

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YATIRIM KARARLARINDA ELLİOTT
DALGALARININ YOLO NESNE ALGILAMA
ALGORİTMASI İLE TESPİTİ VE ANALİZİ

Omar KARIMOV

2501191416

TEZ DANIŞMANI

Dr. Öğr. Üyesi Latife Sinem SARUL

İSTANBUL – 2023

ÖZ

YATIRIM KARARLARINDA ELLİOTT DALGALARININ YOLO NESNE ALGILAMA AIGORİTMASI İLE TESPİTİ VE ANALİZİ

Omar KARIMOV

Genel olarak, piyasaların artan karmaşıklığı ve oynaklığı, yatırımcılar için karar vermeyi her zamankinden daha zor ve belirsiz hale getirmiştir. Yatırımcılar başarılı olmak için araştırmalarında özenli olmalı ve yeni yatırım yöntemlerini incelemelidirler. Bu çalışmada, nesne algılama algoritması olan YOLO kullanılarak iki boyutlu mum grafiklerinde Elliott Dalgaları tespit edilmiş ve yatırım kararlarında farklı bakış açısı kazandırması hedeflenmiştir.

Bununla birlikte, bu tezin temel amacı, iki boyutlu mum grafiklerinde Elliott Dalgalarını doğru bir şekilde tespit ve analiz edebilecek bir yöntem geliştirmektir. YOLO adı verilen bu nesne algılama algoritması, evrimsel sinir ağı mimarisi üzerine inşa edilmiştir. Gerçek zamanlı görüntülerdeki nesneleri doğru ve verimli bir şekilde tespit edebilen son teknoloji bir çözüm olarak kabul edilmektedir. Bu model 2000-2021 yılları arasında işlem gören S&P 500'de listelenen hisse senetleri veri seti üzerinde eğitilmiştir. Model daha sonra performansını ölçmek için 2022 yılı test veri kümeleri üzerinde değerlendirilmiştir. Sonuçlar, YOLO'nun Elliott Dalgalarını %80'lik bir doğrulukla tespit ettiğini ve %10,594'lük toplam kâr oranı ile analiz edebilme yeteneğini ortaya koymaktadır.

Sonuç olarak, bu tezin bulguları YOLO'nun mum grafiklerinde Elliott Dalgalarını tespit ve analiz etmek için uygulanabilir bir teknik olduğuna dair kanıtlar sunmaktadır. Önerilen yaklaşım, zaman serilerine gerek duymadan yalnızca hisse senetlerinin iki boyutlu mum grafiklerini analiz ederek Dürtü-Düzeltici kararları verebilen bir modeldir. Bu model, daha etkili yatırım kararları almak amacıyla kullanılabilir. Özetle, bu araştırma finansal tahmin alanına önemli bir katkı sağlamakta ve yatırımcıların kullanabileceği değerli bir araç sunmaktadır.

Anahtar Kelimeler: Elliott Dalgaları, Nesne Tespit Algoritması, YOLO, S&P 500, CNN, Dürtü-Düzeltici

ABSTRACT

DETECTION AND ANALYSIS OF ELLIOTT WAVES IN INVESTMENT DECISIONS WITH YOLO OBJECT DETECTION ALGORITHM

Omar KARIMOV

In general, the increasing complexity and volatility of markets has made decision-making for investors more difficult and uncertain than ever before. To be successful, investors should be diligent in their research and examine new investment methods. In this study, Elliott Waves were detected in two-dimensional candlestick charts using YOLO, an object detection algorithm, and provided a different perspective on investment decisions.

The main purpose of this thesis is to develop a method that can accurately detect and analyze Elliott Waves in two-dimensional candlestick charts. This object detection algorithm, called YOLO, is built on a convolutional neural network architecture. It is considered a state-of-the-art solution that can accurately and efficiently detect objects in real-time. This model is trained on a dataset of stocks listed on the S&P500 traded between 2000-2021. The model was then evaluated on 2022 test datasets to measure its performance. The results reveal YOLO's ability to detect Elliott Waves with an accuracy of 80% and analyze it with an overall profit rate of 10,594%.

In conclusion, the findings of this thesis provide evidence that YOLO is a viable technique for detecting and analysing Elliott Waves in candlestick charts. The proposed approach is a model that can make Impulse-Corrective decisions by analysing only two-dimensional candlestick charts of stocks without the need for time series. This model can be used to make more effective investment decisions. In summary, this research makes a significant contribution to the field of financial forecasting and offers a valuable tool that investors can utilize.

Keywords: Elliott Waves, Object Detection Algorithm, YOLO, S&P500, CNN, Impulse-Corrective

ÖNSÖZ

Yatırım kararları dünyası sürekli gelişen ve karmaşık bir yapıya sahiptir, bu da geleceğin ne getireceğini tahmin etmeyi zorlaştırmaktadır. Yine de, doğru araçlar ve uzmanlıkla, yatırımcılar bilinçli kararlar almak için mevcut trendlerden ve piyasa hareketlerinden faydalanabilirler. Yatırımcılar arasında giderek daha popüler hale gelen bu araçlardan biri de Elliott Dalga Teorisi'dir. Ralph Nelson Elliott tarafından 1930'larda geliştirilen bu teori, piyasaların tekrarlayan döngüler halinde hareket ettiği fikrine dayanır. Yatırımcılar geçmiş piyasa verilerini analiz ederek gelecekteki piyasa eğilimlerinin yönü hakkında fikir sahibi olabilirler.

Ancak, geçmiş piyasa verilerini analiz etme görevi zordur ve önemli ölçüde çaba ve tecrübe gerektirir. Elliott Dalgalarını doğru bir şekilde tespit etmek ve analiz etmek için büyük bir beceri ve uzmanlık gerektirir. YOLO Nesne Tespit Algoritması işte bu noktada devreye girer. Yatırımcılar bu algoritmayı kullanarak Elliott Dalgalarını çok daha hızlı ve doğru bir şekilde tespit ve analiz edebilirler. Bu çalışmada, yatırım kararlarında Elliott Dalgalarını tespit ve analiz etmek amacıyla YOLO'nun kullanımı araştırılmıştır. Bununla birlikte YOLO'nun bu amaçla kullanmanın temel bileşenleri, sonuçları, faydaları ve bununla ilişkili olabilecek potansiyel dezavantajları uygulama verisi üzerinde detaylıca incelenmiştir. Son olarak, Elliott Dalgası tespit ve analizinin doğruluğunu ve hızını artırmak için YOLO'nun gerçek hayat senaryolarında nasıl kullanılabileceği analiz edilmiştir.

Omar KARIMOV

İSTANBUL, 2023

İÇİNDEKİLER

ÖZ.....	ii
ABSTRACT	iii
ÖNSÖZ.....	iv
TABLolar LİSTESİ.....	viii
GRAFİKLER LİSTESİ.....	ix
KISALTMALAR LİSTESİ.....	x
GİRİŞ	1

BİRİNCİ BÖLÜM

YATIRIM KARARLARI

1.1. Yatırım Kararları ile İlgili Temel Kavramlar	4
1.1.1. Yatırım Kavramı	4
1.1.2. Risk ve Getiri	5
1.1.3. Çeşitlendirme	6
1.1.4. Modern Portföy Teorisi	8
1.1.5. Yatırım Zamanı Ufku.....	10
1.2. Yatırım Süreci	11
1.3. Yatırım Kararlarının Türleri	12
1.3.1. Uzun Vadeli Yatırımlar	12
1.3.2. Kısa Vadeli Yatırımlar.....	13
1.3.3. Aktif Yatırım.....	15
1.3.4. Pasif Yatırım	16
1.3.5. Büyüme Yatırımı	17
1.3.6. Değer Yatırımı	19
1.3.7. Gelir Yatırımı.....	20
1.3.8. Spekülatif Yatırım.....	20
1.3.9 Etki Yatırımı	22
1.4. Yatırım Kararı için Temel Göstergeler.....	23
1.4.1. Ekonomik Göstergeler	23

1.4.2. Piyasa Göstergeleri	24
1.4.3. Finansal Göstergeler	25
1.4.4. Teknik İndikatörler	26
1.4.5. Duyarlılık Göstergeleri	28
1.5. Yatırım Kararlarında Yeni Yöntemler.....	29
1.5.1. Blockchain Teknolojisinin Kullanımı.....	29
1.5.2. Yatırım Kararlarında Yapay Zeka ve Makine Öğreniminin Kullanımı....	30

İKİNCİ BÖLÜM

ELLIOTT DALGA TEORİSİ

2.1. Elliott Dalga Teorisinin Tarihi ve Gelişimi.....	33
2.2. Elliott Dalga Türleri	34
2.2.1. Dürtü Dalgaları	34
2.2.2. Düzeltici Dalgalar	35
2.3. Dürtüsel ve Düzeltici Dalgaların Kombinasyonu	36
2.4. Elliott Dalga Analiz Teknikleri	37
2.4.1. Fraktal Analiz	37
2.4.2. Fibonacci Düzeltme Analizi	38
2.4.3. Elliott Dalga Osilatörü	39
2.4.4. Ayrışmalar	40
2.5. Elliott Dalgaları İle İlgili Vaka Çalışmaları ve Gerçek Dünya Örnekleri	42
2.6. Elliott Dalga Teorisini Kullanmanın Sınırlamaları ve Eleştirileri.....	44

ÜÇÜNCÜ BÖLÜM

DERİN ÖĞRENME İLE NESNE ALGILAMA

3.1. Derin Öğrenme Kavramı	46
3.2. Nesne Algılama İçin Model Türleri	48
3.2.1. Faster R-CNN	48
3.2.2. R-FCN.....	49
3.2.3. RetinaNet	50
3.2.4. Tek Atış Çoklu Kutu Dedektörü (SSD).....	51
3.2.5. Sadece Bir Kez Bak (YOLO)	52
3.3. Derin Öğrenme ile Nesne Algılama Süreci	54

3.3.1. Veri Toplama	54
3.3.2. Veri Ön İşleme.....	55
3.3.3. Modelin Tasarlanması.....	57
3.3.4. Modelin Eğitilmesi	59
3.3.5. Modelin Değerlendirilmesi	61
3.4. Nesne Algılama İçin Transfer Öğrenme	62
3.5. Derin Öğrenme İle Nesne Tespiti Uygulama Alanları	64
3.5.1. Bilgisayarlı Görü.....	64
3.5.2. Gözetleme ve Güvenlik	65
3.5.3. Yatırım Kararları.....	67
3.5.4. Tıbbi Görüntüleme.....	69
3.5.5. Robotik.....	70
3.6. Derin Öğrenme ile Nesne Algılamanın Geleceği.....	72

DÖRDÜNCÜ BÖLÜM

YOLO İLE ELLIOTT DALGALARIN TESPİTİ VE ANALİZİ

4.1. Veri Toplama.....	75
4.2. Veri Ön İşleme	77
4.3. Önerilen Model.....	81
4.4. Eğitim Metodolojisi.....	82
4.5. Test ve Bulgular	86
SONUÇ.....	94
KAYNAKÇA	96
EKLER.....	106

TABLÖLAR LİSTESİ

Tablo 1. Etiketleme örnekleri	79
Tablo 2. Modelin teknoloji sektörüne göre değerlendirilmesi	90
Tablo 3. Sektörlerin yıllık ortalama kârı	91
Tablo 4. Sonuçların değerlendirme tablosu.....	92



GRAFİKLER LİSTESİ

Grafik 1. İki boyutlu mum grafiği.....	76
Grafik 2. Dürtü dalgası.....	78
Grafik 3. Düzeltici dalga	79
Grafik 4. Etiketli görüntünün ".txt" dosya içeriği.	80
Grafik 5. Önerilen modelin adımları.....	82
Grafik 6. Darknet-53-ün mimarisi	83
Grafik 7. Modelin eğitim sonuçları.....	84
Grafik 8. Yukarı yönlü dürtü dalgası	87
Grafik 9. Aşağı yönlü dürtü dalgası	87
Grafik 10. Yukarı yönlü düzeltici dalga.....	88
Grafik 11. Aşağı yönlü düzeltici dalga	89

KISALTMALAR LİSTESİ

YOLO	: You Only Look Once
GSYH	: Gayri Safi Yurtiçi Hasıla
ABD	: Amerika Birleşik Devletleri
ETF	: Exchange-Traded Fund
MPT	: Modern Portföy Teorisi
GYO	: Gayrimenkul Yatırım Ortaklığı
CD	: Certificate of Deposit
S&P 500	: Standard and Poor's 500
Ar-Ge	: Araştırma ve Geliştirme
F/K	: Fiyat/Kazanç
PCR	: Put-Call Ratio
VIX	: Volatility Index
EWO	: Elliott Wave Oscillator
MACD	: Moving Average Convergence Divergence
EMA	: Exponential Moving Average
RSI	: Relative Strength Index
CNN	: Convolutional Neural Network
R-CNN	: Region Based Convolutional Neural Network
YSA	: Yapay Sinir Ağı
DNN	: Deep Neural Network

ReLU	: Rectified Linear Units
RPN	: Region Proposal Network
FCN	: Fully Convolutional Network
R-FCN	: Region Based Fully Convolutional Network
SSD	: Single Shot MultiBox Detector
FPN	: Feature Pyramid Network
ResNet	: Residual Network
GPU	: Graphics Processing Unit
RNN	: Recurrent Neural Network
SGD	: Stochastic Gradient Descent
RMSprop	: Root Mean Squared Propagation
mAP	: Mean Average Precision
MRI	: Magnetic Resonance Imaging
CT	: Computerized Tomography
NAS	: Neural Architecture Search
API	: Application Programming Interface

GİRİŞ

Borsa karmaşık ve dinamik bir ortamdır ve yatırımcılar için en zorlu görevlerden biri hisse senedi alım satımı konusunda bilinçli kararlar vermektir. Bilinçli kararlar verebilmek için yatırımcıların piyasa trendlerini analiz edebilmeleri ve hisse senedi fiyatlarındaki örüntüleri tanıyabilmeleri gerekir. Bu tür bir örüntü tanıma tekniği, hisse senedi fiyatlarının tekrar eden örüntüleri ve döngüleri takip ettiğini öne süren Elliott Dalga teorisidir.

Elliott Dalga teorisi 1930'larda Ralph Nelson Elliott tarafından geliştirilmiştir ve hisse senedi fiyatlarının tanımlanabilen ve tahmin edilebilen bir dizi tekrar eden model içinde hareket ettiği fikrine dayanmaktadır. Teoriye göre, bu kalıplar gelecekteki piyasa davranışları hakkında tahminlerde bulunmak için kullanılabilir ve yatırımcılar için değerli bilgiler sağlar. Popülerliğine rağmen, Elliott Dalga teorisini pratikte uygulamak zor olabilir, çünkü dalga kalıplarını belirlemek yüksek derecede teknik uzmanlık ve deneyim gerektirir.

Bu tezde, YOLO nesne algılama algoritmasını kullanarak yatırım kararlarında Elliott Dalgalarını tespit ve analiz etmek için yeni bir yaklaşım önerilmektedir. YOLO, bilgisayarla görme, otonom araçlar ve güvenlik gibi çeşitli alanlarda başarıyla uygulanan derin öğrenme tabanlı bir nesne algılama algoritmasıdır. Önerilen yaklaşım, YOLO'yu iki boyutlu mum grafiklerine uygulayarak, geçmiş hisse senedi fiyat verilerini analiz etmek ve Elliott Dalga modellerini belirlemek için bilgisayarla görme tekniklerini kullanacaktır.

Mum grafikleri, yatırımcılar tarafından hisse senedi fiyat verilerini temsil etmek ve belirli bir süre boyunca bir hisse senedinin açılış, kapanış, yüksek ve düşük fiyatlarını görüntülemek için yaygın olarak kullanılmaktadır. Önerilen yaklaşımda, büyük miktarda hisse senedi fiyat verisini analiz etme ve Elliott Dalga formasyonlarını yüksek doğrulukla belirleme potansiyeline sahiptir. Bu da yatırımcılara yatırım kararlarını destekleyecek değerli bilgiler sağlayacak ve hisse senedi alım satımı konusunda daha bilinçli tercihler yapmalarına yardımcı olacaktır.

Bu tezin amacı, YOLO algoritmasının Elliott Dalgalarını tespit etmedeki etkinliğini deęerlendirmek ve yatırım kararları üzerindeki etkisini analiz etmektir. Çalışmanın 1., 2. ve 3. bölümlerinde, yatırım kararları, Elliott dalga teorisi, derin öğrenme ile nesne algılama ve bilgisayarla görme teknikleri hakkındaki temel kavramlar ve literatürde yapılan çalışmalara örnekler sunulmuştur. Bunu, YOLO algoritmasının ayrıntılı bir açıklaması takip etmiştir, son bölümde ise S&P 500 endeksinde listelenen hisse senetlerinin grafikleri üzerinde YOLO ile Elliott dalgaların tespiti ve analizi yapılmıştır.



BİRİNCİ BÖLÜM

YATIRIM KARARLARI

Yatırım tercihleri yapmak, bireylerin ve kuruluşların finansal hedeflerine ulaşmaları için çok önemlidir. Bu tercihler kaynakların nasıl dağıtılacağını belirler ve çeşitli yatırım olasılıklarının potansiyel risk ve getirilerini etkiler. Bu kararları verirken önemli bir husus, yatırım hedefleri belirlemektir. Markowitz'in (1952) Modern Portföy Teorisine göre, yatırımcılar riski en aza indirmeye çalışırlar ve diğer taraftan beklenen getiriye en üst düzeye çıkarmaya uğraşırlar. Bu nedenle, yatırım hedefleri gerçekçi olmalı ve tanımlanmış zaman sınırlarına sahip olmalıdır.

Yatırım kararlarının alınmasında bir diğer önemli husus da piyasa eğilimlerinin analizi ve ekonomik koşulların değerlendirilmesidir. GSYH büyümesi, enflasyon oranı ve işsizlik oranı gibi ekonomik göstergeler, ekonominin genel sağlığı ve farklı yatırımların potansiyel performansı hakkında değerli bilgiler sağlayabilir. Buna ek olarak, hisse senedi fiyatlarındaki grafiklerin ve kalıpların incelenmesini içeren teknik analiz, yatırımcıların eğilimleri belirlemelerine ve bilinçli yatırım kararları almalarına yardımcı olabilir (Kaufman, 2010).

Çeşitlendirme de başarılı yatırım kararlarının önemli bir unsurudur. Çeşitlendirme, yatırımları hisse senetleri, tahviller, gayrimenkul ve emtialar dahil olmak üzere farklı varlık sınıflarına yayarak bir yatırım portföyünün riskini azaltmada önemli bir rol oynar.

Ayrıca, vergi ve harçların yatırım getirileri üzerindeki etkisini göz önünde bulundurmak, yatırım kararı almada önemli bir faktördür. Bireysel emeklilik hesapları ve borsa yatırım fonları gibi vergi açısından verimli yatırımlar, vergilerin yatırım getirileri üzerindeki etkisini azaltmaya yardımcı olabilir. Benzer bir şekilde, yönetim ücretleri ve işlem maliyetleri gibi ücretlerin yatırım getirileri üzerindeki etkisini dikkate almak çok önemlidir (Bodie, Kane ve Marcus, 2014).

Diğer taraftan yatırımcılar yatırım kararları verirken kendi risk toleranslarını dikkate almalıdırlar. Risk toleransı, bir kişinin yatırım portföyünde hoş gördüğü

belirsizlik seviyesini ifade eder. Shefrin & Statman'a (2000) göre, yüksek risk toleransına sahip bireyler daha yüksek potansiyel getiriye sahip yatırımları tercih edebilirken, düşük risk toleransına sahip bireyler daha düşük potansiyel getiriye sahip ancak aynı zamanda daha düşük riskli yatırımları tercih edebilirler.

Bu bölüm, yatırım kavramı, risk ve getiri, çeşitlendirme, modern portföy teorisi ve yatırım zaman ufku dahil olmak üzere yatırım kararlarının temellerini kapsamaktadır. Ayrıca, yatırım süreci ile birlikte uzun vadeli, kısa vadeli, aktif, pasif, büyüme, değer, gelir ve spekülasyon gibi yatırım kararlarının türleri açıklanmıştır. Yatırım kararları için kullanılan ekonomik, piyasa, finansal, teknik ve duyarlılık göstergeleri gibi temel göstergelere de yer verilmiştir. Son olarak, yatırım kararlarında blockchain teknolojisi, yapay zeka ve makine öğrenimi gibi yeni yöntemler incelenmiştir.

1.1. Yatırım Kararları ile İlgili Temel Kavramlar

1.1.1. Yatırım Kavramı

Yatırım, eski çağlardan beri insan uygarlığının ayrılmaz bir parçası olmuştur. İnsanlar her zaman servetlerini güvence altına almanın ve finansal kaynaklarını büyütmenin yollarını aramışlardır. Tarih boyunca yatırım, ekonomik büyüme, yenilik ve ilerlemenin temel itici gücü olmuştur. Bugün bildiğimiz modern yatırım kavramı 19. yüzyılda gelişmiştir. Bu dönemde sanayi devrimi devam ediyordu ve birçok ülkenin ekonomisi hızla genişliyordu. İnsanlar yüksek getiri elde etme umuduyla paralarını yeni girişimlere ve gelişmekte olan endüstrilere yatırmaya hevesliydi. Bu, modern yatırım endüstrisinin başlangıcı ve finans alanında yeni bir dönemin başlangıcıydı (Malkiel, 2003).

Yatırımın amacı, kişinin servetini ve finansal kaynaklarını zaman içinde büyütmeqdır. İki ana yatırım türü vardır, birincisi bir şirketten hisse senedi satın almayı içeren hisse senedi yatırımı ve diğeri düzenli faiz ödemeleri karşılığında bir kuruluşa veya devlete borç vermeyi içeren sabit gelirli yatırımdır. Her iki yatırım

türü de getiri elde etme ve gelir kaynağı sağlama potansiyeline sahiptir (Brown, 2020).

Öte yandan, ekonomi yatırımlardan kayda değer bir etki görmektedir. Bireyler ve kuruluşlar, işletmelere para yatırarak faaliyetlerinin genişlemesini finanse edebilir ve ekonomik büyümeyi teşvik edebilir. Bu da başkaları için yeni işler ve fırsatlar yaratır. Ayrıca yatırım, endüstrileri dönüştürebilecek ve insanların yaşamlarını iyileştirebilecek yeni teknolojilerin, ürünlerin ve hizmetlerin geliştirilmesini finanse etmeye de yardımcı olabilir. Buna ek olarak yatırım, insanlara servetlerini ve finansal kaynaklarını büyütme fırsatı sunarak eşitsizliğin azaltılmasına yardımcı olabilir. Bireyler şirketlere ve sektörlerle yatırım yaparak bu kuruluşların başarısını paylaşabilir ve böylece mali refahlarını artırabilirler. Ayrıca yatırım, emekliler için de bir gelir kaynağı oluşturarak, çalışmayı bıraktıktan sonra bile yaşam standartlarını korumalarını sağlayabilir (Elton vd., 2017).

Kuşkusuz, yatırım doğası gereği risk içerir. Yatırımların değeri dalgalanabilir ve varlık beklendiği gibi performans göstermezse para kaybetmek mümkündür. Kayıp riskini en aza indirmek için yatırımcılar genellikle portföylerini çeşitlendirir, paralarını bir dizi farklı varlığa yayarak tek bir yatırıma olan maruziyetlerini azaltırlar (Gibbons & Ferson, 1999).

1.1.2. Risk ve Getiri

Yatırım dünyasında kilit kavramlardan biri risk ve getiri arasındaki ilişkidir. Temel bir ilke, yatırım getirisinin ilgili risk düzeyi ile doğrudan ilişkili olduğunu belirten risk-getiri değiş tokuşudur. Bu nedenle, risk ne kadar büyükse potansiyel getirinin de o kadar büyük olacağı genel bir kuraldır. Bir yatırımın performansı belirsizdir, bu yüzden risk olarak adlandırılır. Yatırımlardaki risk, yatırım başarısızlığı veya yatırım kaybı potansiyelini ifade eder. Yatırımla ilişkili risk, piyasa riski, kredi riski, faiz oranı riski ve kur riskinin bir kombinasyonudur.

Diğer taraftan getiri, şirketin bir yatırımdan elde edilen kâr veya zararını ifade eder. Bir yatırımın zaman içinde kazandığı para miktarıdır ve ilk yatırımın bir

yüzdesi olarak ifade edilir. Bir yatırımın getirisi, sermaye kazançları, temettüleri ve faiz gelirleri dahil olmak üzere birçok şekilde olabilir. Yatırımcılar, yatırım kararları verirken istedikleri getiri seviyesine karşı rahat oldukları risk seviyesini tartmalıdır. Örneğin, mevduat sertifikası gibi düşük riskli bir yatırım düşük bir getiri sunabilirken, yeni kurulan bir şirket gibi yüksek riskli bir yatırım daha yüksek bir getiri sunabilir. Bir yatırımın beklenen getiriyi sağlayacağını garanti etmediğini ve geçmiş performansın gelecekteki sonuçların garantisi olmadığını unutmamak önemlidir.

Risk-getiri ödünleşimi, yatırım dünyasında kritik bir ilkedir. Yatırımcılar, yatırım kararları verirken arzu ettikleri getiri seviyesini riskle ilgili konfor seviyelerine göre tartmalıdır. Çeşitlendirme ve yatırım zaman ufkunun net bir şekilde anlaşılması, yatırımcıların riski yönetmelerine ve finansal hedeflerine ulaşmalarına yardımcı olabilir. Ayrıca, risk ve getiri ekonomik koşullar ve jeopolitik olaylar gibi dış faktörlerden de etkilenebilir. Bu nedenle, yatırımcılar yatırım kararları verirken her zaman bu tür faktörlerin farkında olmalıdır. Bu sayede yatırımlarının hem risk hem de getiri açısından optimize edilmesini sağlayabilirler.

1.1.3. Çeşitlendirme

Çeşitlendirme, işletmeler, kuruluşlar ve yatırımcılar için riski yönetmek ve getiriyi en üst düzeye çıkarmak için önemli bir stratejidir. Bu, varlıkların düşük veya negatif korelasyona sahip, yani genel piyasa ile aynı yönde hareket etmeyen yatırımlara tahsis edilmesiyle elde edilir (Modern Portföy Teorisi, 1952). Buna karşılık, portföye potansiyel büyüme fırsatları ekleyerek, portföy piyasadaki oynaklığın etkisini azaltabilir. Çeşitlendirme tarih boyunca çeşitli şekillerde kullanılmıştır, ancak modern şekli 1950'lerin başından beri mevcuttur. Bir yatırımcının yatırımlarını çeşitlendirmesi halinde başarılı olma olasılığı daha yüksektir. Dolayısıyla, yatırımcılar kayıp riskini dağıtmak için paralarını farklı sektörlerle, varlık sınıflarına ve yatırım tarzlarına yayarlar. Yatırımlar için çeşitlendirme, yatırımcıların arzu ettikleri getiri hedeflerine ulaşmalarına yardımcı olmada kilit öneme sahiptir. Hisse senetlerine, tahvillere, yatırım fonlarına, ETF'lere, gayrimenkule ve yatırım fonlarına yatırım yapmak, kişinin yatırım portföyünü

çeşitlendirmek için iyi bir yoldur. Her varlık sınıfının kendine özgü faydaları ve riskleri vardır, bu nedenle yatırımcılar yatırım yapmadan önce her biriyle ilişkili riskleri ve ödülleri anlamalıdır. Yatırımcılar yatırımlarını farklı ülke ve bölgelere yayabildikleri için çeşitlendirme küresel ölçekte de işe yarar.

Yatırımların yanı sıra işletmeler de çeşitlendirmeyi benimsemiştir. Şirketler yeni pazarlara açılarak, yeni ürünler piyasaya sürerek ve yeni hizmet modelleri yaratarak sundukları hizmetleri çeşitlendirmektedir. Bu tür bir çeşitlendirme, işletmelerin fırsatlardan yararlanmaya devam ederken riski daha iyi yönetmelerine yardımcı olur. Genel olarak, çeşitlendirme işletmeler, yatırımcılar ve kuruluşlar için önemli bir stratejidir. İşletmeler ve yatırımcılar, farklı yatırım ve ürün türleri arasında çeşitlendirme yaparak riski yönetmek için daha akıllıca ve daha başarılı bir yaklaşım sağlayabilirler.

Örneğin, yalnızca tek bir şirketin hisse senedine yatırım yapan bir portföy düşünün. Bu şirkette bir gerileme yaşanırsa, portföyün tamamı büyük olasılıkla önemli kayıplara uğrayacaktır. Diğer taraftan, farklı sektörlerdeki birden fazla şirket arasında çeşitlendirilmiş bir portföyün, tek bir şirketin gerilemesi durumunda önemli kayıplara uğrama olasılığı daha düşük olacaktır. Çeşitlendirme çeşitli şekillerde gerçekleştirilebilir. Çeşitlendirmenin en yaygın biçimleri varlık tahsisi ve coğrafi çeşitlendirmedir. Varlık dağılımı, yatırımların hisse senetleri, tahviller, gayrimenkuller ve emtialar gibi farklı varlık sınıflarına yayılmasını içerir. Bu, yatırımları yüksek korelasyona sahip olmayan varlıklara yayarak portföyün genel riskini azaltmaya yardımcı olur.

Coğrafi çeşitlendirme, farklı ülke veya bölgelerdeki şirketlere veya piyasalara yatırım yapmayı içerir. Örneğin, bir yatırımcı Amerika Birleşik Devletleri merkezli bir şirketin yanı sıra Avrupa veya Asya merkezli bir şirketin hisselerine de yatırım yapabilir. Bu tür bir çeşitlendirme, tek bir ülke veya bölgedeki ekonomik veya siyasi olayların etkisini azaltmaya yardımcı olabilir. Bir başka çeşitlendirme türü de farklı sektörlerdeki şirketlere yatırım yapmayı içeren sektör çeşitlendirmesidir. Örneğin, bir yatırımcı bir teknoloji şirketinin, bir sağlık şirketinin ve bir tüketim malları şirketinin

hisselerine yatırım yapabilir. Bu tür bir çeşitlendirme, ekonomik veya sektöre özgü olayların portföy üzerindeki etkisini azaltmaya yardımcı olabilir.

Çeşitlendirmenin kâr garantisi sağlamadığını veya kayıplara karşı bir koruma işlevi görmediğini akılda tutmak son derece önemlidir. Tüm yatırımcılar için uygun olan tek bir çeşitlendirme stratejisi yoktur ve yatırımcılar bir çeşitlendirme stratejisi seçerken bireysel yatırım hedeflerini ve risk toleranslarını göz önünde bulundurmalıdır. Ayrıca çeşitlendirme, portföyün yatırımcının amaç ve hedefleriyle uyumlu kalmasını sağlamak için sürekli izleme ve ayarlamalar gerektirir.

Çeşitlendirme, modern portföy teorisinin temel bir unsuru olarak büyük önem taşımaktadır ve bir yatırım portföyüyle ilişkili genel riski azaltmak için en iyi uygulama olarak kabul edilmektedir. Yatırımcılar, yatırımlarını farklı varlık sınıflarına, sektörler ve coğrafi bölgelere yayarak piyasa oynaklığının portföyleri üzerindeki etkisini azaltabilir ve potansiyel olarak daha yüksek bir beklenen getiri elde edebilir.

1.1.4. Modern Portföy Teorisi

İlk olarak 1952 yılında Harry Markowitz tarafından ortaya atılan Modern Portföy Teorisi, finans alanında en yaygın kullanılan teorilerden biri olarak önemli bir konuma sahiptir. MPT, çeşitlendirmeye ve bir portföydeki varlıkların etkin dağılımına odaklanan matematiksel bir yatırım yaklaşımıdır (Markowitz, 1952). MPT'nin amacı, bir portföyün beklenen getirisini en üst düzeye çıkarırken, getirilerin standart sapmasıyla ölçülen riskini en aza indirmektir.

MPT'nin yatırım kararları üzerindeki etkisi önemli olmuştur. MPT'den önce yatırımcılar öncelikle tek tek menkul kıymetlere ve bunların beklenen getirilerine odaklanmaktaydı. MPT, bir portföydeki menkul kıymetler arasındaki etkileşimleri dikkate almanın önemini ve çeşitlendirmenin riski nasıl azaltabileceğini vurgulayarak bu durumu değiştirmiştir (Elton vd., 2017). Bu yaklaşım, yatırım kararı vermenin temel taşı haline gelmiştir ve finans ve yatırım derslerinde yaygın olarak öğretilmektedir.

MPT özünde, bir yatırımcının birincil amacının beklenen getiriye maksimize ederken aynı zamanda riski minimize etmek olduğu önermesi üzerine kuruludur. Bu hedef, Markowitz'in 1952'de özetlediği gibi, düşük korelasyonlu menkul kıymetlerden oluşan iyi çeşitlendirilmiş bir portföyün oluşturulmasıyla gerçekleştirilir. Çeşitlendirme, şirkete özgü risk gibi tek bir menkul kıymete özgü risk olan sistematik olmayan riskin azaltılmasını sağlar. Yatırımların birden fazla menkul kıymete yayılmasıyla sistematik olmayan risk azaltılabilir ve portföyün genel riski en aza indirilebilir.

MPT'nin iki farklı türü ortaya çıkmıştır: Klasik yaklaşım ve Bayesçi yaklaşım. Klasik yaklaşım, getirilerin normal dağıldığını ve yatırımcıların riskten kaçındığını varsayan ortalama-varyans optimizasyon yöntemine dayanmaktadır (Markowitz, 1952). Bayesçi yaklaşım ise karar verme sürecine önsel inançları ve öznел olasılıkları dahil eder (DeMiguel, Garlappi ve Uppal, 2009).

MPT'nin inceliklerini araştırırken, titizlikle dikkat edilmesi gereken çok sayıda kısıtın devreye girdiği ortaya çıkmaktadır. Bu kısıtlamalar arasında en önemlilerinden biri rasyonel yatırımcı davranışı varsayımdır. Bu varsayım, Elton ve diğerlerinin 2017 yılında vurguladığı gibi, yatırımcıların kendi çıkarları doğrultusunda hareket ettikleri ve ellerindeki bilgilerden yararlanarak rasyonel kararlar aldıkları düşüncesine dayanmaktadır. Diğer bir kısıtlama ise tam piyasa varsayımdır, yani tüm varlıkların halka açık olduğu ve işlem maliyetleri ya da vergilerin olmadığı varsayımdır (Markowitz, 1952). Son olarak, MPT'si beklenen getirilerin ve getiri varyanslarının zaman içinde sabit olduğunu varsayar ki gerçek dünya yatırımlarında durum her zaman böyle değildir (DeMiguel vd., 2009).

Kısıtlamalarına rağmen MPT, finans uygulayıcıları tarafından yaygın bir şekilde benimsenmiş ve yatırım kararları üzerinde önemli bir etkiye sahip olmuştur. Teorinin çeşitlendirme ve risk yönetimine yaptığı vurgu, yatırımcıların daha verimli portföyler oluşturmalarına ve daha iyi yatırım kararları almalarına yardımcı olmuştur. MPT yatırımcılar için değerli bir araçtır, ancak varsayımlarını ve sınırlamalarını anlamak ve diğer yatırım teorileri ve araçlarıyla birlikte kullanmak önemlidir.

1.1.5. Yatırım Zamanı Ufku

Yatırım Zaman Ufku, yatırımcıların finansal hedeflerini ve bunlara ulaşmayı bekledikleri zaman dilimini anlamalarına yardımcı olduğu için yatırım yönetiminde çok önemli bir kavramdır. Basit bir ifadeyle, yatırım zaman ufku, bir yatırımcının bir getiri görmeyi beklemeden önce parasını yatırmaya istekli olduğu süreyi ifade eder.

Yatırım zaman ufkunun belirlenmesinde en önemli faktörlerden biri yatırımcının yaşıdır. Genç yatırımcılar için daha uzun bir yatırım zaman ufku tipik olarak tercih edilir, çünkü zaman avantajına sahiptirler, bu da piyasa dalgalanmalarını atlattıklarına ve düşük performans dönemlerini atlattıklarına olanak tanır (Bodie, Kane ve Marcus, 2014). Öte yandan, daha yaşlı yatırımcılar genellikle daha kısa bir yatırım süresi ufkuna sahiptir çünkü finansal yükümlülüklerini yerine getirmek için fonlarına daha erken erişimleri gerekebilir.

Yatırım zaman ufku, bir yatırımcının seçebileceği yatırım ürünlerinin türünü de etkiler. Örneğin, bir yatırımcı uzun vadeli bir yatırım zaman ufkuna sahipse, daha uzun bir süre boyunca daha yüksek getiri sağlama potansiyeline sahip olduğu için hisse senetlerine yatırım yapmayı tercih edebilir (Bodie vd., 2014). Bunun aksine, bir yatırımcının daha kısa bir yatırım süresi ufkuna varsa, daha kısa bir zaman diliminde daha istikrarlı ve öngörülebilir getiriler sunan tahvil gibi daha muhafazakar yatırımları tercih edebilir.

Yatırımcının yaşı ve hedeflerine ek olarak, yatırım zaman ufku piyasa koşullarından ve yatırımcının risk toleransından da etkilenir. Örneğin, bir piyasa gerilemesi sırasında, daha uzun bir yatırım süresi ufkuna sahip yatırımcıların, piyasanın toparlanmasını beklemek için zamanları ve sabırları olduğundan, yatırımlarını ellerinde tutma olasılıkları daha yüksek olabilir (Bodie vd., 2014). Bununla birlikte, daha kısa bir yatırım süresi ufkuna sahip yatırımcıların, riskten daha fazla kaçındıkları ve sermayelerini korumak istedikleri için bir piyasa gerilemesi sırasında yatırımlarını satma olasılıkları daha yüksek olabilir.

Yatırım zaman ufkunun sabit olmadığını ve bir yatırımcının koşulları ve finansal hedefleri değiştiğinde zaman içinde değişebileceğini unutmamak önemlidir.

Örneğin, uzun vadeli yatırım zaman ufkuна sahip bir yatırımcı fonlarına beklenenden daha erken erişmesi gerektiğini fark edebilir ve bu durumda yatırım stratejisini daha muhafazakar bir yaklaşıma göre ayarlaması gerekebilir (Bodie vd., 2014). Öte yandan, kısa vadeli yatırım süresi ufkuna sahip bir yatırımcı, daha fazla servet biriktirdikçe yatırım süresi ufkunu uzatabileceğini fark edebilir ve bu da daha fazla risk almasına ve daha yüksek getirili varlıklara yatırım yapmasına olanak tanır.

1.2. Yatırım Süreci

Yatırım süreci, disiplin ve sabır gerektiren devamlı bir döngüdür. Her yatırımcı hedeflerine, risk toleransına ve mevcut mali durumuna göre bilinçli kararlar almaya çalışmalıdır. Ancak, piyasa koşulları, ekonomik göstergeler ve siyasi olaylar da dahil olmak üzere yatırımlarınızın performansını etkileyebilecek birçok faktör vardır. Yatırım sürecinin adımları şunlardır:

Adım 1: Yatırım süreçlerinin ve amaçlarının tanımlanması

Yatırım sürecindeki ilk adım, yatırım hedeflerinin ve amaçlarının tanımlanmasıdır. Bu, yatırım zaman ufkunu, risk toleransını ve istenilen yatırım getirisini belirlemeyi içerir. Yatırım hedefleri, yatırım sürecinin geri kalanını yönlendirmeye ve ihtiyaçlara en uygun yatırım türlerini belirlemeye yardımcı olacaktır.

Adım 2: Mevcut finansal durumun değerlendirilmesi

Bir sonraki adım mevcut mali durumun değerlendirilmesidir. Bu adım, mevcut gelirleri, giderleri, borçları ve varlıkları anlamayı içerir. Bu bilgiler, kişinin yatırılabileceği miktarı ve kabul edebileceği risk seviyesini belirlemesine yardımcı olacaktır.

Adım 3: Yatırım planı geliştirilmesi

Yatırım hedefi ve mali durum net bir şekilde anlaşıldıktan sonra, bir sonraki adım yatırım planı geliştirilmesidir. Bu plan, yapmayı planlanan yatırım türlerini,

portföyün farklı varlık sınıfları arasındaki dağılımını ve planı uygulamak için zaman çizelgesini ana hatlarıyla belirlemektir.

Adım 4: Potansiyel yatırımların araştırılması

Bir sonraki adım potansiyel yatırımları araştırmaktır. Bireysel hisse senetlerinin, tahvillerin, yatırım fonlarının ve diğer menkul kıymetlerin finansal performansını değerlendirmeyi içerir. Bilinçli yatırım kararlar vermek için finansal oranları, kazanç raporları ve piyasa analizi kullanılabilir.

Adım 5: Yatırım planın uygulanması

Araştırma tamamlandığında ve yatırım kararları verildiğinden sonra, bir sonraki adım yatırım planın uygulanmasıdır. Bu, doğrudan veya bir komisyoncu aracılığıyla menkul kıymet satın almayı, bir portföy yönetim sistemi kurmayı ve yatırımları düzenli olarak izlemeyi içerir.

Adım 6: Portföyün izlenmesi ve yeniden dengelenmesi

Portföyün düzenli olarak izlenmesi ve yeniden dengelenmesi, yatırımların amaç ve hedeflere uyumlu kalmasını sağlamak için kritik öneme sahiptir. Bu, yatırımların performansını izlemeyi, piyasa koşulları değiştikçe portföyü ayarlamayı ve yatırım kriterlerini karşılamayan menkul kıymetleri satmayı içerir.

1.3. Yatırım Kararlarının Türleri

1.3.1. Uzun Vadeli Yatırımlar

Uzun vadeli yatırımlar, beş yıl veya daha uzun bir zaman ufku ile alınan finansal kararları ifade eder. Uzun vadeli yatırımın amacı, bileşik yatırımın gücünden ve kısa vadeli yatırımlara kıyasla daha yüksek getiri potansiyelinden yararlanarak serveti uzun bir süre boyunca büyütmektir. Bazı popüler uzun vadeli yatırım

seenekleri arasında hisse senetleri, tahviller, yatırım fonları, gayrimenkul ve deęerli metaller bulunmaktadır. Her biri kendine özgü özelliklere, risklere ve potansiyel getirilere sahip olan eřitli popüler uzun vadeli yatırım seenekleri mevcuttur. En yaygın uzun vadeli yatırım seeneklerinden bazıları řunlardır:

1. Hisse senetleri: Bir birey halka açık bir řirketin hisselerini satın aldığında, řirketin kısmi sahibi haline gelir. řirket büyüdüķe ve daha deęerli hale geldike, bireyin řirketteki yatırımının deęeri de artar. Borsa kısa vadede deęişken olabilir, ancak uzun vadede yatırımcılar iin tarihsel olarak cazip getiriler saęlamıştır.

2. Tahviller: Faiz ödemeleri řeklinde sabit bir gelir sunarlar, bu da onları istikrar ve öngörülebilir bir gelir akışı arayanlar iin popüler bir yatırım seeneęi haline getirir. Tahviller hisse senetlerine kıyasla daha düşük getiri sunma eęiliminde olsalar da, genellikle daha az riskli kabul edilirler.

3. Yatırım Fonları: Yatırım fonu, hisse senetleri, tahviller ve dięer menkul kıymetlerden oluřan eřitlendirilmiş bir portföy satın almak iin birden fazla yatırımcıdan gelen parayı bir araya getiren bir yatırım aracı türüdür. Bireyler bir yatırım fonuna yatırım yaparak profesyonel para yöneticilerinin uzmanlığından faydalanabilir.

4. Gayrimenkul: Gayrimenkul yatırımları, kiralık mülklerin satın alınması, GYO'lara yatırım yapılması veya gayrimenkul kitle fonlamasına katılım dahil olmak üzere birçok řekilde olabilir.

4. Deęerli Metaller: Altın ve gümüş gibi deęerli metaller yüzyıllardır bir deęer deposu olarak kullanılmaktadır. Fiyatlar kısa vadede deęişkenlik gösterse de, uzun vadede deęerli metaller deęerlerini korumuř ve hatta ekonomik belirsizlik dönemlerinde deęerlerini artırmıştır.

1.3.2. Kısa Vadeli Yatırımlar

Kısa vadeli yatırımlar, bir yıl veya daha kısa bir süre içinde nakde dönüştürülmesi veya satılması beklenen finansal varlıkları ifade eder. Genellikle yatırımcılar ve işletmeler tarafından, belirli bir amaç için ihtiyaç duyulana veya daha cazip bir yatırım fırsatı ortaya çıkana kadar kısa bir süre için fazla nakitlerini veya likiditelerini güvenli bir şekilde tutmanın bir yolu olarak kullanılırlar.

Bazı yaygın kısa vadeli yatırım türleri şunlardır:

- **Para piyasası fonları:** Hazine bonoları, ticari kağıtlar ve mevduat sertifikaları gibi yüksek likiditeye sahip, düşük riskli menkul kıymetlere yatırım yapan yatırım fonlarıdır. Güvenli yatırımlar olarak kabul edilirler ve diğer yatırım seçeneklerine kıyasla nispeten düşük getiri (yıllık yaklaşık %1 ila %2) sunarlar.
- **Hazine bonoları:** Bunlar hükümet tarafından ihraç edilir ve mevcut en güvenli yatırımlar arasında kabul edilir. Genellikle bir yıldan kısa sürede vadeleri dolar ve satın alındıkları tarihte geçerli olan faiz oranına göre getiri sunarlar.
- **Ticari kağıt:** Şirketlerin acil kısa vadeli sermaye temin etmek amacıyla ihraç ettikleri teminatsız borçlanma araçlarının bir çeşididir. Genellikle ticari senetlerin yatırım süresi 90 gün ile 270 gün arasında değişir ve para piyasası fonlarına kıyasla marjinal olarak daha üstün bir getiri sunar.
- **Mevduat sertifikaları:** CD'ler, bankalar ve diğer finansal kuruluşlar tarafından verilen zamana bağlı mevduatlardır. Yatırımcının genellikle birkaç aydan birkaç yıla kadar değişen belirli bir süre için sabit bir miktar para yatırmasını gerektirir. Bu taahhüt karşılığında yatırımcı, tasarruf hesabından daha yüksek bir faiz oranı alır (Berger, 2019).

İşletmeler için, fazla nakdi tutmak için düşük riskli bir seçenek sunarlar ve acil finansal ihtiyaçları karşılamak için kullanılabilecek bir likidite kaynağı sağlarlar. Bireyler için ise önemli bir piyasa riskine maruz kalmadan para biriktirmenin bir yolunu sunar ve geleneksel tasarruf hesaplarından daha yüksek bir getiri sağlarlar (Jorion & Go, 2021).

Bununla birlikte, kısa vadeli yatırımlar bazı dezavantajları da beraberinde getirmektedir. En büyük dezavantajlarından biri, diğer yatırım seçeneklerine kıyasla sundukları düşük getiridir. Ayrıca, enflasyona ayak uyduramayabilirler ve bu da zaman içinde yatırımın değerini aşındırabilir. Kısa vadeli yatırımlar ayrıca erken para çekme cezalarına tabi olabilir ve bu da yatırımdan elde edilen getiriye azaltabilir (Jorion & Go, 2021).

1.3.3. Aktif Yatırım

Aktif yatırım, yatırımcının pasif yatırım yöntemlerinden daha yüksek getiri elde etmek amacıyla düzenli olarak menkul kıymet alıp satarak portföyünü aktif bir şekilde yönettiği bir yatırım stratejisi türüdür. Yatırımcının piyasayı sürekli olarak izlemesi ve en son finansal verilere dayanarak bilinçli kararlar vermesi gerektiğinden, bu tür bir yatırım önemli miktarda zaman ve uzmanlık gerektirir.

Aktif yatırımın en önemli avantajlarından biri, potansiyel olarak daha yüksek getiri sağlama yeteneğidir. Malkiel (2003) tarafından yapılan bir çalışmaya göre, aktif olarak yönetilen portföyler, özellikle dalgalı piyasa koşullarında pasif yatırımlardan daha iyi performans gösterme potansiyeline sahiptir.

Aktif yatırımın bir diğer avantajı da piyasadaki değişikliklere yanıt olarak hızlı karar verme yeteneğidir. Örneğin, piyasa koşullarında ani bir değişim olması halinde aktif bir yatırımcı bir menkul kıymeti hızla satabilir ve kayıpları en aza indirmek amacıyla fonlarını başka bir varlık sınıfına taşıyabilir. Öte yandan, endeks fonları gibi pasif yatırımlar belirli bir piyasanın performansını takip etmek üzere tasarlanmıştır ve piyasa koşullarındaki değişikliklere hızlı bir şekilde yanıt veremezler (Swensen, 2005).

Aktif yatırımın en büyük dezavantajlarından biri, menkul kıymetlerin sürekli alınıp satılmasıyla ilişkili yüksek maliyettir. Bogle'a (2007) göre, aktif yatırım stratejileri genellikle pasif yatırım yöntemlerine kıyasla daha yüksek ücret ve masraflara neden olur ve bu da yatırımdan elde edilen toplam getiriye önemli ölçüde azaltabilir. Ayrıca, aktif yatırım önemli miktarda zaman ve uzmanlık gerektirir ki bu da ortalama bir yatırımcı için mümkün olmayabilir.

Aktif yatırımın bir diğer dezavantajı da düşük performans gösterme potansiyelidir. Carhart (1997) tarafından yapılan bir araştırmaya göre, aktif olarak yönetilen portföylerin çoğunluğu uzun vadede karşılaştırma endeksinin altında performans göstermektedir. Bu durum, aktif yatırımla ilişkili yüksek maliyetlere ve yatırımcıların uzun vadeli finansal veriler yerine kısa vadeli piyasa eğilimlerine dayalı fevri kararlar alma eğilimine bağlanabilir.

1.3.4. Pasif Yatırım

Pasif yatırımda yatırımcı, belirli bir piyasa endeksinin performansını takip eden hisse senetleri, tahviller ve borsa yatırım fonları gibi çeşitlendirilmiş bir varlık portföyü tutarak uzun vadeli büyüme sağlamaya çalışır. Tek tek hisse senetlerini seçmek veya piyasadan daha iyi performans göstermek için zamanlama yapmak yerine, pasif yatırımcılar çeşitlendirilmiş bir varlık portföyü tutarlar. (Bogle, 2007). Pasif yatırımın amacı, maliyetleri en aza indirmeye ve aktif yönetimle ilişkili risklerden kaçınmaya vurgu yaparak genel piyasaya benzer getiriler elde etmektir (Swedroe, 2017).

Pasif yatırım stratejileri, aktif yönetimle ilişkili maliyetleri azaltırken, aktif olarak yönetilen portföylere benzer veya daha yüksek uzun vadeli getiriler sağlayabildiklerine dair kanıtlar nedeniyle son yıllarda popülerlik kazanmıştır (Bogle, 2007). Bogle'a (2007) göre, ortalama bir aktif yatırım fonu, yönetim ücretleri, alım satım maliyetleri ve vergiler de dahil olmak üzere aktif yönetimle ilişkili yüksek maliyetler nedeniyle piyasanın altında performans göstermektedir. Buna karşılık, endeks fonları gibi pasif yatırım stratejileri çok daha düşük maliyetlere

sahiptir ve piyasaya benzer getiriler sağlayabilmektedir. Swedroe (2017), S&P 500 şirketlerini takip eden endeks fonlarının, şirketlerin bireysel hisse senetlerini satın almaktan daha uygun maliyetli olduğunu belirtmektedir (Swedroe, 2017). Sonuç olarak, yatırımcı piyasanın genel büyümesinden faydalanabilir ve bireysel hisse senedi seçimiyle ilişkili riski azaltabilir.

Pasif yatırımın bir diğer avantajı da duyguların yatırım kararları üzerindeki etkisini azaltmaya yardımcı olmasıdır. Aktif yönetimde, yatırımcı sürekli olarak piyasadan daha iyi performans göstermeye çalışır ve bu da sağlam yatırım ilkelerinden ziyade duygular tarafından yönlendirilen dürtüsel alım ve satım kararlarına yol açabilir (Bogle, 2007). Buna karşılık pasif yatırım stratejileri, duygulardan veya piyasa koşullarından etkilenmeyen bir dizi iyi tanımlanmış kurala dayanır. Düşünmeden veya ani yatırım kararları verme riskini azaltmaya yardımcı olur ve yatırımcının uzun vadeli bir yatırım ufkunu korumasına olanak tanır.

Pasif yatırım stratejileri, sınırlı kaynaklara veya piyasalar hakkında bilgiye sahip olabilecek bireysel yatırımcılar için de çok uygundur. Swedroe'ya (2017) göre, ortalama bir bireysel yatırımcının tek tek hisse senetlerini araştırarak ve bilinçli yatırım kararları verecek zamana veya kaynağa sahip olması pek olası değildir. Pasif olarak yönetilen endeks fonları, bireysel yatırımcılara çok çeşitli piyasa segmentlerine erişmek için uygun maliyetli bir yol sunar. Aynı zamanda fon yöneticisinin uzmanlığı nedeniyle avantajlı olabilir.

Pasif yatırımın faydalarına rağmen, pasif stratejilerin tüm yatırımcılar için en iyi seçenek olmayabileceğini akılda tutmak önemlidir. Örneğin, bazı yatırımcılar aktif yönetimin sunduğu daha yüksek getiri potansiyelini tercih edebilir veya aktif yönetimle daha iyi elde edilebilecek belirli bir yatırım hedefine sahip olabilir (Bogle, 2007). Ayrıca pasif stratejiler, yatırımcı takip edilen endekste yer alan varlıklarla sınırlı olduğu için aktif stratejilerle aynı düzeyde esneklik sağlamayabilir (Swedroe, 2017).

1.3.5. Büyüme Yatırımı

Büyümeye yatırım yapmak, şirketlerin işlerini ileriye götürmek ve uzun vadeli başarı elde etmek için kullanabilecekleri stratejik bir yaklaşımdır. Büyüme yatırımı, tipik olarak araştırma ve geliştirme, pazarlama ve ürün geliştirme finansmanı yoluyla bir şirketin genişlemesini desteklemeyi amaçlayan bir sermaye yatırımı türüdür. Büyüme için yeni fırsatlar yaratmayı ve zaman içinde şirketin değerini artırmayı amaçlayan bir yatırım türüdür (Baker & Wurgler, 2002).

Büyüme yatırımının başlıca faydalarından biri, şirketlerin faaliyetlerini finanse etmelerini ve işlerini yeni zirvelere ulaşmak için ölçeklendirmelerini sağlamasıdır. Bu durum özellikle, şirketlerin rekabette öne geçmek ve yenilikçi ürünleri pazara sunmak için Ar-Ge'ye büyük yatırım yapmaları gereken teknoloji sektörü için geçerlidir. Şirketler büyümeye yatırım yaparak operasyonlarını desteklemek, yeni çalışanlar işe almak, pazarlama ve ürün geliştirme çabalarını artırmak için ihtiyaç duydukları finansmanı sağlayabilirler.

Büyüme yatırımının bir diğer faydası da şirketlerin ortaya çıkan yeni fırsatlardan yararlanmalarını sağlamasıdır. Yeni teknolojilerin ve pazar trendlerinin hızla ortaya çıkabildiği ve büyüme için yeni fırsatlar yaratabildiği teknoloji gibi hızla gelişen sektörlerde özellikle önemli olabilir (Chen & Lee, 2014).

Büyüme fırsatlarına yatırım yapma eylemi, doğası gereği belirli riskleri de beraberinde getirmektedir. Büyüme yatırımlarıyla ilişkili ana risklerden biri, gelecekteki başarı potansiyeline ilişkin belirsizlikle ilgilidir. Şirketler büyümeye yatırım yaptıklarında, esasen pazara yeni ürün ve hizmetler sunma ve gelir elde etme becerileri üzerine bahis oynamış olurlar. Bu ürün ve hizmetler başarılı olmazsa, şirket yatırımını telafi edemeyebilir ve bu da önemli kayıplara yol açabilir (Zingales, 2000).

Büyüme yatırımıyla ilişkili bir diğer risk de şirketlerin işlerine aşırı yatırım yaparak finansal performanslarında düşüşe yol açabilmeleridir. Bu durum, şirketler Ar-Ge ve pazarlamaya büyük yatırımlar yaptığında, ancak maliyetlerini karşılayacak kadar gelir elde edemediğinde ortaya çıkabilir. Bu gibi durumlarda, şirket faaliyetlerini küçültmek veya ek finansman aramak zorunda kalabilir, bu da finansal performansı üzerinde daha fazla baskı yaratabilir (Baker & Wurgler, 2002).

Bu risklere rağmen, büyüme yatırımı, işlerini ilerletmek ve uzun vadeli başarı elde etmek isteyen şirketler için popüler bir strateji olmaya devam etmektedir. Büyüme yatırımıyla ilişkili riskleri azaltmak için şirketlerin pazarlarını ve rekabetçi konumlarını net bir şekilde anlamalarının yanı sıra büyüme için iyi tanımlanmış bir stratejiye sahip olmaları önemlidir (Chen & Lee, 2014).

1.3.6. Değer Yatırımı

Değer yatırımı, değeri düşük olan ve gelecekte daha yüksek getiri sağlama potansiyeline sahip hisse senetlerini belirlemeyi amaçlayan bir yatırım yaklaşımıdır. Bu kavram ilk olarak Benjamin Graham ve David Dodd tarafından, değer yatırımı felsefesi için bir mihenk taşı görevi gören "Security Analysis" (1934) adlı kitaplarında popüler hale getirilmiştir. Yatırımcılar hisse senedi alımlarına işletme sahibiymiş gibi yaklaşmalı ve temel şirketin finansal sağlığını ve gelecek beklentilerini dikkatle değerlendirmelidir.

Değer yatırımcıları, sağlam bir bilanço, istikrarlı kazançlar ve temettü ödeme geçmişisi gibi güçlü temellere sahip şirketleri ararlar. Bu şirketlerin piyasa tarafından düşük değerlendirildiğine ve büyüme potansiyeline sahip olduğuna inanırlar. Önemli büyüme potansiyeline sahip şirketlere öncelik veren büyüme yatırımından farklı olarak değer yatırımı, piyasa tarafından göz ardı edilen ve indirimli bir fiyattan satın alma fırsatı sunan düşük değerli şirketlerin belirlenmesine odaklanır.

Değer yatırımının sıklıkla kullanıldığı sektörler örnek olarak finans, enerji ve kamu hizmetleri verilebilir. Bu sektörler teknoloji veya sağlık hizmetleri gibi hızlı büyüme potansiyeline sahip olmayabilir, ancak istikrarlı kazançlar ve temettüler sunarak değer yatırımcıları için cazip hale gelebilirler.

Efsanevi değer yatırımcısı Warren Buffett, değeri düşük hisse senetlerini bulma çabalarıyla tanınır. The Intelligent Investor (1949) Benjamin Graham'ın en iyi kitaplarından biridir. Ona göre yatırımcıların en büyük sorunu kendileridir. Değer yatırımcıları, disiplinli ve sabırlı yaklaşımlarla bu sorunun üstesinden gelmek için piyasa trendlerini takip etmekten veya fevri kararlar almaktan kaçınırlar.

1.3.7. Gelir Yatırımı

Bu yatırım türü genellikle emeklilik gelirlerini desteklemek veya devam eden harcamalarını karşılamak için istikrarlı bir gelir kaynağı sağlamak isteyen bireyler tarafından seçilir.

Nobel Ödüllü ekonomist William Sharpe'a göre gelir yatırımı, nispeten düşük riski ve öngörülebilir nakit akışları yaratma kabiliyeti nedeniyle yüzyıllardır popüler bir strateji olmuştur (Sharpe, 1964). Geleneksel gelir getiren varlıklar arasında tahviller, temettü ödeyen hisse senetleri ve gayrimenkul yatırımları yer alır. Bu varlıklar güvenilir bir gelir kaynağı sunarak istikrarlı bir nakit akışı arayanlar için cazip bir seçenek haline gelir.

Ancak, tüm gelir yatırımlarının eşit yaratılmadığını akılda tutmak önemlidir. Örneğin, düşük kredi notuna sahip şirketler tarafından ihraç edilen tahviller daha yüksek risk taşır ve yüksek nota sahip şirketler tarafından ihraç edilen tahvillerle aynı düzeyde gelir sağlamayabilir. Benzer şekilde, yüksek temettü ödeyen hisse senetleri daha yüksek risk taşıyabilir veya piyasa oynaklığına daha duyarlı olabilir (Fama & French, 2010).

Gelir yatırımı ekonomide çok önemli bir rol oynar ve verimli bir etki potansiyele sahiptir. Bireyler tahvillere ve hisse senetlerine yatırım yaptıklarında, hem şirketlere hem de hükümetlere sermaye sağlayarak genişlemelerini ve istihdam yaratmalarını kolaylaştırır, böylece genel ekonomik büyümeyi desteklerler. Ayrıca gelir yatırımı, ekonomik istikrar ve daha fazla büyüme için bir temel teşkil eden istikrarlı ve öngörülebilir bir finansal ortamın oluşturulmasına katkıda bulunur.

1.3.8. Spekülatif Yatırım

Spekülatif yatırımın temel amacı, temettü veya faiz ödemelerinden elde edilen gelire güvenmek yerine, belirli bir varlıktaki fiyat artışından veya fiyat hareketinden kâr elde etmektir. Spekülatif yatırımlar, hisse senetleri, emtialar, para birimleri, gayrimenkul ve hatta kripto para birimleri dahil olmak üzere birçok şekilde olabilir. Bu yatırımlar genellikle yüksek riskli olarak kabul edilir ve yalnızca risk toleransı yüksek olan ve önemli kayıp olasılığını kabul etmeye istekli olan yatırımcılar için uygundur.

Borsa, en çok tercih edilen spekülatif yatırım seçeneklerinden biridir. Çok sayıda yatırımcı, ilgili şirketlerin büyüme yaşayacağı ve değer kazanarak hisse senedi fiyatlarında artışa yol açacağı beklentisiyle hisse senedi satın almaktadır. Bununla birlikte, her zaman şirketin düşük performans gösterme olasılığı vardır, bu da hisse senedi fiyatlarında düşüşe ve yatırımcı için potansiyel mali kayıplara neden olur.

Bir başka spekülatif yatırım türü de altın, gümüş ve petrol gibi emtialara yapılan yatırımlardır. Bu yatırımlar genellikle arz ve talepteki değişiklikler nedeniyle emtia fiyatının artacağı inancına dayalı olarak yapılır. Emtia fiyatları jeopolitik olaylardan ve doğal afetlerden de etkilenerek bu yatırımları özellikle değişken hale getirir.

Döviz spekülasyonu, spekülatif yatırımın farklı bir çeşidini temsil etmektedir. Yatırımcılar, değerinin başka bir para birimine göre artacağı beklentisiyle belirli bir para birimini satın alabilirler. Örneğin, bir yatırımcı Avronun ABD doları karşısında değer kazanacağı umuduyla avro satın alabilir. Ancak döviz kurları siyasi ve ekonomik olaylardan oldukça etkilendiği için döviz spekülasyonu çok riskli olabilir.

Gayrimenkul spekülasyonu, gelecekte daha yüksek bir fiyata satma beklentisiyle mülk satın almayı içeren spekülatif bir yatırımdır. Gayrimenkul spekülasyonu kazançlı bir yatırım olabilir, ancak emlak fiyatları ekonomik koşullar ve hükümet politikaları da dahil olmak üzere birçok faktörden etkilenebileceğinden aynı zamanda yüksek riskli bir yatırımdır.

Kripto para nispeten yeni bir spekülatif yatırım türüdür. Bitcoin, Ethereum ve Litecoin gibi kripto para birimleri, herhangi bir hükümet veya merkezi otorite

tarafından desteklenmeyen merkezi olmayan dijital para birimleridir. Kripto para fiyatları oldukça deęişken olabilir, bu da teknolojiye ve piyasaya aşına olmayanlar için bunu riskli bir yatırım haline getirir.

1.3.9 Etki Yatırımı

Etki yatırımı, hem olumlu sosyal veya çevresel sonuçlar hem de finansal getiriler elde etmek amacıyla kasıtlı olarak yatırım yapma eylemini kapsar. Bu yatırım türü, yoksulluk, iklim deęişikliği ve eşitsizlik gibi dünyanın en acil sorunlarından bazılarıyla mücadele etmeyi amaçlamaktadır. Global Etki Yatırım Ağı tarafından hazırlanan bir rapora göre, etki yatırımı son yıllarda önemli ölçüde büyümüştür ve 2018 yılında küresel olarak 502 milyar dolarlık varlık yönetilmektedir.

Etki yatırımları, sosyal girişimlere yapılan öz sermaye yatırımları, mikrofinans kurumlarına verilen krediler ve yenilenebilir enerji ve sürdürülebilir tarıma yapılan yatırımlar da dahil olmak üzere çeşitli şekillerde olabilir. Bu yatırımlar vakıflar, emeklilik fonları ve kalkınma finansmanı kurumları dahil olmak üzere hem bireysel hem de kurumsal yatırımcılar tarafından yapılabilir.

Etki yatırımındaki en önemli zorluklardan biri etkinin ölçülmesi ve gösterilmesidir. Bunu ele almak için Etki Yönetimi Projesi (2020), etki yönetimi ve ölçümü için bir dizi standartlaştırılmış, ilkelere dayalı yaklaşım geliştirmiştir. Bu, yatırımcıların farklı yatırımların etkisini anlamasına ve karşılaştırmasına olanak tanır ve şirketlere sosyal ve çevresel etkilerini raporlamaları için bir çerçeve sağlar.

Artan popülaritesine rağmen etki yatırımı henüz başlangıç aşamasındadır ve sürdürülebilir kalkınmayı teşvik etme potansiyelini daha iyi anlamak için daha fazla araştırmaya ihtiyaç vardır. Örneğin, Eyre ve Repici'nin (2020) belirttiği gibi, etki yatırımlarının başarısını etkileyen faktörlerin ve etki yatırımcılarının etkili işletmelerin büyümesini ve ölçeklenebilirliğini desteklemede oynayabileceği rolün daha iyi anlaşılmasına ihtiyaç vardır.

1.4. Yatırım Kararı için Temel Göstergeler

1.4.1. Ekonomik Göstergeler

Ekonomik göstergeler, bir ülke ekonomisinin büyüme, üretim, tüketim ve istihdam gibi çeşitli yönlerini ölçen istatistiklerdir. Bu göstergeler ekonomistlere, politika yapıcılara, yatırımcılara ve halka önemli bilgiler sağlayarak ekonominin mevcut durumunu anlamalarına ve gelecekteki yönünü tahmin etmelerine yardımcı olur.

Gayri Safi Yurtiçi Hasıla en yaygın kullanılan ekonomik göstergelerden biridir. Bir ülkenin sınırları içinde belirli bir zaman diliminde, genellikle bir yılda üretilen tüm mal ve hizmetlerin toplam değerini ölçer. Bu gösterge bir ülkenin ekonomik faaliyetlerinin kapsamlı bir resmini sunar ve ekonomik büyüme oranının belirlenmesine yardımcı olur. Büyüyen bir GSYİH genellikle güçlü bir ekonomiye işaret ederken, azalan bir GSYİH zayıf bir ekonominin işaretidir. Bir diğer önemli gösterge de hane halkları tarafından tüketilen mal ve hizmetlerden oluşan bir sepet için zaman içinde fiyatlardaki ortalama değişimi ölçen Tüketici Fiyat Endeksidir. Bu gösterge, mal ve hizmet fiyatlarının zaman içinde yükselme oranı olan enflasyon hakkında fikir verir. Yüksek enflasyon tüketicilerin satın alma gücünün azalmasına ve ekonomik büyümenin düşmesine yol açabilir. Tarım Dışı İstihdam Raporu olarak da bilinen İstihdam Raporu, tarım işçileri, devlet çalışanları ve özel hane halkı çalışanları hariç olmak üzere her ay ekonomiye eklenen veya kaybedilen iş sayısını ölçer. Bu gösterge, işgücü piyasasının sağlığını değerlendirmek için yaygın olarak kullanılmakta ve ekonominin büyük bir bölümünü yönlendiren tüketici harcamaları hakkında fikir vermektedir. Yüksek istihdam ve artan ücretlerle güçlü bir işgücü piyasası genellikle ekonomi için olumlu bir işaret olarak kabul edilir. Bir diğer önemli ekonomik gösterge de bir ülkenin ihracatı ile ithalatı arasındaki farkı ölçen Ticaret Dengesidir. Pozitif bir ticaret dengesi bir ülkenin ithal ettiğiinden daha fazla mal ve hizmet ihraç ettiğini gösterir ki bu da genellikle güçlü bir ekonominin işareti olarak kabul edilir. Öte yandan, negatif bir ticaret dengesi bir ülkenin ihraç ettiğiinden daha fazla mal ve hizmet ithal ettiğini gösterir ki bu da zayıf bir ekonominin işareti

olabilir. Konut Piyasası Endeksi, konut piyasasının mevcut ve gelecekteki gücünü ölçer. Bu gösterge, konut inşaatçıları arasında yapılan bir ankete dayanmaktadır ve tüketici güveni ve ekonomik büyümenin önemli bir göstergesi olan yeni konutlara olan talep hakkında fikir vermektedir. Güçlü bir konut piyasası, konut ve ilgili ürün ve hizmetlerin satışı yoluyla istihdam yarattığından ve gelir sağladığından ekonomik büyümeyi destekleyebilir. Son olarak, S&P 500 veya Dow Jones Industrial Average gibi Borsa Endeksi, borsanın performansını ölçer ve yatırımcı duyarlılığı ve ekonominin genel sağlığı hakkında fikir verir. Yükselen bir borsa genellikle güçlü bir ekonominin işareti olarak kabul edilirken, düşen bir borsa zayıf bir ekonomiye veya yatırımcı endişesine işaret edebilir.

Bu göstergeler ekonomistlere, politika yapıcılara, yatırımcılara ve halka değerli bilgiler sağlayarak bilinçli kararlar almalarına ve ekonomideki değişikliklere uygun şekilde yanıt vermelerine yardımcı olur. Fakat, tek bir göstergenin ekonominin tam bir resmini sunmadığını ve ekonominin sağlığını daha kapsamlı bir şekilde anlamak için birden fazla göstergeyi dikkate almak gerektiğini unutmamak önemlidir.

1.4.2. Piyasa Göstergeleri

Piyasa göstergeleri, piyasa eğilimlerini, ekonomik performansı ve piyasa duyarlılığını ölçmek ve analiz etmek için kullanılan istatistiksel araçlardır. En yaygın olarak takip edilen piyasa göstergelerinden biri, Amerika Birleşik Devletleri'ndeki borsalarda listelenen 500 büyük sermayeli hisse senedinden oluşan bir endeks olan S&P 500'dür. S&P 500, 1957 yılında önde gelen bir finansal hizmetler şirketi olan Standard & Poor's tarafından Amerikan borsasının performansını ölçmenin bir yolu olarak geliştirilmiştir. Başlangıçta endeks 90 hisse senedini içeriyordu, ancak zamanla ABD'deki en büyük halka açık şirketlerden 500'ünü içerecek şekilde gelişti. Bugün S&P 500, ABD borsasının genel sağlığının en iyi göstergelerinden biri olarak kabul edilmektedir.

S&P 500, ABD'deki en büyük ve en köklü şirketlerin performansının bir yansıması olduğu için önemli kabul edilmektedir. Bu şirketler ekonominin genel sağlığının temel göstergeleri olarak görülmektedir ve bu nedenle hisse senedi fiyatlarındaki değişiklikler daha geniş ekonomik eğilimler hakkında fikir verebilir. Ayrıca, S&P 500 aktif olarak yönetilen hisse senedi portföylerinin performansı için bir ölçüt olarak görülür ve yatırımcılar tarafından genellikle kendi portföyleri için bir gösterge olarak kullanılır. S&P 500, bir piyasa göstergesi olarak oynadığı rolün yanı sıra, bir yatırım aracı olarak da yaygın bir şekilde kullanılmaktadır.

1.4.3. Finansal Göstergeler

Finansal Göstergeler, bir ekonominin, piyasanın veya bireysel şirketin performansı ve sağlığı hakkında bilgi sağlayan ölçütlerdir. Yatırımcılar, analistler ve politika yapıcılar tarafından yatırım, ekonomi politikası ve iş stratejisi hakkında bilinçli kararlar almak için kullanılırlar. Şirket göstergeleri ise münferit şirketlerin finansal performansı hakkında spesifik bilgiler sağlar. En yaygın kullanılan şirket göstergelerinden bazıları şunlardır:

- **Hisse başına kazanç:** Bir şirketin kârlılığını değerlendirmek için kullanılan ve tedavüldeki toplam hisse sayısını dikkate alan bir metriktir. Bu önemli ölçüt, bir şirketin finansal performansı hakkında değerli bilgiler sunarak yatırımcılara bir şirketin hisse senedinin gerçek değerini değerlendirmede yardımcı olur.
- **Fiyat-Kazanç (P/E) Oranı:** Hisse senedi fiyatı ile hisse başına kazancını yan yana getiren ve şirketin değerlemesinin bir göstergesi olarak hizmet eden karşılaştırmalı bir ölçüdür. Daha yüksek bir F/K oranı piyasanın önemli bir büyüme beklediğini gösterirken, daha düşük bir F/K oranı şirketin gelecekteki beklentilerine ilişkin piyasa kötümserliğini gösterebilir.
- **Gelir Büyümesi:** Belirli bir zaman dilimi içinde şirketin gelirindeki artış oranını ölçer. Şirketin gelir yaratma kapasitesinin güvenilir bir göstergesi olarak hizmet eder ve şirketin performansını aynı sektörde

faaliyet gösteren diğer kuruluşlarla karşılaştırmak için etkin bir şekilde kullanılabilir.

- **Brüt Kâr Marjı:** Satılan malların maliyeti düşüldükten sonra kalan gelir yüzdesini hesaplar. Yatırımcılar ve paydaşlar brüt kâr marjını analiz ederek şirketin kâr elde etme ve üretim giderlerini kontrol etme kabiliyeti hakkında bir anlayış kazanabilirler.
- **Özkaynak Kârlılığı:** Bu ölçüt incelenerek, hissedarlar tarafından yapılan yatırımlarla ilişkili olarak şirketin kârlılığını etkin bir şekilde kıymetlendirilebilir. Bu analiz, şirketin kazanç elde etmek ve hissedarlarına değer yaratmak için kaynaklarını ve varlıklarını ne kadar verimli kullandığına dair değerli bilgiler sağlar.
- **Borç-Özkaynak Oranı:** Yüksek bir borç-özkaynak oranı, bir şirketin çok fazla borç aldığını ve bunu geri ödeyemeyebileceğini gösterebilirken, düşük bir borç-özkaynak oranı bir şirketin finansal olarak istikrarlı olduğunu gösterebilir.

Bu şirket göstergelerine ek olarak, yatırımcılar ve analistler bir şirketin finansal performansı hakkında kapsamlı bir görüş elde etmek için nakit akışı, işletme marjları ve likidite oranları gibi diğer finansal ölçütlere de bakarlar.

1.4.4. Teknik İndikatörler

Teknik göstergeler, finansal piyasalarda analiz için içgörü ve sinyaller sağlamak üzere bir menkul kıymetin veya sözleşmenin fiyatından, hacminden yararlanılan matematiksel hesaplamaları kapsar. Bu hesaplamalar alım veya satım sinyallerini belirlemek ve alım satım sinyalleri oluşturmak için kullanılır (Nison, 1991). Teknik göstergeler hisse senetleri, tahviller, emtialar ve para birimleri de dahil olmak üzere her türlü finansal piyasada kullanılabilir.

Teknik göstergelerin amacı, yatırımcılara potansiyel trendler, destek ve direnç seviyeleri ve genel piyasa momentumu dahil olmak üzere piyasanın daha net bir resmini sunmaktır (Murphy, 1999). Teknik göstergelerin kullanımı sayesinde yatırımcılar, en uygun giriş ve çıkış noktalarını ayırt etme ve mevcut trendlerin

gücünü değerlendirme becerisi kazanır. Bu önemli bilgiler, yatırımcıların pozisyonlara girme veya pozisyonlardan çıkma zamanlamasına ilişkin iyi bilgilendirilmiş kararlar almalarını ve risklerini etkin bir şekilde yönetmelerini sağlar.

Özellikle teknik göstergeler arasında mum çubukları önemli bir yere sahiptir. Bu grafiksel gösterimler gün, hafta ya da ay gibi belirli bir zaman dilimi için en yüksek, en düşük, açılış ve kapanış değerlerini göstererek fiyat hareketlerini canlı bir şekilde tasvir eder (Nison, 1991). Mum çubukları, piyasa duyarlılığı ve davranışının görsel bir tasvirini sunarak mevcut piyasa dinamiklerinin daha iyi anlaşılmasını sağladığından yatırımcılar için son derece değerlidir. Örneğin, uzun kırmızı bir mum çubuğu o dönemde önemli bir satış baskısı olduğunu gösterirken, uzun yeşil bir mum çubuğu önemli bir alım baskısı olduğunu gösterebilir.

Mum çubukları daha doğru sinyaller üretmek için diğer teknik göstergelerle birlikte kullanılabilir. Örneğin, bir yatırımcı piyasanın genel eğilimini belirlemek için hareketli ortalamaları mum çubuklarıyla birlikte kullanabilir. Hareketli ortalama yukarı doğru işaret ediyorsa, yatırımcı trendi doğrulamak ve bir alım kararı vermek için yükseliş mum çubuklarını arayabilir. Benzer şekilde, hareketli ortalama aşağıya doğru işaret ediyorsa, yatırımcı trendi teyit etmek ve satış kararı vermek için düşüş mum çubukları arayabilir (Nison, 1991).

Bir diğer önemli gösterge kullanımı da potansiyel destek ve direnç seviyelerini belirlemektir. Destek seviyeleri, piyasanın sürekli olarak alım ilgisi bulduğu fiyatlardır; direnç seviyeleri ise piyasanın sürekli olarak satış baskısı bulduğu fiyatlardır (Murphy, 1999). Yatırımcılar bu seviyeleri belirlemek için teknik göstergeleri kullanabilir ve bu göstergeler daha sonra potansiyel giriş ve çıkış noktalarını belirlemek için kullanılabilir. Örneğin, piyasa bir destek seviyesine yaklaşıyorsa, yatırımcı piyasanın destek seviyesinden sıçrayacağını teyit etmek için yükseliş mum çubukları arayabilir. Piyasa bir direnç seviyesine yaklaşıyorsa, tüccar piyasanın direnç seviyesi tarafından itilebileceğini teyit etmek için düşüş mum çubukları arayabilir.

1.4.5. Duyarlılık Göstergeleri

Yatırımda duyarlılık göstergeleri, yatırımcılar tarafından piyasanın veya belirli hisse senetlerinin genel ruh halini ölçmek için kullanılan araçları ve ölçümleri ifade eder. Bu göstergeler yatırımcıların piyasa katılımcılarının görüşlerini, tutumlarını ve beklentilerini anlamalarına ve bu bilgileri bilinçli yatırım kararları almak için kullanmalarına yardımcı olur. Duyarlılık göstergeleri nicel ve nitel olarak iki kategoride sınıflandırılabilir.

Kantitatif duyarlılık göstergeleri piyasa duyarlılığını ölçmek için sayısal veriler ve istatistiksel yöntemler kullanır. En yaygın kullanılan nicel duyarlılık göstergelerinden biri Put-Call Oranı(Put-Call Ratio-PCR)dır. PCR, alım opsiyonlarına kıyasla işlem gören satım opsiyonlarının sayısının bir ölçüsüdür. Yüksek PCR düşüş eğilimini, düşük PCR ise yükseliş eğilimini gösterir (Bodie, Kane ve Marcus, 2014). Yaygın olarak kullanılan bir diğer kantitatif duyarlılık göstergesi, önümüzdeki 30 gün içinde S&P 500 endeksinin beklenen volatilitesi ölçen Volatilite Endeksi(VIX)'dir. Yüksek bir VIX yatırımcı korkusunun ve belirsizliğinin arttığını gösterirken, düşük bir VIX daha kendinden emin ve iyimser bir görünüme işaret eder (Bodie vd., 2014).

Niteliksel duyarlılık göstergeleri piyasa duyarlılığını ölçmek için haber makaleleri, analist raporları ve sosyal medya gibi sayısal olmayan verileri kullanır. Popüler bir nitel duyarlılık göstergesi, finansal haber makalelerinin hacmini ve tonunu ölçen Buzz Endeksidir. Yüksek bir Buzz Endeksi piyasa ilgisinin arttığını gösterirken, düşük bir Buzz Endeksi daha sessiz bir tepkiye işaret eder (Bodie vd., 2014). Bir diğer niteliksel duyarlılık göstergesi, belirli bir hisse senedi veya piyasa için yükseliş ve düşüş yönündeki analist tavsiyelerinin sayısını ölçen Boğa/Ayı Oranıdır. Yüksek bir Boğa/Ayı Oranı yükseliş eğilimine, düşük bir oran ise düşüş eğilimine işaret eder (Bodie vd., 2014).

Duyarlılık göstergelerinin yatırım kararları için bağımsız araçlar olarak kullanılmaması gerektiğine dikkat etmek önemlidir. Bunun yerine, diğer temel ve teknik analiz araçlarıyla birlikte kullanılmalıdırlar. Duyarlılık göstergeleri genellikle öncü göstergeler olarak kabul edilir, yani gelecekteki piyasa hareketleri hakkında

fikir verebilirler. Ancak, duyarlılık ekonomik veri açıklamaları ve jeopolitik olaylar gibi çeşitli faktörlerden etkilenebilir ve hızla değişebilir, bu da duyarlılık göstergelerine tek bir yatırım bilgisi kaynağı olarak güvenmeyi zorlaştırır (Bodie vd., 2014).

1.5. Yatırım Kararlarında Yeni Yöntemler

1.5.1. Blockchain Teknolojisinin Kullanımı

Blockchain teknolojisi, verileri saklama, aktarma ve yönetme şeklimizde devrim yaratarak onu yatırım dünyasında potansiyel bir oyun değiştirici haline getirdi. Blockchain'in şeffaflık, güvenlik ve değişmezlik sağlama yeteneği, onu yatırım kararları almak için değerli bir araç haline getirmektedir.

Yatırım kararlarında blok zinciri teknolojisinin kullanımı nispeten yenidir ve hala gelişimin erken aşamalarında. Bununla birlikte, yatırımların yapıma şeklini dönüştürmek için muazzam bir potansiyele sahiptir. Yatırım kararlarında blok zincirinin en önemli faydalarından biri, doğru ve güncel olan gerçek zamanlı bilgi sağlama yeteneğidir. Bu önemlidir çünkü yatırım kararları genellikle güncel olmayan veya güvenilir verilerle dayanmaktadır. Blok zinciri sayesinde yatırımcılar şirketler, piyasa trendleri ve ekonomik koşullar hakkında doğru ve güncel bilgilere erişebilir ve bu da daha iyi yatırım kararları almalarına yardımcı olabilir (Kshetri, 2019).

Blok zinciri teknolojisi, dolandırıcılık ve bilgisayar korsanlığı riskini azaltarak yatırım kararlarında ek bir fayda sağlar. Blok zincirinin merkezi olmayan yapısı, verilerin birden fazla düğümde depolanmasını sağlayarak bilgisayar korsanlarının bilgileri manipüle etmesini veya çalmasını çok daha zor hale getirir. Yatırım verilerinin bu gelişmiş güvenliği, dolandırıcılık ve siber saldırı riskini azaltmaya yardımcı olarak yatırımcılara daha fazla koruma sağlar (Jappelli & Pagano, 2018).

Blok zinciri teknolojisini yatırım kararlarına dahil ederek işlem maliyetlerinde azalma potansiyeli vardır. İşlemleri doğrulamak için bankalar, borsalar ve finans kurumları gibi aracılara dayanan geleneksel yatırım süreçlerinin aksine, blok zinciri teknolojisi merkezi olmayan doğrulamaya izin verir. Sonuç olarak, aracılara duyulan ihtiyaç azalır, bu da yatırım işlemleriyle ilişkili ücretlerin ve genel olarak maliyetlerin düşmesine yol açar (Schwerdt & Whelan, 2018).

Bu teknoloji, şeffaflığı artırma kabiliyeti sayesinde yatırım kararlarında ek bir avantaj sağlamaktadır. Blok zincirinin merkezi olmayan yapısı, tüm işlemlerin kamuya açık olmasını sağlayarak yatırımcıların yatırımlarını takip etmelerini ve şirketlerin ve piyasaların performansını daha etkin bir şekilde değerlendirmelerini kolaylaştırır. Bu artan şeffaflık, yatırımcılar ve yatırım yaptıkları şirketler arasındaki güveni artırırken, dolandırıcılık faaliyetlerine karşı da caydırıcı bir rol oynamaktadır (Ellinger & Ellinger, 2019).

Tokenizasyon, yatırım kararlarında blockchain teknolojisinin en umut verici uygulamalarından biri olarak ortaya çıkmaktadır. Gayrimenkul, sanat eseri veya hisse senedi gibi çeşitli varlıkların blok zinciri platformlarında alınıp satılabilen dijital tokenlara dönüştürülmesini içerir. Tokenizasyon, bireylerin daha geniş bir varlık yelpazesine yatırım yapma sürecini basitleştirerek ve bu varlıkların daha kolay ve daha verimli ticaretini kolaylaştırarak yatırımı demokratikleştirme potansiyeline sahiptir. Bu dönüştürücü potansiyel, daha fazla bireyin yatırım dünyasına girmesini sağlayarak yatırım sektörünü önemli ölçüde etkileyebilir (Böhme & Christin, 2016).

1.5.2. Yatırım Kararlarında Yapay Zeka ve Makine Öğreniminin Kullanımı

Yapay Zeka ve Makine Öğreniminin ortaya çıkışı, yatırım kararı verme alanında dönüştürücü bir değişimi beraberinde getirmiştir. Yapay zeka, insan zekasının makinelerde kopyalanmasını gerektirirken, makine öğrenimi, bilgisayarların kalıpları tanımlama, karar verme ve doğal dili işleme gibi geleneksel olarak insan zekası gerektiren görevleri yerine getirmesini sağlamak için algoritmalar ve istatistiksel modellerden yararlanır. Bu teknolojiler yatırım

sektöründe kayda değer bir büyüme yaşatmış, finansal veri analizi ve karar verme metodolojilerinde derin bir dönüşüme yol açmıştır.

Gelişmiş hesaplama tekniklerinin uygulanması, özellikle algoritmik ticaretin benimsenmesi yoluyla yatırım karar verme sürecini önemli ölçüde dönüştürmüştür. Bu yaklaşım, piyasa verilerini analiz etmek, tahminler oluşturmak ve alım satımları gerçekleştirmek için bilgisayar algoritmalarını kullanır. Algoritmik alım satım, büyük miktarda piyasa verisini hızlı bir şekilde işleme, iyi bilgilendirilmiş kararlar alma ve insan yeteneklerini aşan hızlarda alım satım gerçekleştirme yeteneği nedeniyle son yıllarda önemli ölçüde popülerlik kazanmıştır. Dahası, algoritmik ticaret, yatırımcıların sıklıkla etkileyen duygusal önyargıların ve psikolojik faktörlerin etkisini azaltmaktadır. Sonuç olarak, büyük finans kurumları ve hedge fonlar için tercih edilen bir araç haline gelmiş ve zamanında ve bilinçli yatırım kararları almalarını sağlamıştır (Bagehot, 2018).

Bir başka kullanma yolu da tahmine dayalı analitiktir. Tahmine dayalı analitik, gelecekteki sonuçları tahmin etmek için geçmiş verileri, makine öğrenimi algoritmalarını ve istatistiksel modelleri kullanır. Tahmine dayalı analitik, hisse senedi fiyatları, kazanç raporları ve piyasa eğilimleri gibi yatırım performansının çeşitli yönlerini analiz etmek için kullanılabilir. Bu, yatırım yöneticilerinin risk yönetimi ve varlık tahsisi hakkında bilinçli kararlar almasını sağlar (Vlachos & Koutmos, 2019).

Makine öğrenimi algoritmaları, büyük miktarda piyasa verisini analiz ederek ve kalıpları belirleyerek, yatırım yöneticilerine maksimum getiri ve minimum risk için optimize edilmiş portföyler oluşturmada yardımcı olabilir. Bu, portföylerini daha etkili bir şekilde yönetmelerini, kaynaklarını daha verimli bir şekilde tahsis etmelerini ve daha iyi yatırım kararları almalarını sağladığı için özellikle büyük kurumsal yatırımcılar için yararlıdır (Brunel, 2019).

Yatırım kararlarında uygulandığı bir diğer alan da robo-danışmanlar alanıdır. Robo-danışmanlar, yatırım tavsiyesi sağlamak ve portföyleri yönetmek için yapay zeka algoritmalarını kullanan çevrimiçi yatırım yönetimi hizmetleridir. Bu hizmetler yatırımcılara risk toleranslarına, hedeflerine ve yatırım zaman ufuklarına göre

kişiselleştirilmiş yatırım önerileri sunabilir. Ayrıca, geleneksel yatırım araçları ile mümkün olmayan bir özelleştirme ve esneklik düzeyi sağlayarak portföyleri sürekli olarak izleme ve ayarlama yeteneğine de sahiptirler (Stein, 2019).

İKİNCİ BÖLÜM

ELLIOTT DALGA TEORİSİ

Elliott Dalga Kavramı, finans ve borsa ticareti alanlarında devamlı olarak kullanılır ve insan psikolojisine dayanmaktadır. Ralph Nelson Elliott tarafından borsa fiyatlarının tekrarlayan kalıplar halinde hareket ettiği fikrine dayanmaktadır. Teori, bu kalıpların gelecekteki piyasa hareketlerini tahmin etmek ve yatırım fırsatları sağlamak için kullanılabileceğini öne sürmektedir.

Elliott, borsanın döngüler halinde işlediğine ve bu döngülerin yatırımcı psikolojisinden kaynaklandığına inanıyordu. Piyasada dürtü dalgaları olarak adlandırdığı beş dalga ve düzeltici dalgalar olarak adlandırdığı üç düzeltici dalga tanımlamıştır. Beş dürtü dalgası 1, 2, 3, 4 ve 5 olarak, üç düzeltici dalga ise A, B ve C olarak etiketlenmiştir. Elliott'un teorisi, piyasanın ana trend yönünde beş dalga ve ardından ters yönde üç dalga halinde hareket ettiğini öne sürmektedir.

Elliott'a göre, yükseliş piyasasındaki ilk dalga 1. dalga olarak adlandırılır ve yatırımcılar arasında bir iyimserlik dalgasını temsil eder. İkinci dalga, dalga 2, bir

düzeltilmez ve yatırımcılar arasında bir ihtiyat dalgasını temsil eder. Üçüncü dalga, dalga 3, en güçlü dalgadır ve yatırımcılar arasında bir heyecan dalgasını temsil eder. Dördüncü dalga olan 4. dalga bir düzeltilmez ve yatırımcılar arasında bir kafa karışıklığı dalgasını temsil eder. Beşinci dalga, dalga 5, son dalgadır ve yatırımcılar arasında bir kötümserlik dalgasını temsil eder.

Elliott Dalga Konseptinde üç düzeltici dalga da önemlidir. İlk düzeltici dalga olan A dalgası, ilk dalganın geri çekilmesidir ve yatırımcılar arasında bir şüphe dalgasını temsil eder. İkinci düzeltici dalga olan B dalgası bir düzeltilmez ve yatırımcılar arasında bir umut dalgasını temsil eder. Üçüncü düzeltici dalga olan C dalgası son dalgadır ve yatırımcılar arasında bir umutsuzluk dalgasını temsil eder.

Elliott'un teorisi geniş çapta incelenmiş ve çok sayıda kitap ve makaleye konu olmuştur. "The Wave Principle" (Elliott, 1938) adlı kitabında yazar, kavramı detaylı bir şekilde özetlemekte ve dalga teorisinin borsa yatırımlarına nasıl uygulanabileceğine dair çok sayıda örnek sunmaktadır. "Mastering Elliott Wave: Neely Yöntemini Sunmak" (Prechter & Frost, 2002) adlı kitapta yazarlar Elliott Dalga Kavramının daha modern bir yorumunu sunmakta ve teorisinin borsayı analiz etmek için nasıl kullanılabileceğini göstermektedir.

2.1. Elliott Dalga Teorisinin Tarihi ve Gelişimi

Elliott Dalga Teorisi, 1920'lerin sonunda Ralph Nelson Elliott tarafından geliştirilen bir piyasa analizi yöntemidir. Teori, Elliott'un insan davranışını yöneten doğal yasalara atfettiği, piyasa fiyatlarının genellikle öngörülebilir kalıplar içinde hareket ettiği gözlemine dayanmaktadır. Elliott, piyasa katılımcılarının tekrarlayan davranışlarının piyasada, okyanustaki dalgaların hareketi gibi diğer doğal olaylarda gözlemlenen kalıplara benzer kalıplar yarattığına inanıyordu. Bu kalıplara "Elliott dalgaları" adını verdi.

Elliott'un teoriyle ilgili orijinal çalışması 1930'lu ve 1940'lı yıllarda bir dizi makale halinde yayınlanmış ve daha sonra "Dalga Prensipleri" (Elliott, 1938) adlı bir kitapta derlenmiştir. Bu çalışmada Elliott, Elliott dalgalarının temel yapısını

tanımlamış ve dalgaların tanımlanması ve sayılması için kılavuz ilkeler sunmuştur. Ayrıca, çeşitli dalga türlerini ve aralarındaki ilişkileri, desenlerin fraktal doğası ve desenlerin kısa vadeden uzun vadeye kadar tüm piyasa faaliyeti seviyelerinde bulunabileceği gerçeğini de tanımladı.

Elliott Dalga Teorisi, başlangıcından bu yana bir dizi analist ve yatırımcı tarafından daha da geliştirilmiştir. Teorinin gelişimine en önemli katkılardan biri, teoriyi popülerleştiren ve konuyla ilgili "Elliott Dalga Prensipleri" (Prechter & Frost, 2002) dahil olmak üzere birkaç kitap yazan Robert Prechter tarafından yapılmıştır. Prechter'in çalışmaları Elliott'un orijinal fikirlerini genişletmiş ve Elliott Dalga Teorisini kullanarak piyasa davranışını analiz etmek için kapsamlı bir çerçeve sağlamıştır.

2.2. Elliott Dalga Türleri

2.2.1. Dörtü Dalgaları

Dörtü dalgaları Elliott Dalga Teorisinin önemli bir bileşenidir. Teoriye göre, dörtü dalgaları bir piyasa hareketindeki ilk beş dalgadır ve genel trend yönünde hareket eder. Piyasa hareketlerinin arkasındaki itici gücü temsil ettikleri için "dörtü dalgaları" olarak adlandırılırlar.

Her bir dörtü dalgası, her biri 1, 2, 3, 4 ve 5 olarak numaralandırılan beş alt dalgadan oluşur. İlk dalga olan dalga 1, trend yönündeki ilk harekettir ve bunu dalga 2'deki bir düzeltme izler. Dalga 3, impuls dalgasındaki en güçlü ve en uzun dalgadır ve genellikle yatırımcıların piyasaya girdiği yerdir. 4. ve 5. dalgalar dörtü dalgasını tamamlar ve trendin son aşamalarını temsil eder.

Dörtü dalgası, borsa, emtia piyasası ve döviz piyasasındaki yatırımcılar için önemli bir araçtır. Yatırımcılar dörtü dalgasını tanımlayarak mevcut piyasa trendini belirleyebilir, bilinçli alım satım kararları alabilir ve gelecekteki piyasa hareketlerini tahmin edebilir. Ayrıca dörtü dalgası, temel piyasa seviyelerini ve hedef fiyatları

belirlemek için kullanılabilir ve yatırımcıların piyasa hareketlerinden yararlanmasına ve kârı maksimize etmesine olanak tanır.

Bir Dürtü dalgasının tanımlanmasının Elliott Dalga Teorisi konusunda yüksek düzeyde uzmanlık ve deneyim gerektirdiğine dikkat etmek önemlidir. Bunun nedeni dalga formasyonunun öznel olabilmesi ve birden fazla yoruma tabi tutulabilmesidir. Bu nedenle, yatırımcıların dürtü dalgasının kullanımı konusunda profesyonel rehberlik ve eğitim almaları önemlidir.

2.2.2. Düzeltici Dalgalar

Düzeltici dalgalar, dürtü dalgalarının tersi olan ve Elliott dalga analizinde kullanılan fiyat hareketleridir. Frost ve Prechter'e (2002) göre düzeltici dalgalar basit ve karmaşık olmak üzere ikiye ayrılır. Basit düzeltici dalgalar üç alt dalgadan oluşurken, karmaşık düzeltici dalgalar üçten fazla alt dalgadan oluşur ve daha fazla zaman alır.

Basit düzeltici dalgalar üç alt dalgadan oluşur ve ayrıca üç türe ayrılır: zikzak, düz ve üçgen. Zikzak 5-3-5 formasyonudur; burada A alt dalgası beş dalgalı bir hareket, B alt dalgası üç dalgalı bir düzeltme ve C alt dalgası başka bir beş dalgalı harekettir. Düz düzeltmeler zikzaklara benzer ancak daha sık bir eğime sahiptir ve 3-3-5 formasyonu olarak etiketlenir. Üçgenler 3-3-3-3-3 formasyonu olarak etiketlenir ve yakınsayan trend çizgileriyle karakterize edilir (Frost & Prechter, 2002).

Karmaşık düzeltici dalgalar daha fazla zaman alır ve üçten fazla alt dalgadan oluşur. Basit düzeltici dalgaların kombinasyonlarından oluşurlar ve ayrıca üç tipte sınıflandırılırlar: çift zigzag, çift düz ve koşan üçgen. Çift zikzaklar iki zikzak düzeltmenin birleşimidir. Çift düzlükler iki düz düzeltmenin birleşimidir ve koşan üçgenler iki ya da daha fazla üçgen düzeltmesinin birleşimidir (Frost & Prechter, 2002).

Düzeltilici dalgalar, yatırımcıların piyasanın potansiyel yönünü belirlemelerine yardımcı oldukları için Elliott dalga analizinde önemli unsurlardır. Düzeltilici dalgaların basit ve karmaşık olarak sınıflandırılması ve ayrıca farklı formasyonlara ayrılması, yatırımcılara mevcut trendi belirlemek ve bilinçli yatırım kararları almak için bir yol haritası sağlar.

Zikzak, düz veya üçgen gibi belirli bir düzeltilici dalga türünün tanımlanması, piyasanın gücü ve yönü hakkında değerli bilgiler sağlayabilir ve yatırımcıların bir işleme ne zaman gireceklerini veya işlemiden ne zaman çıkacaklarını belirlemelerine yardımcı olabilir. Örneğin, bir zikzak formasyonu tipik olarak bir yükseliş trendinde geçici bir düzeltmeye işaret ederken, düz bir formasyon bir konsolidasyon dönemine işaret edebilir.

2.3. Dürtüsel ve Düzeltilici Dalgaların Kombinasyonu

İtici ve düzeltilici dalgaların kombinasyonu bir trendin yönünü ve gücünü belirlemek için kullanılabilir. İtici dalgalar trendin yönünü gösterirken, düzeltilici dalgalar trendin gücü hakkında bilgi verir. Güçlü bir trend derin düzeltilici dalgalarla karakterize edilirken, zayıf bir trend sık düzeltilici dalgalarla karakterize edilir. Buna ek olarak, dürtüsel ve düzeltilici dalgaların örüntüsü alım satımlar için potansiyel giriş ve çıkış noktalarını belirlemek için kullanılabilir.

Örneğin, bir yükseliş trendi sırasında, yatırımcılar düzeltilici dalgalar sırasında piyasayı satın alma fırsatları arayabilir, çünkü bunlar genellikle trenddeki geçici duraklamaları temsil eder. Tersine, bir düşüş trendi sırasında, yatırımcılar itici dalgalar sırasında piyasayı satma fırsatları arayabilir, çünkü bunlar trendin ana yönünü temsil eder.

İtici ve düzeltilici dalga teorisinin bir diğer faydalı uygulaması da trend değişikliklerinin belirlenmesidir. Piyasa dürtüsel bir dalganın sonuna ulaştığında, bunu genellikle önceki trendin bir kısmını geri çeken düzeltilici bir dalga izler. Düzeltilici dalganın derin ve uzun süreli olması trendde bir değişiklik olduğunu gösterebilir. Bu gibi durumlarda, yatırımcılar mevcut pozisyonlarından çıkmayı ya da piyasada kısa pozisyon almayı tercih edebilir.

2.4. Elliott Dalga Analiz Teknikleri

2.4.1. Fraktal Analiz

Fraktal analiz, finans, fizik ve biyoloji dahil olmak üzere çeşitli alanlarda karmaşık örüntü ve yapıları incelemek için kullanılan matematiksel bir tekniktir. Fraktal analiz kavramı ilk olarak yirminci yüzyılın ortalarında Fransız matematikçi Benoît Mandelbrot tarafından ortaya atılmıştır (Mandelbrot, 1977).

Fraktal, farklı ölçeklerde kendini tekrar eden, kendine benzer bir örüntüdür. Bu, bir fraktalın bir kısmı büyütülürse aynı desenin ortaya çıkacağı anlamına gelir. Bu özellik, fraktalları hisse senedi fiyatları ve kıyı şeritleri gibi karmaşık, düzensiz sistemlerin modellenmesinde kullanışlı hale getirir (Mandelbrot, 1983).

Fraktal analizin en yaygın uygulamalarından biri finans alanındadır. Finans alanında fraktallar hisse senedi fiyatlarını ve diğer finansal araçları modellemek için kullanılabilir. Yatırımcılar hisse senedi fiyatlarındaki örüntüleri inceleyerek eğilimleri belirleyebilir ve gelecekteki fiyat hareketleri hakkında tahminlerde bulunabilirler (Baaquie, 2004). Örneğin, Mandelbrot ve Hudson (2004) hisse senedi fiyat hareketlerinin fraktal bir model izlediğini ve büyük fiyat değişikliklerinin geleneksel modellerin beklediğinden daha sık meydana geldiğini bulmuştur.

Fraktal analiz fizikte de kullanılabilir. Örneğin, türbülans da dahil olmak üzere akışkanların davranışını incelemek için kullanılmıştır (Frisch, 1995). Biyolojide fraktal analiz, insan vücudundaki kan damarlarının dallanma şekilleri gibi bitki ve hayvanların yapısını incelemek için kullanılmıştır (West, Brown, & Enquist, 1997).

Fraktal analiz, teknik analizde ve özellikle Elliott dalga analizinin uygulanmasında kullanılan güçlü bir araçtır. Elliott dalga analizi, fiyatların genellikle farklı zaman dilimlerinde tekrar eden kalıplar veya dalgalar halinde hareket ettiği gözlemine dayanan bir finansal piyasa trendlerini tahmin etme yöntemidir (Prechter & Frost, 2002). Elliott dalga analizinde fraktal analizin kullanılması, bu kalıpların

tanımlanmasına ve gelecekteki fiyat hareketlerinin en olası yönünün belirlenmesine yardımcı olur. Prechter ve Frost'a (2002) göre fraktallar hem doğal hem de insan yapımı sistemlerde bulunan kendine benzer modellerdir. Finansal piyasalarda fraktallar, tekrar eden fiyat hareketi modellerini belirlemek ve gelecekteki piyasa eğilimlerini tahmin etmek için kullanılabilir. Örneğin, haftalık bir grafikte bir fraktal desen tespit edilirse, aynı desenin günlük bir grafikte de oluşması beklenebilir. Bu, yatırımcıların bir işleme ne zaman girecekleri veya işlemiden ne zaman çıkacakları konusunda daha bilinçli kararlar vermelerini sağlar.

Bir fraktal analiz gerçekleştirmek için bir fraktal boyut hesaplanmalıdır. Fraktal boyut, bir örüntünün karmaşıklığının bir ölçüsünü sağlar ve daha yüksek boyutlar daha fazla karmaşıklığa işaret eder (Halsey, Jensen, Kadanoff, Palmer ve Shraiman, 1986). Fraktal boyutu hesaplamak için kutu sayma yöntemi ve korelasyon boyutu yöntemi de dahil olmak üzere çeşitli yöntemler bulunmaktadır (Grassberger & Procaccia, 1983).

Elliott dalga analizinde fraktallar, genellikle formasyondaki en uzun ve en güçlü dalga olan beş dalgalı bir formasyonun beşinci dalgasını tanımlamak için kullanılır. Yatırımcılar beşinci dalgayı belirlemek için fraktalları kullanarak trend yönünde bir işleme girebilir ve potansiyel kârlarını en üst düzeye çıkarabilirler. Bununla birlikte, fraktal analizin bağımsız bir ticaret stratejisi olmadığını unutmamak önemlidir. Aksine, piyasa tahminlerinin doğruluğunu artırmak için diğer teknik analiz araçları ve temel analiz ile birlikte kullanılmalıdır (Neely, 2004).

2.4.2. Fibonacci Düzeltme Analizi

Fibonacci geri çekilmesinin altında yatan öncül, fiyatların orijinal yöndeki yörüngelerine devam etmeden önce bir hareketin öngörülebilir bir kısmını geri çekme eğiliminde olduğu fikrine dayanmaktadır. Fibonacci geri çekilme seviyeleri, bir hisse senedinin fiyatındaki büyük bir tepe ve dip arasındaki geri çekilme yüzdesi hesaplanarak belirlenir. En yaygın kullanılan Fibonacci düzeltme seviyeleri %23,6, %38,2, %50, %61,8 ve %100'dür. 61,8 geri çekilme seviyesi en önemlisi olarak

kabul edilir ve "altın oran" olarak bilinir. Bunun nedeni, Fibonacci dizisindeki herhangi bir sayının bir sonraki en yüksek sayıya oranının %61,8'e yaklaşmasıdır.

Fibonacci geri çekilmesi, dalga geri çekilmeleri için potansiyel destek ve direnç seviyelerini belirleyerek Elliott Dalga teorisinde uygulanır. Fibonacci seviyelerini fiyat grafiğine çizerek ve dalga modelini belirleyerek, yatırımcılar varlığın potansiyel fiyat hareketleri hakkında tahminlerde bulunabilirler. Örneğin, beş dalgalı bir formasyonun 1. dalgası itici bir dalga ise, 2. dalganın %23,6, %38,2 veya %50 gibi Fibonacci geri çekilme seviyelerinden birine geri çekilmesi muhtemeldir (Elder, 2006).

Fibonacci geri çekilme seviyelerinin mutlak seviyeler olmadığını ve fiyatların bu seviyelerin ötesine geçebileceğini ve geçtiğini unutmamak önemlidir. Bununla birlikte, yatırımcılara potansiyel fiyat hareketi için bir yol haritası sağlarlar ve bir işleme ne zaman girileceği veya çıkılacağı konusunda bilinçli kararlar alınmasına yardımcı olabilirler. Ayrıca, Fibonacci düzeltmeleri potansiyel fiyat hareketlerini daha fazla teyit etmek için trend çizgileri, hareketli ortalamalar ve mum çubuğu formasyonları gibi diğer teknik analiz araçlarıyla birlikte kullanılabilir (Elder, 2006).

Popülerliğine rağmen Fibonacci düzeltme analizi bazı çevreler tarafından eleştirilmektedir. Bir argüman, tekniğin yüksek ve düşük noktaların belirlenmesinde analistin takdirine dayandığı için öznel olduğudur. Bir diğer eleştiri ise Fibonacci düzeltme seviyelerinin matematiksel bir formülden türetildiği ve bu formülün gerçek piyasa koşullarını tam olarak yansıtmayabileceği yönündedir. Bazıları da %61,8 geri çekilme seviyesine çok fazla önem verildiğini, çünkü bu seviyenin belirli piyasa koşullarında geçerli olmasa bile genellikle varsayılan bir seviye olarak kullanıldığını savunmuştur.

2.4.3. Elliott Dalga Osilatörü

Elliott Dalga Osilatörü(EWO), yatırımcılar tarafından finans piyasalarındaki fiyat hareketlerinin momentumunu belirlemek için kullanılan bir teknik analiz aracıdır. Osilatör, yatırımcıların trendin yönünü ve gücünü belirlemelerine ve

piyasadaki potansiyel dönüm noktalarını tespit etmelerine yardımcı olmak için tasarlanmıştır.

EWO, piyasa fiyatının iki hareketli ortalaması arasındaki farkı hesaplayarak yatırımcıların bu dalgaları tanımlamasına yardımcı olur. İlk hareketli ortalama tipik olarak daha kısa vadeli bir ortalama iken, ikinci hareketli ortalama daha uzun vadeli bir ortalama değildir. EWO daha sonra iki hareketli ortalama arasındaki farkı gösteren bir grafik üzerinde histogram olarak çizilir. Histogram piyasadaki trendleri belirlemek için kullanılabilir ve EWO'nun sıfır çizgisine göre konumu trendin yönünü belirlemek için kullanılabilir (Blau, 2013). EWO sıfır çizgisinin üzerinde olduğunda, piyasanın yükseliş trendinde olduğunu gösterir. Tersine, EWO sıfır çizgisinin altında olduğunda, piyasanın düşüş trendinde olduğunu gösterir. Trendleri belirlemenin yanı sıra, EWO potansiyel alım ve satım sinyallerini belirlemek için de kullanılabilir. Örneğin, EWO yükseliş trendindeyse ve sıfır çizgisinin üzerine çıkarsa, bu bir alım sinyali olarak yorumlanabilir. Tersine, EWO düşüş trendindeyse ve sıfır çizgisinin altından geçiyorsa, bu bir satış sinyali olarak yorumlanabilir (Blau, 2013).

EWO, trend çizgileri, destek ve direnç seviyeleri ve momentum göstergeleri gibi diğer teknik analiz araçlarıyla birlikte kullanılabilir. Örneğin, yatırımcılar trend değişikliklerini ve potansiyel giriş ve çıkış noktalarını belirlemek için EWO'yu trend çizgileriyle birlikte kullanabilir. Ayrıca, trendleri teyit etmek ve potansiyel giriş ve çıkış noktalarını belirlemek için EWO'yu Göreceli Güç Endeksi (RSI) gibi momentum göstergeleriyle birlikte kullanabilirler (Pring, 2002).

2.4.4. Ayırışmalar

Ayırışmalar, fiyat hareketinin yönünün teknik bir göstergenin yönüyle aynı hızda olmadığı bir durumu ifade eder. Aynı zamanda ayırışma fiyat hareketi bir yönde güçlü olsa da, arkasındaki momentumun aslında yavaşladığını gösterir ve bu da potansiyel bir trendin tersine dönmesinin bir uyarı işareti olarak kabul edebilir (Bollinger, 2017). Ayrıca mevcut düzeltmenin gelmekte olduğunu gösterebilirler. Bununla birlikte, ayırışmaya rağmen mevcut trendinde devam edebileceğinden ayırışmalar yanlış sinyaller de olabilir (Boroden, 2002).

Elliott Dalgalarında oluşan ayrışmalar piyasa analizinde karmaşıklıklar yaratabilir. Elliott Dalgaları bağlamında, ayrışmalar finansal piyasaların doğasında var olan öngörülemezliğin ve doğrusal olmamanın bir sonucu olarak görülebilir. İndikatör hareketi ve Elliott Dalga sayısı zıt yönlerde hareket ettiğinde bir ayrışma meydana gelir (Boroden, 2002). Bu, fiyat yeni dipler yaparken Elliott Dalga sayımının yeni zirveler yaptığı ya da tam tersi anlamına gelir. Ayrışmalar Elliott Dalgaların sayılmasında ve tespit olunmasında sıklıkla kullanılmaktadır. Elliott Dalgalarındaki ayrışmaları doğru bir şekilde yorumlamak için, daha büyük trendi göz önünde bulundurmak ve hareketli ortalamalar ve grafik formasyonları gibi diğer teknik analiz araçlarında teyit aramak önemlidir (Frost & Prechter, 2004). Ayrıca, yanlış sinyaller oluşabileceğinden, sabırlı olmak ve herhangi bir işlem yapmadan önce ayrışmanın gerçekleşmesini beklemek önemlidir.

Teknik analizde ayrışmaları tespit etmek için kullanılan en popüler göstergelerden biri hareketli ortalama yakınsama sapması göstergesi MACD (Moving Average Convergence Divergence)dir. MACD, 26 günlük üssel hareketli ortalamanın 12 günlük Üssel Hareketli Ortalama değeri EMA(Exponential Moving Average) 'dan çıkarılmasıyla hesaplanan bir momentum osilatörüdür (Murphy, 2016). MACD değeri, "sinyal çizgisi" olarak bilinen 9 günlük EMA değerinin üzerine çıktığında, fiyatın yükseleceğini gösteren bir yükseliş sinyali üretir. Öte yandan, MACD sinyal çizgisinin altına düştüğünde, fiyatın düşme olasılığının yüksek olduğunu gösteren bir düşüş sinyali üretir (Murphy, 2016).

Ayrışmaları tespit etmek için kullanılan bir diğer popüler gösterge de göreceli güç endeksi(RSI)dir. RSI, belirli bir zaman aralığındaki ortalama kazanç ve kayıplarını karşılaştırarak bir menkul kıymetin fiyat hareketinin gücünü ölçen bir momentum osilatörüdür(Wilder, 1978). RSI, belirli sayıda dönemdeki ortalama kazancın aynı dönemdeki ortalama kayba bölünmesi ve ardından sonucun bir orana dönüştürülmesiyle hesaplanır (Wilder, 1978). Bir menkul kıymetin fiyatı yeni düşükler yaparken RSI daha yüksek düşükler yaptığında yükseliş sapması meydana gelir, bu da satış momentumunun zayıfladığını ve potansiyel bir trendin tersine döndüğünü gösterir (Bollinger, 2017).

Ayrışmalar, stokastik osilatör ve hareketli ortalama gibi diğer teknik göstergelerin kullanımıyla da görülebilir. Örneğin, bir menkul kıymetin fiyatı yeni yüksekler yaparken stokastik osilatör daha düşük yüksekler yaptığında düşüş eğilimi görülebilir (Guppy, 2019). Bu senaryoda, trend daha az yükselişe geçmektedir ve potansiyel bir trendin tersine dönmesi söz konusudur. Benzer şekilde, bir menkul kıymetin fiyatı yeni düşükler yaparken hareketli ortalama daha yüksek düşükler yaptığında yükseliş sapması görülebilir (Bollinger, 2017).

2.5. Elliott Dalgaları İle İlgili Vaka Çalışmaları ve Gerçek Dünya Örnekleri

Elliott Dalga Teorisi 80 yılı aşkın bir geçmişe sahip olsa da, çeşitli piyasalarda ve enstrümanlarda uygulanmasına ilişkin birçok gerçek dünya örneği ile popüler olmaya ve yaygın olarak kullanılmaya devam etmektedir. Bu bölümde Elliott Dalgaları'nın en önemli vaka çalışmalarından ve gerçek dünyadaki örneklerinden bazılarına yer verilmiştir.

Elliott Dalgaları Teorisi'nin en iyi bilinen örneklerinden biri 2008 finansal krizidir. Elliott Dalga analistlerine göre, kriz beş dalgalı formasyonun açık bir örneği olarak gösterilmiştir; üçüncü dalga en uzun ve en güçlü dalga, bunu izleyen dördüncü dalgada keskin bir düzeltme ve beşinci dalgada son bir aşağı hareket izlemiştir. A.J. Frost ve Robert R. Prechter Jr. "The Elliott Wave Principle: Key to Market Behavior" adlı kitabında "2008 finansal krizinin Elliott dalga analizinin bir ders kitabı örneği olduğunu ve teoremin gücünü ve doğruluğunu teyit ettiğini" ifade etmiştir (Frost & Prechter, 2008, s. xi).

Elliott Dalgalarının bir diğer iyi bilinen örneği de 1990'ların sonundaki teknoloji balonudur. Balonun son dalgası en uzun ve en güçlü dalgaydı ve dot-com balonunun nihai çöküşüne yol açtı. "Elliott Dalga Prensipleri" adlı kitaplarında: Eleştirel Bir Değerlendirme" adlı kitaplarında James Frederick Erickson ve Arne E. Carlsen, "Elliott Dalga analizinin 1990'ların sonu ve 2000'lerin başındaki dot-com patlaması ve çöküşü sırasında büyüme ve düşüş modelini anlamada değerli bir araç olduğunu kanıtladığını" yazmaktadır (Erickson & Carlsen, 2014, s. 97).

EUR/USD forex paritesi Elliott Dalga analizi için bir başka popüler araçtır ve birçok analist bu teoriyi paritenin fiyat hareketleri hakkında başarılı tahminler yapmak için kullanmıştır. Steven Poser, "The Complete Guide to the Elliott Wave Principle" adlı kitabında "Elliott Dalga analizinin birçok tüccar tarafından EUR/USD döviz çiftinin gelecekteki hareketlerini tahmin etmek için etkili bir şekilde kullanıldığını" yazmaktadır (Poser, 2013, s. 75).

Elliott Dalga analizi alanında, S&P 500 endeksi yaygın olarak kullanılan bir araç olarak önemli bir öneme sahiptir. Analistler endeksin gelecekteki seyrini tahmin etmek için bu teoriyi yoğun bir şekilde kullanmaktadır. "Elliott Waves, Fibonacci, and Chart Pattern Trading Tools: A Synthesis of Classic Trading Techniques" adlı kitabında Brian J. Shannon, S&P 500 endeksinin gelecekteki yönü hakkında tahminlerde bulunmada Elliott Dalgaları analizinin etkinliğini ileri sürmektedir (Shannon, 2014, s. 123).

Elliott Dalgaları analizi altın piyasasını analiz etmek için yaygın olarak kullanılmakta, metalin fiyat hareketleri hakkında tahminler yapılmasına ve önemli destek ve direnç seviyelerinin belirlenmesine olanak sağlamaktadır. Robert R. Prechter Jr. "The Wave Principle of Human Social Behavior and the New Science of Socionomics" adlı kitabında Elliott Dalgaları analizinin altın piyasasının gelecekteki yönünü tahmin etmedeki ve önemli destek ve direnç seviyelerini belirlemedeki etkinliğini vurgulamaktadır (Prechter, 2002, s. 123).

Son olarak, ham petrol piyasası da Elliott Dalga analizi için popüler bir konudur ve teori, emtianın fiyat hareketleri hakkında tahminlerde bulunmak ve kilit destek ve direnç seviyelerini belirlemek için kullanılabilir. Jeremy Wagner "Elliott Waves for Short-Term Trading" adlı kitabında "Elliott Dalgaları analizinin ham petrol fiyatlarının gelecekteki hareketleri hakkında tahminlerde bulunmak isteyen yatırımcılar için değerli bir araç olabileceğini" belirtmiştir (Wagner, 2015, s. 99).

Bunlar Elliott Dalgaları Teorisi'nin birçok gerçek dünya uygulamasından sadece birkaç örnektir. Teori, çeşitli piyasalarda ve araçlarda kullanılmış ve bilinçli yatırım kararları almak isteyen tüccarlar ve yatırımcılar için değerli bir araç olduğu gösterilmiştir. Elliott Dalgaları'nın birçok teknik analiz aracından yalnızca biri

olduğunu belirtmek önemli olmakla birlikte, devam eden popülaritesi ve yaygın kullanımı, kalıpları belirleme ve finansal piyasalar hakkında tahminlerde bulunma konusundaki etkinliğinin bir kanıtıdır.

2.6. Elliott Dalga Teorisini Kullanmanın Sınırlamaları ve Eleştirileri

Gerçekten de, yaygın popülaritesine rağmen Elliott Dalga Teorisi'nin uygulanması sınırlamalardan ve eleştirilerden muaf değildir. Başlıca dezavantajlarından biri, yorumlanmasıyla bağlantılı olan öznellikte yatmaktadır. Teori, piyasa fiyatlarında tekrar eden kalıpların gözlemlenmesine dayanırken, bu kalıpların yorumlanmasının öznel doğası genellikle aynı verilerin farklı görüş ve yorumlarıyla sonuçlanır (Frost & Prechter, 2002). Bu durum tutarsız dalga sayımlarına yol açabilir ve teoriyi kullananlar için kafa karışıklığı yaratabilir. Bir diğer kısıtlaması da dalga sayısını belirlemek için net bir çerçeveye sahip olmamasıdır. Bir formasyonu oluşturan dalgaların tam sayısını belirlemek için belirlenmiş bir kural yoktur ve bu durum birden fazla yoruma yol açarak dalga sayısının doğrulanmasını zorlaştırabilir (Prechter & Frost, 1999). Bu da teorinin güvenilir bir alım satım aracı olarak kullanılmasını zorlaştırabilir.

Elliott Dalga Teorisi'ni eleştirenler ayrıca teorinin ampirik verilere ya da bilimsel ilkelere dayanmadığına dikkat çekmektedir. Teori öznel gözlemlere dayalı olarak geliştirilmiştir ve doğruluğunu belirlemek için titiz bilimsel yöntemlerle test edilmemiştir (Shiller, 2000). Bu durum Elliott Dalga Teorisi'nin güvenilir bir tahmin aracı olarak kullanılmasını zorlaştırmaktadır. Buna ek olarak, Elliott Dalga Teorisi piyasaların önceden belirlenmiş bir model izlediğini varsayar, ancak durum her zaman böyle değildir. Borsa, ekonomik göstergeler, siyasi olaylar ve insan duyguları da dahil olmak üzere bir dizi faktörden etkilenir ve bu da öngörülen dalga modelinden sapmasına neden olabilir (Shiller, 2000). Bu durum yanlış tahminlere yol açabilir ve yatırımcılar için Elliott Dalga Teorisi kullanımını sorunlu hale getirebilir. Elliott Dalga Teorisi borsada içeriden öğrenilen bilgilerin ve piyasa manipülasyonunun rolünü dikkate almaz. Bu faktörler bir menkul kıymetin fiyatını önemli ölçüde etkileyebilir, ancak teori tahminlerinde bunların etkisini hesaba

katmaz (Shiller, 2000). Bu durum yanlış tahminlere yol açabilir ve alım satım kararları almak için teoriyi kullananlar için sorun yaratabilir.



ÜÇÜNCÜ BÖLÜM

DERİN ÖĞRENME İLE NESNE ALGILAMA

Nesne algılama, bir görüntü veya video içindeki nesneleri tanımlamayı ve konumlandırmayı içeren bir bilgisayarla görme tekniğidir. Otonom araçlar, güvenlik ve gözetim, robotik ve artırılmış gerçeklik dahil olmak üzere çok çeşitli uygulamalar için kritik bir görevdir. Derin öğrenme, nesne algılamada devrim yaratarak görüntü ve videolardaki nesnelerin daha doğru ve verimli bir şekilde algılanmasını sağlamıştır.

Derin öğrenme ile nesne tespitinin nispeten kısa ama etkili bir geçmişi vardır. 2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton, görüntü

sınıflandırma doğruluğunda önemli bir gelişme sağlayan derin bir evrişimli sinir ağı olan AlexNet'i tanıttı. Bu buluş, nesne algılama için olanlar da dahil olmak üzere diğer birçok derin öğrenme modelinin geliştirilmesini tetikledi. 2014 yılında Ross Girshick, nesne tespitinde son teknoloji ürünü sonuçlar elde eden ilk derin öğrenme modeli olan R-CNN'yi önerdi.

Derin öğrenme ile nesne tespitinin amacı, görüntü ve videolardaki nesneleri doğru bir şekilde tanımlamak ve konumlandırmaktır. Bu görev iki alt görev içerir: nesne sınıflandırma ve nesne lokalizasyonu. Nesne sınıflandırma, görüntüdeki nesnenin türünü (örneğin, araba, yaya, trafik işareti) tanımlamayı içerirken, nesne yerelleştirme, görüntüdeki konumunu belirtmek için nesnenin etrafına bir sınırlayıcı kutu çizmeyi içerir. Nesne tespitine yönelik derin öğrenme modelleri, giriş verilerindeki örüntüleri tanımayı öğrenerek bu hedefe ulaşır. Bu modeller, her bir görüntünün mevcut nesneleri ve konumlarını belirten ek açıklamalara sahip olduğu etiketli görüntülerden oluşan büyük veri kümeleri üzerinde eğitilir. Eğitim sırasında model, nesne tespiti için en uygun özellikleri tanımlamayı öğrenir ve bu özellikleri yeni görüntülerdeki nesneleri sınıflandırmak ve konumlandırmak için kullanır.

Araştırma alanlarından biri, düşük güçlü cihazlarda gerçek zamanlı nesne tespiti yapabilen daha verimli modellerin geliştirilmesidir. Bu, hızlı ve doğru nesne tespitinin güvenli ve verimli çalışma için kritik önem taşıdığı robotik ve otonom araçlar gibi uygulamalar için önemlidir. Bir başka araştırma alanı da karmaşık ve dağınık sahnelerdeki nesneleri tespit edebilen modellerin geliştirilmesidir. Bu zorlu bir görevdir çünkü nesneler kısmen örtülü olabilir veya alışılmadık yönlerde görünebilir. Araştırmacılar bu senaryolarda nesne tespitini iyileştirmek için dikkat mekanizmaları ve bağlamsal muhakeme gibi yeni teknikler araştırmaktadır. Derin öğrenme gelişmeye devam ettikçe, nesne algılamanın birçok farklı sektör ve uygulamada giderek daha önemli bir rol oynadığını görmeyi bekleyebiliriz.

3.1. Derin Öğrenme Kavramı

Makine öğreniminin bir alt alanı olan derin öğrenme, sinir ağlarının hiyerarşik katmanlarını kullanarak veri temsillerini elde etmek için özel olarak tasarlanmıştır. Bu yaklaşım, insan beyninin karmaşık yapısından ve işlevselliğinden ilham alır. Derin öğrenmenin bilgisayarla görme, doğal dil işleme ve konuşma tanıma gibi çeşitli uygulamalardaki kayda değer başarısı, bu alanlarda geniş çapta benimsenmesine ve kullanılmasına neden olmuştur.

Derin öğrenmenin kökleri, başlangıçta beyindeki biyolojik nöronlardan esinlenen yapay sinir ağlarının 1950'lerde ve 1960'larda geliştirilmesine dayanmaktadır (Goodfellow, Bengio ve Courville, 2016). Bununla birlikte, ilk YSA'lar sığ mimarileriyle sınırlıydı ve bu da onları verilerin karmaşık temsillerini öğrenememelerine neden oluyordu. Bu sorun 1980'lerde birden fazla nöron katmanından oluşan derin sinir ağlarının ortaya çıkmasıyla çözülmüştür (LeCun, Bengio ve Hinton, 2015). DNN'ler görüntü, konuşma ve metin temsillerini öğrenmede umut vaat ediyordu, ancak ağırlıklarının güncellemek için kullanılan gradyanların önceki katmanlar üzerinde anlamlı bir etkiye sahip olamayacak kadar küçük hale geldiği kaybolan gradyan sorunu nedeniyle eğitilmesi hala zordu (Goodfellow vd., 2016).

2000'li yıllarda derin öğrenme, derin sinir ağlarının eğitimi için yenilikçi tekniklerin kullanılmaya başlanmasıyla önemli bir atılım yaşamıştır. Denetimsiz ön eğitim ve düzleştirilmiş doğrusal birim aktivasyon fonksiyonlarını içeren bu teknikler, alanın ilerlemesinde çok önemli bir rol oynamıştır (LeCun vd., 2015). Denetimsiz ön eğitim, ağı her katmanının ayrı ayrı eğitilmesini içerir ve denetimli öğrenme kullanarak tüm ağı uçtan uca eğitimini gerçekleştirmeden önce verilerin anlamlı bir temsili elde etmesini sağlar. ReLU aktivasyon fonksiyonu, tüm pozitif girdiler için sıfır olmayan bir gradyan sağlayarak kaybolan gradyan sorununu ele alır ve böylece ağı eğitim sürecini iyileştirir.

Derin bir sinir ağının mimarisi tipik olarak bir giriş katmanı, birden fazla gizli katman ve bir çıkış katmanından oluşur. Her katman, ağırlıklı bağlantılar aracılığıyla önceki ve sonraki katmanlardaki nöronlara bağlanan birden fazla nörona oluşur. Bir sinir ağında, giriş katmanındaki nöronlar giriş verilerini temsil etmekten

sorumluyken, çıkış katmanındaki nöronlar ağı bir sınıflandırma, regresyon veya üretim görevi biçimini alabilen çıktısını oluşturur. Gizli katmanlar, doğrusal olmayan dönüşümler yoluyla girdi verilerinin giderek daha karmaşık temsillerini öğrenir.

Derin bir sinir ağının eğitim süreci, girdi verilerinin ağdan geçirildiği ileri yayılımı ve çıktındaki hataların gradyan inişi kullanılarak ağırlıkları güncellemek için ağ boyunca geri yayıldığı geriye yayılımı içerir. Kayıp fonksiyonu ve optimizasyon algoritması seçimi ağın performansı üzerinde önemli bir etkiye sahip olabilir. Yaygın kayıp fonksiyonları arasında sınıflandırma görevleri için çapraz entropi ve regresyon görevleri için ortalama karesel hata bulunurken, popüler optimizasyon algoritmaları arasında stokastik gradyan inişi, Adam ve Adagrad bulunur.

Derin öğrenmenin bilgisayarla görme, doğal dil işleme ve konuşma tanıma gibi çeşitli alanlarda çok sayıda uygulaması vardır. Bilgisayarla görmede, derin sinir ağları görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevlerde en gelişmiş performansı elde etmiştir (Russakovsky vd., 2015). Doğal dil işlemede, derin sinir ağları dil modelleme, makine çevirisi ve duygu analizi gibi görevler için kullanılmıştır (Goldberg, 2017). Konuşma tanımada, derin sinir ağları konuşmadan metne sistemlerinin doğruluğunu artırmıştır (Hinton vd., 2012).

3.2. Nesne Algılama İçin Model Türleri

3.2.1. Faster R-CNN

Faster R-CNN, Shaoqing Ren, Kaiming He, Ross Girshick ve Jian Sun tarafından 2015 yılında tanıtılan popüler bir nesne algılama algoritmasıdır. Bölge Tabanlı Evrişimsel Sinir Ağları anlamına gelen orijinal R-CNN algoritmasının geliştirilmiş bir versiyonudur. Faster R-CNN, nesne tespiti için iki aşamalı bir çerçeveye dayanmaktadır. İlk aşamada, görüntüde bir nesne içermesi muhtemel bölgeler olan bir dizi öneri oluşturur. İkinci aşamada, önerileri sınıflandırır ve nesneye daha iyi uyması için sınırlayıcı kutularını iyileştirir.

Faster R-CNN'nin ilk aşaması bir bölge öneri ağına dayanmaktadır. RPN, bir görüntüyü girdi olarak alan ve bir dizi nesne önerisi çıkaran tamamen konvolüsyonel

bir ağıdır. RPN görüntü üzerinde küçük bir pencere kaydırır ve her konumda bir dizi bağlantı kutusu oluşturur.

Faster R-CNN'nin ikinci aşaması bölge tabanlı bir CNN'e dayanır. Bölge tabanlı CNN, RPN tarafından üretilen önerileri girdi olarak alır ve nesne sınıflandırması ve sınırlayıcı kutu regresyonu gerçekleştirir. Bölge tabanlı CNN, orijinal R-CNN algoritmasında kullanılan CNN'e benzer, ancak konvolüsyonel özellikleri RPN ile paylaştığı için daha verimlidir.

Faster R-CNN, orijinal R-CNN algoritmasına göre çeşitli avantajlara sahiptir. İlk olarak, RPN ve bölge tabanlı CNN arasındaki konvolüsyonel özellikleri paylaştığı için çok daha hızlıdır. İkincisi, daha doğrudur çünkü RPN için çoklu ölçeklerde ve en boy oranlarında teklifler oluşturabilen tamamen evrişimli bir ağ kullanır. Üçüncü olarak, uçtan uca eğitilebildiği için daha esnektir, yani RPN ve bölge tabanlı CNN aynı anda eğitilir.

Faster R-CNN'nin yayınlandığı yılda PASCAL VOC ve COCO dahil olmak üzere çeşitli kıyaslama veri kümelerinde en iyi performansı elde ettiği gösterilmiştir. Ayrıca yaya algılama, yüz algılama ve nesne izleme gibi çok çeşitli uygulamalara da uygulanmıştır. Faster R-CNN'nin sınırlamalarından biri, iyi performans elde etmek için büyük miktarda eğitim verisi gerektirmesidir. Bunun nedeni, RPN ve bölge tabanlı CNN'in ayrı ayrı eğitilmesi ve RPN'in yüksek kaliteli nesne önerileri oluşturmak için çok sayıda öneri gerektirmesidir. Diğer bir sınırlama ise bağlantı kutularının sayısı ve evrişimsel filtrelerin boyutu gibi hiperparametrelerin seçimine duyarlı olabilmesidir.

3.2.2. R-FCN

Bölge Tabanlı Tam Evrişimli Ağ 2016 yılında Microsoft Research Asia'dan Jifeng Dai, Yi Li, Kaiming He ve Jian Sun tarafından tanıtılan bir tür nesne algılama modelidir (Dai vd., 2016). R-FCN, hem bölge tabanlı evrişimsel sinir ağlarının hem de tam evrişimsel ağların güçlü yönlerini birleştirerek görüntülerde daha hızlı ve daha doğru nesne tespiti sağlamak için tasarlanmıştır.

R-FCN mimarisi, en popüler nesne algılama modellerinden biri olan Faster R-CNN modeli üzerine inşa edilmiştir. Faster R-CNN modeli iki aşamadan oluşur: bölge önerme ve nesne algılama. Bölge önerme aşaması, bir bölge önerme ağı kullanarak bir görüntüdeki nesnelerin potansiyel bölgelerini oluşturur. Nesne algılama aşaması, önerilen bölgelerdeki nesneleri sınıflandırmak için tipik olarak bir Hızlı R-CNN ağı olan ikinci bir ağ kullanır. Buna karşılık, R-FCN hem bölge önerme hem de nesne tespitini tek bir aşamada gerçekleştirmek için tam evrişimli bir ağ kullanır.

Bir FCN kullanmanın en önemli avantajı, tüm uzamsal konumlarda nesne algılama puanlarının aynı anda hesaplanmasına olanak sağlamasıdır. Bu, Faster R-CNN modelinde önemli bir darboğaz olan, önerilen her bölge için ayrı bir sınıflandırıcı ihtiyacını ortadan kaldırır. Ayrıca FCN mimarisi, tüm bölgelerde paylaşılan evrişimsel özelliklerin kullanılmasına olanak tanıyarak nesne tespitinin hesaplama ek yükünü daha da azaltır.

R-FCN mimarisi üç ana bileşenden oluşur: paylaşılan bir evrişimsel ağ, konuma duyarlı bir skor haritası ve bir bölge öneri ağı. Paylaşılan konvolüsyonel ağ, bir giriş görüntüsünden özellikleri çıkaran bir dizi konvolüsyonel katmandır. Konuma duyarlı skor haritası, önerilen bir bölge içindeki her konum için, konumun bölge içindeki göreceli konumuna dayalı olarak bir skor çıktısı veren bir dizi evrişimsel katmandır. Bölge öneri ağı, Daha Hızlı R-CNN modelinde kullanılan RPN'nin değiştirilmiş bir versiyonunu kullanarak görüntüdeki nesnelerin potansiyel bölgelerini oluşturur. Özellikle, R-FCN'nin hem doğruluk hem de hız açısından Faster R-CNN ve Single Shot Detector gibi diğer nesne algılama modellerinden daha iyi performans gösterdiği gösterilmiştir.

3.2.3. RetinaNet

RetinaNet, özellik piramidi ağı ve yeni bir kayıp fonksiyonu kullanan popüler bir nesne algılama modelidir ve çeşitli ölçütlerde etkili bir performansı elde etmiştir. Tsung-Yi Lin, Priya Goyal, Ross Girshick, Kaiming He ve Piotr Dollár tarafından 2017 yılında yayınlanan bir makalede tanıtılmıştır (Lin vd., 2017). Makale, nesne

tespitinde sınıf dengesizliği sorununu ele alan yeni bir odak kayıp fonksiyonu önermektedir.

Son yıllarda, konvolüsyonel sinir ağları nesne tespitinde büyük başarı göstermiştir (Girshick, 2015). Bununla birlikte, çoğu nesne algılama modelinde, nesne örneklerinden çok daha fazla arka plan örneğinin bulunduğu sınıf dengesizliği sorunu ortaya çıkmaktadır. Bu durum, modelin arka plana daha fazla odaklanma eğiliminde olduğu ve ilgilenilen nesneleri ihmal ettiği önyargılı bir eğitim sürecine yol açmaktadır.

RetinaNet, fokal kayıp adı verilen yeni bir kayıp fonksiyonu sunarak sınıf dengesizliği sorununu ele almaktadır. Odak kaybı, zor örnekler (yani yüksek güvenle yanlış sınıflandırılan örnekler) daha yüksek ağırlıklar ve kolay örnekler (yani doğru sınıflandırılan veya düşük güvenle yanlış sınıflandırılan örnekler) daha düşük ağırlıklar atar (Lin vd., 2017). Bu, modelin zor örnekler daha fazla odaklanmasına yardımcı olur ve kolay örneklerin etkisini azaltır, bu da nadir sınıflardaki algılama performansını artırır.

RetinaNet ayrıca birden fazla ölçekte özellik çıkarmak için bir özellik piramidi ağı kullanır. Özellik Piramit Ağı (FPN), her bir seviyenin giriş görüntüsünün farklı bir ölçeğine karşılık geldiği bir özellik piramidi oluşturmak için bir omurga ağının (örn. ResNet) farklı katmanlarından özellik haritalarını birleştirir (Lin vd., 2017). Bu, modelin farklı ölçeklerdeki nesneleri tespit etmesini sağlar ve küçük nesne tespitinin doğruluğunu artırır. Özellikle RetinaNet, çok sayıda küçük nesne ve nadir sınıf içeren zorlu COCO veri kümesinde önceki son teknoloji modellerden daha iyi performans göstermektedir.

3.2.4. Tek Atış Çoklu Kutu Dedektörü (SSD)

Tek Atış Çoklu Kutu Dedektörü, bilgisayarla görme uygulamalarında yaygın olarak kullanılan popüler bir nesne algılama algoritmasıdır. Berkeley'deki California Üniversitesi'nden araştırmacılar tarafından geliştirilen SSD, nesneleri gerçek zamanlı olarak tespit edip sınıflandırabilen derin bir sinir ağıdır (Liu vd., 2016).

SSD, nesneleri tespit etmek için tek bir derin sinir ağı kullanan tek aşamalı bir nesne tespit algoritmasıdır. Faster R-CNN gibi iki aşamalı dedektörlerin aksine SSD, aday nesne bölgeleri oluşturmak için ayrı bir bölge önerme ağı gerektirmez. Bunun yerine SSD, görüntüdeki her nesne için sınırlayıcı kutuları ve sınıf olasılıklarını doğrudan tahmin eder.

SSD, giriş görüntüsünden birden fazla ölçekte özellikler çıkarmak için bir özellik piramit ağı kullanır (Girshick vd., 2014). FPN, görüntüyü farklı çözünürlüklerde işleyerek SSD'nin farklı boyutlardaki en ve boy oranlarındaki nesneleri tespit etmesini sağlar. FPN'den çıkarılan özellikler daha sonra her nesne için sınırlayıcı kutuları ve sınıf olasılıklarını tahmin eden bir dizi evrimsel katmana beslenir.

SSD'nin en önemli avantajlarından biri hızıdır. Ayrı bir RPN gerektirmediğinden, SSD nesneleri tek bir GPU üzerinde gerçek zamanlı olarak tespit edebilir. Bu da onu otonom sürüş ve robotik gibi hızlı nesne tespiti gerektiren uygulamalar için ideal hale getirir. SSD ayrıca nesne tespitinin sağlamlığını artırmak için çeşitli teknikler içerir. Bu tekniklerden biri, sınıflandırılması zor olan yanlış pozitiflerin bir alt kümesi üzerinde ağı yeniden eğitilmesini içeren sert negatif madenciliğidir. Bu, yanlış pozitiflerin sayısını azaltmaya ve modelin genel doğruluğunu artırmaya yardımcı olur (Liu vd., 2016).

3.2.5. Sadece Bir Kez Bak (YOLO)

Sadece Bir Kez Bak (YOLO), bir görüntüdeki nesnelerin sınırlayıcı kutularını ve sınıf olasılıklarını tahmin etmek için tek bir sinir ağı kullanan bir nesne algılama algoritmasıdır. YOLO, giriş görüntüsünü bir ızgaraya böler ve ızgaradaki her hücre için bir sınırlayıcı kutu ve sınıf olasılıkları tahmin eder. Sınırlayıcı kutular, kutunun merkezinin x ve y koordinatları, kutunun genişliği, yüksekliği ve kutunun güven puanı ile parametrelendirilir. Güven puanı, modelin kutunun bir nesne içerdiğinden ne kadar emin olduğunun bir ölçüsüdür.

YOLO'nun en önemli avantajlarından biri hızıdır. Sinir ağından yalnızca tek bir ileri geçiş gerektirdiğinden, YOLO nesneleri tek bir GPU üzerinde gerçek zamanlı olarak algılayabilir. YOLO'nun bir diğer avantajı da doğruluğudur. Nesne algılama algoritmaları üzerine yapılan karşılaştırmalı bir çalışmada YOLOv3, COCO veri kümesinde RetinaNet ve SSD gibi diğer tek aşamalı dedektörlerden daha iyi performans göstererek en iyi performansı elde etmiştir (Redmon & Farhadi, 2018).

YOLO, her biri doğruluk ve hızda iyileştirmeler içeren çeşitli sürümlerden geçmiştir. YOLOv2, sınırlayıcı kutu tahminlerinin doğruluğunu artırmak için bağlantı kutularının kullanımı, aşırı uyumu azaltmak için toplu normalleştirme ve birden fazla ölçekte nesneleri tespit etmek için bir özellik piramidi ağı dahil olmak üzere orijinal YOLO algoritmasına göre çeşitli iyileştirmeler getirmiştir (Redmon & Farhadi, 2017).

YOLOv3, sinir ağının farklı çözünürlüklerdeki görüntüler üzerinde eğitilmesini içeren çok ölçekli eğitim adı verilen bir teknik de dahil olmak üzere birkaç yeni özellik sunarak YOLO'nun doğruluğunu daha da geliştirmiştir. Bu, YOLOv3'ün farklı boyutlardaki en ve boy oranlarındaki nesneleri daha doğru bir şekilde tespit etmesini sağlar. YOLOv3 ayrıca, YOLO'nun önceki sürümlerinden daha fazla katmana sahip olan ve giriş görüntüsünden daha fazla özellik çıkarabilen Darknet-53 adlı yeni bir omurga ağını da tanıtmıştır (Redmon & Farhadi, 2018).

YOLOv3'ün piyasaya sürülmesinden bu yana, her biri hız ve doğrulukta daha fazla iyileştirme sağlayan birkaç yeni YOLO sürümü tanıtılmıştır 2020'de piyasaya sürülen YOLOv4, birden fazla ölçekte özellik çıkarmak için bir uzamsal piramit havuzlama modülü, nesne algılamayı iyileştirmek için bir odak kaybı işlevi ve ağın doğrusal olmayanlığını iyileştirmek için bir mish aktivasyon fonksiyonu dahil olmak üzere birçok yeni özellik sunmuştur (Bochkovskiy, Wang ve Liao, 2020). YOLOv4 ayrıca ağ mimarisinde, giriş görüntüsünden daha fazla özellik çıkarabilen bir CSPDarknet53 omurga ağı ve nesne algılama doğruluğunu artıran bir Uzamsal Piramit Havuzu-Mish ağı da dahil olmak üzere çeşitli iyileştirmeler yapmıştır.

Ultralytics tarafından 2020 yılında piyasaya sürülen YOLOv5, YOLOv5 omurgası adı verilen farklı bir ağ mimarisi kullanması nedeniyle YOLO'nun önceki

sürümlerinden önemli bir farklılıktır. Bu omurga ağı, hem verimli hem de doğru olacak şekilde tasarlanmış olan EfficientNet mimarisine dayanmaktadır. YOLOv5 ayrıca, çapa kutularına olan ihtiyacı ortadan kaldıran çapasız algılama ve hem geleneksel hem de kendi kendine denetimli öğrenmeyi içeren hibrit bir eğitim yaklaşımı da dahil olmak üzere birkaç yeni özellik içerir (Ultralytics, 2020).

Yine Ultralytics tarafından 2020 yılında piyasaya sürülen YOLOv6, ağı farklı çözünürlüklerdeki görüntülere uyum sağlamasına olanak tanıyan dinamik bir giriş şekli ve ağı mimarisini optimize etmek için genetik bir algoritma kullanan Evrimsel Eğitim adı verilen yeni bir eğitim yaklaşımı da dahil olmak üzere birçok yeni özellik sunarak YOLOv5'in iyileştirmelerine dayanmaktadır (Ultralytics, 2020).

3.3. Derin Öğrenme ile Nesne Algılama Süreci

3.3.1. Veri Toplama

Nesne tespiti için veri toplamanın ilk adımı, tespit edilmesi gereken nesneleri belirlemektir. Bu nesneler yayalar, arabalar ve trafik işaretlerinden hayvanlar, bitkiler ve binalara kadar her şey olabilir. Nesnelerin seçimi, nesne algılama sisteminin özel uygulamasına bağlıdır. Örneğin, sürücüsüz bir arabanın yayaları, diğer arabaları ve yol işaretlerini tespit etmesi gerekirken, bir güvenlik sisteminin davetsiz misafirleri, hayvanları ve şüpheli nesneleri tespit etmesi gerekebilir.

Nesneler belirlendikten sonra, bir sonraki adım nesneleri içeren görüntü ve videoları toplamaktır. Görüntüler ve videolar çeşitli olmalı ve farklı bağlam ve ortamlardaki nesneleri temsil etmelidir. Örneğin, yaya tespiti için veri topluyorsak, yayaların farklı kıyafetler, aydınlatma koşulları ve hava koşullarındaki görüntülerini dahil etmeliyiz.

Veri kümesinin çeşitliliğini artırmak için veri artırma teknikleri kullanılabilir. Bu teknikler, görüntülere ve videolara döndürme, öteleme, ölçekleme ve çevirme gibi dönüşümlerin uygulanmasını içerir. Bu, derin öğrenme algoritmasının daha iyi genelleme yapmasına ve giriş verilerindeki değişikliklere karşı daha dayanıklı olmasına yardımcı olabilir.

Verilerin kalitesi, nesne algılama sisteminin performansı için kritik öneme sahiptir. Görüntüler ve videolar, minimum gürültü ve bozulma ile yüksek çözünürlükte ve netlikte olmalıdır. Nesneler açıkça görülebilmeli ve diğer nesnelerle en az düzeyde örtüşme ve çakışma olmalıdır. Ek açıklamalar doğru ve tutarlı olmalı, ilgilenilen nesnelerin etrafında kesin sınırlayıcı kutular bulunmalıdır.

Açıklamalar, nesne tespiti için veri toplama sürecinin önemli bir yönüdür. Ek açıklamalar, görüntü ve videolardaki nesneler için temel gerçek etiketlerini sağlar. Açıklamalar genellikle nesnelerin etrafındaki sınırlayıcı kutulardan ve sol üst ve sağ alt köşelerin koordinatlarından oluşur. Açıklamalar tüm görüntü ve videolarda tutarlı olmalı ve nesnelerin kapsamını doğru bir şekilde yakalamalıdır.

Ek açıklamalar manuel veya otomatik olarak yapılabilir. Manuel açıklama, insan açıklamacıların görüntü ve videolardaki nesneleri etiketlemesini içerir. Bu zaman alıcı ve pahalı olabilir, ancak yüksek doğruluk ve tutarlılık sağlar. Otomatik açıklama, nesneleri tespit etmek ve etiketlemek için bilgisayarla görme algoritmalarının kullanılmasını içerir. Bu daha hızlı ve daha ucuz olabilir, ancak özellikle karmaşık nesneler ve ortamlar için manuel açıklama kadar doğru olmayabilir.

Veri kümesinin boyutu, nesne algılama sisteminin performansı için çok önemlidir. Veri kümesi, nesnelerin ve bağlamlarının değişkenliğini ve çeşitliliğini yakalayacak kadar büyük olmalıdır. Küçük bir veri kümesi aşırı uyuma ve zayıf genellemeye yol açabilirken, büyük bir veri kümesi derin öğrenme algoritmasının sağlamlığını ve doğruluğunu artırabilir.

Veri kümesinin kalitesi hassasiyet, geri çağırma ve F1 puanı gibi metrikler kullanılarak değerlendirilebilir. Hassasiyet, tüm tespitler arasında doğru pozitif tespitlerin oranını ölçer. Geri çağırma, tüm gerçek nesneler arasında gerçek pozitif tespitlerin oranını ölçer. F1 puanı, hassasiyet ve geri çağırmanın harmonik ortalamasıdır ve performansın dengeli bir ölçüsünü sağlar.

3.3.2. Veri Ön İşleme

Veri ön işleme, nesne algılama da dahil olmak üzere tüm derin öğrenme sistemlerinin kritik bir bileşenidir. Ön işleme, ham giriş verilerinin derin öğrenme algoritması tarafından kullanılabilir bir formata dönüştürülmesini içerir. Ön işleme adımları arasında normalleştirme, yeniden boyutlandırma, veri büyütme, özellik çıkarma ve açıklama yer alabilir.

İlk adım verileri temizlemektir. Bu, tekrarlanan veya ilgisiz verilerin kaldırılmasını, hataların ve tutarsızlıkların düzeltilmesi ile gürültü ve aykırı değerlerin filtrelenmesini içermektedir.

İkinci adım verileri normalleştirmektir. Bu, derin öğrenme algoritması tarafından işlenebilmeleri için görüntülerin ve videoların piksel değerlerinin 0 ile 1 veya -1 ile 1 aralığına ölçeklendirilmesini içerebilir. Normalleştirme, algoritmanın yakınsamasını ve kararlılığını artırabilir ve sayısal taşma veya düşük akışı önleyebilir.

Üçüncü adım verileri yeniden boyutlandırmaktır. Bu adım, derin öğrenme algoritması tarafından verimli bir şekilde işlenebilmeleri için görüntülerin ve videoların sabit bir boyuta veya en/boy oranına göre ölçeklendirilmesini içermektedir. Yeniden boyutlandırma, girdi verilerindeki varyasyonların etkisini azaltarak algoritmanın geliştirilmesini ve sağlamlığını da artırabilir.

Dördüncü adım, veri setini büyütme, görüntülere ve videolara döndürme, öteleme, ölçekleme, çevirme ve renk titretme gibi çeşitli dönüşümlerin uygulanmasını içerebilir. Veri artırımı, veri kümesinin boyutunu ve çeşitliliğini artırabilir, derin öğrenme algoritmasının performansını ve genellemesini iyileştirebilir ve aşırı uyumu azaltabilir.

Beşinci adım, verilerden özelliklerin çıkarılmasıdır. Bu, görüntülerden ve videolardan üst düzey özellikler çıkarmak için VGG, ResNet veya Inception gibi önceden eğitilmiş evrimsel sinir ağlarının kullanılmasını içerebilir. Özellik çıkarma, verilerin boyutluluğunu azaltabilir, en ayırt edici bilgileri yakalayabilir ve derin öğrenme algoritmasının eğitimini ve çıkarımını hızlandırabilir.

Altıncı adım, verilere açıklama eklemektir. Bu, sınırlayıcı kutular, segmentasyon maskeleri veya anahtar noktalar kullanmak gibi verilerdeki nesnelerin manuel veya otomatik olarak etiketlenmesini içerebilir. Ek açıklama, verilerdeki nesneler için temel gerçek etiketleri sağlayabilir, derin öğrenme algoritmasının eğitimini ve değerlendirilmesini mümkün kılabilir ve sistemin yorumlanabilirliğini ve açıklanabilirliğini geliştirebilir.

Yedinci adım, verileri eğitim, doğrulama ve test kümelerine ayırmaktır. Bu, derin öğrenme algoritmasının performansının görünmeyen veriler üzerinde değerlendirilmesini sağlayabilir ve aşırı uyumu ve veri sızıntısını önleyebilir. Eğitim seti derin öğrenme algoritmasını eğitmek için, doğrulama seti algoritmanın hiperparametrelerini ayarlamak için ve test seti de algoritmanın performansını değerlendirmek için kullanılır.

3.3.3. Modelin Tasarlanması

Özellikle modelleme adımı, modelin mimarisini ve parametrelerini belirleyen kritik bir aşamadır. Derin öğrenmedeki modelleme adımı, katman sayısının, aktivasyon fonksiyonunun türünün ve optimizasyon algoritmasının türünün seçilmesini içeren model mimarisinin tasarlanmasını içerir. Modelin mimarisi, ele alınan özel probleme ve verilerin özelliklerine bağlıdır. Örneğin, konvolüsyonel sinir ağı genellikle görüntü tanıma için kullanılır. Buna karşılık, doğal dil işleme gibi dizi verileri için tekrarlayan bir sinir ağı kullanılır (Goodfellow, Bengio ve Courville, 2016).

Bir derin öğrenme modelindeki katman sayısı önemli bir husustur. Derin öğrenme modelleri tipik olarak birden fazla gizli katmana sahiptir ve bu da modelin verilerdeki karmaşık örüntüleri öğrenmesine olanak tanır. Bununla birlikte, çok fazla katman eklemek, modelin eğitim verilerine çok fazla uzmanlaştığı ve yeni verilerde düşük performans gösterdiği aşırı uyuma yol açabilir. Optimum katman sayısı, veri kümesinin boyutuna, karmaşıklığına ve mevcut hesaplama kaynaklarının miktarına bağlıdır (Chollet, 2017).

Aktivasyon fonksiyonunun seçimi de modelleme adımında kritik öneme sahiptir. Aktivasyon fonksiyonu, ağdaki her bir nöronun çıktısını belirler ve doğrusal olmama özelliğini devreye sokarak ağı karmaşık örüntüleri öğrenmesini sağlar. En yaygın kullanılan aktivasyon fonksiyonu, derin öğrenme modellerinde etkili olduğu gösterilen düzeltilmiş doğrusal birimdir (ReLU) (Goodfellow vd., 2016). Bununla birlikte, RNN'lerde yaygın olarak kullanılan hiperbolik tanjant (tanh) fonksiyonu gibi belirli veri türleri için daha uygun olabilecek başka aktivasyon fonksiyonları da vardır (Chollet, 2017).

Optimizasyon algoritmaları, eğitim sırasında kayıp fonksiyonunu en aza indirmek için kullanılır. Bir optimizasyon algoritmasının seçimi, modelin performansı üzerinde önemli bir etkiye sahip olabilir. En yaygın kullanılan optimizasyon algoritması, kayıp fonksiyonunun parametrelere göre gradyanına dayalı olarak modelin parametrelerini güncelleyen stokastik gradyan inişidir. Bununla birlikte, modelin yakınsama hızını ve kararlılığını artırabilen momentum tabanlı ve uyarlanabilir öğrenme oranı yöntemleri gibi SGD'nin çeşitli varyantları vardır (Goodfellow vd., 2016).

Modelleme adımıdaki bir diğer önemli husus, aşırı uyumu önlemek için kullanılan düzenleme teknikleridir. Düzenli hale getirme teknikleri, modelin karmaşıklığını azaltarak aşırı uyuma daha az eğilimli hale getirmeyi amaçlar. Yaygın olarak kullanılan düzenleme teknikleri arasında eğitim sırasında bazı nöronları rastgele çıkaran dropout ve modeldeki büyük ağırlıkları cezalandıran ağırlık azalması (Weight decay) yer almaktadır (Chollet, 2017).

Modelleme adımı, eğitim sırasında öğrenilmeyen ancak eğitimden önce ayarlanan parametreler olan modelin hiperparametrelerinin ayarlanmasını da içerir. Hiperparametreler arasında öğrenme oranı, yığın boyutu ve epok sayısı yer alır. Öğrenme oranı, optimizasyon algoritmasının her iterasyonu sırasında modelin parametrelerinin ne kadar güncellendiğini belirler. Yüksek bir öğrenme oranı modelin optimum çözümü aşmasına neden olabilirken, düşük bir öğrenme oranı yavaş yakınsamaya neden olabilir. Yığın boyutu, optimizasyon algoritmasının her bir iterasyonu sırasında modelin parametrelerini güncellemek için kaç örnek

kullanılacağını belirler. Küçük parti boyutları gürültülü güncellemelere neden olabilirken, büyük parti boyutu yavaş yakınsamaya yol açabilir. Epok sayısı, eğitim sırasında tüm veri kümesinin modelden kaç kez geçirileceğini belirler. Epok sayısının çok düşük ayarlanması modelin yetersiz uyum sağlamasına neden olabilirken, çok yüksek ayarlanması aşırı uyuma neden olabilir (Chollet, 2017).

Derin öğrenmede modelleme adımı çok fazla deneme yanılma içerir. Ele alınan spesifik problem için en iyi kombinasyonu bulmak amacıyla farklı mimariler, aktivasyon fonksiyonları, optimizasyon algoritmaları, düzenleme teknikleri ve hiperparametreler ile denemeler yapmak yaygındır. Bu süreç zaman alıcı ve hesaplama açısından pahalı olabilir, ancak derin öğrenme modellerinde yüksek performans elde etmek için gereklidir (Goodfellow vd., 2016).

Yukarıda belirtilen hususlara ek olarak, modelleme adımında dikkate alınması gereken veri artırma teknikleri, model yorumlanabilirliği ve model toplulaştırma gibi başka faktörler de vardır. Veri artırma teknikleri, mevcut verilere görüntüleri döndürme veya çevirme gibi rastgele dönüşümler uygulayarak yeni eğitim verileri oluşturmayı içerir. Bu, aşırı uyumu önlemeye ve modelin genelleme performansını artırmaya yardımcı olabilir. Modelin yorumlanabilirliği, modelin tahminlerini nasıl yaptığını anlamak için önemlidir; bu, özellikle modelin tahminlerine dayalı kararların sağlık veya finans gibi önemli sonuçlara yol açabileceği uygulamalarda önemlidir. (Chollet, 2017).

3.3.4. Modelin Eğitilmesi

Derin öğrenmede model eğitimi süreci, belirli bir görevdeki kayıp fonksiyonunu en aza indirmek için bir sinir ağının ağırlıklarını ve sapmalarını iteratif olarak ayarlamayı içerir. Bu süreç tipik olarak veri ön işleme, ileri yayılım, kayıp hesaplama, geri yayılım ve optimizasyon dahil olmak üzere birkaç temel adımı içerir.

Veri ön işleme, ham girdi verilerinin sinir ağı tarafından kullanılacak bir formata dönüştürülmesini içerdiğinden model eğitiminde önemli bir ilk adımdır. Bu, sinir ağının performansını ve yakınsamasını iyileştirmeye yardımcı olabilecek

normalleştirme, özellik ölçekleme ve özellik çıkarma gibi teknikleri içerebilir (Géron, 2019).

Veriler ön işleme tabi tutulduktan sonra, bir sonraki adım ileri yayılımdır. Bu, bir çıktı oluşturmak için önceden işlenmiş giriş verilerinin sinir ağından geçirilmesini içerir. Bu adım sırasında, sinir ağının her katmanı giriş verilerine doğrusal bir dönüşüm uygular ve bunu doğrusal olmayan bir aktivasyon fonksiyonu izler. Her katmanın çıktısı daha sonra çıktı katmanına ulaşılan kadar bir sonraki katmana girdi olarak aktarılır (Chollet, 2017).

Çıktı oluşturulduktan sonra, bir sonraki adım kayıp fonksiyonunu hesaplamaktır. Kayıp fonksiyonu, verilen görev için öngörülen çıktı ile gerçek çıktı arasındaki farkı ölçer. Kayıp fonksiyonunun seçimi, regresyon görevleri için ortalama karesel hata ve sınıflandırma görevleri için çapraz entropi kaybı kullanılır (Goodfellow vd., 2016).

Kayıp fonksiyonu hesaplandıktan sonra, bir sonraki adım geriye yayılımdır. Geriye yayılım, sinir ağının ağırlıklarına ve önyargılarına göre kayıp fonksiyonunun gradyanlarını hesaplamak için kullanılır. Bu, çıktı katmanının gradyanlarını hesaplamak ve bunları girdi katmanına geri yaymak için hesaplamaların zincir kuralını kullanmayı içerir. Gradyanlar daha sonra bir optimizasyon algoritması kullanılarak sinir ağının ağırlıklarını ve önyargılarını güncellemek için kullanılır (Nielsen, 2015).

Model eğitimi sırasında kullanılabilecek stokastik gradyan inişi, Adam ve RMSprop gibi çeşitli optimizasyon algoritmaları vardır. Her algoritmanın kendine özgü avantajları ve sınırlamaları olduğundan, optimizasyon algoritmasının seçimi sinir ağının performansını önemli ölçüde etkileyebilir (Géron, 2019; Goodfellow vd., 2016).

Model eğitimi sırasında, aşırı uyumu önlemek için sinir ağının performansını bir doğrulama seti üzerinde izlemek de önemlidir. Aşırı uyum, sinir ağı eğitim verilerine çok fazla özelleştiğinde ve yeni, görünmeyen verilere genelleme yapamadığında ortaya çıkar. Bırakma ve erken durdurma gibi düzenli hale getirme teknikleri, model eğitimi sırasında aşırı uyumu önlemeye yardımcı olabilir (Chollet, 2017; Goodfellow vd., 2016).

3.3.5. Modelin Değerlendirilmesi

Bir derin öğrenme modelinin değerlendirilmesi, uygun bir değerlendirme metriğinin seçilmesiyle başlayan birkaç adımdan oluşur. Metrik seçimi, çözülmekte olan problemin doğasına ve kullanılan veri türüne bağlıdır (Chollet, 2017). Örneğin, bir ikili sınıflandırma problemi için doğruluk, kesinlik, geri çağırma ve F1-skoru gibi metrikler yaygın olarak kullanılır. Öte yandan, regresyon problemleri için ortalama karesel hata ve ortalama mutlak hata gibi metrikler kullanılır. Uygun bir değerlendirme metriğinin seçilmesi, modelin ne kadar iyi performans gösterdiğini belirlediği ve güçlü ve zayıf yönleri hakkında fikir verdiği için çok önemlidir.

Bir değerlendirme metriği seçtikten sonra, bir sonraki adım veri kümesini eğitim, doğrulama ve test kümelerine ayırmaktır. Eğitim seti modeli eğitmek için kullanılırken, doğrulama seti hiperparametrelerde ince ayar yapmak ve eğitim sırasında modelin performansını izlemek için kullanılır. Son olarak, test seti eğitimden sonra modelin performansını değerlendirmek için kullanılır. Test seti, eğitim ve doğrulama setlerinden tamamen bağımsız olmalı ve verilerin gerçek dünyadaki dağılımını temsil etmelidir (Chollet, 2017).

Veri kümesi bölündükten sonra, bir sonraki adım derin öğrenme modelini eğitmektir. Bu, öğrenme oranı, yığın boyutu ve epok sayısı gibi hiperparametrelerin ayarlanmasını ve uygun bir optimize edici ve kayıp fonksiyonunun seçilmesini içerir (Chollet, 2017). Hiperparametreler doğrulama seti kullanılarak ayarlanır ve performans seçilen değerlendirme ölçütü kullanılarak izlenir. Eğitimin amacı, seçilen kayıp fonksiyonunu en aza indirmek ve doğrulama setindeki performansını iyileştirmek için modelin parametrelerini optimize etmektir.

Model eğitildikten sonra, seçilen değerlendirme metriği kullanılarak test seti üzerinde değerlendirilir. Bu adım, modelin gerçek dünya senaryolarındaki performansına ilişkin bir tahmin sağlar. Ancak, test setindeki performansın modele ince ayar yapmak için kullanılmaması gerektiğine dikkat etmek önemlidir, çünkü bu aşırı uyuma ve güvenilir olmayan sonuçlara yol açabilir (Chollet, 2017).

Yukarıdaki adımların yanı sıra, derin öğrenme modellerini değerlendirmek için kullanılan başka teknikler de vardır. Bu tekniklerden biri, veri kümesini birkaç kata bölmeyi ve geri kalanını doğrulama için kullanırken modeli her katta eğitmeyi içeren çapraz doğrulamadır. Bu teknik, aşırı uyum riskini azaltmaya yardımcı olur ve modelin performansı hakkında daha sağlam bir tahmin sağlar (Goodfellow vd., 2016). Diğer bir teknik ise genel performansı iyileştirmek için birkaç modeli birleştirmeyi içeren topluluk öğrenmesidir. Topluluk öğrenmesi, yanlılık ve varyans riskini azaltmaya ve modelin genelleme yeteneğini geliştirmeye yardımcı olabileceğinden derin öğrenmede yaygın olarak kullanılmaktadır (Sze vd., 2019).

3.4. Nesne Algılama İçin Transfer Öğrenme

Transfer öğrenmesi, çeşitli uygulamalarda yaygın olarak kullanılan bir makine öğrenmesi tekniğidir (Pan ve Yang, 2010). İnce ayar, yeni bir görev için önceden eğitilmiş bir modelin değiştirilmesini içeren yaygın bir transfer öğrenme tekniğidir (Yosinski vd., 2014). Özellik çıkarma, yeni bir veri kümesinden özellik çıkarmak için önceden eğitilmiş bir modelin kullanılmasını içeren başka bir transfer öğrenme tekniğidir (Oquab vd., 2014).

Nesne tespiti için transfer öğrenme, farklı bir veri kümesindeki nesne tespit modelinin performansını artırmak için büyük bir veri kümesinde önceden eğitilmiş bir modelin kullanılmasını içerir. Önceden eğitilmiş model genellikle ImageNet gibi büyük bir görüntü sınıflandırma veri kümesi üzerinde eğitilir. ImageNet, 14 milyondan fazla görüntü ve 20.000 nesne kategorisi içeren büyük ölçekli bir görüntü sınıflandırma veri kümesidir. Önceden eğitilmiş model ImageNet veri kümesindeki nesneleri sınıflandırmayı öğrenir ve bu görevden öğrenilen bilgi nesne algılama görevlerine aktarılabilir.

Nesne tespiti için en yaygın transfer öğrenme tekniklerinden biri ince ayardır. İnce ayar, önceden eğitilmiş bir modeli alıp açıklamalı nesne algılama etiketlerine sahip yeni bir veri kümesi üzerinde eğitmeyi içerir. İnce ayar yapılırken, önceden eğitilmiş modelin son katmanına yeni veri kümesiyle aynı sayıda çıktı sınıfına sahip yeni bir katman eklenir. Önceden eğitilmiş katmanların ağırlıkları dondurulur ve

yalnızca yeni katmanın ağırlıkları yeni veri kümesi üzerinde eğitilir. İnce ayar etkilidir çünkü önceden eğitilmiş katmanlar birçok görüntüde ortak olan kenarlar, şekiller ve dokular gibi birçok düşük seviyeli özelliği zaten öğrenmiştir. Yeni bir nesne algılama veri kümesi üzerinde önceden eğitilmiş katmanlara ince ayar yaparak, model yeni veri kümesine özgü üst düzey özellikleri öğrenebilir.

Nesne tespiti için bir başka transfer öğrenme tekniği de özellik çıkarmadır. Özellik çıkarma, yeni bir veri kümesindeki görüntülerden özellik çıkarmak için önceden eğitilmiş bir modelin kullanılmasını içerir. Çıkarılan özellikler daha sonra yeni bir nesne algılama modelini eğitmek için kullanılır. Özellik çıkarmı etkilidir çünkü önceden eğitilmiş model birçok görev için faydalı olan genel görüntü özelliklerini öğrenebilir ve bu özellikler nesne algılama görevleri için yeni bir modeli eğitmek için kullanılabilir.

Nesne tespiti için transfer öğrenmenin birçok faydası vardır. Başlıca faydalarından biri, yeni bir nesne algılama modelini eğitmek için gereken etiketli veri miktarını azaltmasıdır. Etiketli verilerin toplanması pahalı ve zaman alıcıdır ve transfer öğrenimi yeni bir veri kümesinde iyi performans elde etmek için gereken etiketli veri miktarını azaltabilir. Nesne algılama için transfer öğrenmenin bir diğer faydası da yeni bir modeli eğitmek için gereken hesaplama kaynaklarının miktarını azaltmasıdır. Derin bir sinir ağını büyük bir veri kümesi üzerinde sıfırdan eğitmek GPU'lar ve bellek gibi çok fazla hesaplama kaynağı gerektirir. Transfer öğrenimi, yeni bir modeli eğitmek için başlangıç noktası olarak önceden eğitilmiş bir modeli kullanarak hesaplama gereksinimlerini azaltabilir.

Bununla birlikte, nesne tespiti için transfer öğrenmenin bazı zorlukları da vardır. Nesne tespiti için transfer öğrenmenin zorluklarından biri, önceden eğitilmiş modelin yeni görev için uygun olmayabilmesidir(Bengio vd., 2012). Örneğin, önceden eğitilmiş model yeni veri kümesinden farklı nesne kategorilerine veya nesne boyutlarına sahip bir veri kümesi üzerinde eğitilmişse, önceden eğitilmiş model yeni göreve iyi bir şekilde aktarılamayabilir. Nesne tespiti için transfer öğrenmenin bir başka zorluğu da, yeni veri kümesi küçükse veya önceden eğitilmiş model çok

karmaşıksa, önceden eğitilmiş modelin yeni veri kümesine aşırı uyum sağlayabilmesidir.

3.5. Derin Öğrenme İle Nesne Tespiti Uygulama Alanları

3.5.1. Bilgisayarlı Görü

Bilgisayarla görme, makine öğrenimi ve derin öğrenme tekniklerindeki gelişmeler sayesinde son yıllarda önemli ilerlemeler kaydeden ve hızla gelişen bir alandır (Szeliski, 2011). Bilgisayarlı görü alanındaki en önemli zorluklardan biri, görsel bilgileri doğru ve güvenilir bir şekilde tanıyabilen ve yorumlayabilen algoritmalar geliştirmektir; bu da nesneleri tespit etme ve sınıflandırma becerisinin yanı sıra görüntü ve videolardaki kalıpları ve ilişkileri tanımayı gerektirir (Gonzalez & Woods, 2018).

Bunu başarmak için, bilgisayarla görme araştırmacıları özellik çıkarma, makine öğrenimi, derin öğrenme ve evrişimli sinir ağları gibi çeşitli teknikler geliştirmiştir (LeCun, Bengio ve Hinton, 2015). Özellik çıkarma, görüntülerden kenarlar, köşeler veya doku gibi önemli özelliklerin veya karakteristiklerin çıkarılmasını içeren ve daha sonra görüntüleri sınıflandırmak veya içindeki nesneleri tespit etmek için kullanılabilen bir tekniktir (Szeliski, 2011). Makine öğrenimi, bilgisayarla görmede yaygın olarak kullanılan bir başka tekniktir; burada algoritmalar, içlerindeki nesneleri ve desenleri tanımayı öğrenmek için etiketli görüntülerden oluşan büyük veri kümeleri üzerinde eğitilir (Gonzalez ve Woods, 2018).

Derin öğrenme, son yıllarda bilgisayarla görmede devrim yaratan daha yeni bir tekniktir (LeCun vd., 2015). Derin öğrenme, görüntüleri tanımayı ve sınıflandırmayı öğrenmek için birçok katmana sahip sinir ağlarının eğitilmesini içerir. Bir tür derin öğrenme algoritması olan evrişimli sinir ağları, görüntülerden ilgili özellikleri otomatik olarak öğrenme yetenekleri nedeniyle görüntü tanıma ve nesne algılama görevleri için özellikle popüler hale gelmiştir (Szeliski, 2011).

Bilgisayarla görmenin en popüler uygulamalarından biri, güvenlik kamerası görüntülerindeki kişileri tanımlamaktan tıbbi görüntülerdeki nesneleri tanımlamaya kadar çok sayıda pratik kullanıma sahip olan görüntü ve video tanımadır (Gonzalez & Woods, 2018). Bilgisayarla görmenin bir diğer önemli uygulaması, özellikle robotik ve otonom araçlar gibi alanlarda, makinelerin gezinmek ve onlarla etkileşimde bulunmak için çevrelerindeki nesneleri tanımlayabilmeleri ve izleyebilmeleri gereken nesne algılama ve izlemedir (Szeliski, 2011).

Son yıllarda, bilgisayarla görme, hastalıkların teşhis ve tedavisinde daha doğru ve verimli yöntemler geliştirmek için kullanıldığı tıbbi görüntülemeye de uygulanmıştır (Gonzalez & Woods, 2018). Örneğin, tıbbi görüntülerdeki kanserli tümörleri otomatik olarak tespit etmek ve teşhis etmek ve ayrıca hastalıkların zaman içindeki ilerlemesini izlemek için bilgisayarla görme algoritmaları geliştirilmiştir.

Son yıllarda bilgisayarla görme alanında kaydedilen birçok ilerlemeye rağmen, hala ele alınması gereken çok sayıda zorluk ve sınırlama vardır (Szeliski, 2011). Başlıca zorluklardan biri, görsel bilgileri insan algısına benzer bir şekilde tanıyabilen ve yorumlayabilen algoritmalar geliştirmektir. Bir diğer zorluk ise aydınlatma, bakış açısı ve diğer çevresel faktörlerdeki değişikliklere karşı dayanıklı algoritmalar geliştirmektir.

Genel olarak, bilgisayarla görme, güvenlik sistemlerinden tıbbi görüntülemeye kadar çeşitli alanlarda çok sayıda pratik uygulaması olan heyecan verici ve hızla gelişen bir alandır. Makine öğrenimi ve derin öğrenme tekniklerinde devam eden araştırma ve geliştirmelerin önümüzdeki yıllarda da bu alanda ilerleme sağlamaya devam etmesi muhtemeldir.

3.5.2. Gözetleme ve Güvenlik

Derin öğrenme, çevremizi izleme ve koruma şeklimizde devrim yaratarak gözetim ve güvenlik alanına önemli katkılarda bulunmuştur. Derin öğrenme algoritmaları, büyük miktarda veriyi analiz etmek ve anormallikleri tespit etmek, olayları tahmin etmek ve potansiyel güvenlik tehditlerini önlemek için kullanılan kalıpları tanımlamak için kullanılmıştır. Derin öğrenme, nesne algılama, yüz tanıma,

anormal davranış algılama ve olay tahmini dahil ancak bunlarla sınırlı olmamak üzere gözetim ve güvenlik alanında geniş bir uygulama yelpazesine sahiptir.

Nesne algılama, gözetim ve güvenlikte derin öğrenmenin birincil uygulamalarından biridir. Belirli bir ortamdaki nesnelerin tespit edilmesini ve tanınmasını içerir. Bu teknik, silah veya patlayıcı gibi şüpheli nesneleri tanımlamak ve güvenlik personeli uyararak için kullanılabilir. Nesne algılama ayrıca trafiği izlemek ve kazaya karışan veya trafik kurallarını ihlal eden araçları belirlemek için de kullanılabilir

Yüz tanıma, derin öğrenmenin gözetim ve güvenlik alanındaki bir başka uygulamasıdır. Bireylerin yüz özelliklerine göre tanımlanmasını içerir. Bu teknik, kısıtlı alanlara erişimi izlemek, suçluları tespit etmek ve kimlik hırsızlığını önlemek için kullanılabilir. Yüz tanıma, pazarlama kampanyalarını kişiselleştirmek ve müşteri deneyimlerini iyileştirmek için de kullanılabilir (Goodfellow vd., 2016).

Anormal davranış tespiti, derin öğrenmenin gözetim ve güvenlik alanlarında pratik uygulama bulduğu önemli bir alandır. Belirli bir ortamdaki bireylerin davranışlarının analiz edilmesini ve normların dışındaki faaliyetlerin belirlenmesini içerir. Bu teknik, aylaklık gibi şüpheli davranışları tespit etmek ve güvenlik personeli uyararak için kullanılabilir. Anormal davranış tespiti, hastanelerdeki hasta davranışlarını izlemek ve akıl hastalığının erken belirtilerini tespit etmek için de kullanılabilir (Goodfellow vd., 2016).

Olay tahmini, derin öğrenmenin gözetim ve güvenlik alanlarındaki bir diğer kayda değer uygulamasıdır. Geçmiş verilerin analiz edilmesini ve gelecekteki olayları tahmin etmek için kullanılabilecek kalıpların belirlenmesini içerir. Bu teknik, potansiyel güvenlik tehditlerini tespit etmek ve gerçekleşmeden önce önlemek için kullanılabilir. Olay tahmini, ürün ve hizmetlere yönelik talebi tahmin etmek ve envanter yönetimini iyileştirmek için de kullanılabilir (Goodfellow vd., 2016).

Derin öğrenme, potansiyel güvenlik tehditlerinin ortaya çıkmadan önce tespit edilmesini sağlayan araçlar sunarak gözetim ve güvenlik alanına önemli ölçüde katkıda bulunmuştur. Derin öğrenmenin gözetim ve güvenlik alanındaki uygulamaları arasında nesne algılama, yüz tanıma, anormal davranış algılama ve

olay tahmini yer almaktadır. Bu uygulamalar havaalanları, hastaneler, bankalar ve alışveriş merkezleri de dahil olmak üzere çeşitli halka açık yerlerde güvenliği artırmak için kullanılmıştır.

Ayrıca derin öğrenme, büyük miktarda video verisini gerçek zamanlı olarak analiz edebilen ve gerektiğinde uyarılar sağlayabilen akıllı video gözetim sistemlerinin geliştirilmesini sağlamıştır. Bu sistemler insanları ve araçları tespit ve takip edebilir, şüpheli davranışları belirleyebilir ve suç faaliyetleri durumunda adli kanıt sağlayabilir.

Ancak derin öğrenmenin gözetim ve güvenlik alanında kullanımına ilişkin endişeler de bulunmaktadır. Bazıları bu teknolojilerin kullanımının gizlilik ihlallerine ve ayrımcılığa yol açabileceğini savunmaktadır. Bu nedenle, derin öğrenmenin gözetim ve güvenlikte kullanımını düzenleyen ve kamu yararına kullanılmasını sağlayan etik kuralların geliştirilmesi çok önemlidir.

3.5.3. Yatırım Kararları

Yatırım kararlarında nesne tespitinin uygulanması, yatırımcılara çeşitli varlık sınıfları hakkında değerli bilgiler sağlama potansiyeline sahip nispeten yeni bir araştırma alanıdır. Bu bağlamda, nesne tespiti uydu görüntüleri, finansal tablolar, haber makaleleri, sosyal medya gönderileri, tedarik zinciri verileri ve gayrimenkul verileri gibi farklı veri kaynaklarına uygulanabilmektedir (Rooney vd., 2019; Ramos ve Coelho, 2019; He ve Yang, 2020; Liang ve Yu, 2019; Lu vd., 2020).

Nesne tespiti kullanılarak yapılan uydu görüntüsü analizi, yatırımcılar için ekin tarlalarının izlenmesi, nakliye limanlarındaki faaliyetlerin değerlendirilmesi ve petrol depolama tanklarının envanter seviyelerinin takip edilmesi gibi değerli bilgiler sağlayabilir (Rooney vd., 2019). Örneğin, yatırımcılar belirli bir limandaki gemi sayısındaki değişiklikleri veya petrol depolama tanklarının boyutundaki değişiklikleri tespit etmek için nesne algılama algoritmalarını kullanabilir, bu da petrol piyasasının arz ve talep dinamiklerindeki değişiklikleri gösterebilir.

Yatırım kararlarında bir diğer çalışma Birogul, Temür ve Kose (2020) tarafından önerilmiştir.

Bu yeni yaklaşma Yolo nesne algılama algoritması ve teknik analiz göstergelerini kullanarak yatırımcılar için bir karar destek aracı sunmaktadır. Bu modelin kullanımı sayesinde yatırımcılar, geleneksel göstergeleri tamamlayarak daha bilinçli kararlar verebilirler. Bu model, Yolo ve mum formasyonları kullanarak alım sinyallerini doğrulamada ve satış sinyallerini tahmin etmede makul bir doğruluk göstermiştir. Bu çalışma sonuçlarına göre geleneksel birçok yöntemlere göre daha iyi performans göstermiştir.

Nesne algılama algoritmaları, bir şirketin finansal sağlığını değerlendirmek için gelir, gider ve hisse başına kazanç gibi finansal tablolardan belirli veri noktalarını çıkarmak için de kullanılabilir (Ramos & Coelho, 2019). Yatırımcılar, nesne tespiti ile mali tabloları analiz ederek bir şirketin mali performansındaki eğilimleri belirleyebilir, rakipleriyle karşılaştırabilir ve bilinçli yatırım kararları verebilir.

Haber makalelerini ve sosyal medya gönderilerini nesne algılama ile analiz etmek, yatırımcıların pazarda rekabet avantajı elde etmek için ürün lansmanları, birleşme ve satın almalar ve liderlik değişiklikleri gibi belirli olayları belirlemelerine yardımcı olabilir (He ve Yang, 2020). Örneğin, yatırımcılar bir şirketin liderlik ekibindeki kilit yöneticileri belirlemek için nesne algılama algoritmalarını kullanabilir ve duyarlılıklarını ve şirketin hisse senedi fiyatı üzerindeki potansiyel etkilerini ölçmek için sosyal medya etkinliklerini analiz edebilir.

Nesne tespiti aynı zamanda tedarik zinciri verilerini analiz etmek ve kesintiler, gecikmeler ve kalite sorunları gibi belirli olayları tespit ederek daha bilinçli yatırım kararları almak için de kullanılabilir (Liang ve Yu, 2019). Yatırımcılar, tedarik zinciri verilerini nesne tespiti ile analiz ederek bir şirketin tedarik zincirindeki potansiyel riskleri belirleyebilir ve bunların şirketin operasyonları ve finansal performansı üzerindeki etkisini değerlendirebilir.

Son olarak, gayrimenkul verilerinin nesne algılama ile analiz edilmesi, yatırımcıların daha iyi bilgilendirilmiş yatırım kararları vermek için bina boyutu,

konumu ve durumu gibi belirli özellikleri belirlemelerine yardımcı olabilir (Lu vd., 2020). Örneğin, yatırımcılar yeni inşaat projelerini belirlemek, belirli bir bölgedeki kiralık mülklere olan talebi değerlendirmek ve emlak piyasasında bilinçli yatırım kararları almak için bir şehrin silüetinin hava görüntülerini analiz etmek için nesne algılama algoritmalarını kullanabilir.

Sonuç olarak, nesne tespiti yatırımcılara çeşitli varlık sınıfları hakkında değerli bilgiler sağlayabilir ve bilinçli yatırım kararları almalarına yardımcı olabilir. Yatırım kararlarında nesne tespitin uygulanması nispeten yeni bir araştırma alanıdır ve nasıl etkili bir şekilde kullanılabileceği konusunda hala öğrenilecek çok şey vardır. Bununla birlikte, daha fazla veri elde edildikçe ve algoritmalar daha sofistike hale geldikçe, nesne tespitin gelecekte yatırımcılar için giderek daha önemli bir araç haline gelmesi muhtemeldir.

3.5.4. Tıbbi Görüntüleme

Tıbbi görüntülemede nesne tespiti, görüntülerdeki anormalliklerin tanımlanmasını ve lokalizasyonunu sağlayan kritik bir görevdir (Wang, Huang ve Wang, 2018). Son yıllarda, derin öğrenme teknikleri, özellikle de evrimsel sinir ağları, tıbbi görüntülemede nesne tespitinde devrim yaratarak doğruluk ve verimlilikte önemli gelişmeler sağlamıştır (Shen & Wu, 2017).

CNN'ler, özellikleri doğrudan verilerden öğrenebildikleri ve çok çeşitli görüntü özelliklerine uyum sağlayabildikleri için tıbbi görüntülerde nesne tespiti için özellikle uygundur (Zhu, Xie ve Liao, 2019). CNN tabanlı nesne algılama modelleri mamogramlar, CT taramaları ve MRI taramaları gibi tıbbi görüntülerdeki kanserli lezyonları tespit etmek için kullanılmıştır (Li, Liu, Li, Zhang ve Liang, 2018). Bu modeller radyologlara teşhislerinde yardımcı olabilir ve kanser tespitinin doğruluğunu artırabilir.

Tıbbi görüntülemede derin öğrenme tabanlı nesne tespitin en önemli avantajlarından biri, insanların tespit etmesi zor olan ince desenleri ve özellikleri yakalayabilen görüntülerin karmaşık temsillerini öğrenebilmesidir (Shen & Wu,

2017). Örneğin, CNN tabanlı modeller, kanser belirtisi olabilecek lezyonların şekli, dokusu ve yoğunluğundaki düzensizlikleri tanımlayabilir (Wang ve ark., 2018). Bu modeller ayrıca iyi huylu ve kötü huylu lezyonlar arasında ayrım yapmayı öğrenerek klinisyenlerin en iyi tedavi yöntemini belirlemelerine yardımcı olabilir.

Dermatologlar, cilt lezyonlarını doğru bir şekilde tanımlamak ve sınıflandırmak için genellikle nesne algılama algoritmaları kullanırlar. Derin öğrenme tabanlı modeller, dermoskopik görüntülerden lezyon tespitinde umut verici sonuçlar göstermiştir. Örnek olarak, Esteva ve diğerleri (2017) çeşitli cilt kanseri türlerini yüksek doğrulukla tespit edebilen ve erken cilt kanseri taraması için değerli bir araç sağlayan bir evrişimli sinir ağı (CNN) mimarisi geliştirmiştir.

Nesne algılama algoritmaları, bilgisayarlı tomografi taramalarında akciğer nodüllerini tespit etmek ve sınıflandırmak için kullanılabilir ve akciğer kanserinin erken teşhisine yardımcı olabilir. Örneğin, Ardila ve diğerleri (2019) bilgisayarlı tomografi taramalarında akciğer nodüllerinin tespiti için derin öğrenme tabanlı bir yöntem geliştirerek akciğer kanserinin taranmasına ve teşhisine yardımcı olmuştur.

Tıbbi görüntülemede nesne tespitinin birçok faydasına rağmen, bazı zorluklar ve sınırlamalar da vardır. Örneğin, derin öğrenme algoritmaları hesaplama açısından pahalı olabilir ve büyük miktarlarda hesaplama gücü ve bellek gerektirir. Bu durum, zaman ve kaynakların genellikle sınırlı olduğu klinik ortamlarda pratik kullanımlarını sınırlayabilir. Ayrıca, derin öğrenme algoritmalarının yorumlanması bazen zor olabilir, bu da tahminlerine nasıl ulaştıklarını anlamayı zorlaştırabilir.

3.5.5. Robotik

Nesne algılama, makinelerin çevrelerini algılamalarına ve nesnelerle gerçek zamanlı olarak etkileşime girmelerine olanak tanıdığı için robotik uygulamalarının çok önemli bir yönüdür (Russell vd., 2019). Nesne algılama, belirli bir ortamdaki nesneleri tanımlamak için sensörlerin, kameraların ve algoritmaların kullanılmasını içerir ve otonom araçlar, üretim ve sağlık hizmetleri gibi alanlarda çok çeşitli pratik uygulamalara sahiptir.

Robotik bağlamında, nesne algılama tipik olarak robotlara veya diğer cihazlara monte edilmiş kameralardan gelen görüntüleri veya video akışlarını analiz etmek için bilgisayarla görme tekniklerinin kullanılmasını içerir (Russell vd., 2019). Nesne tespitine yönelik yaygın yaklaşımlardan biri, görüntülerdeki belirli nesneleri veya desenleri tanımak için eğitilebilen bir tür derin öğrenme algoritması olan konvolüsyonel sinir ağlarını kullanmaktır (Ren vd., 2015). CNN'lerin nesne algılama görevlerinde oldukça etkili olduğu ve CNN tabanlı yaklaşımları kullanan birçok son teknoloji nesne algılama sistemi olduğu gösterilmiştir (Russell vd., 2019).

Robotikte nesne tespitinin bir örneği otonom araçlar alanındadır. Kendi kendine giden arabalar gibi otonom araçlar, çevrelerinde güvenli bir şekilde gezinmek ve diğer araçlar, yayalar ve engellerle çarpışmalardan kaçınmak için nesne algılama algoritmalarına güvenir (Russell vd., 2019). Bu sistemlerde, kameralar ve diğer sensörler aracın çevresiyle ilgili verileri yakalamak için kullanılır ve CNN tabanlı nesne algılama algoritmaları bu verileri gerçek zamanlı olarak analiz etmek ve nasıl gezinileceğine dair kararlar vermek için kullanılır.

Robotikte nesne tespitinin bir başka örneği de üretim uygulamalarıdır. Üretim ortamlarında robotlar genellikle ürünleri monte etmek veya malzemeleri farklı konumlar arasında taşımak gibi tekrarlayan görevleri yerine getirmek için kullanılır (Russell vd., 2019). Nesne algılama algoritmaları, bu robotların çevrelerindeki nesneleri tanımlamalarına ve bulmalarına yardımcı olarak görevlerini daha verimli ve doğru bir şekilde yerine getirmelerini sağlamak için kullanılabilir.

Robotikte nesne tespitinin üçüncü bir örneği de sağlık uygulamalarıdır. Cerrahi robotlar gibi tıbbi robotlar, tümörler veya diğer anormallikler gibi vücuttaki belirli yapıları tanımlamak ve bulmak için nesne algılama algoritmalarını kullanabilir (Russell vd., 2019). Bu, cerrahların daha hassas ve hedefe yönelik prosedürler gerçekleştirmesine yardımcı olarak komplikasyon riskini azaltabilir ve hasta sonuçlarını iyileştirebilir.

Robotik uygulamalarda nesne tespitinin birçok faydasına rağmen, dikkate alınması gereken bazı zorluklar ve sınırlamalar da vardır. En büyük zorluklardan biri, çok çeşitli ortamlarda ve aydınlatma koşullarında çalışabilen sağlam ve güvenilir

algoritmalarla duyulan ihtiyaçtır (Russell vd., 2019). Bir diğer zorluk ise robotik uygulamalarda gerçek zamanlı nesne tespiti sıklıkla gerekli olduğundan doğruluk ve hız arasında denge kurma ihtiyacıdır.

Sonuç olarak, nesne algılama birçok robotik uygulamasının kritik bir bileşenidir ve makinelerin çevrelerini gerçek zamanlı olarak algılamalarını ve etkileşime girmelerini sağlar. CNN tabanlı algoritmaların nesne algılama görevlerinde oldukça etkili olduğu kanıtlanmıştır ve otonom araçlar, üretim ve sağlık hizmetleri de dahil olmak üzere çeşitli alanlarda başarıyla uygulanmıştır (Russell vd., 2019). Teknoloji ilerlemeye devam ettikçe, nesne algılamanın robotik uygulamalarında giderek daha önemli bir rol oynaması, makinelerin daha karmaşık görevleri yerine getirmesine ve çevreleriyle yeni ve yenilikçi yollarla etkileşime girmesine olanak sağlaması muhtemeldir.

3.6. Derin Öğrenme ile Nesne Algılamanın Geleceği

Son yıllarda, nesne algılama önemli ilerlemeler kaydetmiş ve bilgisayarla görme alanında temel bir görev haline gelmiştir. Bir görüntü veya video içindeki nesneleri tanımlama ve konumlandırma işlemidir ve otonom sürüş, robotik ve gözetim gibi çok sayıda uygulamaya sahiptir. Nesne algılama teknikleri Haar kaskadları, Viola-Jones ve SIFT gibi geleneksel yöntemlerden Faster R-CNN, YOLO ve RetinaNet gibi derin öğrenme tabanlı modellere doğru evrilmiştir. Bu modern yöntemler etkileyici sonuçlar elde etti ve gelişmeye devam ediyor.

Nesne tespitinin gelişmesi muhtemel alanlarından biri doğruluktur. Mevcut nesne algılama yöntemleri yüksek hassasiyet ve hatırlama oranlarına sahiptir, ancak hala iyileştirme için yer vardır. Özellikle, oklüzyon, küçük nesne tespiti ve görüntü bozulmasını ele alabilen tekniklere hala ihtiyaç vardır. Bu zorlukların üstesinden gelebilecek daha gelişmiş algoritmaların geliştirilmesinin nesne algılama modellerinin doğruluğunu artırması beklenmektedir. Örneğin, araştırmacılar oklüzyon ve küçük nesne tespitini ele almak için dikkat mekanizmalarını kullanmayı önermiş ve sonuçlar umut verici olmuştur (Wang vd., 2020).

Nesne tespitiinin gelişmesi muhtemel bir diğer alanı da hızdır. Mevcut nesne algılama modelleri, video akışları için gerçek zamanlı işleme sağlayabilir, ancak milisaniyelik gecikmelerin kritik olabileceği otonom sürüş gibi uygulamalarda kullanım için her zaman yeterince hızlı değildir. Akıllı telefonlar ve gömülü sistemler gibi düşük güçlü cihazlarda gerçek zamanlı işlem yapabilen daha verimli modellere ihtiyaç vardır. Bu sorunu çözmek için niceleme, budama ve NAS dahil olmak üzere çeşitli yaklaşımlar önerilmiştir (Tan vd., 2020). Bu teknikler, yüksek doğruluğu korurken nesne algılama modellerinin hesaplama gereksinimlerini azaltmada önemli bir umut vaat etmiştir.

Nesne tespitiinin diğer bilgisayarla görme görevleriyle entegrasyonu, potansiyel gelişimin bir başka alanıdır. Nesne algılama genellikle segmentasyon, izleme ve tanıma gibi diğer görevlerle birlikte kullanılır. Bu görevlerin entegrasyonu, bilgisayarla görme sistemlerinin genel performansını artırabilir. Örneğin, nesne tespitiinin örnek segmentasyonu ile birleştirilmesi daha doğru ve hassas nesne lokalizasyonu sağlayabilir (Li vd., 2017). Ayrıca, nesne tespitiinin takviyeli öğrenme ile entegrasyonu, robotların çevrelerini daha etkili bir şekilde algılamalarını ve etkileşimde bulunmalarını sağlayabilir (Zhang vd., 2020).

Son olarak, nesne tespitinde sentetik veri kullanımının daha yaygın hale gelmesi beklenmektedir. Sentetik veri üretimi, gerçek dünya verilerinin çeşitlilik eksikliği ve yüksek açıklama maliyeti gibi sınırlamalarının üstesinden gelmeye yardımcı olabilir. Sentetik veri üretmek için üretken karşıt ağlar ve simülasyon ortamları kullanmak da dahil olmak üzere çeşitli yaklaşımlar önerilmiştir (Tremblay vd., 2018). Sentetik veriler, nesne algılama modellerinin farklı aydınlatma koşullarına, kamera açılarına ve nesne varyasyonlarına karşı sağlamlığını artırmak için kullanılabilir.

Sonuç olarak, nesne algılama son yıllarda uzun bir yol kat etti ve gelişmeye devam ediyor. Nesne algılamanın geleceğinin gelişmiş doğruluk, hız, diğer bilgisayarla görme görevleriyle entegrasyon ve sentetik veri kullanımı ile karakterize edilmesi beklenmektedir. Bu gelişmeler, nesne algılamanın daha geniş bir uygulama

yelpazesinde kullanılmasını ve daha karmaşık görevleri yerine getirmesini sağlayacaktır.



DÖRDÜNCÜ BÖLÜM

YOLO İLE ELLIOTT DALGALARIN TESPİTİ VE ANALİZİ

Bu bölümde, popüler bir nesne algılama algoritması olan YOLO tekniği kullanılarak Elliott Dalgalarının tespiti ve analizi 2000-2021 yılları arasında Yahoo Finance'dan alınan toplamda 500 adet veri üzerinde eğitilmiştir. Amaç, hisse senetlerin 2 boyutlu mum grafiklerinde Elliott Dalgalarının karmaşık modellerini doğru bir şekilde tanımlayabilen ve analiz edebilen bir model geliştirmektir.

Bir önceki bölümde, makine öğrenimi modellerinin eğitimi için veri toplamının önemini tartışmıştık. Bu nedenle, ilk olarak YOLO tabanlı modelimizi etkili bir şekilde eğitmek için kapsamlı veri toplanmıştır. Daha sonra toplanan verilerin kalitesi ve uyumluluğu sağlanmıştır. Ayrıca, modelin performansını değerlendirmek için verileri eğitim ve test kümelerine ayrılmıştır.

YOLO modelini eğitmek için, büyük bir etiketli veri kümesi kullanarak modelin parametrelerini optimize etmeyi içeren bir metodoloji kullanılmıştır. Eğitim sürecinde, modelin kayıp fonksiyonunu en aza indirmek ve tespit doğruluğunu artırmak için gradyan inişi ve geriye yayılma gibi teknikler kullanılmış ve YOLO modeli eğitildikten sonra, test veri kümesini kullanarak performansı değerlendirilmiştir.

4.1. Veri Toplama

Bu çalışmada önerilen model, S&P 500 endeksinde listelenen hisse senetlerinin fiyat verilerinin iki boyutlu mum çubuğu grafik görünümleri kullanılarak eğitilmiş ve değerlendirilmiştir. Geçmiş hisse senedi fiyatlarını toplamak için Yahoo Finance API'sini kullanmış ve Python programlama dilinden faydalanılmıştır.

S&P 500'den elde edilen finansal veriler Python'da işlenerek 2 boyutlu mum çubuğu grafik gösterimleri elde edilmiştir. S&P 500 endeksinde listelenen hisse senetlerin özellikle farklı sektörlerden olmasına özen gösterilmiştir. Veri kümesi,

2000 ila 2021 yıllarını kapsayan ve boyutları 1800 × 650 piksel olan iki boyutlu mum çubuğu grafiklerinden oluşmaktadır. Bu grafiklerde, hisse senetlerinin spekülâtif ve manipülâtif grafik formasyonları sergilediği durumlar dışında, herhangi bir ek gösterge kullanılmamıştır.

Bu çalışma için, Grafik 1'de gösterildiği gibi, toplam 500 adet 2 boyutlu mum çubuğu grafiği toplanmış ve saklanmıştır. Her mum çubuğu bir günü temsil etmektedir. Veri setinde ayrıca gün sonu fiyatları kullanılarak oluşturulan test grafikleri de yer almıştır. Bu grafikler Elliott dalgalarını analiz etmek için değerli kaynaklar olarak kullanılmıştır. Her grafik, yarım yıl gibi belirli bir zaman dilimini temsil eden yaklaşık 180 mum çubuğundan oluşuyor. Bununla birlikte, bir yıldaki işlem günü sayısındaki küçük farklılıklar nedeniyle, toplam mum çubuğu sayısında yaklaşık %10'luk hafif bir dalgalanma olmuştur.

Grafik 1. İki boyutlu mum grafiği



Grafik 1'de gösterilen mum grafiği, finansal piyasalardaki fiyat hareketlerini analiz etmek için teknik analizde popüler ve yaygın olarak kullanılan bir araçtır. Mum grafikleriyle ilgili önemli noktalar:

Temsil: Mum çubuğu grafikleri bir varlığın belirli bir zaman aralığındaki fiyat hareketini temsil eder ve genellikle bir grafik üzerinde bir dizi mum çubuğu olarak gösterilmektedir.

Bileşenler: Her mum çubuğu dikdörtgen bir gövde ve gövdeden uzanan fitil veya gölge adı verilen iki çizgiden oluşur. Gövde, açılış ve kapanış fiyatları

arasındaki fiyat aralığını temsil ederken, fitiller zaman dilimi içindeki en yüksek ve en düşük fiyatları temsil eder.

Renkler: Mum çubuğunun gövdesinin rengi fiyat hareketi hakkında bilgi verir. Yeşil veya beyaz bir gövde, kapanış fiyatının açılış fiyatından yüksek olduğu bir yükseliş veya pozitif fiyat hareketini gösterir. Buna karşılık, kırmızı veya siyah gövde kapanış fiyatının açılış fiyatından daha düşük olduğu ayı veya negatif fiyat hareketini gösterir.

Yorumlama: Mum çubuğu grafikleri yatırımcıların ve analistlerin piyasa duyarlılığını belirlemelerine ve bilinçli kararlar almalarına yardımcı olur. Mum çubuğu, fiyat oynaklığı, destek ve direnç seviyeleri, trend dönüşleri ve alım satım için potansiyel giriş veya çıkış noktaları hakkında görsel ipuçları sağlamaktadır.

Veri setinin kapsamlı bir piyasa koşulları yelpazesini kapsamasını sağlamak için grafikler yıllık verileri içerecek şekilde tasarlanmıştır. Sonuç olarak, her grafik iki ayrı bölüme ya da kısma ayrılmıştır. İlk kısım yılın ilk yarısındaki piyasa faaliyetlerini temsil ederken, ikinci kısım yılın ikinci yarısını göstermiştir. Bu bölünme, farklı zaman dilimlerindeki fiyat hareketlerini ve kalıplarını inceleyip karşılaştırmasına olanak tanıyarak piyasa dinamiklerinin daha derinlemesine anlaşılmasını sağlamaktadır.

Grafikleri iki bölüme ayırarak, bir yıl içinde meydana gelebilecek potansiyel mevsimsel veya döngüsel kalıpları gözlemlemek daha kolay hale geldi. Ayrıca bu bölümlenme, belirli bir dönemde meydana gelmiş olabilecek önemli olayların veya piyasa değişimlerinin tespit edilmesini kolaylaştırarak veri setinin analitik değerini daha da artırmıştır.

4.2. Veri Ön İşleme

Elliott Dalgalarını 500 adet 2 boyutlu mum çubuğu grafiği üzerinde etiketleme işlemi "LabelImg" adı verilen görsel yazılımın kullanımı ile yapılmıştır. Bu yazılım özellikle açık kaynak kodlu olarak Python programlama dili kullanılarak

Veri ön işleme tüm uygulama sürecinin en uzun süren ve en önemli bölümüdür. Öncelikle grafikler etiketleme programına yüklendi ve mevcut dalgaları tanımlandı. Etiketleyici yazılımı kullanarak her bir mum grafiğini dikkatle incelendi ve fiyat hareketlerinin oluşturduğu formasyonlar tespit edildi.

Grafik 2. Dürtü dalgası



78

Grafik 3. Düzeltici dalga



Grafik 2 ve 3’de olduğu gibi mum grafiklerindeki her dalganın etrafına sınırlayıcı kutular çizmek için etiketleme yazılımı kullanmıştır. Daha sonra çizilen her kutu için, Tablo 1’de gösterildiği gibi tanımlanan dalga modeline göre 'Dürtü' ya da 'Düzeltici' gibi uygun bir etiket atanmıştır.

Tablo 1. Etiketleme örnekleri

Dürtü Etiketi				
Düzeltici Etiketi				

Bu işlem 2 boyutlu 500 mum çubuğu grafiğinin tamamı için manuel tekrarlanarak veri kümesi genelinde tutarlı ve doğru etiketleme sağlanmıştır. Görüntüdeki nesneleri etiketlemeyi tamamladıktan sonra, LabelImg kullanarak ek açıklamaları farklı formatlarda kaydetme seçeneği vardır. Bu araç Pascal VOC XML,

YOLO ve COCO JSON gibi çeşitli ek açıklama formatlarını destekler. Önerilen model YOLO olduğu için veriler YOLO formatında kaydedildi. Grafik 4’de gösterildiği gibi bu formatlar nesnelerin koordinatları, bunlara karşılık gelen etiketler ve diğer ilgili ayrıntılar gibi önemli bilgileri içerir.

Grafik 4. Etiketli görüntünün ".txt" dosya içeriği.

0	0.318056	0.476154	0.209444	0.650769
1	0.601667	0.703077	0.355556	0.206154

Bu '.txt' dosyalarında bulunan içeriğin açıklanması:

Nesne Bilgileri: Metin dosyasındaki her satır açıklamalı bir nesneyi temsil eder. Her nesne için bilgiler boşluk veya sekmelerle ayrılmıştır.

Nesne Sınıfı İndeksi: Her satırdaki ilk öge nesne sınıfının indeksine veya kimliğine karşılık gelir. YOLO'da sınıf indeksi genellikle 0'dan başlar ve her benzersiz sınıf için artar. Bu indeks, nesnenin ait olduğu belirli sınıfın tanımlanmasına yardımcı olur.

Nesne Koordinatları: Satırdaki sonraki ögeler nesnenin sınırlayıcı kutu koordinatlarını temsil eder. Bu koordinatlar tipik olarak sınırlayıcı kutunun merkez koordinatlarını (x, y) ve genişliğini (w) ve yüksekliğini (h) içerir. YOLO uygulamasına bağlı olarak, bu koordinatlar görüntü boyutlarına göre mutlak değerler veya normalleştirilmiş değerler olarak gösterilebilir.

Normalleştirme: Koordinatlar normalleştirilirse, genellikle 0 ile 1 arasında ölçeklendirilirler; burada (0, 0) görüntünün sol üst köşesini ve (1, 1) sağ alt köşesini temsil eder.

Grafik 4’e baktığımızda ilk satır, sınırlayıcı kutu koordinatları (0,318056, 0,476154) merkez, genişliği 0,209444 ve yüksekliği 0,650769 olan 0 sınıfı bir nesneyi temsil eder. İkinci satır ise sınırlayıcı kutu koordinatları (0.601667, 0.703077) merkez, genişliği 0.355556 ve yüksekliği 0.206154 olan sınıf 1'e ait bir

nesneyi temsil etmektedir. Bu '.txt' dosyaları, YOLO tabanlı nesne algılama modelleri için eğitim sürecinde yaygın olarak girdi olarak kullanılır.


Veri ön işleme sonucunda toplamda 2037 adet etiket hazırlandı, bunlardan 1026-sı “Dürtü” sınıfına kalan 1012-si ise “Düzeltilici” sınıfına aittir. Bu etiketlenmiş veri seti artık makine öğrenimi modellerini eğitmek veya finansal piyasalardaki Elliott dalga modellerinin daha fazla analizini yapmak gibi çeşitli amaçlar için kullanılabilir.

4.3. Önerilen Model

Daha önce de belirtildiği gibi bu çalışma, finansal ticaret alanında Elliott dürtü ve düzeltme dalgalarını doğru bir şekilde tanımlamak ve analiz etmek için YOLO metodolojisini etkin bir şekilde kullanan yeni bir model sunmaktadır. Bu yeni modelin temel amacı, yatırımcılar için yatırım kararlarını basitleştirirken alım satım tercihlerinin genel kalitesini yükseltmektir. Geleneksel yöntemlerden farklı olarak bu model, yalnızca zaman serisi verilerine dayanmak yerine hisse senetlerinin 2 boyutlu mum grafiklerini kullanarak öncü bir yaklaşım benimsemektedir. Ayrıca model, dalgaları dürtü ve düzeltme olmak üzere iki kategoriye ayırarak bir sınıflandırma görevi de üstlenmektedir.

Modelin karmaşık tasarımı ve işlevselliği Grafik 5'de açıklanmaktadır. Süreç, ham iki boyutlu mum grafiklerinin toplanması ve ardından tanımlanan dalgalara uygun etiketlerin atanmasıyla başlar. Bu etiketli dalgalar daha sonra modelin performansını iyileştirmek ve geliştirmek için Darknet-53 ağı da dahil olmak üzere birden fazla katmandan geçerek kapsamlı bir eğitim sürecinden geçer. Sonuç olarak, eğitilmiş model etiketli dalgaları girdi olarak alır ve sistemin çıktısı olarak Dürtü ve Düzeltilici dalgalarını yetkin bir şekilde tanır.

Grafik 5. Önerilen modelin adımları



Eğitim sürecini kolaylaştırmak için, belirlenen dalgalara uygun etiketler atanır. Bu etiketler, modelin dürtü ve düzeltme dalgaları arasında ayırım yapmasını sağlayan önemli göstergeler olarak hizmet eder. Model, bu iki dalga türünü birbirinden ayırarak yatırımcılara piyasa trendlerini anlamak ve gelecekteki fiyat hareketlerini tahmin etmek için değerli bir araç sunar.

Modelin performansını artırmak için Darknet-53 ağını kullanan çok katmanlı bir yaklaşım kullanılmaktadır. Darknet-53 ağı, karmaşık verilerden üst düzey özellikler çıkarma kabiliyetiyle ünlüdür. Etiketlenmiş dalgaların bu ağdan geçirilmesiyle model bir iyileştirme ve optimizasyon sürecinden geçer. Ağ, dürtü ve düzeltme dalgalarına özgü kalıpları ve özellikleri tanımayı öğrenerek yeni dalgaları gerçek zamanlı olarak doğru bir şekilde sınıflandırmasını sağlar.

4.4. Eğitim Metodolojisi

Eğitim metodolojisi verimli ve doğru nesne tespitini kolaylaştırmak için YOLOv4, Darknet-53 ve önceden eğitilmiş parametreleri entegre etmektedir. Darknet-53'ün önceden eğitilmiş parametrelerinin omurga ağında kullanılması, daha

hızlı yakınsama sağlar ve kapsamlı eğitim süresi ve kaynaklarına olan talebi azaltır. Bu yaklaşım, özel veri setindeki ince ayarlarla birleştğinde, modelin Elliottun dürtü ve düzeltme dalgalarını etkili bir şekilde tespit etmesini sağlar. Grafik 6’da Darknet-53-ün detaylı mimarisi verilmiştir.

Grafik 6. Darknet-53-ün mimarisi


	Type	Filters	Size	Output
	Convolutional	32	3 × 3	256 × 256
	Convolutional	64	3 × 3 / 2	128 × 128
1×	Convolutional	32	1 × 1	
	Convolutional	64	3 × 3	
	Residual			128 × 128
	Convolutional	128	3 × 3 / 2	64 × 64
2×	Convolutional	64	1 × 1	
	Convolutional	128	3 × 3	
	Residual			64 × 64
	Convolutional	256	3 × 3 / 2	32 × 32
8×	Convolutional	128	1 × 1	
	Convolutional	256	3 × 3	
	Residual			32 × 32
	Convolutional	512	3 × 3 / 2	16 × 16
8×	Convolutional	256	1 × 1	
	Convolutional	512	3 × 3	
	Residual			16 × 16
	Convolutional	1024	3 × 3 / 2	8 × 8
4×	Convolutional	512	1 × 1	
	Convolutional	1024	3 × 3	
	Residual			8 × 8
	Avgpool		Global	
	Connected		1000	
	Softmax			

Darknet-53 mimarisi 53 konvolüsyonel katmandan oluşmaktadır, dolayısıyla adı da buradan gelmektedir. Her katmanın giriş verilerini sırayla işleyerek giderek daha soyut temsiller çıkardığı sıralı bir yapı izler. Mimari, hem yerel hem de küresel bağlamsal bilgileri yakalamak için konvolüsyonel katmanlar, maksimum havuzlama katmanları ve kısayol bağlantılarının bir kombinasyonunu kullanır.

Darknet-53 mimarisinin verimliliği önemli bir özelliktir. Tasarımı, doğruluğu korurken hesaplama kaynaklarının optimizasyonuna öncelik verir. Bu, özellik kanallarının miktarını azaltan 1x1 konvolüsyonel katmanların dahil edilmesiyle gerçekleştirilir. Sonuç olarak, model parametreleri ve hesaplama karmaşıklığı etkili bir şekilde azaltılır.

Daha önce belirtildiği gibi YOLO modeli "Dürtü" ve "Düzeltici" etiketlerini içeren özel bir veri kümesi üzerinde eğitilmiştir. Grafik 7 incelendiğinde, 6,81446'lık mevcut ortalama kayıp ve %64,4'lük etkileyici nihai mAP yüzdesinden de anlaşılacağı üzere, eğitim sürecinin kayda değer başarısını ortaya koymaktadır. Veri kümesindeki belirli unsurların tanımlanmasındaki potansiyel zorluklara rağmen, elde edilen sonuçlar eğitim prosedürünün etkinliğini göstermektedir. Eğitim süreci boyunca elde edilen en yüksek mAP değerinin %71 olduğunu belirtmek gerekir. Bu nedenle, araştırmanın amaçları doğrultusunda, bu %71'lik mAP değerine karşılık gelen ağırlıkları kullanılmıştır.

Grafik 7. Modelin eğitim sonuçları



Modelin eğitim sürecinde .cfg (yapılandırma) dosyası kullanılmıştır. YOLOv3 ve YOLOv4 gibi nesne algılama modelleri de dahil olmak üzere eğitim modellerinde önemli bir bileşendir. Model mimarisinin çeşitli yönlerini, hiperparametreleri, eğitim ayarlarını ve başarılı model eğitimi için gerekli diğer önemli parametreleri tanımlayan bir yapılandırma dosyası görevi görür. Yapılandırma dosyasında kullanılmış en önemli parametreler aşağıda belirtilmiştir:

Toptan: Toptan boyutu 64 olarak ayarlanmıştır, bu da her eğitim iterasyonunda 64 görüntünün birlikte işleneceği anlamına gelir. Bu parametre modelin bellek kullanımını ve eğitim hızını etkiler.

Alt bölümler: 64 değeriyle, yığın daha küçük parçalara bölünerek eğitim sırasında bellek optimizasyonuna olanak tanır. Her alt bölüm, yığının bir alt kümesini işleyerek genel bellek gereksinimlerini azaltır.

Genişlik ve yükseklik: Giriş görüntüleri 416x416 piksel sabit bir boyuta yeniden boyutlandırılacaktır. Model, eğitim sırasında tutarlılığı korumak için bu boyuttaki görüntüleri bekler.

Kanallar: 3 değeri verilmiştir, girdi görüntülerinin kırmızı, yeşil ve mavi olmak üzere üç renk kanalından oluşan RGB formatında olduğunu gösterir.

Momentum: Momentum parametresi, optimizasyon sırasında önceki ağırlık güncellemelerinin mevcut güncelleme üzerindeki etkisini belirleyen 0,949 değeri olarak ayarlanmıştır. Daha yüksek bir momentum değeri daha hızlı yakınsama sağlar.

Sönüm: Sönme parametresi 0,0005 olarak ayarlanmıştır ve ağırlık bozulması veya düzenleme faktörünü gösterir. Eğitim sırasında büyük ağırlık değerlerini cezalandırarak aşırı uyumu önlemeye yardımcı olur.

Açı, doygunluk, pozlama, renk tonu: Bu parametreler giriş görüntülerine uygulanan veri artırımının kapsamını kontrol eder. Açının 0 olması döndürme olmadığı anlamına gelirken, 1,5'lik doygunluk ve pozlama değerleri artan renk doygunluğu ve pozlama seviyelerini gösterir. 0,1'lik bir renk tonu değeri, büyütme sırasında hafif renk tonu değişimleri sunar.

Öğrenme oranı: Öğrenme oranı 0,001 olarak ayarlanır ve eğitim sırasında model parametrelerinin güncellendiği adım boyutunu belirler. Yakınsama hızını ve optimizasyon sürecini etkiler.

Yanma: 1000 değeriyle, yanma aşaması eğitimin ilk 1000 iterasyonu için sürer. Bu aşama sırasında, optimizasyon sürecini stabilize etmek için öğrenme oranı kademeli olarak artar.

Maksimum yığın: Eğitim için maksimum yığın veya iterasyon sayısı 1800 olarak ayarlanır. Bu sınıra ulaşıldığında eğitim süreci sonlandırılır.

Politika, adım, ölçek: Öğrenme oranı çizelgesi bir adım politikası izler. Öğrenme oranı 1440 ve 1620 iterasyonlarda 0,1 kat azalır. Bu adımlar, iyileştirilmiş optimizasyon için öğrenme hızı düşüşünün ince ayarının yapılmasına yardımcı olur.

Bu parametrelerin .cfg dosyasında anlaşılması ve uygun şekilde ayarlanması, etkili model eğitimi için çok önemlidir. Bellek kullanımı, yakınsama hızı, düzenlileştirme ve veri artırımı gibi eğitim sürecinin çeşitli yönlerini etkilerler ve sonuçta eğitilen modelin performansını ve doğruluğunu belirler.

4.5. Test ve Bulgular

Önerilen modelin eğitim aşamasında S&P 500 endeksinde listelenen hisse senetlerinin 2000-2021 yılları grafiklerinden faydalanmıştır, test aşamasında ise modele dahil edilmemiş 2022 yılı grafikleri kullanılmıştır. Model başarısını değerlendirmek ve yatırım kararlarında faydalı olup olmadığını ölçmek için modelin tespit ettiği “Dürtü” ve “Düzeltilici” dalgaları esasında Al-Sat kararları verilmiştir. Dürtü ve düzeltme dalgalarına dayalı alım satım süreci birkaç temel adım içermektedir. İlk olarak, önerilen model, finansal alım satım verilerinde hem yukarı ve aşağı yönlü dürtü dalgalarını hem de düzeltme dalgalarını tanımlamak için kullanılır. Bu model, dürtü dalgalarının hem yukarı hem de aşağı yönde oluşabileceğini göz önünde bulundurarak her dalga için sınıflandırmalar sağlar. Dalgalar tespit edildikten sonra bir alım satım stratejisi oluşturulur. Grafik 8’de gösterildiği gibi yukarı yönlü bir dürtü dalgası tespit edildiğinde, dürtü dalgasından sonra düzeltme olacağı için fiyatın düzeltilmesi beklendiğinden kısa bir pozisyon (satış) düşünülür. Öte yandan, Grafik 9’da olduğu gibi aşağı yönlü bir dürtü dalgası tespit edilirse, yine ters yönde düzeltme dalgası oluşacağı için yukarı yönlü bir fiyat hareketi öngörülerek uzun bir pozisyon (alım) düşünülür.

Grafik 8. Yukarı yönlü dürtü dalgası



Grafik 9. Aşağı yönlü dürtü dalgası



Önerilen model ilk düzeltici dalgayı tespit ettiğinde, bunun yukarı ya da aşağı yönde gerçekleşebileceğini kabul etmek önemlidir. Modelin sınıflandırması, yukarı yönlü bir düzeltme mi yoksa aşağı yönlü bir düzeltme mi olduğunu göstererek düzeltici dalganın doğası hakkında fikir verecektir.

Grafik 10’da gösterildiği gibi yukarı yönlü bir düzeltme dalgası söz konusu olduğunda, genel bir düşüş trendi içinde geçici bir geri çekilme veya düzeltme anlamına gelir. Bu durum, düzeltme tamamlandıktan sonra fiyatın aşağı yönlü hareketine devam edeceği beklentisiyle yatırımcıların potansiyel olarak kısa bir pozisyona girmesi (satış) için bir fırsat sunar.

Grafik 10. Yukarı yönlü düzeltici dalga



Diğer taraftan, Grafik 11’de gösterildiği gibi model aşağı yönlü düzeltici bir dalga tespit ederse, daha büyük bir yükseliş eğilimi içinde geçici bir düşüş demektir. Yatırımcılar, düzeltmeden sonra yükseliş trendinin sürmesi beklentisiyle kâr elde etmek için uzun bir pozisyon başlatmayı düşünebilirler. Alış sürecine benzer şekilde, satış sürecinde de giriş ve çıkış noktalarının belirlenmesi ve risk yönetimi tekniklerinin uygulanması çok önemlidir.

Grafik 11. Aşağı yönlü düzeltici dalga



Modelin değerlendirilmesinde tesadüf etkisi olmaması için farklı beş sektörden toplam 25 hisse senedi seçilmiştir ve her sektör bir grubu temsil etmektedir. Değerlendirme, farklı sektörlerden hisse senetlerinin sinyal, pozisyon, tarih, önerilen fiyat ve sonuç yüzdesi gibi bilgilerini içermektedir. Bu veriler, modelin değerlendirilmesinde belirli bir dönemde yapılan işlemleri ve önerileri göstermektedir. Başlıklarla ilgili detaylı bilgi aşağıda belirtilmiştir:

Sektörler: Tabloda Teknoloji, Sağlık, Enerji, Finans ve Gayrimenkul gibi çeşitli sektörler yer almaktadır. Her sektör, piyasanın belirli bir endüstrisini veya alanını temsil eder.

Hisse Senedi İsimleri: Tabloda listelenen hisse senedi adları, kendi sektörlerindeki belirli şirketlere karşılık gelir.

Sinyaller: Sinyaller, tespit edilen dalganın bir dürtü (Dürtü) mü yoksa bir düzeltme (Düzeltilici) mi olduğunu gösterir. Bu sinyaller önerilen model tarafından üretilir ve potansiyel piyasa trendlerinin belirlenmesine yardımcı olur.

Pozisyonlar: Pozisyonlar, tespit edilen dalgalara dayalı olarak alınması önerilen eylemleri gösterir. "AL" uzun pozisyonu (alış) temsil ederken, "SAT" kısa pozisyonu (satış) temsil eder.

Tarihler: Tarihler, dalgaların model tarafından tespit edildiği veya önerilen eylemlerin başlatıldığı ve bittiği belirli tarihleri belirtir.

Önerilen Fiyatlar: Önerilen fiyatlar, ilgili pozisyonlar için önerilen giriş veya çıkış fiyatlarını gösterir. Uzun pozisyonlar için bir alış fiyatı, kısa pozisyonlar için ise bir satış fiyatı önerir.

Sonuç (%): Sonuç sütunu, önerilen fiyat ile çıkış noktasındaki önerilen fiyat arasında ortaya çıkan yüzde değişimini temsil eder. Pozitif değerler kazançları gösterirken, negatif değerler kayıpları gösterir.

Tablo 2. Modelin teknoloji sektörüne göre değerlendirilmesi

Sektör	Hisse adı	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sonuç %
Teknoloji	AAPL	Dürtü	SAT	2022.08.19	173	Düzeltilici	AL	2022.09.12	163,43	5,53
Teknoloji	ACN	Dürtü	AL	2022.03.08	303,9	Düzeltilici	SAT	2022.03.30	336,5	10,72
Teknoloji	ADBE	Dürtü	AL	2022.06.24	380,48	Düzeltilici	SAT	2022.08.12	439,29	15,45
Teknoloji	AMD	Düzeltilici	SAT	2022.06.08	104,5	Dürtü	AL	2022.07.07	77,3	26
Teknoloji	CRM	Dürtü	AL	2022.02.18	200,18	Düzeltilici	SAT	2022.08.05	187,39	-6,39

Tablo 2’de teknoloji sektöründeki hisse senetlerinin fiyatlarındaki değişimler incelendiğinde, farklı sonuçlar elde edildiği görülmektedir. Bazı hisse senetleri üzerinde gerçekleştirilen işlemler kârlı sonuçlanmışken, bazıları ise zararlı sonuçlanmıştır. Örnek olarak, AMD hisse senedi üzerinde yapılan işlem %26 kârlı bir sonuç vermiştir. Bu, hisse senedinin önerilen fiyatından satın alındığında değerinin %26 arttığını gösterir. Bu durum, AMD hisse senedinin yüksek bir performans gösterdiğini ve yatırımcılara kâr getirdiğini işaret eder. AAPL hisse senedi üzerinde gerçekleştirilen işlem ise daha küçük bir kâr yüzdesiyle %5,53 kârlı sonuçlanmıştır. Bu, hisse senedinin önerilen fiyatından satın alındığında değerinin daha az oranda arttığını gösterir. AAPL hisse senedinin performansı, AMD hissesine kıyasla daha ılımlı olsa da yine de bir kâr getirmiştir. Ancak, tablodaki diğer hisse senetlerinde bazı işlemler zararlı sonuçlanmıştır. Örneğin, CRM hisse senedi üzerinde yapılan işlem %6,39 kayıpla sonuçlanmıştır. Bu, hisse senedinin önerilen fiyatından satın alındığında değerinin %6,39 azaldığını gösterir. Benzer şekilde, diğer tüm sektörlerin sonuçları Ekler bölümünde verilmiştir.

Tablo 3. Sektörlerin yıllık ortalama kârı

Sektör	Dönemsel Ortalama Kâr %	Dönemsel Ortalama Kâr	Anapara (50000\$)
Teknoloji	10,26	\$1026	\$11026
Sağlık	11,16	\$1116	\$11116
Enerji	10,6	\$1060	\$11060
Finans	4,76	\$476	\$10476
Emlak	16,19	\$1619	\$11619
Sonuç		Toplam Kâr % ≈ 10,594	
Not: 50000\$ olan anapara her sektör için eşit 10000\$ olarak ayrılmıştır.			

Tablo 3, modelin başarısını yıllık sektörlere göre özetlemek için hazırlanmıştır. Tabloda yer alan bilgiler, farklı sektörlerin 2022 yılı kâr performansını göstermektedir. Tabloda gösterildiği gibi toplam beş sektörden oluşmaktadır ve yıllık periyod için hazırlanan bu tabloda tüm sektörlerde toplam yapılan 25 adet alım ve 25 adet satış işlemi esasında oluşturuldu. Sektördeki şirketlerin hisse senetlerinin tavsiye edilen fiyatlarına göre gerçekleştirilen alım ve satım işlemlerinde elde edilen kâr yüzdelerinin ortalaması hesaplanarak, sektöre özgü dönemsel ortalama kâr yüzdesi bulunmuştur. Her bir sektör için dönemsel ortalama kâr miktarı ise, başlangıç anapara olan 10000\$ ile dönemsel ortalama kâr yüzdesinin çarpılmasıyla elde edildi. Teknoloji sektöründeki dönemsel ortalama kâr yüzdesi %10,26 olduğunda, başlangıç anaparası olan 10000\$ ile çarpılarak dönemsel ortalama kâr miktarı olan 1026 \$ hesaplanarak anaparaya eklendi. Bu hesaplama diğer sektörler için de aynı şekilde hesaplandı. Her bir sektöre \$10,000 yatırıldığı için, toplamda \$50000 yatırılmış olmaktadır. Toplam kâr, her sektörün elde ettiği kârları topladığımızda \$5297 olarak hesaplanmıştır. Sonuç olarak, kâr yüzdesi yaklaşık olarak %10,594 hesaplanmıştır. Tablo 3'ün sonuç satırında da belirtildiği gibi yatırımın kârlı olduğu görülmektedir.

Tablo 4. Sonuçların değerlendirme tablosu

Sonuç ve Bulgular	
Başlangıç tarihi	1 Ocak 2022
Bitiş Tarihi	31 Aralık 2022
Toplam Sinyal	50
Toplam Al-Sat	50
Modelin Başarısı %	80
Toplam Kâr %	10,594
Başlangıç Anapara	\$50000
Sonuç Anapara	\$55297

Tablo 4’de bakıldığında, başlangıç tarihi 1 Ocak 2022 ve bitiş tarihi 31 Aralık 2022 olarak belirlenmiştir. Toplamda 50 dürtü-düzeltilici sinyal ve 50 al-sat pozisyonu bulunmaktadır. Özellikle Ek 5’e bakıldığında modelin başarı oranı %80 olarak gözlemlenmektedir. Toplam kâr yüzdesi ise %10,594 olarak hesaplanmıştır. Başlangıç anaparası \$50,000 iken sonuç anaparası \$55297 olarak belirlenmiştir.



SONUÇ

Bu çalışmada, YOLO nesne algılama algoritması kullanılarak yatırım kararlarında Elliott Dalgalarının tespiti ve analizi araştırılmıştır. Araştırma dönemi boyunca 50 dürtü-düzeltilici sinyal analiz edilmiştir. Birincil amaç, YOLO algoritmasının Elliott Dalgalarını tanımlamadaki etkinliğini ve yatırım kararı verme üzerindeki etkisini değerlendirmektir.

Analizden elde edilen sonuçlar, YOLO nesne tespit algoritmasının Elliott Dalgalarını doğru bir şekilde tespit etmede %80'lik bir başarı oranına ulaştığını göstermektedir. Bu başarı oranı, algoritmanın önemli fiyat kalıplarını ve piyasa eğilimlerini tespit etme yeteneğini göstermekte ve onu yatırım analizi için değerli bir araç haline getirmektedir.

Ayrıca, YOLO algoritmasına dayalı olarak verilen yatırım kararlarından hesaplanan toplam kâr yüzdesi %10,594 olarak bulunmuştur. Bu olumlu bir sonuca işaret etmekte ve algoritmanın kârlı yatırım stratejileri üretilmesine katkıda bulunabileceğini göstermektedir. Özellikle, 50000 \$'lık başlangıç anaparası, çalışma döneminin sonunda 55297 \$'a yükselmiştir. Nihai anaparadaki bu artış, YOLO nesne algılama algoritmasının yatırım getirilerini artırma potansiyelini göstermektedir.

Bu bulgular, YOLO nesne tespit algoritmasının yatırım karar alma süreçlerine entegre edilmesinin olumlu sonuçlar verebileceği önermesini desteklemektedir. Elliott Dalgalarını doğru bir şekilde tanımlayarak ve %80 başarı oranıyla dürtü-düzeltilici sinyalleri üreterek, algoritma yatırım stratejilerini geliştirme ve genel kârlılığı artırma potansiyeline sahiptir.

Bu çalışmanın sonuçları umut verici olsa da, dikkate alınması gereken bazı sınırlamalar olduğunu belirtmek önemlidir. Bir yıllık araştırma süresi, algoritmanın farklı piyasa koşulları altındaki performansını tam olarak yansıtmayabilir. Ayrıca, bulguların güvenilirliğini ve genelleştirilebilirliğini güçlendirmek için daha büyük bir veri seti ve daha uzun zaman dilimleri kullanılarak daha fazla analiz ve doğrulama

yapılması önerilmektedir. Öte yandan, ileriki çalışmalarda “Dürtü” ve “Düzeltici” dalgaların iç yapıları da tespit edilebilir.

Genel olarak bu çalışma, YOLO nesne tespit algoritması kullanılarak yatırım kararlarında Elliott Dalgalarının tespiti ve analizi konusunda değerli bilgiler sağlamaktadır. Gözlemlenen %80'lik başarı oranı ve hesaplanan %10,594'lük toplam kâr yüzdesi, algoritmanın karar verme süreçlerini optimize etmek isteyen yatırımcılar için faydalı bir araç olma potansiyeline sahip olduğunu göstermektedir. Bu alanda yapılacak daha fazla araştırma, algoritmanın iyileştirilmesi ve finans sektöründeki uygulamalarının genişletilmesine katkıda bulunabilir.

KAYNAKÇA

Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., Tse, D., Etemadi, M., Ye, W., Corrado, G., Naidich, D. P., & Shetty, S. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25(6), 954-961.

<https://www.nature.com/articles/s41591-019-0447-x>

Baaquie, B. E. (2004). *Fractal finance: a path integral approach*. World Scientific.

Bacon, F. (1597). *The Essays*. London, UK: Printed by Iohn Legatt.

Bagehot, W. (2018). *The Future of the Professions: How Technology Will Transform the Work of Human Experts*. Oxford University Press.

Baker, M., & Wurgler, J. (2002). Market liquidity and funding liquidity. *The Review of Financial Studies*, 15(1), 809-843.

Bengio, Y., Courville, A., & Vincent, P. (2012). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.

Berger, A. N. (2019). Short-term investments. In *Corporate Financial Management* (pp. 331-339). Pearson.

Birogul, S., Temür, G., & Kose, U. (2020). YOLO Object Recognition Algorithm and "Buy-Sell Decision" Model Over 2D Candlestick Charts. *IEEE Access*, 8, 86643-86651. doi: 10.1109/ACCESS.2020.2994282

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Blau, J. (2013). *Elliott wave principle: Key to market behavior*. John Wiley & Sons.

Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.

Bodie, Z., Kane, A., & Marcus, A. J. (2014). *Investments* (10th ed.). McGraw-Hill Education

Bogle, J. C. (2007). *The little book of common sense investing: The only way to guarantee your fair share of stock market returns*. John Wiley & Sons.

Böhme, R., & Christin, N. (2016). Bitcoin: Under the Hood. *Communications of the ACM*, 59(7), 104-113.

Bollinger, J. (2017). *Bollinger on Bollinger Bands*. New York, NY: McGraw-Hill Education.

Boroden, F. (2002). *Fibonacci analysis*. New York, NY: McGraw-Hill.

Bridle, C. (2019). *The Future of Investing: How Virtual and Augmented Reality Are Changing the Game*. New York: Palgrave Macmillan.

Brown, R. (2020). Investment. In *Financial Markets, Institutions, and Money* (pp. 67-80). Routledge.

Brunel, J. (2019). *Artificial Intelligence and Machine Learning in Investment Management*. John Wiley & Sons.

Buffett, W. (1949). *The Intelligent Investor*. New York: HarperCollins.

Carhart, M. M. (1997). On persistence in mutual fund performance. *The Journal of Finance*, 52(1), 57-82.

Chen, L., & Lee, J. (2014). Investment behavior and the capital market: An empirical analysis of the information content of institutional trades. *Journal of Banking & Finance*, 43, 174-189.

Chen, S. & Hu, K. (1999). An evaluation of fractal dimension methods. *Physica A: Statistical Mechanics and its Applications*, 270(1-2), 140-146.

Chollet, F. (2017). *Deep learning with Python*. Manning Publications.

Dai, J., Li, Y., He, K., & Sun, J. (2016). R-FCN: Object Detection via Region-based Fully Convolutional Networks. In *Advances in Neural Information Processing Systems* (pp. 379-387).

DeMiguel, V., Garlappi, L., & Uppal, R. (2009). A generalized approach to portfolio optimization: Improving performance by constraining portfolio norms. *Management Science*, 55(5), 798-812.

- Elder, A. (2006). *Trading for a living: Psychology, trading tactics, money management*. John Wiley & Sons.
- Ellinger, A. E., & Ellinger, A. (2019). Blockchain in finance: Opportunities and challenges. *Journal of Digital Banking*, 2(3), 161-173.
- Elliott, R. N. (1938). *The Wave Principle*. New York: R.N. Elliott.
- Elton, E. J., Gruber, M. J., Brown, S. J., & Goetzmann, W. N. (2017). *Modern Portfolio Theory and Investment Analysis*. Wiley.
- Erickson, J. F., & Carlsen, A. E. (2014). *Elliott wave principle: A critical appraisal*. John Wiley & Sons.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://www.nature.com/articles/nature21056>
- Eyre, N., & Repici, L. (2020). Impact Investing: A Review of the Literature. *Journal of Sustainable Finance & Investment*, 10(4), 459-476.
- Fama, E. F., & French, K. R. (2010). Luck versus skill in the cross-section of mutual fund returns. *Journal of finance*, 65(5), 1915-1947.
- Frisch, U. (1995). *Turbulence*. Cambridge University Press.
- Frost, A. J., & Prechter Jr, R. R. (2008). *The Elliott wave principle: Key to market behavior*. New Classics Library.
- Frost, A., & Prechter, R. (2004). *Elliott wave principle: Key to market behavior*. New York, NY: McGraw-Hill.
- Frost, A., & Prechter, R. R. (2002). *Elliott wave principle: Key to market behavior*. New Classics Library.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.

Gibbons, M. R., & Ferson, W. E. (1999). Optimal portfolios with macroeconomic uncertainty. *Journal of Financial Economics*, 53(3), 427-466.

Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*, 1440-1448.

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).

Global Impact Investing Network (GIIN). (2017). *Annual Impact Investor Survey*.

Goldberg, Y. (2017). Neural network methods for natural language processing. *Synthesis Lectures on Human Language Technologies*, 10(1), 1-309.

Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing*. Pearson Education India.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.

Graham, B., & Dodd, D. (1934). *Security Analysis*. New York: McGraw-Hill.

Grassberger, P. & Procaccia, I. (1983). Measuring the strangeness of strange attractors. *Physica D: Nonlinear Phenomena*, 9(1-2), 189-208.

Guppy, D. (2019). *Trend Trading: A Seven-Step Approach to Success*. John Wiley & Sons.

Halsey, T. C., Jensen, M. H., Kadanoff, L. P., Palmer, R. G., & Shraiman, B. I. (1986). Fractal measures and their singularities: the characterization of strange sets. *Physical Review A*, 33(2), 1141.

He, J., & Yang, C. (2020). Incorporating financial news into stock selection using object detection. *Expert Systems with Applications*, 160, 113619.

Hinton, G. E., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82-97.

<https://finance.yahoo.com>

Impact Management Project (IMP). (2020). Principles for Impact Management and Measurement.

Jappelli, T., & Pagano, M. (2018). The economics of blockchain. Handbook of digital currency, 1, 69-95.

Javalgi, R. G.& Dhaiya, D. (2019). Artificial intelligence and machine learning in sustainability: An exploratory study. Journal of Cleaner Production, 214, 759-769.

Jorion, P., & Go, C. H. (2021). Financial markets and institutions (7th ed.). Pearson.

Kaufman, P. J. (2010). Trading systems and methods. John Wiley & Sons.

Kshetri, N. (2019). Blockchain-enabled supply chain management in the food industry: Opportunities and challenges. Journal of Business Research, 98, 367-376.

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

Li, B., Liu, J., Li, L., Zhang, H., & Liang, C. (2018). Object detection in medical images using a two-stage convolutional neural network fine-tuned by transfer learning. IEEE Access, 6, 57965-57973.

Li, X., Qi, J., Dai, J., Ji, X., & Wei, Y. (2017). Fully convolutional instance-aware semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2359-2367).

Liang, J., & Yu, M. (2019). Risk management in supply chain using object detection. Journal of Cleaner Production, 230, 273-282.

Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2017). Focal loss for dense object detection. Proceedings of the IEEE international conference on computer vision, 2980-2988.

Lin, T. Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2018). Focal Loss for Dense Object Detection. Proceedings of the IEEE International Conference on Computer Vision, 2999-3007. <https://doi.org/10.1109/iccv.2017.324>

Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. European conference on computer vision, 740-755.

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. Shen, D., & Wu, G. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221-248.

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. In *European Conference on Computer Vision* (pp. 21-37). Springer, Cham.

Lu, H., Li, S., & Li, Y. (2020). Aerial image analysis for real estate investment: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 228-243.

Malkiel, B. G. (2003). *A Random Walk Down Wall Street*. WW Norton & Company.

Malkiel, B. G. (2003). *A random walk down Wall Street: Including a life-cycle guide to personal investing*. WW Norton & Company.

Malkiel, B. G., & Ellis, C. D. (2014). *The elements of investing: Easy lessons for every investor*. New York: McGraw-Hill Education.

Mandelbrot, B. & Hudson, R. (2004). *The (Mis)behavior of Markets: A Fractal View of Risk, Ruin and Reward*. Basic Books.

Mandelbrot, B. (1977). *Fractals: form, chance and dimension*. Freeman.

Mandelbrot, B. B. (1963). The Variation of Certain Speculative Prices. *The Journal of Business*, 36(4), 394-419.

Modern Portfolio Theory. (1952). *The Journal of Finance*, 7(1), 77-91.

Murphy, J. J. (1999). *Technical analysis of the financial markets*. New York: New York Institute of Finance.

Murphy, J. J. (2016). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. New York, NY: New York Institute of Finance.

Neely, C. (2004). *Mastering Elliott wave: Presenting the Neely method: The first scientific, objective approach to market forecasting with the Elliott wave theory*. Gainesville, GA: New Classics Library.

Nielsen, M. (2015). *Neural Networks and Deep Learning*. Determination Press.

Nison, S. (1991). Japanese candlestick charting techniques. New York: New York Institute of Finance.

Oquab, M., Bottou, L., Laptev, I., & Sivic, J. (2014). Learning and transferring mid-level image representations using convolutional neural networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1717-1724).

Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. IEEE Transactions on knowledge and data engineering, 22(10), 1345-1359.

Peitgen, H.-O., Jurgens, H., & Saupe, D. (1992). Chaos and fractals: new frontiers of science. Springer-Verlag.

Poser, S. (2013). The complete guide to the Elliott wave principle. John Wiley & Sons.

Prechter Jr, R. R. (2002). The wave principle of human social behavior and the new science of socionomics. New Classics Library.

Prechter, R. R., & Frost, A. J. (1999). Elliott Wave Principle: A Critical Appraisal. The Journal of Portfolio Management, 26(1), 52-58.

Prechter, R. R., & Frost, A. J. (2002). Elliott wave principle: Key to market behavior. Gainesville, GA: New Classics Library.

Prechter, R., & Frost, A. J. (2002). Mastering Elliott Wave: Presenting the Neely Method. Gainesville, GA: New Classics Library.

Pring, M. J. (2002). Technical analysis explained: The successful investor's guide to spotting investment.

Ramos, R. G., & Coelho, M. L. (2019). Financial statement analysis using object detection. Journal of Information Systems Engineering & Management, 4(3), 18.

Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, faster, stronger. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7263-7271).

Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. arXiv preprint arXiv:1804.02767.

Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In *Advances in Neural Information Processing Systems* (pp. 91-99).

Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. In *Advances in Neural Information Processing Systems* (pp. 91-99).

Rooney, T., Goh, G., & Shirzadi, B. (2019). How machine learning and satellite imagery can improve commodity investing. *Journal of Commodity Markets*, 13, 1-11.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015). ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211-252.

Russell, S. J., Norvig, P., Davis, E., & Tien, J. (2019). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Schwerdt, G., & Whelan, S. (2018). The future of corporate finance: How technology is reshaping the role of CFOs. *Harvard Business Review*, 96(5), 58-64.

Shannon, B. J. (2014). *Elliott waves, Fibonacci, and chart pattern trading tools: A synthesis of classic trading techniques*. John Wiley & Sons.

Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19(3), 425-442.

Shefrin, H., & Statman, M. (2000). Behavioural portfolio theory. *Journal of financial and quantitative analysis*, 35(2), 127-151.

Shiller, R. J. (2000). *Irrational Exuberance* (2nd ed.). Princeton University Press.

Siddiqui, M. H., & Mehmood, I. (2019). *Deep learning in computer vision*. Springer.

Stein, E. (2019). *The future of wealth management: How robo-advisors are disrupting the industry*. John Wiley & Sons.

Swedroe, L. E. (2017). *The Incredible Shrinking Alpha: And What You Can Do to Avoid It*. RMB - Rocky Mountain Books.

Swensen, D. F. (2005). *Unconventional success: A fundamental approach to personal investment*. Simon and Schuster.

Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S. (2019). Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12), 2295-2329. doi: 10.1109/JPROC.2017.2761740

Szeliski, R. (2011). *Computer vision: Algorithms and applications*. Springer Science & Business Media.

Tan, M., Le, Q. V., & Duchi, J. (2020). EfficientNet: Rethinking model scaling for convolutional neural networks. In *International Conference on Machine Learning* (pp. 6105-6114).

Tremblay, J., Prakash, A., Acuna, D., Brophy, M., Jampani, V., Anil, C., ... & Birchfield, S. (2018). Training deep networks with synthetic data: Bridging the reality gap by domain randomization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 9696-9704).

Ultralytics (2020). YOLOv5: State-of-the-art object detection at blazing speed. Retrieved from <https://github.com/ultralytics/yolov5>

Vlachos, D., & Koutmos, D. (2019). Predictive analytics in finance: A review of the literature. *European Journal of Operational Research*, 276(3), 975-993.

Wagner, J. (2015). *Elliott waves for short-term trading*. John Wiley & Sons.

Wang, S., Huang, Y., & Wang, Y. (2018). Object detection in medical images using convolutional neural networks. *Neural Computing and Applications*, 29(11), 1071-1079.

Wang, X., Han, X., Huang, T., & Shan, S. (2020). Object detection in heavily occluded scenarios with stacked spatial attention networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 10608-10617).

West, G. B., Brown, J. H., & Enquist, B. J. (1997). A general model for the origin of allometric scaling laws in biology. *Science*, 276(5309), 122-126.

Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research.

Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? In Advances in neural information processing systems (pp. 3320-3328).

Zhang, Y., Wang, X., Yang, S., Huang, T., & Zhao, Q. (2020). Object detection with reinforcement learning: A review. arXiv preprint arXiv:2012.05187.

Zhang, Y., Zhang, Z., & Wu, J. (2018). Deep learning for image processing applications. Springer.

Zhu, W., Xie, Y., & Liao, H. (2019). Deep learning in medical image analysis: a review. Journal of Healthcare Engineering, 2019, 1-17.

Zingales, L. (2000). Inefficient investment. The Review of Economic Studies, 67(2), 307-332.

EKLER

EK 1. Modelin sađlık sektörüne göre değeriendirilmesi

Sektör	Hisse adı	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sonuç %
Sađlık	BDX	Düzeltilici	AL	2022.07.14	232,19	Dürtü	SAT	2022.08.22	264	13,7
Sađlık	ABC	Dürtü	SAT	2022.04.07	158,16	Düzeltilici	AL	2022.09.20	139,61	11,72
Sađlık	CAH	Düzeltilici	AL	2022.06.21	51,36	Dürtü	SAT	2022.08.26	69,07	34,48
Sađlık	CRL	Düzeltilici	AL	2022.05.12	232,71	Dürtü	SAT	2022.07.05	215,22	-7,51
Sađlık	BMV	Dürtü	SAT	2022.06.15	73,16	Düzeltilici	AL	2022.09.15	70,65	3,43

EK 2. Modelin enerji sektörüne göre değerlendirilmesi

Sektör	Hisse adı	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sonuç %
Enerji	APA	Dürtü	SAT	2022.05.10	38,16	Düzeltilici	AL	2022.08.11	34,83	8,72
Enerji	BKR	Dürtü	SAT	2022.03.22	36,17	Düzeltilici	AL	2022.05.09	31,63	12,55
Enerji	EQT	Dürtü	SAT	2022.05.09	39,95	Düzeltilici	AL	2022.05.13	39	2,37
Enerji	KMI	Dürtü	SAT	2022.01.28	17,19	Düzeltilici	AL	2022.09.01	18,16	-5,64
Enerji	MRO	Dürtü	SAT	2022.06.10	30,66	Düzeltilici	AL	2022.07.14	19,9	35

EK 3. Modelin finans sektörüne göre değerlendirilmesi

Sektör	Hisse adı	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sonuç %
Finans	AIG	Düzeltilici	SAT	2022.04.22	63	Dürtü	AL	2022.07.18	50,61	19,66
Finans	JPM	Düzeltilici	SAT	2022.06.07	128,81	Dürtü	AL	2022.07.27	113,97	11,52
Finans	ALL	Düzeltilici	SAT	2022.04.11	142,66	Dürtü	AL	2022.04.18	139,93	1,91
Finans	CMA	Düzeltilici	AL	2022.06.09	81,27	Dürtü	SAT	2022.06.13	74,11	-8,81
Finans	L	Düzeltilici	SAT	2022.04.13	64,26	Dürtü	AL	2022.04.28	64,57	-0,48

EK 4. Modelin emlak sektörüne göre değerlendirilmesi

Sektör	Hisse adı	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sinyal	Pozisyon	Tarih	Önerilen Fiyat	Sonuç %
Emlak	BXP	Düzeltilici	SAT	2022.03.22	126,42	Dürtü	AL	2022.09.12	86,68	31,43
Emlak	O	Düzeltilici	AL	2022.03.08	64,6	Dürtü	SAT	2022.04.18	72,6	12,38
Emlak	CCI	Dürtü	AL	2022.02.25	165,63	Düzeltilici	SAT	2022.04.12	194,69	17,54
Emlak	KIM	Dürtü	SAT	2022.08.24	22,04	Düzeltilici	AL	2022.09.20	20,58	6,62
Emlak	PEAK	Dürtü	AL	2022.03.01	31,11	Düzeltilici	SAT	2022.04.08	35,18	13

EK 5. Model Sonuçlarının Dağılımı

