama (Crossover):** İki çözüm adayının özelliklerini birleştirerek yeni çözüm adayları oluşturur. Bu, iki ebeveynin özelliklerini birleştirerek daha iyi çözüm adayları üretme işlemidir.
- **Mutasyon:** Bir çözüm adayının özelliklerini rastgele değiştirerek yeni çözüm adayları oluşturur. Mutasyon, genetik çeşitliliği artırır ve yeni çözüm varyasyonlarını keşfetmeye yardımcı olur.

5. Seçilim: Çözüm adaylarının Pareto ön sahildeki konumlarına dayalı olarak seçildiği bir işlem. Ön sahilde daha yakın olan adaylar, bir sonraki nesilde daha fazla temsil edilme olasılığına sahiptir.

6. Elitizm: En iyi çözüm adaylarının her nesilde korunduğu bir işlem. Bu, en iyi çözümlerin kaybolmasını önler ve daha hızlı yakınsamayı sağlar.

7. Jenerasyonlar: MOGA, belirli bir sayıda jenerasyon veya belirli bir Pareto ön sahil kalitesi elde edene kadar nesilleri sırayla oluşturur ve geliştirir.

MOGA, birden fazla amaç veya kritere sahip karmaşık optimizasyon problemlerini çözmek için etkili bir yaklaşımdır. Özellikle mühendislik tasarımı, portföy optimizasyonu, enerji yönetimi ve karar verme gibi alanlarda kullanılır. MOGA, birçok farklı hedefi dengeleyebilme yeteneğine sahip olduğu için çok amaçlı optimizasyon problemlerine uygundur ve çelişen hedefleri ele alabilir.

2.3.4.5. Gelişmiş Genetik Algoritmalar (Enhanced Genetic Algorithms - EGA)

"Gelişmiş Genetik Algoritmalar" (Enhanced Genetic Algorithms - EGA) terimi, genetik algoritma (GA) temel modelini özelleştirmek ve geliştirmek amacıyla kullanılır. EGA'lar, belirli bir uygulama veya problem türüne özgü gereksinimlere daha iyi uyan veya performansı artıran farklı genetik operatörler, stratejiler veya özellikler içerebilirler. Bu nedenle EGA, genetik algoritmanın temel bileşenlerini (seçilim, çaprazlama, mutasyon, uygunluk fonksiyonu, vb.) değiştiren veya özelleştiren birçok farklı varyasyon içerebilir.

EGAs, çeşitli uygulama alanlarında ve problemlerde kullanılabilirler. İşte bazı özellikleri ve özelleştirmeleri:

- 1. Özelleştirilmiş Genetik Operatörler:** EGA'lar, problem türüne ve hedeflere göre özelleştirilmiş çaprazlama, mutasyon ve seçilim operatörleri içerebilirler. Örneğin, karmaşık problemler için özel çaprazlama operatörleri geliştirilebilir.
- 2. Hibrit Genetik Algoritmalar:** EGA'lar, farklı optimizasyon teknikleri (örneğin, simülasyon tabanlı optimizasyon, lokal arama yöntemleri, yapay sinir ağları, vb.) ile birleştirilerek hibrit genetik algoritmalar oluşturabilirler. Bu, GA'nın güçlü yönlerini diğer tekniklerle birleştirme potansiyeline sahiptir.
- 3. Özellik Mühendisliği:** Veri madenciliği ve örüntü tanıma problemleri için, EGA'lar özellik seçimi veya özellik mühendisliği için özel stratejiler içerebilirler.
- 4. Dinamik Parametre Ayarları:** EGA'lar, GA'nın parametrelerini problem dinamiklerine veya çevresel değişikliklere uyacak şekilde ayarlayabilen otomatik parametre ayarları içerebilirler.

5. **Popülasyon Yapıları:** EGA'lar, popülasyonların yapısını özelleştirebilirler. Örneğin, hücre yapıları veya çevresel etkileşimleri içeren modeller geliştirilebilir.
6. **Özelleştirilmiş Uygunluk Fonksiyonları:** EGA'lar, problem alanına özgü uygunluk fonksiyonları veya değerlendirme kriterleri içerebilirler.

EGAs, birçok farklı problem türüne ve uygulama alanına uygun olarak tasarlanabilir ve özelleştirilebilirler. Bu özelleştirmeler ve geliştirmeler, bir GA'nın belirli bir problemi daha etkili bir şekilde çözebilmesini sağlar. Ancak, EGA'lar da parametre ayarları ve performans değerlendirmesi gerektiren karmaşık sistemler olabilir. Probleminize en iyi uyan EGA yaklaşımını seçerken dikkatli bir şekilde analiz yapmalısınız.

Sonuç olarak, genetik algoritmanın portföy optimizasyonunda kullanımı, yatırımcıların risk ve getiri oranlarını optimize etmelerine yardımcı olabilir. Ancak, doğru şekilde kullanılmadığında, sonuçların doğruluğu ve etkililiği etkilenebilir. Bu nedenle, yatırımcıların genetik algoritmayı diğer analiz yöntemleriyle birleştirerek kullanmaları ve sonuçları dikkatli bir şekilde değerlendirmeleri önerilir.

Genetik Algoritmanın temel prensiplerini kullanan DGA'da bireyler gerçek değerleriyle kodlanmaktadır. Popülasyon tabanlı bir yöntem olan DGA, kodlanması basit ama etkili sonuçlar veren bir direkt araştırma yöntemidir. Bilimde ve özellikle mühendislik alanındaki problemler gerçek parametrelili optimizasyon problemleri olarak adlandırılmaktadır. Gerçek değerle kodlama sayesinde DGA bu alanda kullanılan önemli yöntemlerden biridir. Özetle, Evrimsel hesaplama tekniklerinin bir üyesi olan DGA, stokastik direkt arama ve küresel optimizasyon algoritmasıdır. Ayrık optimizasyon algoritması değil nümerik optimizasyon için geliştirilmiş gelişime dayalı bir algoritmadır. DGA'nın basit ve sade yapısı, kullanım ve kodlama kolaylığı, hızı ve dinçliği kullanımı konusunda önemli avantajlar sağlamaktadır. (Derviş Karaboğa,2011, s.161)

BÖLÜM 3

YAPAY ZEKA MAKİNE ÖĞRENME MODELİ, LGBM ALGORİTMASI KULLANARAK BİST100 HİSSE SENEDLERİNE UYGULAMA

3.1.ÇALIŞMANIN AMACI VE KAPSAMI

Bu çalışmada bir varlığın gelecekteki fiyat hareketlerini tahmin etmek için bir makine öğrenme modelinin uygulanması karar verilmiştir. Öncelikle RSI, MACD farklı periyotları bir dizi teknik göstergelere dayalı olarak Makine öğrenme tekniklerinin LightGBM algoritması kullanarak bir model eğitildi.

Eğitim süreci, Belirli bir dönemde piyasa verilerini modele beslemeyi ve verilerdeki desenleri ve trendleri tanımayı öğrenmeyi içerir. Model daha sonra, alım, satım veya varlığı tutma konusunda işlem sinyalleri sağlayarak mevcut piyasa verilerini analiz ederek gelecekteki fiyat tahminlerinde bulunmak için kullanılır.

Ayrıca, kullanılan teknik analiz göstergelerini özelleştirmemize ve analiz edilen grafiğin zaman çerçevesini ayarlamamıza izin veren birçok giriş parametresi içerir (örneğin, Uzunluk parametresi, modelin verileri analiz etmek için ne kadar uzun bir zaman çerçevesi kullanacağını belirlemeye yardımcı olur).

Genel olarak, bu modelin amacı, teknik göstergelerin ve makine öğrenme modellerinin kombinasyonunu kullanarak yatırımcıların doğru işlem sinyalleri oluşturarak bilinçli kararlar vermesini sağlamaktır.

Bu Çalışmada Python programlama dilini kullanarak finansal veri analizi ve model oluşturma finansal verilerin analiz edilmesi için Python'un güçlü veri analizi kütüphanelerini Pandas, NumPy ve Matplotlib gibi kütüphaneler veri işleme, veri keşfi ve veri görselleştirme ,sınıflandırma, kümeleme ve boyut azaltma gibi konular, bu programla rahatlıkla çok hızlı bir şekilde yapılabilir,Yapay zeka ve makine öğrenme kullanarak portföy yönetimi stratejileri geliştirilebilir

(yves HİLPİSCH, “A Python-based Guide”, Artificial Intelligence in Finance: A Python-Based Guide, USA: O`Reilly Media,2020)

İş dünyasını Yapay Zeka ile stratejik bir avantaj haline getirilebilir, İş süreçlerini iyileştirme, müşteri deneyimini geliştirme ve operasyonel verimlilik sağlama gibi konularda büyük etkisi vardır.

(Mariya Yao, Adelyn Zhou, Marlene Jia, Mariya Yao, Adelyn Zhou, Marlene Jia , **Applied Artificial Intelligence**, New York: *Topbots Inc*, 2018)

Sistemik Ticaret Stratejileri geliştirmek için makine öğrenme tekniklerini kullanarak Ticaret sinyalleri, risk yönetimi, portföy yönetimi ve gerçek zamanlı ticaret uygulaması gibi konularda kullanılır, Alternatif verilerin finansal piyasalarda Yapay zeka ve doğal dil işleme tekniklerini kullanarak alternatif verilerden ticaret sinyalleri üretme imkanını sağlar.

(Stefan Jansen, **Machine Learning for Algorithmic Trading: Predictive models to extract signals from market and alternative data for systematic trading strategies with Python**", Birmingham, UK : *Packt Publishing*, 2020.)

Makine öğrenmesi birçok alanda çok başarılı sonuçlar vermiştir. Metin işleme (Aggarwal & Zhai, 2012; Berry & Castellanos, 2004; Tan, 1999), doğal dil işleme (Jurafsky, 2000; C. D. Manning ve diğ., 1999; C. Manning ve diğ., 2014), resim işleme (Chan ve diğ., 2015; LeCun, Bengio, & Hinton, 2015; Wan ve diğ., 2014; Wang & Yeung, 2013), zaman serileri tahminlemesi (Ahmed ve diğ., 2010; Cao & Tay, 2003), sınıflandırma (Kotsiantis ve diğ., 2007; Nasrabadi, 2007) ve gruplandırma çalışmaları (Hartigan & Wong, 1979; Jain & Dubes, 1988; Steinbach ve diğ., 2000) örnek olarak verilebilir.

Son yıllarda piyasa analizi için makine öğrenmesi konusunda çeşitli çalışma kitapları yayınlanmıştır. Bu çalışmada işte bazı önemli incelenen kitaplardan birkaç örnek:

1. "Advances in Financial Machine Learning" - Marcos López de Prado

Finansal piyasa verilerini analiz etmek ve tahminlerde bulunmak için makine öğrenmesi tekniklerini kullanmanın yanı sıra portföy yönetimi ve risk yönetimi konularını ele alan kapsamlı bir kaynak.

2. "Machine Learning for Algorithmic Trading" - Stefan Jansen

Algoritmik ticaret için makine öğrenmesini anlatan bu kitap, finansal veri analizi, ticaret stratejileri oluşturma ve uygulama, veri temizleme ve makine öğrenmesi algoritmalarının kullanımı gibi konulara odaklanmaktadır.

3. "Python for Finance: Analyze Big Financial Data" - Yves Hilpisch

Finansal veri analizi ve piyasa tahmini için Python programlama dilini kullanmayı öğreten bir kaynak. Makine öğrenmesi tekniklerinin yanı sıra finansal modelleme ve portföy analizi gibi konulara da değinmiştir.

4. "Machine Learning and Data Science for Algorithmic Trading" - Igor Marinkovic

Algoritmik ticaret ve finansal piyasa analizi için makine öğrenmesi ve veri bilimi konularını ele alan bir kitap. Hem temel kavramları hem de pratik uygulamaları kapsar.

5. "Machine Learning for Trading" - Ernest Chan

Finansal piyasalarda makine öğrenmesi tekniklerini uygulamak için pratik bir rehber olan bu kitap, ticaret stratejileri oluşturma, gerçek zamanlı işlem yapma ve risk yönetimi gibi konuları ele alır.

3.2.UYGULAMA YÖNTEMİ

Bu çalışmada, İstanbul Borsası endekslerinin analizi ve tahmini için yapay zeka modelinin kullanılmasını hedeflemektedir. Proje aşağıdaki adımlarla gerçekleştirilebilir:

Adım 1: Veri Toplama: Bu adımda, İstanbul Borsası endekslerine ait verileri Yahoo Finance kaynağından toplanmıştır. Bu veriler, hisse senedin açılış kapanış ve en yüksek, En düşük fiyatları, Ve işlem hacmi yer almaktadır.

Adım 2: Veri Ön İşleme: Verileri topladıktan sonra, verileri işleme ve temizleme yapılmıştır. Bu adım, eksik veya hatalı verilerin temizlenmesi, verilerin yapay zeka modelleri için uygun formata dönüştürülmesi vb. işlemleri içermiştir.

Adım 3: Önce verileri teknik analiz MACD ve RSI göstergeleri kullanarak fiyat tahmini ve AL/SAT sinyalleri üretilmiştir, Daha sonra Yapay Zeka Modelinin Seçimi ve Eğitimi aşaması olarak Bu adımda, verileri analiz etmek için (Light GBLM) yapay zeka modeli seçtikten sonra, topladığımız verileri kullanarak model teknik analiz sonuçlarına dayalı eğitilmiştir.

Adım 4: Modelin Test Edilmesi ve Değerlendirilmesi: Modeli eğittikten sonra, Model test edildi ve değerlendirildi. Bu çalışmada modelin gerçek verilerle yapmış olduğu tahminleri teknik analizin yaptığı fiyat tahminiyle karşılaştırma yapılmıştır.

Adım 5: Sonuçların Sunumu Bu adımda, çalışmamızın sonuçlarını sunulmuştur, Bu, proje süreci hakkında açıklamalar, modelin tahminleri, sonuçların analizi vb, içerir.

Bu çalışmada, yatırımcılar için birçok uygulama alanına sahiptir ve mevcut verilere dayanarak daha iyi kararlar vermelerine yardımcı olabilir.

3.3. UYGULAMADA KULLANILAN GÖSTERGELER

Adım 1: Veri Toplama Bu adımda, BİST100 deki finans sektörün gösterge niteliğin taşıyan ve domine eden, yüksek volatilité, Yüksek getiri ve yüksek işlem hacmine sahip olan ,AkBank (AKBNK), Türk Hava Yolları(THY) ve (SASA) gibi şirketlere ait günlük frekansta hisse senedi verilerini 1 Ocak 2020'den 1 Haziran 2023'e kadar toplandı.

Adım 2: Veri Ön İşleme Bu adımda, verileri sınıflandırma, veri standardizasyonu ve eksik verilerin işlenmesi (örneğin, cumartesi ve pazar günleri piyasa kapalı olduğu için bu günlerdeki verilerin çıkarılması veya düzeltilmesi) gibi işlemlerle temizleme yapılmıştır. Ayrıca verileri getiri (returns) değişkenine dönüştürülmüştür.

Adım 3: Veri Analizi Bu adımda, her bir şirketin günlük fiyat grafiği oluşturuldu. Ayrıca hareketli ortalama (MA), (EMA), Ve RSI , MACD gibi teknik analiz

göstergelerini bu verilere uyguladık. İlgili göstergeleri belirli bir şirketin verilerine uygulayarak, bir grafikte hem MACD hem de RSI göstergelerini gösterildi.

Adım 4: Makine Öğrenimi Modelinin Eğitimi Bu adımda, toplanan verileri kullanarak Light GBM algoritmasını kullanarak bir makine öğrenimi modeli eğitilmiştir. Bu adım, öğrenme ve test aşamalarına ayırarak.

Adım 5: Sonuçların Değerlendirilmesi Bu adımda, elde edilen sonuçları tablolar ve grafiklerde gösterilmiştir. Geçmiş analiz ve her bir hisse senedi için farklı parametrelerin incelenmesiyle oluşturulan bir modeli sunulacaktır.

Teknik analiz (RSI/MACD) ile yapay zeka tarafından oluşturulan grafik arasındaki ortak noktaları ve hata yüzdesini karşılaştırarak bir analiz yapılmıştır.

Bu çalışmanın sonucunda, yapay zeka modellerinin geçmiş analizle piyasayı iyileştirdiği ve her bir hisse senedi için "Al/Sat" sinyalleri önerdiği gözlemlenmektedir.

3.4. UYGULAMA ALGORİTMA SEÇİMİ

Light GBM Algoritma Tanım ve Özellikler:

Light GBM (Light Gradient Boosting Machine) gibi makine öğrenimi algoritmaları, özellikle büyük veri kümeleri üzerinde yüksek performans sergileyen ve hızlı çalışan modeller oluşturmayı sağlayan bir yöntemdir. Light GBM, bir gradient boosting framework'ü olan GBM'nin hafifletilmiş bir versiyonudur.

Light GBM'nin tercih edilmesinin bazı nedenleri şunlardır:

1. Hızlı ve verimli: Light GBM, düşük bellek tüketimiyle yüksek hızda çalışır. Büyük veri kümeleriyle bile hızlı bir şekilde başa çıkabilir ve model eğitimi süresini önemli ölçüde azaltır.

2. Yüksek performans: Light GBM, diğer geleneksel boosting algoritmalarına göre daha iyi bir performans sergiler. Özellikle büyük veri kümeleri veya yüksek boyutlu özellik uzayları gibi zorlu veri setleri üzerinde etkilidir.
3. Daha az aşırı uydurma (overfitting) eğilimi: Light GBM, düşük öğrenme hızı ve daha fazla ağaç (tree) kullanarak aşırı uydurma sorununu azaltır. Bu, daha iyi genelleştirme yeteneği ve daha iyi tahminler sağlar.
4. Kategorik değişkenlerin otomatik işlenmesi: Light GBM, kategorik değişkenleri otomatik olarak işleyebilir, böylece kategorik değişkenlerin dönüştürülmesi veya kodlanması gibi ayrı bir ön işleme adımına ihtiyaç duymaz.
5. Paralel işleme yeteneği: Light GBM, paralel işleme yeteneği sayesinde çoklu işlemci veya dağıtık sistemlerde verimli bir şekilde çalışabilir. Bu da büyük ölçekli veri işleme ve model eğitimi için avantaj sağlar.

Bu nedenlerle, Light GBM gibi hızlı, verimli ve yüksek performanslı bir makine öğrenimi algoritması seçmek, borsa endekslerinin analizi ve tahmini gibi karmaşık görevler için uygundur. Ancak her zaman veri setinin özelliklerine ve projenin gereksinimlerine bağlı olarak en uygun algoritma seçilmelidir.

3.5. TEMEL VE ALT PROBLEM SORULARI

Temel alt problem, BİST100 hisse senetlerine yapay zeka ve makine öğrenmesi kullanarak LGBM (Light Gradient Boosting Machine) algoritmasıyla uygulama yapılmasıyla ilgili spesifik bir sorunu ifade eder. Bu problem genellikle hisse senedi fiyatlarının tahminlenmesi, trendlerin belirlenmesi veya alım-satım sinyallerinin üretilmesi gibi finansal analiz konularında odaklanır.

Bu tür bir uygulama için aşağıdaki sorulara yanıt aranabilir:

1. Hisse senedi fiyatları nasıl tahminlenebilir?
2. Hangi faktörler hisse senedi fiyatlarını etkiler?

3. Hangi teknik göstergeler hisse senedi performansını tahmin etmede daha etkilidir?
4. Geçmiş verilerin analiziyle gelecekteki fiyat hareketleri tahmin edilebilir mi?
5. LGBM algoritması gibi bir makine öğrenme modeli kullanarak hisse senedi fiyat tahmini yapılabilir mi?
6. Risk ve getiri analizinde makine öğrenmesi nasıl yardımcı olabilir?
7. Duygusal faktörlerin hisse senedi fiyatları üzerindeki etkisi nasıl hesaba katılabilir?
8. Piyasa haberlerinin hisse senedi fiyatlarına etkisi nasıl değerlendirilebilir?
9. Makine öğrenmesi algoritmalarıyla elde edilen sonuçlar ne kadar güvenilir ve tutarlıdır?
10. Makine öğrenme yöntemi teknik analiz yöntemine göre daha etkili ve yararlı olacak mı?

Bu sorular, yapay zeka ve makine öğrenmesi kullanarak hisse senedi analizi ve tahmini yapmak isteyen biri tarafından yanıtlanması gereken temel sorular arasındadır.

3.6.ANALİZ VE BULGULAR

Bu çalışmada, Belirli bir hisse senetlerini 1 Ocak 2020'den 1 Haziran 2023'e kadar olan hisse senedi fiyatlarını analiz ve gelecek fiyat tahmin etmeyi amaçlamaktadır. Bu çalışmada iki farklı metodoloji kullanılmaktadır: Hareketli Ortalama Yakınsama Sapma (MACD) ve Göreceli Güç Endeksi (RSI) kullanan teknik analiz ve Makine Öğrenimi (ML) teknikleri.

Metodoloji

Proje iki aşamada gerçekleştirildi:

1.Teknik Analiz:

İlk aşama, hisse senedi fiyatlarını analiz etmek için teknik göstergelerin - MACD ve RSI - kullanılmasını içeriyordu. Hem MACD hem de RSI, gelecekteki fiyat eğilimlerini tahmin etmek için borsa analizinde yaygın olarak kullanılır. Analiz için veriler Yahoo Finance platformundan, Python programı kullanılarak alınmış ve uygulanmıştır.

2.Makine Öğrenimi Analizi:

İkinci aşamada ise aynı stok verilere Makine öğrenme (ML) teknikleri uygulanmıştır. Seçilen model, geçmiş stok verileri MACD ve RSI fiyat tahminlerin sonucuna dayalı eğitildi ve ardından performansı değerlendirildi.

3.Sonuçlar ve Karşılaştırma:

Her iki metodolojiden elde edilen çıktılar daha sonra tahmin performanslarını değerlendirmek için karşılaştırıldı. Bu karşılaştırma, bir yaklaşımın diğerine göre farklılıklarını ve potansiyel avantajlarını vurgulamayı amaçlamaktadır.

Vaka Çalışması: Akbank T.A.Ş.

Proje, Türkiye'nin önde gelen bankalarından Akbank T.A.Ş.'nin günlük işlem verilerinin analizi ile başlamaktadır. İşlem hacmi, açılış, kapanış, en yüksek ve en düşük fiyatları içeren veriler titizlikle incelenmiştir.

Şekil 3.1. AKBANK- MA



Yukarıdaki şekilde, 1 Ocak 2020'den 1 Haziran 2023'e kadar olan hisse senedinin performansının net bir resmini veren verilerin MA , görsel temsili yer almaktadır.

Şekil.3.2. AKBANK- EMA



Yukarıdaki şekilde, 1 Ocak 2020'den 1 Haziran 2023'e kadar olan hisse senedinin performansının net bir resmini veren verilerin EMA, görsel temsili yer almaktadır.

Tablo.3.1. Teknik Analiz işlem Detayları

Başlık	Değer
Ticaret aralığı	2020-01-01— 2023-06-01
Geriye dönük test aralığı	2020-01-01— 2023-06-01
Sembol	BIST:AKBANK
Zaman aralığı	1 day
Grafik tipi	Mumlar
Nokta değeri	1
Para Birim	TRY
Kene Boyutu	0.05
Kesinlik	Default
Hızlı Uzunluk	12
Yavaş Uzunluk	26
Sinyal Yumuşatma	9
RSI Uzunluğu	14
Stop Loss (%)	1
Take Profit (%)	2
Başlangıç sermayesi	100000 USD
Order size	10000 USD

piramitleme	1 orders
Comisyon	%0
Limit emirleri için fiyatı doğrulayın	0 ticks
kayma	0 ticks


Bunun yanı sıra, MACD ve RSI teknik göstergelerine dayalı bir işlem listesi oluşturulur. Bu tabloda Liste, işlemin tarihi, işlemin türü (alış veya satış) ve işlemin gerçekleştirildiği fiyat ve bir çok parametre ayrıntıları içerir.

Şekil.3.3. AKBANK –Teknik Analiz (RSI)




Bist100 deki Akbank Hisse senedinin 1 Ocak 2020'den 1 Haziran 2023e kadar günlük frekansta fiyat kapanışı ve ona göre teknik analizin RSI gösterge analizleri gösterilmiştir.

Şekil.3.4. AKBANK –Teknik Analiz (MACD)



Şekil 3.4’de Bist100 deki Akbank Hisse senedinin 1 Ocak 2020’den 1 Haziran 2023’e kadar günlük frekansta fiyat kapanışı ve Ona göre teknik analizin MACD gösterge analizleri gösterilmiştir.

Şekil 3.5. AKBANK –TEKNİK ANALİZ AL/SAT POZİSYONLAR



Şekil 3.5’de belirlenen dönemde teknik analiz göstergeleri total olarak 56 işlem açıp kapatmıştır ve bu işlemlerin 24 tanesi zarar ve 33 işlem getiri elde etmiştir,teknik analiz bu verdiği sinyallerin % 56 getiri ve % 44 oranı zarara sebep olmuştur.ve 1 ocak 2020’den 99.900 USD haziran 2023 kadar 103.800 USD olarak verdiği sinyaller sonucu 3.900 USD getiri elde etmiştir.

Makine Öğrenimi Analizi:

Çalışma kapsamında yapay zeka yöntemlerinden olan Makine öğrenim, Light GBM algoritma kullanılarak hisse senedi fiyat tahmini ve AL/SAT sinyaller üretim yapılması amaçlanmaktadır.Bu model yaptığımız Teknik analiz tahminlerin sonucuna dayalı yapılmaktadır ,ve teknik analiz bir çok göstegesini (MA,EMA,SMA,RSI,MACD,ADX) yer almaktadır, Ayrıca bu yöntem sonucu elde edilen sonuçlar teknik analiz tahminlerine göre kıyaslanarak elde edilen portföylerin performansları değerlendirilecektir.

Python Programı kullanılarak LGBM yöntem için portföy analiz ve AL/SAT sinyalleri elde edilecek ve portföylerin performansları getiri/risk oranı ile belirlenecektir. Bu kapsamda Python programda kullanılan LGBM parametrelerinden hiperparametreler


1. learning_rate
2. max_depth
3. n_estimators
4. num_leaves

Kullanarak model tasarlanmıştır.

Bu model , fiyat değişim yüzdesini tahmin etmek amacıyla ve AL/SAT sinyalleri vermesi için kurulmuştur. Model, Teknik analiz sonuçlarına dayalı mevcut verilere dayanarak yarınki fiyat değişim yüzdesini tahmin etmektedir. Tahminler pozitif ise (yüzde değişim oranı %2'nin üzerinde), Alım (long) sinyali verilmektedir. Tahminler negatif ise (yüzde değişim oranı %2'nin altında), Satış (short) sinyali verilmektedir.


Bu modelin pozisyon almadan önce pozitif ve negatif ayrımını yapabilmesi için bir kriter belirlenmiştir. Yani, tahmin edilen fiyat değişim yüzdesi %2'nin üstünde değilse, alım (long) sinyali verilmemekte ve tahmin edilen fiyat değişim yüzdesi %2'nin altında değilse, satış (short) sinyali verilmemektedir. Bu şekilde %2 değişim filtresi kullanılarak modelin sinyalleri belirlenmektedir.

Şekil.3.6.AKBAK- Makine Öğrenme AL/SAT Sinyal grafiği



Şekil 3.6 de gösterildiği gibi makine öğrenme modeli 1 Ocak 2020’den 1 Haziran 2023 kadar toplam 65 sinyal vermiştir ,59 sinyal 92 % oranı ile getiri, ve 6 sinyal 8% oranı ile zarar olarak elde etmiştir. Yani modelin 1 Ocak 2020’de 100.200 USD, 1 Haziran 2020e kadar AI/SAT sinyalleriyle 111.200 USD yapmış, ve tasarladığımız model 11.000 USD kar elde etmiştir.

Şekil.3.7. AKBANK- TEKNİK ANALİZ VE MAKİNE ÖĞRENME SONUCU KARŞILAŞTIRMA



Bu sonuçlara dayanarak, AKBANK hisse senedinin uygulama çalışmasında Makine Öğrenimi Analizinin daha yüksek bir kâr, Ve daha az risk potansiyeli sağladığı belirtebiliriz. Bu çalışmada daha az risk için 2% stop-stop kuralı uygulanmıştır bu filtre büyük kayıp olasılığını azaltmak için yapılmıştır makine öğrenimi modelinin parametrelerini ayarlamak gibi bu riski azaltmak için stratejiler keşfedilmiştir.

Makine Öğrenimi Analizi, Teknik Analizdeki 3.900 \$'a kıyasla 7.100 \$'lık daha yüksek bir Net Kâr elde etti.ve AI/SAT sinyalleri daha başarılı bir sonuç vermektedir.

Vaka Çalışması: THY


1: Teknik Analiz

Türk Hava Yolları (THY) şirketin 2020'den 1 Haziran 2023'e kadar olan hisse senedi fiyatlarını analiz etmeyi ve tahmin etmeyi amaçlamaktadır. Bu çalışmada iki farklı

metodoloji kullanılmaktadır: Hareketli Ortalama Yakınsama Sapma (MACD) ve Göreceli Güç Endeksi (RSI) kullanan teknik analiz ve Makine Öğrenimi (ML) teknikleri.

Proje, (THY)'nin günlük frekansta işlem verilerinin analizi ile başlamaktadır. İşlem hacmi, açılış, kapanış, en yüksek ve en düşük fiyatları içeren veriler titizlikle incelenir. Aşağıda,

Şekil.3.8. THY- MA göstergesi



Şekil 3.8’de belirtilen dönem boyunca hisse senedinin MA, performansının net bir resmini veren verilerin görsel temsili yer almaktadır.

Şekil.3.9. THY- EMA göstergesi



Şekil 3.9’de belirtilen dönem boyunca hisse senedinin EMA, performansının net bir resmini veren verilerin görsel temsili yer almaktadır.

Tablo.3.2. Teknik Analiz Detay listesi

Başlık	Değer
Ticaret aralığı	2020-01-01— 2023-06-01
Geriye dönük test aralığı	2020-01-01— 2023-06-01
Sembol	BIST:THY
Zaman aralığı	1 day
Grafik tipi	Mumlar
Nokta değeri	1
Para Birim	TRY
Kene Boyutu	0.05
Kesinlik	Default
Hızlı Uzunluk	12
Yavaş Uzunluk	26
Sinyal Yumuşatma	9
RSI Uzunluğu	14
Stop Loss (%)	1
Take Profit (%)	2
Başlangıç sermayesi	100000 USD
Order size	10000 USD
piramitleme	1 orders
Comısyon	%0
Limit emirleri için fiyatı doğrulayın	0 ticks
kayma	0 ticks


Bununla birlikte, MACD ve RSI teknik göstergelerine dayalı olarak bir işlem listesi hazırlanır. Bu liste, işlemin gerçekleştirildiği tarih, işlemin türü (alış veya satış) ve işlemin gerçekleştiği fiyat gibi detayları içerir.

Şekil.3.10. THY – Teknik Analiz (RSI) Göstergeleri




Şekil 3.10'de Bist100 deki Türk Hava Yolları Hisse senedinin belirlenen tarihe kadar günlük frekansta fiyat kapanışı ve Ona göre teknik analizin RSI gösterge analizi gösterilmiştir.

Şekil.3.11. THY – Teknik Analiz (MACD) Göstergeleri



Şekil 3.11'de Bist100 deki Türk Hava Yolları Hisse senedinin 1 Ocak 2020'den 1 Haziran 2023e kadar günlük frekansta fiyat kapanışı ve Ona göre teknik analizin MACD gösterge analizi gösterilmiştir.

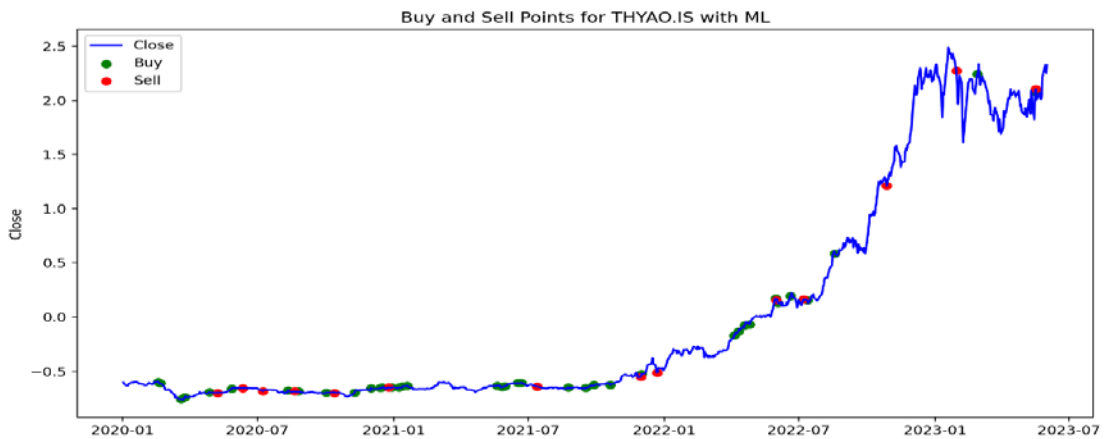
Şekil.3.12. THY-Teknik Analiz AL/SAT sinyalleri



Şekil 3.12’de belirlenen dönemde teknik analiz göstergeleri total olarak 57 işlem açıp kapatmıştır ve bu işlemlerin 15 tanesi zarar ve 42 işlem getiri elde etmiştir,teknik analizin bu verdiği sinyallerin % 75 getiri ve % 25 oranı zarara sebep olmuştur.ve 1 ocak 2020’den 100.200 USD ,haziran 2023 kadar 106.900 USD olarak verdiği sinyaller sonucu 6.700 USD getiri elde etmiştir.

THY Makine Öğrenimi(ML) Analiz

Şekil.3.13. THY-ML- AL/SAT sinyalleri




Şekil 3.13’de gösterildiği gibi makine öğrenme modeli belirlenen dönemde toplam 52 sinyal vermiştir ,44 sinyal 85 % oranı ile getiri, ve 8 sinyal 15% oranı ile zarar olarak elde etmiştir. Yani modelin 1 Ocak 2020’de 100.200 USD, 1 Haziran 2020e kadar

Al/SAT sinyalleriyle 108.000 USD yapmış, ve tasarladığımız model 7.800 USD kar elde etmiştir.

Karşılaştırmak:

İki analiz sonularına bakıldığında, not edilmesi gereken birkaç temel farklılık ve benzerlik vardır:

Şekil.3.14. THY-Teknik Analiz ve ML sonuç Karşılaştırma



Bu sonuçlardan hareketle, THY hisse senedi üzerinde yapılan makine öğrenimi analizinin, teknik analiz modeline göre daha etkili bir şekilde risk azaltma stratejisi sağladığını ve %10 daha yüksek bir kar potansiyeli sunabileceğini söyleyebiliriz. Ayrıca, makine öğrenimi analiziyle elde edilen net karın, teknik analizde elde edilen karın 1.100 dolar daha fazla olduğu görülmektedir. Al/SAT sinyallerinin de daha başarılı sonuçlar verdiği belirlenmiştir.


SASA:

1: Teknik Analiz

SASA Polyeste Sanayi AŞ'nin hisse senedi fiyatlarını analiz etmek ve tahmin etmek amacıyla, 2020'den 1 Haziran 2023'e kadar olan veriler kullanılmaktadır. Bu analizde, teknik analiz yöntemleri olarak Hareketli Ortalama Yakınsama Sapma (MACD) ve Göreceli Güç Endeksi (RSI) kullanılmaktadır. Bu yöntemler, günlük frekansta işlem


verilerini inceleyerek işlem hacmi, açılış, kapanış, en yüksek ve en düşük fiyatları dikkatlice değerlendirir.

Şekil.3.15. SASA-MA göstergesi



Şekil 3.15’de belirtilen dönem boyunca hisse senedinin Hareketli Ortalama (MA) performansını gösteren verilerin görsel bir temsili bulunmaktadır. Bu görsel, hisse senedinin fiyat trendleri ve hareketli ortalamaların ilişkisini net bir şekilde göstermektedir.

Şekil.3.16. SASA- EMA göstergesi



Şekil 3.16’de belirtilen dönem boyunca hisse senedinin Üstel Hareketli Ortalama (EMA) performansını gösteren verilerin görsel bir temsili bulunmaktadır. Bu görsel, hisse

senedinin fiyat trendleri ve hareketli ortalamaların ilişkisini net bir şekilde göstermektedir.

Tablo.3.3. SASA-Teknik Analiz işlemler Detayı

Başlık	Değer
Ticaret aralığı	2020-01-01— 2023-06-01
Geriye dönük test aralığı	2020-01-01— 2023-06-01
Sembol	BIST:SASA
Zaman aralığı	1 day
Grafik tipi	Mumlar
Nokta değeri	1
Para Birim	TRY
Kene Boyutu	0.05
Kesinlik	Default
Hızlı Uzunluk	12
Yavaş Uzunluk	26
Sinyal Yumuşatma	9
RSI Uzunluğu	14
Stop Loss (%)	1
Take Profit (%)	2
Başlangıç sermayesi	100000 USD
Order size	10000 USD
piramitleme	1 orders


MACD ve RSI teknik göstergelerine dayalı olarak, bir işlem listesi hazırlanmaktadır. Bu liste, işlemlerin gerçekleştirildiği tarihleri, işlemlerin türünü (alış veya satış) ve işlemlerin gerçekleştiği fiyatları içermektedir. Bu göstergelerin sinyalleri ve diğer belirleyici faktörler göz önünde bulundurularak, alış veya satış işlemleri gerçekleştirilmiştir. İşlem listesi, yatırımcıya gerçekleştirdiği işlemlerle ilgili detaylı bir bakış sunmaktadır.

Şekil.3.17. SASA-Teknik Analiz-RSI göstergeleri




Bist100 deki Türk Hava Yolları Hisse senedinin 1 Ocak 2020'den 1 Haziran 2023e kadar günlük frekansta fiyat kapanışı ve Ona göre teknik analizin RSI gösterge analizleri gösterilmiştir.

Şekil.3.18. SASA-Teknik Analiz- MACD göstergeleri



Şekil 3.18'de Bist100 deki Türk Hava Yolları Hisse senedinin 1 Ocak 2020'den 1 Haziran 2023e kadar günlük frekansta fiyat kapanışı ve Ona göre teknik analizin MACD gösterge analizleri gösterilmiştir.


Şekil.3.19. SASA- Teknik Analiz AL/SAT sinyalleri



Şekil 3.19’de belirlenen dönemde teknik analiz göstergeleri total olarak 42 işlem açıp kapatmıştır ve bu işlemlerin 11 tanesi zarar ve 31 işlem getiri elde etmiştir,teknik analizin bu verdiği sinyallerin % 75 getiri ve % 25 oranı zarara sebep olmuştur.ve 1 ocak 2020’den 100.200 USD ,haziran 2023 kadar 105.100 USD olarak verdiği sinyaller sonucu 4.900 USD getiri elde etmiştir.

SASA ML ANALİZ

Şekil.3.20. SASA-ML-AL/SAT Sinyalleri

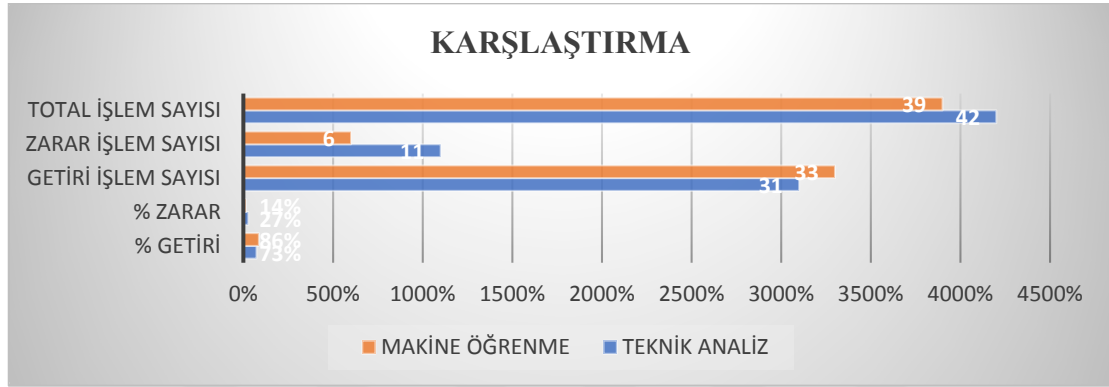


Şekil 3.20’de gösterildiği gibi, makine öğrenme modeli belirlenen dönemde toplam 39 sinyal üretmiştir. Bu sinyallerin 33’ü (%86) kar, 6’sı (%14) ise zarar olarak

sonuçlanmıştır. Bu durumda, modelin 1 Ocak 2020'de 100.200 USD olan portföy değerini, AI/SAT sinyalleriyle 1 Haziran 2020'ye kadar 106.000 USD'ye yükselttiği görülmektedir. Bu şekilde tasarlanmış olan model, 5.800 USD kar elde etmiştir.

SONUÇ KARŞILAŞTIRMA

Şekil.3.21. SASA-ML Ve Teknik Analiz Karşılaştırma



Bu sonuçlar göz önüne alındığında, SASA hisse senedi üzerinde gerçekleştirilen makine öğrenimi analizinin, teknik analiz modeline göre daha etkili bir risk azaltma stratejisi sağladığı ve daha yüksek bir kar potansiyeli sunduğu söylenebilir. Bu analiz sonucunda elde edilen net karın, teknik analizden elde edilen karın 900 dolar daha fazla olduğu görülmektedir. Ayrıca, AI/SAT sinyallerinin de daha başarılı sonuçlar verdiği belirlenmiştir. Bu durum, makine öğrenimi analizinin SASA hisse senedi üzerinde daha iyi bir performans sergilediğini ve yatırımcılar için daha avantajlı bir strateji olduğunu göstermektedir.

SONUÇ VE ÖNERİLER

Makine öğrenme stratejisi (ML) ile teknik analiz stratejisi karşılaştırıldığında, ML'nin Teknik analiz yöntemine göre karlı işlemlerin daha yüksek oranıyla sonuçlandığı gözlemlenmektedir. Çalışma kapsamında, teknik analiz fiyat tahminlerine dayanarak ML algoritmalarından Light GBM kullanılarak BIST 30 hisse senetlerinde bir uygulama yapılmış ve sonuçlar karşılaştırılmıştır.

Bu analizlere göre, Light GBM algoritmasının teknik analize göre daha yüksek getiri sağladığı ve gerçek fiyatlarla daha yakın sonuçlar elde ettiği görülmüştür. Bu durum, algoritmaların piyasa analizi ve optimizasyon problemi için etkin bir çözüm olduğunu göstermektedir.

Sonuç olarak, ikinci strateji daha verimli ve ayrıca daha az risk taşımaktadır. Bu nedenle, daha yüksek getiri elde etmek ve daha az risk almak isteyen yatırımcılar, makine öğrenme modelini tercih edebilirler. Ancak, bu kararı vermeden önce dikkate alınması gereken diğer faktörler de vardır.

Yatırımcılar, bu analizlerin her zaman kesin ve net sonuçlar vermeyebileceğini ve finansal piyasaların karmaşıklığını göz önünde bulundurarak, yatırım stratejilerini dikkatlice değerlendirmelidirler. Piyasa koşulları, ekonomik olaylar ve diğer değişkenler de yatırım kararlarını etkileyebilir, bu nedenle tüm faktörlerin dikkate alınması önemlidir.

Sonuç olarak, makine öğrenme modellerinin teknik analiz yöntemine göre daha verimli ve düşük riskli olabileceği göz önünde bulundurulmalı, ancak yatırım kararları dikkatli bir şekilde ve tüm değişkenler göz önünde bulundurularak verilmelidir.

KAYNAKLAR

- [1] Aksoy, A., & Tanrıöven, C. (2014). Sermaye Piyasası Yatırım Araçları ve Analizi. Ankara: Detay Yayıncılık.
- [2] ANON., 2009, İMKB Eğitim Seti: Hisse Senetleri Piyasası - Grafikler ve Teknik Analiz, <http://www.imkb.gov.tr/Training/TrainingSets.aspx> (İstanbul Menkul Kıymetler Borsası)
- [3] Casaretto, F. (2017). *Finansal Korunma Hedging*. İstanbul: Scala Yayıncılık.
- [4] Çağırman, H. (1999). Finans Piyasalarında Bermuda Şeytan Üçgeni: Borsada Teknik Analiz. Ankara: Siyasal Kitabevi.
- [5] Çetin Elmas, Yapay Zeka Uygulamaları, Ankara: Seçkin Yayıncılık, 2007, s.398.
- [6] Charles Tapiero ,Fuzzy Logic in Financial Analysis" ,1999
- [7] Christian L.Dunis,Peter W.Middleton, "**Artificial Intelligence for Financial Markets**: Cutting Edge Applications for Investment Management, Real-Time Trading and Risk Management",London: *Palgrave Macmillan*,2016
- [8] Derviş Karaboğa, Yapay Zeka Optimizasyon Algoritmaları, Genişletilmiş 2. Baskı, Nobel Yayın Dağıtım, 2011, s.161.
- [9] (Erdoğan, 2004, s. 491).
- [10] Ekosentez. (2018, Haziran 27). *Money Flow Inx*. <https://www.ekosentez.com>: <https://www.ekosentez.com/money-flow-inx/>
- [11] Forrest, Stephanie, Genetic Algorithms, Computing Surveys Vol. 28:1, 1996, s. 79
- [12] HARP Akademileri Komutanlığı Yayınlarından, Uzman Sistemler ve Yapay Zekâ, HARP Akademileri Basımevi, İstanbul, Mart-1996 HARP Akademileri Komutanlığı Yayınlarından, Adı Geçen Eser, S. 49-51

- [13] Holland, J. H., Genetic Algorithms, Scientific American, 1992, s.44
- [14] (İlhan Aydın ve dğr., “Genetik Algoritma Kullanan Yapay Bağışık Sistem Tabanlı Arıza Teşhis Modeli”, **DEÜ Mühendislik Fakültesi Fen ve Mühendislik Dergisi**, Cilt:11 Sayı:31, 57-72, 2009, s.60.)
- [15] Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: **Trends, perspectives, and prospects**. *Science*, 349(6245), 255–260.
- [16] (J.Kennedy ve R.C. Eberhart, “Particle Swarm Optimization”, Proc. IEEE int’l Conf. On Neural Networks, vol IV, 1942-1948, 1995)
- [17] Jannes KLAAS. "**Machine Learning for Finance**:Principles and practice for financial insiders" ,Birmingham,UK:*Packt Publishing; I.BASKI*, 2019
- [18] Karşlı, M. (2004). *Sermaye Piyasası Borsa Menkul Kıymetler*. İstanbul: Alfa Yayıncılık.
- [19] López de Prado (b), M. (2018). Ten Applications of Financial Machine Learning (Lecture <https://ssrn.com/abstract=3197726>)
- [20] Marco Dorigo ve dğr., Ant Colony Optmization: Artificial Ants as a Computational Intelligence Technique, IRIDIA-Technical Report Series, TR/IRIDIA/2006-023, September 2006, s. 4. Marco Dorigo ve dğr., a.g.e., 1991)
- [21] Murphy, J. (1998). Görsel Yatırımcı Borsada Teknik Analiz. (A. Çev: Perşembe, Dü.) İstanbul: Skala Yayıncılık.
- [22] Mergen, A. (2005). *Grafiklerle Borsa Uygulamalı Teknik Analiz*. İstanbul: Mergen Yayınları.
- [23] (Mergen, Kurtlarla Tango Göstergelerle Borsa Süper Teknik Analiz, 2005, s. 143).
- [24] Münyas, T., & Atasoy, F. (2019). *Sermyaye Piyasası Temel ve Teknik Analiz Yöntemleri*. Bursa: Ekin Yayınevi.
- [25] Michalewicz, Z., Heuristic Methods for Evolutionary Computation Techniques, Journal of

Heuristics, Vol.1, No.2, 1995, s. 177

[26] Nilsson, N. J. (2014). Principles of Artificial Intelligence. In *Morgan Kauffmann*.

Erişim adresi:

<https://stacks.stanford.edu/file/druid:zd294jv9941/zd294jv9941.pdf>

[27] Neter, J., Wasserman, W., & Kutner, M. H. (1989). Applied linear regression models.

[28] Öztemel, E. (2012).Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık

[29] Perşembe, A. (2017). *Teknik analiz mi dedin? Hadi canım sen de! 3. Kitap*. İstanbul: Scala Yayıncılık.

[30] (Perşembe, Teknik analiz mi dedin? Hadi canım sen de! 3. Kitap, 2017, s. 158)

[31] Perşembe, A. (2015). *Teknik analiz mi dedin? Hadi canım sen de! 4. Kitap*. İstanbul: Scala Yayıncılık.

[32] Pereira Robert, Genetic Algorithm Optimisation for Finance and Investement, Latrobe University School of Business Discussion Papers, 2000
<http://www.latrobe.edu.au/business/research/dps/downloads/dps00/a00-02.pdf>

[33] Sarı, Y. (1998). *Borsada Göstergelerle Teknik Analiz*. İstanbul: Alfa Yayıncılık

[34] Stefan Zohren, Stephen Roberts, Training, Testing and Implementing Strategies, Financial Machine Learning, Ithaca: Cornell university, 2019

[35] Sebastian RASCHAKA ve Vahid MİRJALİLİ, Python Machine Learning: **Machine Learning and Deep Learning with Python**, scikit-learn, and TensorFlow 2, BASKI" , Birmingham, UK:*Packt Publishing*,2017

[36] Mergen, A. (2005). *Kurtlarla Tango Göstergelerle Borsa Süper Teknik Analiz*. İstanbul: Mergen Yayınları.

- [37] Mariya Yao, Adelyn Zhou, Marlene Jia, Mariya Yao, Adelyn Zhou, Marlene Jia , **Applied Artificial Intelligence**, New York: *Topbots Inc*, 2018
- [38] Marcos Lopez de Prado, "**Advances in Financial Machine Learning**", Manhattan.usa, *Wiley; I.BASKI*,2018
- [39] Siau, K., & Wang, W. (2018). Building Trust in Artificial Intelligence, Machine learning, and Robotics. *Cutter Business Technology Journal*, 31(2), 47–53. Erişim adresi:
https://www.researchgate.net/publication/324006061_Building_Trust_in_Artificial_Intelligence_Machine_Learning_and_Robotics
- [40] Stefan Jansen, **Machine Learning for Algorithmic Trading**: Predictive models to extract signals from market and alternative data for systematic trading strategies with Python", Birmingham, UK : *Packt Publishing*, 2020
- [41] Ulusoy, H. (1994). Teknik Analiz ve Türkiye Sermaye Piyasasında Geçerliliği. Ankara: Gazi Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi.
- [42] Yves HILPISCH, "A Python-based Guide", **Artificial Intelligence in Finance: A Python-Based Guide**, USA: O`Reilly Media,2020

EKLER

AKBANK-Teknik Analiz AL/SAT Sinyal listesi

Signal Date	Position Close Date	Signal Price	Position Close Price	Budget	Status
2020-03-05 00:00:00	2020-03-06 00:00:00	-0.291785404	-0.28886755	99900	Loss
2020-03-26 00:00:00	2020-03-27 00:00:00	-0.693359971	-0.686426371	99800	Loss
2020-07-06 00:00:00	2020-07-07 00:00:00	-0.606160896	-0.600099287	99700	Loss
2020-08-14 00:00:00	2020-08-17 00:00:00	-0.874642195	-0.892135038	99900	Profit
2020-11-09 00:00:00	2020-11-10 00:00:00	-0.771380098	-0.7868077	100100	Profit
2020-12-30 00:00:00	2020-12-31 00:00:00	-0.420289253	-0.428695038	100300	Profit
2021-02-09 00:00:00	2021-02-10 00:00:00	-0.438646929	-0.447419868	100500	Profit
2021-03-02 00:00:00	2021-03-03 00:00:00	-0.560266594	-0.554663928	100400	Loss
2021-04-02 00:00:00	2021-04-05 00:00:00	-0.883821033	-0.901497454	100600	Profit
2021-07-07 00:00:00	2021-07-08 00:00:00	-0.771380098	-0.7868077	100800	Profit
2021-08-02 00:00:00	2021-08-03 00:00:00	-0.789737775	-0.80553253	101000	Profit
2021-10-05 00:00:00	2021-10-06 00:00:00	-0.796621958	-0.812554397	101200	Profit
2021-12-09 00:00:00	2021-12-10 00:00:00	-0.303258898	-0.300226309	101100	Loss
2021-12-13 00:00:00	2021-12-14 00:00:00	-0.282606457	-0.288258586	101300	Profit
2022-01-19 00:00:00	2022-01-20 00:00:00	-0.197702146	-0.195725125	101200	Loss
2022-01-31 00:00:00	2022-02-01 00:00:00	-0.160986792	-0.159376924	101100	Loss
2022-02-09 00:00:00	2022-02-10 00:00:00	-0.140334351	-0.138931007	101000	Loss
2022-03-14 00:00:00	2022-03-15 00:00:00	-0.362921457	-0.370179886	101200	Profit
2022-05-31 00:00:00	2022-06-01 00:00:00	-0.087556084	-0.089307206	101400	Profit
2022-07-18 00:00:00	2022-07-19 00:00:00	-0.108208307	-0.110372473	101600	Profit
2022-10-07 00:00:00	2022-10-10 00:00:00	0.945064229	0.935613586	101500	Loss
2022-11-16 00:00:00	2022-11-17 00:00:00	1.819349523	1.801156028	101400	Loss
2022-12-15 00:00:00	2022-12-16 00:00:00	2.239281766	2.284067402	101600	Profit
2023-01-23 00:00:00	2023-01-24 00:00:00	2.25344679	2.232791232	101500	Loss
2023-02-17 00:00:00	2023-02-21 00:00:00	1.66330905	1.64667596	101400	Loss
2023-04-12 00:00:00	2023-04-13 00:00:00	2.191093028	2.169182098	101300	Loss
2023-05-10 00:00:00	2023-05-11 00:00:00	1.851475348	1.888504855	101500	Profit
2023-05-30 00:00:00	2023-05-31 00:00:00	1.750508344	1.733003261	101400	Loss
2020-03-12 00:00:00	2020-03-13 00:00:00	-0.557971939	-0.563551658	101300	Loss
2020-07-03 00:00:00	2020-07-06 00:00:00	-0.652055088	-0.658575639	101200	Loss
2020-07-08 00:00:00	2020-07-09 00:00:00	-0.647465669	-0.634516355	101400	Profit
2020-10-26 00:00:00	2020-10-27 00:00:00	-0.888410452	-0.897294557	101300	Loss
2020-11-27 00:00:00	2020-11-30 00:00:00	-0.544203681	-0.533319608	101500	Profit
2021-01-14 00:00:00	2021-01-15 00:00:00	-0.372100296	-0.36465829	101700	Profit
2021-02-17 00:00:00	2021-02-18 00:00:00	-0.535024843	-0.524324346	101900	Profit
2021-03-22 00:00:00	2021-03-23 00:00:00	-0.7828537	-0.767196626	102100	Profit
2021-06-17 00:00:00	2021-06-18 00:00:00	-0.798916613	-0.782938281	102300	Profit
2021-07-08 00:00:00	2021-07-09 00:00:00	-0.785148355	-0.769445388	102500	Profit
2021-09-08 00:00:00	2021-09-09 00:00:00	-0.711717648	-0.718834824	102400	Loss
2021-11-24 00:00:00	2021-11-25 00:00:00	-0.40422623	-0.396141706	102600	Profit
2021-12-10 00:00:00	2021-12-13 00:00:00	-0.337679597	-0.341056393	102500	Loss
2021-12-20 00:00:00	2021-12-21 00:00:00	-0.323911339	-0.317433112	102700	Profit
2022-01-25 00:00:00	2022-01-26 00:00:00	-0.239007029	-0.234226888	102900	Profit
2022-02-04 00:00:00	2022-02-07 00:00:00	-0.213765168	-0.21590282	102800	Loss
2022-02-14 00:00:00	2022-02-15 00:00:00	-0.17475505	-0.1765026	102700	Loss
2022-04-26 00:00:00	2022-04-27 00:00:00	0.066189624	0.06685152	102600	Loss
2022-06-28 00:00:00	2022-06-29 00:00:00	-0.099029468	-0.097048879	102800	Profit
2022-09-15 00:00:00	2022-09-16 00:00:00	0.926706552	0.908172421	103000	Profit
2022-10-28 00:00:00	2022-11-01 00:00:00	1.362701926	1.335447888	103200	Profit
2022-12-01 00:00:00	2022-12-02 00:00:00	1.993747673	1.95387272	103400	Profit
2022-12-28 00:00:00	2022-12-29 00:00:00	2.383848418	2.407686902	103300	Loss
2023-01-26 00:00:00	2023-01-27 00:00:00	1.906548379	1.868417412	103500	Profit
2023-03-17 00:00:00	2023-03-21 00:00:00	2.172734914	2.129280216	103700	Profit
2023-04-26 00:00:00	2023-04-27 00:00:00	1.86294917	1.881578662	103600	Loss
2023-05-18 00:00:00	2023-05-22 00:00:00	1.431543105	1.402912243	103800	Profit

AKBANK- ML -AL/SAT sinyal listesi

Signal Date	Position Close Date	Signal Price	Position Close Price	Budget	Status
2020-02-28 00:00:00	2020-02-28 00:00:00	-0.457004606	-0.466144699	100200	Profit
2020-03-23 00:00:00	2020-03-23 00:00:00	-0.764496023	-0.779785944	100400	Profit
2020-08-06 00:00:00	2020-08-06 00:00:00	-0.922831151	-0.941287774	100600	Profit
2020-08-14 00:00:00	2020-08-14 00:00:00	-0.874642195	-0.892135038	100800	Profit
2020-08-25 00:00:00	2020-08-25 00:00:00	-0.883821033	-0.901497454	101000	Profit
2020-10-30 00:00:00	2020-10-30 00:00:00	-0.909062784	-0.92724404	101200	Profit
2020-11-17 00:00:00	2020-11-17 00:00:00	-0.629107992	-0.641690152	101400	Profit
2021-01-27 00:00:00	2021-01-27 00:00:00	-0.551087755	-0.562109511	101600	Profit
2021-01-29 00:00:00	2021-01-29 00:00:00	-0.541908917	-0.552747095	101800	Profit
2021-02-24 00:00:00	2021-02-24 00:00:00	-0.626813228	-0.639349492	102000	Profit
2021-03-23 00:00:00	2021-03-23 00:00:00	-0.904473365	-0.922562832	102200	Profit
2021-03-29 00:00:00	2021-03-29 00:00:00	-0.913652203	-0.931925247	102400	Profit
2021-04-07 00:00:00	2021-04-07 00:00:00	-0.892999872	-0.910859869	102600	Profit
2021-05-11 00:00:00	2021-05-11 00:00:00	-0.849400334	-0.866388341	102800	Profit
2021-10-15 00:00:00	2021-10-15 00:00:00	-0.826453238	-0.842982303	103000	Profit
2021-11-11 00:00:00	2021-11-11 00:00:00	-0.560266594	-0.571471926	103200	Profit
2021-12-15 00:00:00	2021-12-15 00:00:00	-0.19999691	-0.203996849	103400	Profit
2021-12-21 00:00:00	2021-12-21 00:00:00	-0.342269016	-0.349114396	103600	Profit
2021-12-28 00:00:00	2021-12-28 00:00:00	-0.317027156	-0.323367699	103800	Profit
2022-01-18 00:00:00	2022-01-18 00:00:00	-0.305553662	-0.311664735	104000	Profit
2022-01-20 00:00:00	2022-01-20 00:00:00	-0.206880984	-0.211018604	104200	Profit
2022-01-24 00:00:00	2022-01-24 00:00:00	-0.266543544	-0.271874415	104400	Profit
2022-03-01 00:00:00	2022-03-01 00:00:00	-0.390457973	-0.398267132	104600	Profit
2022-04-13 00:00:00	2022-04-14 00:00:00	0.057010786	0.058151001	104800	Profit
2022-04-22 00:00:00	2022-04-25 00:00:00	0.091431594	0.093260226	105000	Profit
2022-05-17 00:00:00	2022-05-17 00:00:00	-0.20458633	-0.208678056	105200	Profit
2022-06-08 00:00:00	2022-06-08 00:00:00	-0.108208307	-0.110372473	105400	Profit
2022-06-20 00:00:00	2022-06-21 00:00:00	0.070779153	0.072194736	105600	Profit
2022-07-28 00:00:00	2022-07-28 00:00:00	-0.053135276	-0.054197981	105800	Profit
2022-08-02 00:00:00	2022-08-03 00:00:00	0.011116593	0.011338925	106000	Profit
2022-08-12 00:00:00	2022-08-15 00:00:00	0.288776731	0.294552265	106200	Profit
2022-08-18 00:00:00	2022-08-19 00:00:00	0.52742675	0.522152482	106100	Loss
2022-08-24 00:00:00	2022-08-25 00:00:00	0.534310824	0.54499704	106300	Profit
2022-08-29 00:00:00	2022-08-31 00:00:00	0.722477341	0.715252568	106200	Loss
2022-09-29 00:00:00	2022-10-03 00:00:00	0.577910471	0.58946868	106400	Profit
2022-10-28 00:00:00	2022-10-31 00:00:00	1.362701926	1.349074907	106300	Loss
2020-03-24 00:00:00	2020-03-25 00:00:00	-0.688770551	-0.67499514	106500	Profit
2020-04-10 00:00:00	2020-04-13 00:00:00	-0.603866131	-0.591788809	106700	Profit
2020-06-23 00:00:00	2020-06-24 00:00:00	-0.599276712	-0.587291178	106900	Profit
2020-10-23 00:00:00	2020-10-26 00:00:00	-0.842516151	-0.825665827	107100	Profit
2020-11-16 00:00:00	2020-11-17 00:00:00	-0.555677175	-0.544563631	107300	Profit
2020-11-23 00:00:00	2020-11-24 00:00:00	-0.571740197	-0.560305393	107500	Profit
2020-11-25 00:00:00	2020-11-26 00:00:00	-0.560266594	-0.56586926	107400	Loss
2021-01-22 00:00:00	2021-01-25 00:00:00	-0.46388879	-0.454611014	107600	Profit
2021-03-24 00:00:00	2021-03-25 00:00:00	-0.879231614	-0.861646982	107800	Profit
2021-09-15 00:00:00	2021-09-16 00:00:00	-0.730075325	-0.715473818	108000	Profit
2021-11-10 00:00:00	2021-11-11 00:00:00	-0.537319498	-0.526573108	108200	Profit
2021-11-24 00:00:00	2021-11-25 00:00:00	-0.40422623	-0.396141706	108400	Profit
2021-12-16 00:00:00	2021-12-17 00:00:00	-0.11968191	-0.117288271	108600	Profit
2021-12-27 00:00:00	2021-12-28 00:00:00	-0.209175749	-0.204992234	108800	Profit
2022-01-21 00:00:00	2022-01-24 00:00:00	-0.188523308	-0.184752841	109000	Profit
2022-02-09 00:00:00	2022-02-10 00:00:00	-0.140334351	-0.137527664	109200	Profit
2022-02-23 00:00:00	2022-02-24 00:00:00	-0.225238661	-0.220733888	109400	Profit
2022-04-25 00:00:00	2022-04-26 00:00:00	0.141915096	0.139076794	109600	Profit
2022-06-07 00:00:00	2022-06-08 00:00:00	0.02947427	0.028884785	109800	Profit
2022-06-17 00:00:00	2022-06-20 00:00:00	0.082252756	0.080607701	110000	Profit
2022-07-08 00:00:00	2022-07-13 00:00:00	-0.149513189	-0.146522926	110200	Profit
2022-08-17 00:00:00	2022-08-18 00:00:00	0.589384074	0.577596392	110400	Profit
2022-09-12 00:00:00	2022-09-13 00:00:00	2.01210535	1.971863243	110600	Profit
2022-09-20 00:00:00	2022-09-21 00:00:00	0.720182577	0.705778925	110800	Profit
2022-12-07 00:00:00	2022-12-08 00:00:00	1.60823602	1.62431838	110700	Loss
2023-02-08 00:00:00	2023-02-15 00:00:00	1.137820055	1.149198256	110600	Loss
2023-04-25 00:00:00	2023-04-26 00:00:00	1.95244279	1.913393935	110800	Profit
2023-05-15 00:00:00	2023-05-16 00:00:00	1.979979525	1.940379934	111000	Profit
2023-05-17 00:00:00	2023-05-18 00:00:00	1.569225901	1.537841383	111200	Profit

THY- Teknik Analiz

Signal Date	Position Close Date	Signal Price	Position Close Price	Budget	Status
2020-03-25 00:00:00	2020-03-26 00:00:00	-0.73910117	-0.753883193	100200	Profit
2020-07-23 00:00:00	2020-07-24 00:00:00	-0.670904011	-0.684322091	100400	Profit
2020-08-11 00:00:00	2020-08-12 00:00:00	-0.675553818	-0.689064895	100600	Profit
2020-09-07 00:00:00	2020-09-08 00:00:00	-0.694153026	-0.708036087	100800	Profit
2020-11-06 00:00:00	2020-11-09 00:00:00	-0.717623487	-0.731975956	101000	Profit
2020-12-15 00:00:00	2020-12-16 00:00:00	-0.652526206	-0.665576731	101200	Profit
2020-12-31 00:00:00	2021-01-04 00:00:00	-0.644333672	-0.657220345	101400	Profit
2021-01-13 00:00:00	2021-01-14 00:00:00	-0.639019612	-0.651800005	101600	Profit
2021-02-11 00:00:00	2021-02-12 00:00:00	-0.663597174	-0.676869118	101800	Profit
2021-04-27 00:00:00	2021-04-28 00:00:00	-0.668468385	-0.681837752	102000	Profit
2021-08-03 00:00:00	2021-08-04 00:00:00	-0.652969034	-0.666028415	102200	Profit
2021-10-26 00:00:00	2021-10-27 00:00:00	-0.607135235	-0.61927794	102400	Profit
2021-11-24 00:00:00	2021-11-25 00:00:00	-0.512589182	-0.522840966	102600	Profit
2021-12-08 00:00:00	2021-12-09 00:00:00	-0.481369057	-0.490996438	102800	Profit
2022-01-05 00:00:00	2022-01-06 00:00:00	-0.403429435	-0.411498024	103000	Profit
2022-03-15 00:00:00	2022-03-16 00:00:00	-0.320175753	-0.326579268	103200	Profit
2022-05-05 00:00:00	2022-05-06 00:00:00	0.012396124	0.012272163	103100	Loss
2022-05-30 00:00:00	2022-05-31 00:00:00	0.163846964	0.167123904	103300	Profit
2022-06-22 00:00:00	2022-06-23 00:00:00	0.219866034	0.217667373	103200	Loss
2022-07-20 00:00:00	2022-07-21 00:00:00	0.204366662	0.208453995	103400	Profit
2022-08-02 00:00:00	2022-08-03 00:00:00	0.226508597	0.231038769	103600	Profit
2022-10-04 00:00:00	2022-10-05 00:00:00	0.856446756	0.873575691	103800	Profit
2022-11-08 00:00:00	2022-11-09 00:00:00	1.569417003	1.553722833	103700	Loss
2022-11-30 00:00:00	2022-12-01 00:00:00	1.72441055	1.758898761	103900	Profit
2023-01-19 00:00:00	2023-01-20 00:00:00	2.490521644	2.465616428	103800	Loss
2023-02-27 00:00:00	2023-03-01 00:00:00	2.242531699	2.287382333	104000	Profit
2023-04-04 00:00:00	2023-04-05 00:00:00	1.90376036	1.884722757	103900	Loss
2023-05-11 00:00:00	2023-05-12 00:00:00	2.085324162	2.06447092	103800	Loss
2023-05-16 00:00:00	2023-05-18 00:00:00	2.076467185	2.055702513	103700	Loss
2020-02-25 00:00:00	2020-02-26 00:00:00	-0.633705553	-0.621031442	103900	Profit
2020-06-15 00:00:00	2020-06-16 00:00:00	-0.654076135	-0.640994612	104100	Profit
2020-07-28 00:00:00	2020-07-29 00:00:00	-0.687289038	-0.673543257	104300	Profit
2020-09-03 00:00:00	2020-09-04 00:00:00	-0.703009813	-0.688949617	104500	Profit
2020-10-26 00:00:00	2020-10-27 00:00:00	-0.715852134	-0.701535091	104700	Profit
2020-12-10 00:00:00	2020-12-11 00:00:00	-0.662268649	-0.649023276	104900	Profit
2020-12-21 00:00:00	2020-12-22 00:00:00	-0.662932901	-0.649674243	105100	Profit
2021-01-04 00:00:00	2021-01-05 00:00:00	-0.651861933	-0.638824694	105300	Profit
2021-01-22 00:00:00	2021-01-25 00:00:00	-0.646326449	-0.63339992	105500	Profit
2021-03-18 00:00:00	2021-03-19 00:00:00	-0.623963111	-0.611483849	105700	Profit
2021-06-23 00:00:00	2021-06-24 00:00:00	-0.610235092	-0.598030391	105900	Profit
2021-10-20 00:00:00	2021-10-21 00:00:00	-0.627062968	-0.614521709	106100	Profit
2021-11-19 00:00:00	2021-11-22 00:00:00	-0.554216002	-0.559758162	106000	Loss
2021-11-26 00:00:00	2021-11-29 00:00:00	-0.556430204	-0.5453016	106200	Profit
2021-12-21 00:00:00	2021-12-22 00:00:00	-0.491332903	-0.481506245	106400	Profit
2022-01-24 00:00:00	2022-01-25 00:00:00	-0.356488514	-0.349358743	106600	Profit
2022-04-26 00:00:00	2022-04-27 00:00:00	-0.066872045	-0.067540765	106500	Loss
2022-06-08 00:00:00	2022-06-09 00:00:00	0.101849563	0.102868058	106400	Loss
2022-06-24 00:00:00	2022-06-27 00:00:00	0.180010567	0.176410356	106600	Profit
2022-07-25 00:00:00	2022-07-26 00:00:00	0.164289813	0.161004017	106800	Profit
2022-09-01 00:00:00	2022-09-02 00:00:00	0.641669883	0.648086582	106700	Loss
2022-10-28 00:00:00	2022-10-31 00:00:00	1.214038875	1.226179264	106600	Loss
2022-11-14 00:00:00	2022-11-16 00:00:00	1.496348549	1.466421578	106800	Profit
2022-12-16 00:00:00	2022-12-19 00:00:00	2.149535639	2.171030995	106700	Loss
2023-01-30 00:00:00	2023-01-31 00:00:00	2.273530611	2.228059999	106900	Profit
2023-03-13 00:00:00	2023-03-14 00:00:00	2.074253194	2.03276813	107100	Profit
2023-04-28 00:00:00	2023-05-03 00:00:00	1.897117712	1.916088889	107000	Loss
2023-05-15 00:00:00	2023-05-16 00:00:00	1.821835099	1.84005345	106900	Loss

THY-ML-AL/SAT sinyal listesi

Signal Date	Position Close Date	Signal Price	Position Close Price	Budget	Status
2020-02-18 00:00:00	2020-02-18 00:00:00	-0.60049265	-0.612502503	100200	Profit
2020-02-21 00:00:00	2020-02-21 00:00:00	-0.611785042	-0.624020743	100400	Profit
2020-03-20 00:00:00	2020-03-20 00:00:00	-0.755929035	-0.771047616	100600	Profit
2020-03-25 00:00:00	2020-03-25 00:00:00	-0.73910117	-0.753883193	100800	Profit
2020-04-27 00:00:00	2020-04-27 00:00:00	-0.693045946	-0.706906865	101000	Profit
2020-05-27 00:00:00	2020-05-27 00:00:00	-0.659611619	-0.672803851	101200	Profit
2020-08-11 00:00:00	2020-08-11 00:00:00	-0.675553818	-0.689064895	101400	Profit
2020-08-25 00:00:00	2020-08-25 00:00:00	-0.68529626	-0.699002186	101600	Profit
2020-10-02 00:00:00	2020-10-02 00:00:00	-0.69703148	-0.71097211	101800	Profit
2020-11-09 00:00:00	2020-11-09 00:00:00	-0.696145804	-0.71006872	102000	Profit
2020-12-01 00:00:00	2020-12-01 00:00:00	-0.656290337	-0.669416144	102200	Profit
2020-12-14 00:00:00	2020-12-14 00:00:00	-0.654518963	-0.667609342	102400	Profit
2020-12-16 00:00:00	2020-12-16 00:00:00	-0.650533429	-0.663544097	102600	Profit
2020-12-29 00:00:00	2020-12-29 00:00:00	-0.647212126	-0.660156368	102800	Profit
2021-01-08 00:00:00	2021-01-08 00:00:00	-0.648319227	-0.661285611	103000	Profit
2021-01-13 00:00:00	2021-01-13 00:00:00	-0.639019612	-0.651800005	103200	Profit
2021-01-19 00:00:00	2021-01-19 00:00:00	-0.633926977	-0.646605517	103400	Profit
2021-05-20 00:00:00	2021-05-20 00:00:00	-0.6319342	-0.644572884	103600	Profit
2021-05-27 00:00:00	2021-05-27 00:00:00	-0.64366942	-0.656542808	103800	Profit
2021-05-31 00:00:00	2021-05-31 00:00:00	-0.637691108	-0.65044493	104000	Profit
2021-06-17 00:00:00	2021-06-17 00:00:00	-0.608020912	-0.62018133	104200	Profit
2021-06-22 00:00:00	2021-06-22 00:00:00	-0.60580671	-0.617922844	104400	Profit
2021-08-24 00:00:00	2021-08-24 00:00:00	-0.648983479	-0.661963149	104600	Profit
2021-09-17 00:00:00	2021-09-17 00:00:00	-0.650976257	-0.663995782	104800	Profit
2021-09-28 00:00:00	2021-09-28 00:00:00	-0.627505817	-0.640055933	105000	Profit
2021-10-20 00:00:00	2021-10-20 00:00:00	-0.627062968	-0.639604228	105200	Profit
2021-12-01 00:00:00	2021-12-01 00:00:00	-0.524988654	-0.535488427	105400	Profit
2022-04-05 00:00:00	2022-04-05 00:00:00	-0.168724913	-0.172099411	105600	Profit
2022-04-11 00:00:00	2022-04-11 00:00:00	-0.131969304	-0.13460869	105800	Profit
2022-04-19 00:00:00	2022-04-19 00:00:00	-0.074400306	-0.075888312	106000	Profit
2022-04-26 00:00:00	2022-04-26 00:00:00	-0.066872045	-0.068209486	106200	Profit
2022-05-31 00:00:00	2022-06-01 00:00:00	0.172260923	0.170538314	106100	Loss
2022-06-03 00:00:00	2022-06-06 00:00:00	0.129748364	0.12845088	106000	Loss
2022-06-20 00:00:00	2022-06-21 00:00:00	0.193295694	0.197161608	106200	Profit
2022-07-13 00:00:00	2022-07-14 00:00:00	0.156761552	0.155193936	106100	Loss
2022-08-19 00:00:00	2022-08-22 00:00:00	0.584100885	0.578259876	106000	Loss
2023-02-27 00:00:00	2023-03-01 00:00:00	2.242531699	2.287382333	106200	Profit
2023-05-16 00:00:00	2023-05-18 00:00:00	2.076467185	2.055702513	106100	Loss
2020-05-08 00:00:00	2020-05-11 00:00:00	-0.697917157	-0.683958814	106300	Profit
2020-06-11 00:00:00	2020-06-12 00:00:00	-0.655847488	-0.642730538	106500	Profit
2020-07-08 00:00:00	2020-07-09 00:00:00	-0.681974979	-0.668335479	106700	Profit
2020-08-20 00:00:00	2020-08-21 00:00:00	-0.684632008	-0.670939368	106900	Profit
2020-10-13 00:00:00	2020-10-14 00:00:00	-0.697474329	-0.683524842	107100	Profit
2020-12-25 00:00:00	2020-12-28 00:00:00	-0.65009058	-0.637088768	107300	Profit
2021-07-13 00:00:00	2021-07-14 00:00:00	-0.642562319	-0.629711072	107500	Profit
2021-11-30 00:00:00	2021-12-01 00:00:00	-0.551337569	-0.556850945	107400	Loss
2021-12-22 00:00:00	2021-12-23 00:00:00	-0.51458196	-0.504290321	107600	Profit
2022-06-01 00:00:00	2022-06-02 00:00:00	0.158090014	0.159670914	107500	Loss
2022-07-08 00:00:00	2022-07-13 00:00:00	0.164289813	0.161004017	107700	Profit
2022-10-28 00:00:00	2022-10-31 00:00:00	1.214038875	1.226179264	107600	Loss
2023-01-30 00:00:00	2023-01-31 00:00:00	2.273530611	2.228059999	107800	Profit
2023-05-17 00:00:00	2023-05-18 00:00:00	2.103037778	2.060977022	108000	Profit

SASA-Teknik Analiz AL/SAT Sinyalleri

Signal Date	Position Close Date	Signal Price	Position Close Price	Budget	Status
2020-03-25 00:00:00	2020-03-26 00:00:00	-0.829964803	-0.846564099	100200	Profit
2020-08-18 00:00:00	2020-08-19 00:00:00	-0.761664277	-0.776897563	100400	Profit
2020-10-13 00:00:00	2020-10-14 00:00:00	-0.726282954	-0.740808613	100600	Profit
2020-10-23 00:00:00	2020-10-26 00:00:00	-0.730933593	-0.745552264	100800	Profit
2020-11-05 00:00:00	2020-11-06 00:00:00	-0.735037082	-0.749737824	101000	Profit
2020-12-24 00:00:00	2020-12-25 00:00:00	-0.706950902	-0.72108992	101200	Profit
2021-02-03 00:00:00	2021-02-04 00:00:00	-0.635914669	-0.648632962	101400	Profit
2021-04-27 00:00:00	2021-04-28 00:00:00	-0.433330346	-0.441996953	101600	Profit
2021-06-02 00:00:00	2021-06-03 00:00:00	-0.456709856	-0.452142757	101500	Loss
2021-07-06 00:00:00	2021-07-07 00:00:00	-0.529063326	-0.539644593	101700	Profit
2022-02-09 00:00:00	2022-02-10 00:00:00	-0.273365187	-0.270631535	101600	Loss
2022-03-01 00:00:00	2022-03-02 00:00:00	-0.31175681	-0.317991946	101800	Profit
2022-05-30 00:00:00	2022-05-31 00:00:00	-0.043507549	-0.0443777	102000	Profit
2022-07-29 00:00:00	2022-08-01 00:00:00	0.209975758	0.214175273	102200	Profit
2022-09-23 00:00:00	2022-09-26 00:00:00	0.638682388	0.651456035	102400	Profit
2022-10-24 00:00:00	2022-10-25 00:00:00	1.57632425	1.607850735	102600	Profit
2022-12-21 00:00:00	2022-12-23 00:00:00	2.174347963	2.152604483	102500	Loss
2023-01-11 00:00:00	2023-01-12 00:00:00	1.642771426	1.675626855	102700	Profit
2023-02-16 00:00:00	2023-02-17 00:00:00	1.861800457	1.899036466	102900	Profit
2023-04-10 00:00:00	2023-04-11 00:00:00	1.805197469	1.787145494	102800	Loss
2023-05-16 00:00:00	2023-05-17 00:00:00	1.571402374	1.602830422	103000	Profit
2020-02-27 00:00:00	2020-02-28 00:00:00	-0.801878624	-0.785841051	103200	Profit
2020-08-05 00:00:00	2020-08-06 00:00:00	-0.769506541	-0.754116411	103400	Profit
2020-09-30 00:00:00	2020-10-01 00:00:00	-0.732574983	-0.717923483	103600	Profit
2020-10-22 00:00:00	2020-10-23 00:00:00	-0.734125218	-0.719442714	103800	Profit
2020-10-26 00:00:00	2020-10-27 00:00:00	-0.737407999	-0.722659839	104000	Profit
2020-12-21 00:00:00	2020-12-22 00:00:00	-0.7126046	-0.698352508	104200	Profit
2021-01-29 00:00:00	2021-02-01 00:00:00	-0.651234413	-0.638209725	104400	Profit
2021-02-25 00:00:00	2021-02-26 00:00:00	-0.504420193	-0.49433179	104600	Profit
2021-05-07 00:00:00	2021-05-10 00:00:00	-0.459416953	-0.450228614	104800	Profit
2021-06-16 00:00:00	2021-06-17 00:00:00	-0.490917808	-0.481099452	105000	Profit
2021-12-20 00:00:00	2021-12-21 00:00:00	-0.250354834	-0.245347738	105200	Profit
2022-02-24 00:00:00	2022-02-25 00:00:00	-0.366637175	-0.370303546	105100	Loss
2022-04-19 00:00:00	2022-04-20 00:00:00	-0.06516438	-0.063861093	105300	Profit
2022-06-21 00:00:00	2022-06-22 00:00:00	0.239507775	0.23471762	105500	Profit
2022-08-19 00:00:00	2022-08-23 00:00:00	0.419653138	0.423849669	105400	Loss
2022-10-17 00:00:00	2022-10-18 00:00:00	1.185024769	1.196875017	105300	Loss
2022-11-18 00:00:00	2022-11-21 00:00:00	2.831435493	2.774806783	105500	Profit
2022-12-27 00:00:00	2022-12-28 00:00:00	1.7215234	1.738738634	105400	Loss
2023-01-26 00:00:00	2023-01-27 00:00:00	1.625544316	1.641799759	105300	Loss
2023-03-20 00:00:00	2023-03-21 00:00:00	1.723984447	1.741224292	105200	Loss
2023-04-26 00:00:00	2023-04-27 00:00:00	1.659998318	1.676598301	105100	Loss

SASA-AL/SAT Sinyal listesi

Signal Date	Position Close Date	Signal Price	Position Close Price	Budget	Status
2020-03-03 00:00:00	2020-03-03 00:00:00	-0.801787428	-0.817823176	100200	Profit
2020-06-15 00:00:00	2020-06-15 00:00:00	-0.786923608	-0.80266208	100400	Profit
2020-06-18 00:00:00	2020-06-18 00:00:00	-0.785738157	-0.80145292	100600	Profit
2020-07-01 00:00:00	2020-07-01 00:00:00	-0.784917489	-0.800615838	100800	Profit
2020-08-07 00:00:00	2020-08-07 00:00:00	-0.77096554	-0.786384851	101000	Profit
2020-08-21 00:00:00	2020-08-21 00:00:00	-0.751907076	-0.766945217	101200	Profit
2020-09-10 00:00:00	2020-09-10 00:00:00	-0.741055578	-0.755876689	101400	Profit
2020-10-30 00:00:00	2020-10-30 00:00:00	-0.745067872	-0.759969229	101600	Profit
2020-11-05 00:00:00	2020-11-05 00:00:00	-0.735037082	-0.749737824	101800	Profit
2020-11-27 00:00:00	2020-11-27 00:00:00	-0.729656931	-0.74425007	102000	Profit
2021-01-06 00:00:00	2021-01-06 00:00:00	-0.692451826	-0.706300862	102200	Profit
2021-02-03 00:00:00	2021-02-03 00:00:00	-0.635914669	-0.648632962	102400	Profit
2021-04-15 00:00:00	2021-04-15 00:00:00	-0.471409774	-0.480837969	102600	Profit
2021-04-27 00:00:00	2021-04-27 00:00:00	-0.433330346	-0.441996953	102800	Profit
2021-10-08 00:00:00	2021-10-08 00:00:00	-0.546290355	-0.557216162	103000	Profit
2021-12-09 00:00:00	2021-12-09 00:00:00	-0.288623405	-0.294395873	103200	Profit
2021-12-24 00:00:00	2021-12-24 00:00:00	-0.298959584	-0.304938776	103400	Profit
2022-02-16 00:00:00	2022-02-16 00:00:00	-0.291084397	-0.296906085	103600	Profit
2022-02-21 00:00:00	2022-02-21 00:00:00	-0.29354539	-0.299416298	103800	Profit
2022-02-24 00:00:00	2022-02-24 00:00:00	-0.366637175	-0.373969918	104000	Profit
2022-03-02 00:00:00	2022-03-02 00:00:00	-0.303389414	-0.309457202	104200	Profit
2022-03-09 00:00:00	2022-03-09 00:00:00	-0.198058514	-0.202019685	104400	Profit
2022-03-24 00:00:00	2022-03-24 00:00:00	-0.164219719	-0.167504113	104600	Profit
2022-05-11 00:00:00	2022-05-11 00:00:00	-0.076484978	-0.078014677	104800	Profit
2022-05-25 00:00:00	2022-05-25 00:00:00	-0.105032631	-0.107133284	105000	Profit
2022-07-07 00:00:00	2022-07-08 00:00:00	0.122364014	0.124811294	105200	Profit
2022-10-24 00:00:00	2022-10-25 00:00:00	1.57632425	1.607850735	105400	Profit
2023-04-04 00:00:00	2023-04-05 00:00:00	1.723984447	1.706744603	105300	Loss
2023-05-16 00:00:00	2023-05-17 00:00:00	1.571402374	1.602830422	105500	Profit
2021-05-12 00:00:00	2021-05-17 00:00:00	-0.46852269	-0.473207917	105400	Loss
2022-01-18 00:00:00	2022-01-19 00:00:00	-0.27533397	-0.278087309	105300	Loss
2022-05-10 00:00:00	2022-05-11 00:00:00	-0.048429534	-0.047460943	105500	Profit
2022-12-02 00:00:00	2022-12-05 00:00:00	2.06852469	2.027154196	105700	Profit
2022-12-13 00:00:00	2022-12-14 00:00:00	2.056219674	2.01509528	105900	Profit
2022-12-23 00:00:00	2022-12-26 00:00:00	1.989772716	1.949977262	106100	Profit
2023-02-24 00:00:00	2023-02-27 00:00:00	1.696913367	1.713882501	106000	Loss
2023-03-20 00:00:00	2023-03-21 00:00:00	1.723984447	1.741224292	105900	Loss
2023-04-05 00:00:00	2023-04-06 00:00:00	1.664920412	1.631622004	106100	Profit
2023-05-09 00:00:00	2023-05-11 00:00:00	1.367139188	1.38081058	106000	Loss