

FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ BÖLÜMÜ



TEKNİK ANALİZ VE DERİN PEKİŞTİRMELİ ÖĞRENME İLE
KRİPTOPARA ALIM-SATIMI

YÜKSEK LİSANS TEZİ

MUHAMMED SAİD ÜNLÜ

tarafından

YÜKSEK LİSANS

derecesi şartını sağlamak için hazırlanmıştır.

Mayıs 2019

Program: Bilgisayar Mühendisliği

TEKNİK ANALİZ VE DERİN PEKİŞTİRMELİ ÖĞRENME İLE

KRİPTOPARA ALIM-SATIMI

YÜKSEK LİSANS TEZİ

MUHAMMED SAİD ÜNLÜ

Tarafından


OKAN ÜNİVERSİTESİ

Bilgisayar Mühendisliği Bölümüne

Yüksek Lisans

derecesi şartını sağlamak için sunulmuştur

Onaylayan:



Doç. Dr. Pınar YILDIRIM
Danışman



Prof. Dr. Bekir Tefik AKGÜN
Jüri Üyesi



Doç. Dr. Erchan APTOULA
Jüri Üyesi

Mayıs 2019

Program: Bilgisayar Mühendisliği

KISA ÖZET

TEKNİK ANALİZ VE DERİN PEKİŞTİRMELİ ÖĞRENME İLE KRIPTOPARA ALIM-SATIMI

Son yıllarda teknolojinin yıkıcı etkisi birçok alanda kendini göstermektedir. Finans sektörü de bu durumdan fazlasıyla etkilenmiş durumdadır. Finansal piyasalar, artan rekabet ve gelişen teknoloji ile kriptopara piyasası gibi yenilikçi piyasaların oluşmasına zemin hazırlamaktadır. Finansal piyasalardaki değişime paralel olarak, yapay zeka alanındaki çalışmalarda da çok önemli gelişmeler olmaktadır. Bu çalışmada Robotik üzerine başarılı sonuçlar veren modern Derin Pekiştirmeli Öğrenme yöntemlerinden Soft-Aktör-Kritik(Soft Actor Critic - SAC) yöntemi ile finansal piyasalarda sıklıkla tercih edilen Teknik Analiz yöntemlerini kullanarak alım-satım stratejileri geliştirilmiştir. Piyasa değeri en yüksek üç kriptopara (Bitcoin, Ethereum ve Ripple), hem USD hem de BTC paritesinde veri seti olarak kullanılmaktadır. Çalışma kapsamında OpenAI-Gym ile kriptopara alım-satım ortamı oluşturulmuş ve bu ortamda SAC etmeni öğrenme süreci gerçekleştirilmektedir. Teknik Analiz yöntemleri ve SAC yöntemiyle oluşturulan stratejilerin performansları geriye yönelik testler(Backtesting) yapılarak karşılaştırılmaktadır.

Anahtar Kelimeler: Derin Pekiştirmeli Öğrenme, Kriptoparalar, Algoritmik Alım-Satım, OpenAI-Gym, Soft-Aktör-Kritik, Teknik Analiz, Geriye Yönelik Testler

ABSTRACT

A CRYPTOCURRENCY TRADING WITH DEEP REINFORCEMENT LEARNING AND TECHNICAL ANALYSIS

In recent years, the destructive effect of technology is manifested in many areas. The financial sector has been also highly affected by this situation. Financial markets set the stage for the development of innovative markets such as increasing competition and developing technology and cryptographic market. Parallel to the change in financial markets, there are also important developments in artificial intelligence studies. In this study, trading strategies have been developed using Soft-Actor Critic (SAC) method, which is a state-of-the-art deep reinforcement learning method, which gives successful results on robotics, and the technical analysis methods which are frequently preferred in financial markets. Three cryptocurrencies (Bitcoin, Ethereum and Ripple) with the highest market value are used as the data set in both USD and BTC parity. Within the scope of this study, a cryptocurrency trading environment has been created with OpenAI-Gym and the process of SAC agent's learning is realized in this environment. Technical Analysis methods and SAC method's performances are compared by backtesting.

Keywords: Deep Reinforcement Learning, Cryptocurrencies, Algorithmic Trading, Backtesting, OpenAI-Gym, Soft-Actor-Critic, Technical Analysis

TEŐEKKÜR

Tez alıőmam sűrecinde bilgisini benden esirgemeyerek, bana her konuda liderlik eden danıőman hocam Sayın Pınar Yıldırım'a teőekkűr ederim.

Hayatım boyunca her alanda desteklerini benden esirgemeyen ok deęerli Anne ve Babama teőekkűr ederim.

Tez yazım sűrecinde her konuda yanımda olan sevgili Eőime teőekkűrlerimi sunuyorum.

İÇİNDEKİLER

TABLolar LİSTESİ	VII
ŞEKİL LİSTESİ	VIII
KISALTMALAR	X
I. GİRİŞ	1
II. LİTERATÜR ARAŞTIRMASI	5
III. FİNANSAL KAVRAMLAR.....	11
3.1. TEMEL ANALİZ	14
3.2. TEKNİK ANALİZ.....	14
3.2.1. Destek, direnç ve trendler	17
3.2.2. Göstergeler	20
3.2.3. Geriye dönük testler	24
3.3. KRİPTO PARALAR	26
3.3.1. Bitcoin(BTC).....	27
3.3.2. Ripple(XRP)	30
3.3.3. Ethereum(ETH)	30
3.4. ALGORİTMİK TİCARET	31
IV. DERİN PEKİŞTİRMELİ ÖĞRENME.....	33
4.1. PEKİŞTİRMELİ ÖĞRENME	36
4.1.1. Markov karar süreçleri	43
4.1.2. Q-öğrenme ve derin q-ağları	44
4.1.3. Aktör – kritik	45
4.2. DERİN ÖĞRENME	46
4.2.1. Yapay sinir ağları ve çok katmanlı yapay sinir ağları	47
4.2.2. Evrişimsel sinir ağları.....	51
4.2.3. Yinelenen sinir ağları	53
4.2.4. Uzun kısa vadeli hafıza	55

V. KULLANILAN TEKNOLOJİLER.....	56
5.1. JUPYTER NOTEBOOK VE GOOGLE COLAB	56
5.2. TENSORFLOW.....	57
5.3. OPENAI GYM.....	59
5.4. STABLE-BASELİNES	60
5.5. BACKTRADER	60
5.6. DASH	60
VI. TEKNİK ANALİZ VE SOFT – ACTOR – CRITIC(SAC) İLE KRİPTOPARA TİCARETİ UYGULAMASI.....	61
6.1. SOFT ACTOR CRITIC(SAC) ALGORİTMASI.....	62
6.2. VERİLERİN ELDE EDİLMESİ VE ÖN ANALİZLER	64
6.3. OPENAI-GYM ORTAMI	67
6.4. BACKTRADER İLE GERİYE YÖNELİK TESTLER (BACKTESTING)	68
6.5. ARAYÜZ.....	71
VII. DEĞERLENDİRME.....	73
VIII. SONUÇLAR.....	74
8.1. SAC ETMENİ	74
8.2. STRATEJİ SONUÇLARI	76
KAYNAKÇA	87
EK A.....	101
EK B	103
EK C	105
EK D.....	109
ÖZGEÇMİŞ.....	111

TABLolar LİSTESİ

Tablo 2.1.	Literatür Özet Tablosu	10
Tablo 4.1	Gözetimli Öğrenme, Gözetimsiz Öğrenme ve Pekiştirmeli Öğrenme	33
Tablo 4.2	Kriptopara Alım-Satım Örneği Q-Tablosu	45
Tablo 6.1	Soft Actor Critic(SAC) Parametreleri.....	63
Tablo 6.2.	Çalışmada Kullanılan Kriptopara Verileri	65
Tablo 6.3.	ETH-BTC Günlük Veri Çerçevesi Örneği.....	66
Tablo 6.4.	OpenAI-Gym Uygulama Sınıfları	67
Tablo 6.5.	Backtrader Uygulama Sınıfları	68
Tablo 8.1.	Kullanılan Metrikler ve Açıklamaları	77
Tablo 8.2.	WMA Strateji Sonuçları	79
Tablo 8.3.	EMA Strateji Sonuçları.....	80
Tablo 8.4.	RSI Strateji Sonuçları	81
Tablo 8.5.	BB Strateji Sonuçları	82

ŞEKİL LİSTESİ

Şekil 3.1.	Emir Defteri ve Gerçekleşen İşlemleri [28]	12
Şekil 3.2.	Bitcoin Mum Grafiği	16
Şekil 3.3.	Bitcoin Bar Grafiği	17
Şekil 3.4.	4 Saatlik XBT/USD çifti üzerinde Bollinger Bantları [36]	24
Şekil 3.5.	Bitcoin Piyasa Değeri ve Fiyat Grafiği [1]	28
Şekil 4.1.	Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme, Gözetimli Öğrenme, Gözetimsiz Öğrenme, Pekiştirmeli Öğrenme ve Derin Pekiştirmeli Öğrenme Arasındaki ilişki [56]	35
Şekil 4.2.	Pekiştirmeli Öğrenme Yöntemleri	40
Şekil 4.3.	Pekiştirmeli Öğrenme Algoritmalarının Model Bağlamında Sınıflandırılması [64]	42
Şekil 4.4.	Markov Karar Süreçlerindeki Etmen Çevre Etkileşimi [67]	43
Şekil 4.5.	Aktör – Kritik Örneği Şeması [79]	46
Şekil 4.6.	Çok Katmanlı Sinir Ağı Örneği	47
Şekil 4.7.	Aktivasyon Fonksiyonları Grafikleri [80]	50
Şekil 4.8.	Yüksek Seviye CNN Mimarisi [80]	52
Şekil 4.9.	Normal Sinir Ağları ve Tekrarlayan Sinir Ağları	54
Şekil 5.1.	Jupyter ve Colab Notebook Örnekleri	57
Şekil 5.2.	TensorBoard Görselleştirme Örneği	58
Şekil 6.1.	Teknik Analiz ve Derin Pekiştirmeli Öğrenme ile Kriptopara Alım – Satım.....	61
Şekil 6.2.	Uygulama Bileşenleri ve Kütüphaneler	62

Şekil 6.3.	Soft Aktör-Kritik Sözde Kodu [10]	63
Şekil 6.4.	Backtrader ile RSI Stratejisi	69
Şekil 6.5.	Backtrader ile Bollinger Bantları Stratejisi	70
Şekil 6.6.	Backtrader ile EMA Stratejisi	70
Şekil 6.7.	Backtrader ile WMA Stratejisi.....	71
Şekil 6.8.	Uygulama Arayüzü.....	72
Şekil 8.1.	Soft Aktör Kritik Entropi ve Ödül	75
Şekil 8.2.	Soft Aktör Kritik Kayıp Fonksiyonları	76
Şekil 8.3.	Stratejilerin BTC – USD Günlük Alım – Satım Toplam Karları.....	83
Şekil 8.4.	Stratejilerin BTC – USD Saatlik Alım – Satım Toplam Karları.....	83
Şekil 8.5.	Stratejilerin ETH – BTC Günlük Alım – Satım Toplam Karları.....	84
Şekil 8.6.	Stratejilerin ETH – BTC Saatlik Alım – Satım Toplam Karları.....	84
Şekil 8.7.	Stratejilerin ETH – USD Günlük Alım – Satım Toplam Karları.....	84
Şekil 8.8.	Stratejilerin ETH – USD Saatlik Alım – Satım Toplam Karları.....	85
Şekil 8.9.	Stratejilerin XRP – USD Saatlik Alım – Satım Toplam Karları.....	85
Şekil 8.10.	Stratejilerin XRP – USD Günlük Alım – Satım Toplam Karları.....	85
Şekil 8.11.	Stratejilerin XRP – BTC Saatlik Alım – Satım Toplam Karları.....	86
Şekil 8.12.	Stratejilerin XRP – BTC Günlük Alım – Satım Toplam Karları.....	86

KISALTMALAR

API: Uygulama Programlama Arayüzü	Application Programming Interface
A2C: Avantaj Aktör Kritik	Advantage Actor Critic
BPTT: Zaman İçinde Geriye Doğru Yayılım	Backpropagation Through Time
BTC: Bitcoin	
CNN: Evrimsel Sinir Ağı	Convolutional Neural Network
CPU: Merkezi İşlem Birimi	Central Processing Unit
DDPG: Derin Deterministik Politika Gradyanları	Deep Deterministic Policy Gradients
DQN: Derin Q-Ağları	Deep Q-Network
DNN: Derin Sinir Ağları	Deep Neural Networks
EMA: Üssel Hareketli Ortalama	Exponential Moving Average
ETH: Ethereum	
GBT: Güçlendirilmiş Gradyan Ağaçları	Gradient Boosting Tree
GPU: Grafik İşlemci Birimi	Graphics Processing Unit
LSTD: En Küçük Kareler Geçici Fark Öğrenme	Least Squares Temporal
Difference Learning	
LSTM: Uzun Kısa Süreli Hafıza	Long Short Term Memory
MA: Hareketli Ortalama	Moving Average
MACD: Hareketli Ortalama Yakınsama – İraksama	Moving Average Convergence
Divergence	
MDP: Markov Karar Süreçleri	Markov Decision Process
NPGPE: Doğal Parametre Tabanlı Keşif ile Politika Gradyanları	Natural policy
gradient methods with parameter-based exploration	
PAMR: Passive Aggressive Mean Reversion	Pasif Agresif Ortalama Ters Çevirme
PG: Politika Gradyanı	Policy Gradients
PGPE: Parametre Tabanlı Keşif ile Politika Gradyanları	Policy Gradient with
Parameter-based Exploration	
PPO: Proksimal Politika Optimizasyonu	Proximal Policy Optimization
PÖ: Pekiştirmeli Öğrenme	Reinforcement Learning
ReLU: Rectified Linear Unit	

RNN: Tekrarlayan Sinir Ađı	Recurrent Neural Network
ROI: Yatırımın geri dönüşü	Return of Investment
RSI: Bağlı Güç Endeksi	Relative Strenght Index
RRL: Recurrent Reinforcement Learning	Tekrarlayan Pekiřtirmeli Öğrenme
SAC: Soft Actor Critic	
SMA: Basit Hareketli Ortalama	Simple Moving Average
SO: Sharpe Oranı	Sharpe Ratio
TA: Teknik analiz	
TD: Geçici Fark	Temporal Difference
TF: Tensorflow	
TPU: Tensor İşleme Birimi	Tensors Processing Unit
TRY: Türk Lirası	
USD: Amerikan Doları	United States Dollar
WMA: Ađırlıklı Hareketli Ortalama	Weighted Moving Average
XRP: Ripple	
XBT: Bitcoin Sürekli İndeks	Bitcoin Perpetual Index
YSA: Yapay Sinir Ađları	
ZP: Zaman Periyodu	

I. GİRİŞ

Son yıllarda teknolojinin yıkıcı etkisi birçok alanda kendini göstermektedir. Finans sektörü de bu durumdan fazlasıyla etkilenmiş durumdadır. Finansal piyasalar, artan rekabet ve gelişen teknoloji ile kriptopara piyasası gibi yenilikçi piyasaların oluşmasına zemin hazırlamıştır. Bu bağlamda, gündelik hayatımıza yeni yeni girmekte olan kriptoparaların öncüsü olan Bitcoin 2008 yılında Satoshi Nakamoto takma adlı bir kişi veya bir grup tarafından ortaya atılmıştır. Bir süre çok dikkatleri üzerine çekmesine de ardındaki blokzincir teknolojisinin birçok farklı fikri, ürünü ortaya çıkarmaya öncü olabileceği düşüncesi kriptopara dünyasının popüleritesinin artmasına sebep olmuştur. Sonrasında birçok kriptoparanın ortaya çıkmasıyla birlikte, kriptopara piyasası gün geçtikçe finansal piyasalarda kendine yer edinmeye başlamıştır. Coinmarketcap.com verilerine göre¹ alım-satımı yapılan 2104 adet kriptopara bulunmaktadır. Dünya çapında bu piyasaya artan ilgi, devletlerin para politikalarından, şirketlerin ödeme sistemlerine, uluslararası para transferinden bireysel yatırıma kadar birçok noktada kriptoparaların etkin rol almasına sebep olmaktadır.

Teknolojik gelişmeler vasıtasıyla yazılımsal ve donanımsal kaynaklara ulaşımın maliyeti düşük seviyelere indirgenmiştir. Dolayısıyla birçok finansal platform bireyselden kurumsala her türlü yatırımcı için ulaşılabilir hale gelmiştir. Finansal piyasalarda ticaret; yatırımcılar, hisselerin değiş tokuşunda karar kıldıkları zaman

¹ www.coinmarketcap.com 01.03.2019 tarihinde erişilmiştir.

gerçekleşen alım satım işlemidir[2]. Fiyatlar alıcıların ve satıcıların oluşturduğu piyasa koşulları doğrultusunda belirlenmekte, iki tarafın emirleri örtüşüğünde ticaret gerçekleşmektedir.

Son yıllarda hisse senedi, forex, kriptopara vb. piyasalarda yapay zekâ yardımlı ticaret tahmin edilenden çok daha fazla talep görmektedir. Makine öğrenmesi, yapay zekânın alt alanlarından biridir. Makine öğrenmesi Gözetimli Öğrenme, Gözetimsiz Öğrenme ve Pekiştirmeli Öğrenme olmak üzere 3 temel bölümde ele alınmaktadır. Bu çalışma da ana başlıklardan biri olan Pekiştirmeli Öğrenme(PÖ) robotikten[3] oyun teorisine² [5], hisse senedi piyasa tahmininden[6], optimizasyona[2] birçok alanda kullanılmaktadır. Pekiştirmeli Öğrenme, basitçe deneme yanılma yöntemiyle öğrenmedir. Burada bir etmen vasıtasıyla çevreyle girilen etkileşim sonucunda alınan aksiyon ödüllendirilmektedir [7]. Derin Pekiştirmeli Öğrenme, AlphaGo[8], AlphaGoZero gibi çalışmalar ile dikkatleri üzerine çekmeyi başarmıştır. Bunların yanında son yıllarda Doğal Dil İşlemeden, Görüntü Tanımaya birçok alanda başarılı sonuçlar veren Derin Öğrenme de bu kapsamda ilgi çekici başlıklardandır. Bölüm 4.2' de detaylıca bahsedilen Derin Öğrenme ile Pekiştirmeli Öğrenmenin kombinasyonu Derin Pekiştirmeli Öğrenme'yi oluşturmaktadır.

² Oyun teorisi stratejik düşünce ve karar verme aşamalarında şirketlerin optimum kazancı sağlayabilmeleri için izlemeleri gereken stratejileri araştıran matematiksel temelli bilimsel bir yöntemdir.[4]

Altcoin olarak da bilinmekte olan bazı kriptoparalarda kısa süreler için hacminde veya fiyatında ani yükseliş ve düşüşler olmaktadır. Geleneksel finansal piyasalarla kıyaslandığında kriptopara piyasası henüz stabil olarak görülmemektedir. Bu nedenle bu çalışmada piyasa değeri en yüksek olan ve diğer kriptoparalara göre daha stabil olduğu düşünülen 3 kripto para BTC, ETH ve XRP tercih edilmektedir. BTC-USD, ETH-USD, ETH-USD, XRP - BTC ve XRP-USD çiftleri kullanılmaktadır.

Bu tez kapsamında, kriptoparalar üzerinde modern Derin Pekiştirmeli Öğrenme algoritmalarından Soft-Actor-Critic(SAC)³ algoritması ile kriptopara ticaretinde alım-satım stratejisi olarak kullanılabilirliği araştırılmaktadır. Literatürde diğer derin pekiştirmeli öğrenme algoritmalarıyla finansal alım satım çalışmaları bulunsa da, henüz Soft Actor Critic yöntemle kriptopara alım-satımı üzerine bir çalışmayla karşılaşılmamıştır. Çalışma kapsamında OpenAI-Gym ile kriptopara alım satım ortamı geliştirilmiştir. Backtrader kütüphanesi kullanılarak oluşturulan Teknik Analiz tabanlı stratejiler ve SAC etmeni performansları karşılaştırılmaktadır.

Çalışma 8 ana başlıktan oluşmaktadır. Bölüm 2’de Literatür Araştırması, Bölüm 3’ te finansal kavramlar ve açıklamalarına yer verilmiştir. Bölüm 4 Derin Pekiştirmeli Öğrenme detaylarını içermektedir. Bölüm 5 ise bu çalışma kapsamında kullanılan teknolojiler ve yararlanılan kütüphaneleri içermektedir. Bölüm 6’da Soft-Actor-Critic

³ Haarnoja, T., Zhou, A., Abbeel, P. and Levine, S., “Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor.” arXiv preprint arXiv:1801.01290, 2018

Algoritması ile Kriptopara Ticareti uygulamasını, Bölüm 7 kullanılan yöntem için genel bir değerlendirme içermektedir. Son bölümde ise uygulama sonuçları bulunmaktadır.



II. LİTERATÜR ARAŞTIRMASI

Literatürde finansal piyasaların tahminlenmesiyle ilgili bir çok çalışma mevcuttur. Finansal piyasalardaki hareketlerin veya getirilerin tahmin edilmesi uzun süredir üzerinde çalışılan alanlardan biridir. Borsa getirilerini veya altın, döviz gibi finansal varlıklarının getirilerini inceleyen ve bunların tahminleri üzerinde bir çok çalışma olmasına karşın kripto paraların getirilerinin tahmin edilmesini inceleyen çalışmalarla karşılaşma olasılığı diğer finansal varlıklara göre daha düşük düzeydedir. Dahası, bu getiriler üzerinde Derin Pekiştirmeli öğrenme ile yapılan çalışmalar yeni bir alan olması nedeniyle yeterli olgunluğa henüz ulaşmamıştır. Bu kapsamda Pekiştirmeli Öğrenme, Derin Öğrenme ve Algoritmik Ticaret başlıklarını içinde barındıran veya bu araştırmaların birlikte kullanıldığı çalışmalar incelenmiştir.

Huang, Huang ve Ni yaptıkları çalışmada[11], Ocak 2012'den Aralık 2017 ye kadar BTC-USD paritesindeki verileri temel alarak 124 farklı teknik göstergiyi getiri tahminlemek için karar ağacı tabanlı sınıflandırıcı kullanarak bir model geliştirmişlerdir. Çalışmada, büyük veri ve teknik göstergelerin birleşiminin Bitcoin getirilerinin tahmin edilebilirliğine yardımcı olabileceğini ortaya koymuşlardır.

Kaur[12], yaptığı özgün çalışmada algoritmik ticaret için duygu analizi ve pekiştirmeli öğrenmeyi birlikte kullanmıştır. Yapay Sinir ağları ile haberlerden duygu analizi gerçekleştirmiş ve geçmiş piyasa verilerini kullanarak trend analizi yaparak elde ettiği çıktıları Markov Karar Süreci ile modelleyerek pekiştirmeli öğrenme yöntemlerinden

Q-Öğrenme yöntemiyle çözümlenmektedir. Sadece PÖ kullandığında elde ettiği Sharpe Oranı 0.85 olurken, YSA kullanarak elde edilen trend analiziyle birlikte PÖ kullandıklarında 1.4 Sharpe Oranına ulaşılmıştır, dahası PÖ, Trend Analizi ve Duygu Analizini birlikte kullandığı durumda Sharpe oranı 2.4 olmaktadır.

Alessandretti ve arkadaşları yazdıkları makalade[13], Kasım 2015 ile Kasım 2018 arasındaki 1681 farklı kriptoparanın günlük fiyatlarını kullanarak 3 farklı yöntem üzerinde test etmişlerdir. İlk iki yöntem regresyon temelli Güçlendirilmiş Gradyan Karar Ağaçları'ndan oluşmaktadır. Diğer yöntem ise zaman serisi problemleri için başarılı sonuçlar elde edilen uzun-kısa süreli hafıza (Long Short Term Memory-LSTM) yöntemidir [14]. Referans hattı olarak Basit Hareketli Ortalama yöntemini baz almaktadırlar. Lu da Tekrarlayan Pekiştirmeli Öğrenme ile yaptığı çalışmada [15], uzun kısa süreli hafıza kullanmaktadır.

Piotrowski va. [16], 2007 yılında yaptıkları çalışmada yatırımcıları bir piyasa oyuncusu olarak ele almışlardır. Çalışmanın sonucunda algoritmaların basit ama zaman ve kaynak bakımında yüksek tüketime ihtiyaçları olduklarını, işlem maliyetlerini göz önünde bulundurarak testlerin yapılması gerektiğini ve piyasa market modellerinin öngörülebilir olduğunu belirtmektedirler.

Lim ve Gorse[17], yüksek frekanslı işlemler için en uygun piyasa yapıcılığını hedefledikleri çalışmada Q-Öğrenme yöntemiyle en uygun politikayı oluşturmaya

çalışmaktadırlar. Diğer yöntemlerle kıyasladıklarında Pekiştirmeli Öğrenme toplam kar bakımından daha iyi performans göstermektedir.

Liang va. genel olarak oyunlar ve robotik kontroller için kullanılan, Proksimal Politika Optimizasyonu, Derin Deterministik Politika Gradyanları ve Politika Gradyanı olmak üzere 3 modern sürekli Pekiştirmeli Öğrenme algoritmalarını portfolyo yönetimi için implemente ettikleri çalışmada[18], farklı optimizasyon yöntemleri ve ağ mimarileri deneyimleyerek Çin Hisse Senedi Piyasası'nda test etmişlerdir. DDPG ve PPO yöntemlerinde eğitim sürecinde tatmin edici performans elde edememişlerdir. Bunun yanında, elde ettikleri genel sonuçlar Derin Pekiştirmeli Öğrenme'nin portfolyo yönetimi için oyunlar, robotik gibi alanlardaki kadar dikkate değer bir başarı olmadığı yönündedir.

Du ve arkadaşları klasik Pekiştirmeli Öğrenme yöntemlerinden Q-Öğrenme ve Tekrarlayan Pekiştirmeli Öğrenme'den faydalanarak portfolyo optimizasyonu üzerinde yaptıkları çalışmada [19], gürültülü veri kümelerinde Tekralayan Pekiştirmeli Öğrenme yönteminin değer tabanlı arama yöntemlerinden daha sağlam performans elde ettiği sonucuna ulaşmışlardır. Uzel'in[20] Çevrimiçi öğrenme ve örüntü tanıma yöntemi kullanarak, TRY/USD çiftinde Forex piyasalarında %65 ve üzerindeki oranlarda başarılı alım-satım işlemleri yaptığı görülmektedir.

Jiang ve Liang kriptoparaların portfölyo yönetimi⁴ üzerine yaptıkları çalışmada [21] Q fonksiyonu tahminini kullanmadan, basit bir deterministik politika gradyanı yöntemiyle portfölyo yönetimi için doğrudan bir ödüllendirme yöntemini önermektedirler. Çalışmalarını sadece geriye dönük testlerle gerçekleştirdikleri çalışmalarında, performanslarını farklı algoritmalarla kıyasladıklarında oluşturmuş oldukları Evrişimsel Sinir Ağı (Convolutional Neural Network - CNN) etmeni “Kaybedenleri takip et” yaklaşımını temel alan PAMR(Passive Aggressive Mean Reversion) algoritmasından[22] sonra en başarılı ikinci yöntem olmuştur.

Deng va. oluşturdukları uygulama çatısında [23], Derin Öğrenme ve Pekiştirmeli Öğrenme yaklaşımlarından faydalanmışlardır. Derin Öğrenmeyi piyasa şartlarını otomatik algılamak için kullandıkları çatıda, Pekiştirmeli Öğrenmeyi derin sinir ağlarıyla etkileşime girip maksimum ödülü kazanmak üzere alım satım kararlarını vermektedir. Deng va. arkadaşları algoritmik ticaret için Pekiştirmeli Öğrenme yönteminin finansal ortamının temsil edilmesi ve alım satım işleminin dinamik davranışta olması gibi zorlukları olduğunu ifade etmektedirler. Bunun yanında çalışmalarında derin öğrenmenin otomatik özellik öğrenme avantajını kullanarak teknik göstergeler kullanmamaları bir diğer dikkat çekici unsurdur.

⁴ Portfölyo yönetimi: Farklı finansal varlıkların fonlanmasının karar verme süreci olarak özetlenmektedir. [21]

Necchi çalışmasında [24], Parametre Tabanlı Keşif ile Politika Gradyanları PGPE [25] ve Doğal Parametre Tabanlı Keşif ile Politika Gradyanları NPGPE [26] algoritmalarını kullanarak Al ve Tut stratejisiyle performanslarını kıyaslamaktadır. İşlem maliyetlerinin göz ardı edildiği durumda, NPGPE 231.63%, PGPE 314.34% performans toplam kara ulaşmasına karşın, al ve tut strateji yüzde 7 toplam karını artırabilmiştir. Ek olarak bu yöntemler yüksek Sharpe Oranlarına da sahiptirler. Necchi, işlem maliyetlerinin etkisini de çalışmasına dahil etmiş ve analiz sonuçlarını ortaya koymuştur. Bu durumda her iki yöntemde işlem maliyetlerinin toplam ödüle etkisini göz ardı etmediğini, daha düşük ödüle neden olduğunu zaman içerisinde algılayabilmekte ve sürekli alım-satımı düşürmektedir.

Cumming tezinde[27], Forex piyasalarında pekiştirmeli öğrenme yöntemleri kullanarak yeni bir yaklaşımla algoritmik alım-satım üzerinde çalışmıştır. En Küçük Kareler Geçici Fark Öğrenme (Least Squares Temporal Difference Learning - LSTD) tabanlı bir yöntem önermektedir. Farklı para paritelerinde 11 farklı mumlar (candlesticks) ile yaklaşık her bir çift için 360000 mum gösterimi kullanılmaktadır. Cumming[27], çalıştığı yöntemde, umduğu kadar karlı bir alım-satım gerçekleştirilememiş olmasına rağmen bu yöntem üstünde yeni çalışmalar yapılabileceğini ifade etmektedir. Tablo 2.1'de literatür araştırmalarının özeti bulunmaktadır.

Tablo 2.1. Literatür Özet Tablosu

Çalışma	Hedef	Yöntem	Yıl
Piotrowski va.[16]	Piyasa Oyunu	Pekiştirmeli Öğrenme (Reinforcement Learning - RL) Q-Öğrenme (Q-Learning)	2007
Du va. [19]	Portfölyo Optimizasyonu	Tekrarlayan Pekiştirmeli Öğrenme(Recurrent Reinforcement Learning-RRL) Q-Öğrenme(Q-Learning)	2009
Cumming[27]	Algoritmik Ticaret	En Küçük Kareler Geçici Fark Öğrenme (Least Squares Temporal Difference Learning - LSTD)	2015
Necchi[24]	Algoritmik Ticaret	Parametre Tabanlı Keşif ile Politika Gradyanları (Policy Gradient with Parameter-based Exploration - PGPE) Doğal Parametre Tabanlı Keşif ile Politika Gradyanları (Natural policy gradient methods with parameter-based exploration - NPGPE)	2016
Deng va.[23]	Finansal Ticaret	Pekiştirmeli Öğrenme(Reinforcement Learning) Derin Tekrarlayan Sinir Ağları (Deep Neural Networks - DNN)	2016
Kaur[12]	Algoritmik Ticaret	Yapay Sinir Ağları(Artificial Neural Networks) Q-Öğrenme(Q-Learning)	2017
Lu[15]	Robo-Danışman	Tekrarlayan Pekiştirmeli Öğrenme (Recurrent Reinforcement Learning -RRL) Uzun Kısa Süreli Hafıza(Long-Short-Term-Memory)	2017
Jaing ve Liang [21]	Kripto Para Portfölyo Yönetimi	Derin Deterministik Politika Gradyanı (Deep Deterministic Policy Gradients - DDPG) Evrişimsel Sinir Ağları (Convolutional neural network - CNN)	2017
Liang va. [18]	Portfölyo Yönetimi	Derin Deterministik Politika Gradyanı (DDPG) Proksimal Politika Optimizasyonu (Proximal Polcicy Optimization -PPO) Politika Gradyanı (Policy Gradients - PG)	2018
Huang va. [11]	Kripto Para Fiyat Tahminleme	Karar Ağaçları (Decision Tree)	2018
Lim ve Gorse[17]	Yüksek Frekanslı İşlemler En uygun piyasa yapıcı	Q-Öğrenme (Q-Learning)	2018
Alessandretti vd.[13]	Kripto Para Fiyat Tahminleme	Güçlendirilmiş Gradyan Ağaçları (Gradient Boosting Tree - GBT) Uzun Kısa Süreli Hafıza (Long Short Term Memory - LSTM)	2019

III. FİNANSAL KAVRAMLAR

Diğer finansal piyasalarda olduğu gibi Kriptopara piyasalarında da alım satım işlemleri için genel olarak Temel Analiz ve Teknik Analiz olmak üzere iki farklı yaklaşım kullanılmaktadır. Bu iki yaklaşımın detayları Bölüm 3.1 ve Bölüm 3.2’ de sunulmaktadır. Detaylara inilmeden önce takip eden kısımda bir takım finansal ticaret terimlerinden söz edilmektedir.

Finansal marketlerde işlem yapanlar uzun veya kısa olarak adlandırılan iki tip pozisyon açmaktadırlar. Bunlardan ilki olan *Uzun pozisyon*, bir döviz veya bu tez bağlamında kripto çiftinin alınmasıyla oluşan ve baz para veya baz kripto para biriminin değer kazanmasıyla kârı artan pozisyonudur. Örneğin uzun BTC/USD pozisyonu açan bir yatırımcı BTC’nin USD karşısında değer kazanmasıyla kar elde edecektir. Diğer pozisyon ise kısa pozisyon olarak kullanılmaktadır. *Kısa Pozisyon*, bir döviz veya bu tez kapsamında kripto para çiftinin satılmasıyla oluşan ve baz para biriminin veya baz kripto paranın değer kaybetmesiyle kârı artan pozisyonudur. Örneğin kısa BTC/USD pozisyonu olan bir oyuncu BTC’nin USD karşısında değer kaybetmesiyle kâr etmiş olmaktadır [20].

ORDER BOOK BTC/USD							TRADES BTC/USD			
COUNT	AMOUNT	TOTAL	PRICE	PRICE	TOTAL	AMOUNT	COUNT	TIME	PRICE	AMOUNT
10	9.67	9.67	4,096.7	4,096.8	6.44	6.44	2	19:50:45	4,096.7	0.0040
1	4.41	14.08	4,096.6	4,096.9	7.35	0.92	3	19:50:28	4,096.7	0.0040
1	0.02	14.09	4,096.5	4,097.0	7.55	0.20	1	19:50:13	4,096.7	0.0040
2	1.50	15.59	4,096.3	4,097.6	8.05	0.50	1	19:50:11	4,096.7	0.0058
1	0.08	15.66	4,096.2	4,097.8	8.08	0.03	1	19:50:00	4,096.7	0.0040
1	0.02	15.68	4,096.0	4,098.0	8.28	0.20	1	19:49:45	4,096.7	0.0040
1	1.33	17.01	4,095.7	4,099.0	8.83	0.54	1	19:49:33	4,096.7	0.0125
1	0.03	17.04	4,095.5	4,099.1	9.61	0.79	1	19:49:30	4,096.7	0.0040
3	6.43	23.48	4,095.4	4,099.3	9.63	0.02	2	19:49:28	4,096.7	0.4323
2	5.07	28.55	4,095.2	4,099.4	9.70	0.08	1	19:49:17	4,096.7	0.0074
1	2.95	31.50	4,095.0	4,099.5	10.20	0.50	1	19:49:17	4,096.8	0.0526
1	2.95	34.45	4,094.9	4,099.8	10.21	0.01	1	19:49:06	4,096.7	0.0050
1	0.79	35.24	4,094.4	4,100.0	11.16	0.94	4	19:48:58	4,096.7	0.0040
1	0.06	35.30	4,094.0	4,100.1	11.56	0.40	2	19:48:53	4,096.7	0.1666
1	0.21	35.51	4,093.6	4,100.3	11.95	0.39	1	19:48:43	4,096.7	0.0040
1	1.52	37.03	4,093.5	4,100.4	13.17	1.22	1	19:48:42	4,096.7	0.0054
1	1.11	38.14	4,093.2	4,100.5	13.97	0.80	1	19:48:21	4,096.7	0.0323
2	0.27	38.40	4,093.1	4,100.6	19.94	5.97	1	19:48:18	4,096.7	0.0074
1	0.00	38.41	4,093.0	4,100.7	20.22	0.28	2	19:48:18	4,096.8	0.0026
2	0.21	38.62	4,092.8	4,100.9	21.12	0.90	1	19:48:04	4,096.7	0.0125
2	4.29	42.91	4,092.4	4,101.3	25.53	4.41	2	19:47:19	4,096.7	1.4431
1	50.00	92.91	4,092.0	4,102.0	26.53	1.00	1	19:47:01	4,096.7	0.0050
1	1.00	93.91	4,091.9	4,102.1	27.38	0.86	1	19:47:00	4,096.7	0.0050
1	0.04	93.95	4,091.8	4,102.4	27.78	0.39	1	19:47:00	4,096.7	0.0150

Şekil 3.1. Emir Defteri ve Gerçekleşen İşlemler⁵

Şekil 3.1’de Bitfinex borsasındaki BTC/USD çifti emir defterinin ekran görüntüsünde görüldüğü üzere Emir Defterinin sol tarafında alıcılar, sağ tarafında ise satıcılar bulunmaktadır Satış fiyatı(ask price), emir defterin sağ tarafında bulunan minimum fiyat, alış fiyatı emir defterinin sol tarafında bulunan maksimum fiyattır. Alış fiyatı ile satış fiyatı arasındaki fark, makas (spread) olarak ifade edilmektedir. Finansal piyasalarda kullanılan çeşitli emir türleri bulunmaktadır. Kriptopara borsalarındaki bazı emir türleri şunlardır:

- **Al Emri (Buy Market):** Bir kriptopara çiftinin piyasa fiyatından alınmasıyla oluşan emirdir.

⁵ www.bitfinex.com 10.03.2019 tarihinde erişilmiştir[28].

- **Sat Emri (Sell Market):** Bir kriptopara çiftinin piyasa fiyatından satılmasıyla oluşan emirdir.
- **Al Limit Emri (Buy Limit):** Talimat ile belirlenen bu emir türünde, piyasadaki fiyattan daha düşük seviyede bir fiyatın oluşması durumunda uzun pozisyon açılması veya başka bir tabirle alım emri gerçekleşmektedir.
- **Sat Limit Emri (Sell Limit):** Talimat ile belirlenen bir diğer emir türü olan Sat Limit emri, piyasadaki fiyattan daha yüksek seviyede bir fiyatın oluşması durumunda satış yapılmasını olanak sağlayan emirdir.
- **Kar Al(Take Profit):** Yatırımcının açtığı pozisyondan beklediği karı elde ettiğinde pozisyonun kapatılmasını sağlayan emir türüdür. Kısa pozisyonlarda açılış seviyesinin altındaki fiyatlar, Uzun pozisyonlarda açılış seviyesinin üzerindeki fiyatlar Kar Al seviyesi olarak belirlenir. Bu emir türü kullanıldığında, piyasada Kar Al fiyatı oluşması durumunda pozisyon otomatik olarak kar ile kapatılmaktadır [20].
- **Zarar Durdur(Stop Loss):** Yatırımcının açmış olduğu pozisyondan büyük zararlarda ayrılmasının önüne geçen başka bir ifadeyle zararını sınırlandıran emirdir. Uzun pozisyonlar için açılış seviyesinin altında, kısa pozisyonlar için açılış seviyesinin üzerindeki fiyatlar Zarar Durdur seviyesi olarak belirlenerek, fiyatın bu seviyeyi görmesi durumunda pozisyonun otomatik olarak zararla kapatılmasını sağlar. Oyuncunun tahmininin tersi yöndeki piyasa hareketlerinden doğacak zarar sınırlandırılmış olur [20].

3.1. Temel Analiz

Genellikle orta veya uzun vadeli yatırımlar için tercih edilen Temel analiz, eğer bir ülke para birimini için kullanılmaktaysa milli gelir, sanayi endeksleri, faiz oranı gibi makroekonomik göstergeler dikkate alınırken; hisse senedi analizleri için başvurulduğunda, şirket bilançosu, şirket finansal oranları gibi nicel ve nitel bütün faktörleri inceleyerek yapılan analizdir [20]. Bunların yanı sıra, özellikle bu çalışma kapsamında ele almakta olduğumuz Kriptoparaların temel analizinde ilgili kripto varlığın çözmeyi vadettiği veya gerçekleştirdiği problemler, sahip olduğu kaynaklar, ekip ve danışmanlar, projenin kullanılabileceği potansiyel alanlar, kriptoparanın işlem hacmi gibi bir çok durum göz önünde bulundurularak projenin potansiyel değeri içsel görümlerle belirlenmeye çalışılmaktadır.

3.2. Teknik Analiz


Teknik analiz geçmiş fiyatlardan yola çıkarak ve geçmiş fiyatların gelecek fiyatları etkileyeceği varsayımına dayanarak yapılan analizdir[20]. Bir başka tanımla Teknik analiz (TA), finansal bir varlığın fiyatının gelecekte ne olacağını tahminlemek adına matematiksel kalıpları ve göstergeleri kullanmayı önceleyen stratejidir [29]. Forex piyasalarında olduğu gibi bu teze konu olan kriptopara piyasalarında da profesyonel veya bireysel yatırımcılar teknik analizi daha çok tercih etmektedirler.

Teknik Analiz yapılırken grafiklere yüksek oranda ihtiyaç olmaktadır. Grafikler, finansal varlığın fiyat hareketleri konusunda zaman, en yüksek fiyat, açılış ve kapanış fiyatı gibi en temel bilgileri muhteva etmektedirler [30]. Genel olarak, grafiklerin yatay

ekseni zamanı, dikey eksen ise finansal varlığın fiyatını göstermektedir. Grafiklerin temsili, doğrusal ölçekte veya çoğunlukla geniş zaman aralıklarında büyük fiyat değişimlerini daha dar bir alanda görüntülemek için kullanılan logaritmik ölçekte olabilir. Teknik analizde grafikler türüne göre geçmiş fiyatlar, dakikalık, saatlik, günlük, haftalık, aylık gibi seçilebilen periyotlarda çizdirilebilir.


Finansal analizler için yaygın olarak 3 çeşit grafik kullanılmaktadır.

1. **Mum Grafik:** Mum grafikler Teknik Analiz'de en çok tercih edilen grafiklerden biridir. Finansal bir varlığın işlem geçmişini bu grafikler vasıtasıyla temsil edilebilmektedir ve finansal varlığın fiyatının ilerleyen periyotlarda nasıl değişeceğini tahmin etmeye yardımcı olacağı düşünülmektedir. Farklı zaman periyotları kullanılarak, farklı mum grafikleri oluşturabilmektedir. Örneğin 30 dakikalık mum grafikleri 30 dakika boyunca gerçekleşen işlemleri sunmaktayken, 1 günlük mum grafikleri 1 gün boyunca gerçekleşen işlemleri göstermektedir [2]. Mum grafiğinde açılış ve kapanış fiyatlarına göre renkler değişmektedir. Mumlar açılışkapanışından yukarıdaysa yeşil renkte, aşağıdaysa kırmızı renkte gösterilmektedir. Şekil 3.2'de Bitcoin Mum Grafiği örneği bulunmaktadır.



Şekil 3.2. Bitcoin Mum Grafiği

2. **Bar Grafik:** Finansal varlıklar için kullanılan bir diğer grafik Bar Grafiktir. Bar grafik, en yüksek ve en düşük fiyat seviyesinin birleştirilmesiyle oluşan dikey çizgi, açılış ve kapanış fiyatlarının ise kısa yatay çizgilerle işaretlendiği grafik türüdür. Açılış fiyatı sola doğru, kapanış fiyatı sağa doğru çizilerek gösterilmektedir [20]. Mum grafiğe kıyasla daha az bilgi içermesine rağmen, okunuş anlamında daha rahat bir temsil sunmaktadır. Şekil 3.3'te Bitcoin Bar Grafiği örneği bulunmaktadır.



Şekil 3.3. Bitcoin Bar Grafiği

- Çizgi Grafik:** Çizgi grafik, finansal ürünün açılış, kapanış, en yüksek, en düşük fiyatlarından sadece birinin çizgi olarak gösterildiği grafik türüdür. Daha uzun süreler için finansal varlığın eğiliminin belirlenmesine yardımcı olmasının yanında kısa periyotlar analiz edilirken çok tercih edilmemektedir [20].

Teknik analizin finansal piyasalarda çokça tercih edilmesine rağmen bir takım sakıncaları mevcuttur. Finansal veriler çok miktarda gürültü ve sıçrama içermektedir. Bu durum, TA için bir sorun oluşturabilmektedir. Diğer bir sakıncası ise Teknik Analiz'in yaygın olarak genelleştirilememesidir [23].

3.2.1. Destek, direnç ve trendler

Teknik analizin temellerini oluşturan Carles Dow'un önerdiği Dow Teorisi'nde fiyatların trendler içinde hareket ettiği belirtilmektedir. Burada Trend, fiyatların rastgele hareket etmeyerek belirli bir genel yönde salınımlarla değiştiğini ifade etmektedir [27]. Trendleri belirlemek için grafikler üzerine fiyat değişimleri doğrultusunda çizgiler çizilir. Bu çizgiye trend çizgisi denir. Trendin varlığından söz

etmek için fiyatların grafik üzerindeki iki nokta arasında çizilen doğrunun üstünde ya da altında olması gerekir.

Trendler kısa, orta ve uzun süreli zamana bağlı olarak veya piyasa eğilimine göre düşüş ve yükseliş olarak kategorize edilmektedir. Yükseliş trendi, kesin olarak bir süresi bulunmamakla birlikte günlük bazda değil en azından haftalar veya aylar bazında finansal piyasalarda uzun vadeli ve yukarı yönlü bir eğilim olarak tanımlanmaktadır. Finans ekosisteminde boğa eğilimi olarak da adlandırılmaktadır. Düşüş trendi de yükseliş trendinin tersine uzun vadeli düşüş eğilimini belirtmektedir. Düşüş trendi ayı eğilimi olarak da bilinmektedir. Yükseliş ve düşüş trendlerinin bazı aşamaları bulunmaktadır. Yükselen trendlerin ilk aşamasında, kötü piyasa şartlarında uzun vadede olumlu bir beklentisi olan yatırımcıların alım yapmasıyla başlayıp, ikinci aşamada piyasa koşullarının iyileşmesiyle finansal varlığın fiyatları artmaktadır, bu durumda piyasa daha cazip hale geldiği için daha çok yatırımcı alım yapmaktadır. Son aşamada ise alım yapmış yatırımcılar karlarını realize etmek istemektedirler, başlangıç aşamasından aldıkları varlıkları satmaya başlamaktadırlar. Bu noktadan sonra düşüş trendi başlar ve satış baskısıyla piyasa koşulları daha kötüye gitmektedir. Dolayısıyla daha çok satış gerçekleşir, son aşamada panik satışlarıyla çok düşük seviyelerden satışlar gerçekleştirilmektedir [31].

Piyasa ile ilgili bir yargıya varmak için endeksler, teknik göstergeler ve hareketli ortalamalar birbiri ile tutarlı olmalıdır. Bir trendin onaylanması için farklı endekslerde aynı trendin görülmesi gerekmektedir.

Direnç, teknik analiz bağlamında tarihsel veriler göz önünde bulundurularak satış baskısının satın alma baskısından yüksek olduğu fiyat seviyesini temsil etmektedir. Piyasada, bu fiyat seviyesi kırılmaya çalışıldığında dirençle karşılaşılacağı düşünülmektedir [29].

Destek, tarihsel veriler gözetildiğinde satın alma baskısının satış baskısından yüksek olduğu fiyat seviyesidir. Fiyatın, bu seviyenin altına yönelmesi durumunda destekleneceği düşünülmektedir. Bazı yatırımcılar dirençler kırıldığında, desteğe dönüştüğü varsayımında bulunmaktadır [29]. Bir başka açıdan destek ve direnç, fiyatın gitmekte olduğu yönde duraksayacağı düşünüldüğü seviyelerdir [20].

Bunların yanında, destek ve direnç, teknik analizde en çok kullanılan tekniklerden biri olup, geçmişte fiyatların geri dönerek veya en azından yavaşlayarak tepki verdiği fiyat bölgelerinin tespit edilip bu analizlerle alım satım stratejilerinin oluşturulmasına katkı sağlamaktadır [32].

3.2.2. Göstergeler

Teknik Göstergeler⁶, geçmiş fiyat verilerini kullanarak güncel fiyattan alım satım kararları verilmesine veya piyasanın yönünün belirlenmesine yardımcı olan matematiksel formüllerdir [20]. Yıllar içinde geliştirilmiş hareketli ortalama, MACD, Bollinger Bantları, RSI gibi birçok teknik gösterge tanımlanmıştır.

3.2.2.1. Hareketli ortalamalar

Hareketli ortalama belirli bir periyot sayısındaki geçmiş verinin ortalamasının alınmasıdır. Hareketli Ortalama (Moving Average - MA), finansal varlığın fiyatındaki küçük dalgalanmaları düzeltmek için kullanılmaktadır [29]. Bu sayede trend daha belirgin olarak anlaşılmaktadır. Hareketli Ortalama'da, periyot sayısı sabit tutularak yeni fiyat verileri ortalamaya dahil edilirken, eski fiyatlar ortalamadan çıkarılmaktadır.

Farklı hareketli ortalama türleri bulunmasına rağmen literatürde yaygın olarak kullanılan Basit Hareketli Ortalama(Simple Moving Average - SMA), Ağırlıklı Hareketli Ortalama(Weighted Moving Average - WMA) ve Üssel Hareketli Ortalama(Exponential Moving Average - EMA) olmak üzere üç çeşit hareketli ortalama kullanılmaktadır.

Basit Hareketli Ortalama: Basit hareketli ortalama yönteminde, belirli dönemdeki fiyatların hareketli ortalaması gösterilmektedir. Piyasa eğilim yönünü belirlemek üzere

⁶ Teknik indikatörler olarak da bilinmektedir.

SMA değerlerinin farklı aralık değerleri ile kesişimi kullanılmaktadır. Örneğin, Bitcoin fiyatı SMA'dan yüksekse, Bitcoin'in fiyatının artacağı öngörülmektedir. SMA'nın 50 günlük değeri 200 günlük değerini yukarıya doğru kesiyorsa fiyatların yükseliş eğiliminde olacağı, aşağı doğru kesiyorsa eğilimin alçalan yönde olacağı varsayılmaktadır. Ortalamaya katılan fiyatlar herhangi bir zamana göre katsayılandırılmadan eşit ağırlıklarla değerlendirilir. Seçilen periyot sayısı kadar fiyatın toplanarak gün sayısına bölünmesi ile bulunur. Denklem 3.1 de Basit Hareketli Ortalama formülü gösterilmektedir. ZP, Zaman periyodunu ifade etmektedir [33],[20].

$$SMA(ZP) = \sum_{k=a+1}^{a+ZP} \frac{Kapanış(k)}{ZP} \quad (3.1)$$

Ağırlıklı Hareketli Ortalama: Yakın zamandaki fiyatların daha önemli olduğu varsayımıyla, son periyoda yaklaştıkça oluşan fiyatların ortalama içindeki ağırlığının daha çok olduğu hareketli ortalama türüdür. Yakın periyottan geriye doğru uzaklaştıkça önemlilik doğrusal olarak azalmaktadır [33],[20]. Denklem 3.2'de WMA formülü bulunmaktadır.

$$WMA(ZP) = \frac{Kapanış Fiyatlarının Ağırlıklı Ortalamalarının Toplamları}{Ağırlıkların Toplamı} \quad (3.2)$$

Üssel Hareketli Ortalama: Bir diğer yakın zamandaki fiyatların daha önemli olduğu hareketli ortalama türü olan Üssel hareketli ortalama, alınan ilk periyot için kapanış fiyatından SMA çıkarılarak katsayı ile çarpılır ve SMA'ya eklenir. Sonraki günlerde ise SMA yerine önceki günün üssel hareketli ortalaması kullanılır. Üssel hareketli

ortalamada, son günlerin önemi katlanarak artmaktadır [33],[20]. EMA formülü denklem 3.3’de gösterilmektedir.

$$EMA(ZP) = (Kapanış - EMA(Önceki Gün)) * \frac{2}{ZP + 1} + EMA(Önceki Gün) \quad (3.3)$$

3.2.2.2. Hareketli Ortalama Yakınsama Uzaksama

Teknik analizde kullanılan en popüler göstergelerden biri olan Hareketli Ortalama Yakınsama – Iraksama (Moving Average Convergence Divergence -MACD) basitçe kısa dönemdeki fiyat değişimlerinin yönüyle, uzun dönemdeki fiyat değişimlerinin yönünün karşılaştırılmasıdır[34]. MACD genel olarak, Bölüm 3.2.2.1.’de tarif edilen üssel hareketli ortalamanın kısa dönemi sembolize eden 12 ve uzun dönemi işaret 26 günlük değerlerinin arasında oluşan farktır. Fakat parametrik olarak periyotlar değiştirilebilir. MACD hattına ek olarak bir de sinyal hattı bulunmaktadır. Sinyal hattı, MACD değerinin 9 günlük üssel hareketli ortalamasının hesaplanmasıyla bulunmaktadır [33]. Denklem 3.4’te MACD hattı formülü gösterilmektedir.

$$MACD \text{ Hattı} = EMA(12) - EMA(26) \quad (3.4)$$

3.2.2.3. Bağlı Güç Endeksi

Fiyat değişimlerinin hızını ve yönün gösteren Bağlı Güç Endeksi(Relative Strenght Index - RSI) aşağıdaki formülle ifade edilmektedir [40]. 0 -100 arasında değişmektedir. RSI değeri 30’dan küçükse aşırı satım olduğu, 70’den büyükse aşırı alım olduğu düşünülmektedir. RSI göstergesi ile ilgili varlığın, mevcut değerinin daha önceki fiyatlara göre kıyaslanarak alım satım için uygunluğu belirlenebilmektedir. RSI ile

artışlar ve azalışlar arasındaki güç farkını görebiliriz. Denklem 3.5 ve 3.6 'da RSI ile ilgili gösterimler mevcuttur.

$$RS = \frac{\text{Önceki t gün için mevcut değerden yüksek kapanışların ortalaması}}{\text{Önceki t gün için mevcut değerden düşük kapanışların ortalaması}} \quad (3.5)$$

$$RSI = 100 - \left(\frac{100}{1+RS} \right) \quad (3.6)$$

3.2.2.4. Bollinger Bantları

Özünde fiyat hareketlerinin üst ve alt limitlerini gösteren Bollinger Bantları, John Bollinger tarafından ortaya atılmıştır. Genel olarak, fiyatlardaki dönüş noktalarını belirlemek amacıyla kullanılan bu bantlar, volatilité ölçümü yapmaktadır[35]. Bollinger bantları üç çizgiden oluşmaktadır. Ortadaki çizgi genellikle 20 günlük SMA ile oluşturulmaktadır, fakat burada net bir kural yoktur, yaygın kullanım bu şekildedir. Oluşturulan bu orta çizgi üst ve alt bantlara bir temel oluşturmaktadır. Bu bantlar aracılığıyla volatilité ölçülmektedir. Üst ve alt bantlar genel olarak 2 standart sapma yukarıda ve aşağıda şeklinde oluşturulmaktadır [36]. Denklem 3.7 -3.9 Bollinger bantları hesaplamalarını göstermektedir.


$$\text{Orta Bant} = SMA(20) \quad (3.7)$$

$$\text{Üst Bant} = SMA(20) + (\text{Standart Sapma} * 2) \quad (3.8)$$

$$\text{Alt Bant} = SMA(20) - (\text{Standart Sapma} * 2) \quad (3.9)$$

Bollinger Bantları kullanılırken, daralma ve genişleme olmak üzere iki kavram mevcuttur. Daralma, fiyatların ortalamaya yakın kapanışlarla standart sapmanın azalması sonucu oluşmaktadır. Genel kanı, daralma olduğunda fiyatlarda bir

hareketlenme olacağı yönündedir. Trendler genel olarak daralmalardan sonra başlamaktadır. Diğer kavram genişleme ise, fiyatların ortalamadan uzak değerler alması ile standart sapmanın artması ile oluşmaktadır. Genişleme ile üst ve alt bant arası uzaklaşmaktadır. Trendler genel olarak genişlemeler sonrası bitmektedir [35]. Şekil 3.4'te XBT/BTC çiftinin 4 saatlik periyotlardaki mum grafiği üzerinde Bollinger Bantları gösterilmektedir.



Şekil 3.4. 4 Saatlik XBT/USD çifti üzerinde Bollinger Bantları⁷

3.2.3. Geriye dönük testler

Finansal piyasalarda strateji oluşturulmasına müteakip, stratejiyi borsalarda kullanmadan önce bir takım testler yapılması gerekmektedir. Bu testlerden en yaygın olanı geriye dönük testlerdir. Geriye dönük testlerin temel amacı gerçekleşmiş

⁷www.tradingview.com 08.04.2019 tarihinde erişilmiştir. Tradingview kullanılarak oluşturulmuştur.

fiyatlardan faydalanarak stratejinin performansını ölçmektir. Stratejinin başarısını ölçmek için Volatilité, Sharpe Oranı, Maksimum Düşüş Kalıcılığı Getiri, En yüksek alım satım, ortalama kazanç, ortalama kayıp, alım satım sayısı gibi metrikler kullanılmaktadır [37].

Sharpe Oranı (Sharpe Ratio): Alım-satım işlemlerinde performans kriterlerinden biri olan Sharpe Oranı, risk bazında ölçeklenmiş getiri olarak adlandırılır. SO, finansal yatırımın performansını söz konusu riske göre değerlendirmek için kullanılan bir ölçüttür.

SO yatırımcılar tarafından genel olarak 1'den büyükse iyi, 2'den büyükse çok iyi ve 3'ten büyükse harika olarak değerlendirilmektedir [38]. Sharpe Oranı denklem 3.10'daki gibi hesaplanmaktadır.

$$SO = \frac{E(R_t) - R_f}{\sqrt{Var(R_t)}} \quad (3.10)$$

Burada R_f risksiz yatırımı ve R_t yatırımın ortalama getirisini temsil etmektedir[37].

Getiri: Kar olarak da bilinen getiri finansal varlık için yatırılan miktarın bir sonraki zaman periyodundaki durumuna göre kazanılan kazanç veya kaybedilen miktar olarak ifade edilebilir. Yatırımın geri dönüşünü (Return of Investment - ROI) ifade eden ROI, Denklem 3.11'de gösterildiği gibi hesaplanmaktadır.

$$ROI = \frac{\text{Yatırımın şu andaki değeri} - \text{Yatırım maliyeti}}{\text{Yatırım Maliyeti}} \quad (3.11)$$

3.3. Kripto Paralar

Kriptoparalar, en genel şekliyle işlemlerin güven içinde gerçekleşmesini sağlamak için şifreleme(kriptoloji) yöntemini kullanan dijital paralardır [11]. Kriptoparaların geneli, kişilerin veya kurumların ödemelerini ve diğer işlemlerini anonim olarak güvenli bir şekilde yapabilmelerine imkan tanımaktadır. Giriş bölümünde de bahsedildiği üzere piyasalarda işlem gören 2104 adet kriptopara bulunmaktadır⁸.

Bitcoin'in yıllardır toplam piyasa kapitalizasyonunun %90'ından fazlasına sahip olma durumu 2017 yılının başından itibaren değişime uğramış ve ilk defa 2017 yılı içinde diğer para birimlerinin piyasa kapitalizasyonu toplamı Bitcoin'i geçmiştir.

Kriptoparaların son yıllarda kullanımının yaygınlaşması sebebiyle birçok kriptopara borsası ortaya çıkmıştır. Coinmarketcap verilerine göre şu günlerde yatırımcılara hizmet veren 16308 adet kriptopara borsası bulunmaktadır. Bunlardan bazılarında fiat para birimiyle işlemler yapılabilirken[39],[40], bazılarında ise sadece kriptoparalarla işlemler yapılabilmektedir [41]. Bunlara ek olarak, IDEX⁹ gibi merkeziyetsiz kriptopara borsalarında da alım satım işlemleri gerçekleştirilmektedir.

Devlet paralarının gayri merkezi alternatifi olan Kriptoparalar belli kriterlere göre ayrılmaktadır. Bazılarında[43] madencilik işlemi yapılabilirken bazılarında[44] ise

⁸ www.coinmarketcap.com 16.03.2019 tarihinde erişilmiştir.

⁹ https://idex.market 16.03.2019 tarihinde erişilmiştir.

yapılamamaktadır. Kriptoparalar için piyasa değerinden, günlük işlem hacmine, piyasa sıralamasından kapitalizasyonuna kadar değerlendirilmeye tabi tutulduğu bir takım metrikler de bulunmaktadır.

3.3.1. Bitcoin(BTC)

Dünyadaki ilk merkeziyetsiz kriptopara olan Bitcoin, son yıllarda önemli kullanıcı kitlesi yakalayarak, talebini artırmış ve piyasa değerini yükseltmiştir. Bitcoin ilk olarak 2008 yılında Satoshi Nakamoto takma adını kullanan biri veya birileri tarafından kaleme alınan bir makale¹⁰ ile ortaya çıkmıştır. Dijital ortamlar için tasarlanmış, beraberinde teknolojik olarak da yenilikler getirmiş ve ilk işlemi 2009 yılında gerçekleştirmiştir. İsminin gerçekliği bile şüpheli anonim bir kişi veya topluluk tarafından oluşturulan bu sistemde; herhangi bir devlet, merkez bankası gibi klasik para birimlerinin sahip oldukları otoriteler bulunmamaktadır. İşlemler ağ üzerinde iki taraf arasında herhangi bir aracı kurum olmaksızın gerçekleşmektedir. Maliyeti yok denecek kadar azdır. Ancak herhangi bir devlet otoritesinin kontrol ve sorumluluğunun olmamasından doğabilecek handikapları da içinde barındırmaktadır.

Şekil 3.5'te Bitcoin Piyasa Değeri ve Fiyat Grafiği gösterilmektedir.

¹⁰ <https://bitcoin.org/bitcoin.pdf> 25.02.2019 tarihinde erişilmiştir.



Şekil 3.5. Bitcoin Piyasa Değeri ve Fiyat Grafiği¹¹

Uluslararası para transferinin online olarak gerçekleştirilmesine altyapı sağlayan, belirli bilgisayar algoritmalarıyla üretilen, merkezi olmayan bir sanal para sistemi ve bu sisteme ait para birimi olarak tasarlanan Bitcoin; son yıllarda yatırımcı kitlesini artırarak piyasa değerini yükseltmiş ve denetim, otorite ya da finans politikalarına bağlılığı olmaması sebebiyle dünyanın her yerinden yenilikçi bir piyasa olarak ilgi toplamıştır.

Bitcoin'in beraberinde gelen Blokzinciri özetle işlemlerin değiştirilemez listesinin tutulduğu bir kayıt defteridir. Blokzinciri, yapılan işlemleri ve bir önceki blokun adresini tutmaktadır. Blok zincirleri, sahip oldukları yüksek güvenlik özellikleri ve şifreleme yöntemleri sayesinde mevcut yöntemlerle kırılması bir hayli zordur. Bitcoin transferi yapılmak istendiğinde bu aktarım süreci birden fazla bilgisayardan gelecek onayla gerçekleşir. Bu da güvenlik açısından önemli bir avantajdır.

¹¹ www.coinmarketcap.com 01.03.2019 tarihinde erişilmiştir.

Bitcoin oluřturma iřlemine madencilik (mining) denilmektedir. Madencilik, iřlem gúcünü kullanarak matematiksel bulmacaları çözümlayıp, elde edilen çözümlerden sonra oluřan ödüllerin yani Bitcoin'in ortaya çıkma sürecidir. Bu iřlemleri yapmak için, sunulan yazılımı indirerek donanımları üzerinde yoğun iřlemci gücü gerektiren iřlemleri gerçekteřtiren ađdaki bireylere "madenci" denilmektedir. Aynı zamanda her madenci eřten eře kurulan örneđin Bitcoin veya alternatif diđer birçok kriptoparanın ađında bulunan bir düđümü temsil etmektedir [46],[41].

Bitcoinin arkasındaki teknoloji olan Blokzincir, Tübitak Blok Zincir arařtırma merkezindeki tanıma göre, merkezi bir sunucunun veya güvenilir bir otoritenin kaldırılmasına olanak sađlayarak, merkezi güvenin internet ortamında dađıtılmasına denir. Blokzincir teknolojisi, tek merkeze dayalı güven sistemlerindeki merkezi güven yapısını dađıtıp, eřten eře bir yöntem kullanarak bu güven probleminin ařılmasına yardımcı olmuřtur [47].

Bitcoin ile ilgili iřlemlerin online sistem üzerinden dođrudan gerçekteřtirilmesi, aracı kurumlar, bankalar gibi komisyon alıcı herhangi bir kurumun olmaması ve bu yolla maliyetlerin düşük ve iřlemlerin hızlı olması sebebiyle büyük ilgi toplayan Bitcoin'in sunduđu kolaylıkların yanı sıra herhangi bir garantör kuruluřun olmaması, denetlenememesi ve muhatap kabul edilecek bir platformun olmaması gibi dezavantajları da göz önünde bulundurulmalıdır.

3.3.2. Ripple(XRP)

Coincap verilerine göre Ethereum'dan sonra piyasa değeri olarak 3. büyük kriptopara olan Ripple kendini ödeme sistemlerinin dijital varlığı olarak konumlandırmaktadır. Geleneksel yöntemlerle saatlerce veya günlerce süren ödemeler Ripple ile 4 saniyede gerçekleştirilebilir. Aynı zamanda Ripple'in saniyede 1500 işlem gerçekleştirme kapasitesi bulunmaktadır. Bitcoin ve Ethereum'un aksine Ripple da madencilik işlemleri gerçekleştirilmemektedir [43]. Toplam arzı 100 milyar civarında olan Ripple'in bu günlerde dolaşımdaki yaklaşık 41 milyar adedi bulunmaktadır [1]. Dünya'da birçok finans kuruluşunda kullanılan Ripple Ağı, Türkiye'de Akbank tarafından müşterilerin kullanımına sunulmuştur [48].

3.3.3. Ethereum(ETH)

Coinmarketcap¹² verilerine göre piyasa değeri Bitcoin'den sonra en büyük ikinci kriptopara olan Ethereum, Blokzincir üzerinde uygulamalar geliştirmeye olanak sağlamaktadır. Ethereum ile akıllı sözleşmeler¹³ oluşturularak, uygulamalar merkeziyetsiz bir şekilde çalıştırılabilmektedir. Aynı zamanda uygulamalar, kesinti dolandırıcılık veya dış faktörlerden etkilenmeyecek şekilde çalışmaktadır. Ek olarak, uygulama geliştiricilere veyahut bu anlamda bir değer oluşturmak isteyen kişi veya

¹² coinmarketcap.com - 13.03.2019 tarihinde erişilmiştir.

¹³ Akıllı sözleşmeler, blokzincirleri üzerinde belirlenen kurallara göre işlemler yapılmasına olanak vererek, bu kuralların sonuçlarına göre hesaplamaların veya işlemlerin gerçekleştirilmesini sağlayan kendi kendine çalışan programlardır[43].

kurumlara, fonlarını saklamalarına, pazarlar oluşturabilmelerine, geçmişte verilen talimatlara uygun olarak işlemler yapabilmelerine imkân sunmaktadır [43], [69].

Ethereum ile herkes kendine ait kriptopara oluşturabilmektedir. Oluşturulan bu paralar(token) Ethereum cüzdanında ether veya diğer kripto varlıklar olarak tutulabilmektedir [42]. Hali hazırda Ethereum ile geliştirilen finans[70],[71] alanından, medya endüstrisine[72],[73] yüzlerce uygulama bulunmaktadır ve Ethereum ağı üzerinde blokzincirleri kullanılarak oyunlar[74],[75] oynanabilmektedir.

3.4. Algoritmik Ticaret

Finansal piyasaların teknolojik ilerlemeleri benimsemesiyle algoritmik ticaret olarak adlandırılan bir kavram ortaya çıkmıştır. Algoritmik ticaret, bir alım satım işleminin bir kısmını veya tamamını otomatikleştirmek üzere önceden belirlenen bir takım algoritmaları insan müdahalesi olmaksızın gerçekleştirme işlemi olarak özetlenebilmektedir [49]. Burada algoritmalar alış ve satış emirlerinin verilmesinden, emirlerin zamanlamasına veya miktarına, alınabilecek risk boyutuna kadar birçok işleme karar verebilmektedirler. Aynı zamanda bu işlemleri yürütmekten de sorumludurlar.

Özellikle kriptopara piyasasında da algoritmik ticaret yöntemleri, finansal kurumların yanı sıra geliştiricilerin ve finansa ilgi duyan bireylerin de tercihi olmaktadır. Zira kriptopara borsaları diğer geleneksel borsaların aksine 7 gün 24 saat açık olmaktadır. Açık kaynaklı uygulamaların yaygınlaşmasının da bu duruma etkisi olduğu

düşünülmektedir. Github¹⁴ üzerinde algoritmik ticaret dersleri[51] gibi birçok ders, kriptopara alım satımı için algoritmik ticaret kütüphanesi[52] gibi birçok kütüphane veya Sample-Market- Maker[34] gibi birçok uygulama bulunmaktadır.

Alım-satım işlemlerini botlar¹⁵ vasıtasıyla yapmanın bir kaç öne çıkan avantajı bulunmaktadır. Bunlardan ilki, alım veya satıma dair çok sayıda olasılık içerisinde belli bir seçeneği seçme süreci olarak tanımlanan karar verme faaliyeti esnasında rasyonel davranabilmektedir [54]. Yani bu karara insan doğasında mevcut olan duyguları karıştırmamaktadır. Borsa işlemlerinde karar vermeyi etkileyen önemli faktör ise borsada yaşanacak hareketi öngörebilme yeteneğidir [12]. Bir diğeri önceki kısımda bahsedilen kriptopara piyasalarının 7/24 açık olmasıdır, insanlar uyur algoritmalar/botlar uyumaz [29]. Algoritmik ticarete, oluşturulan stratejinin geriye dönük testleri gerçekleştirilebilmektedir, dolayısıyla stratejinin geçerliliği hakkında ön bilgiye sahip olunmaktadır.

¹⁴ www.github.com

¹⁵ Ücretsiz olandan profesyonellerin kullanıma sunulan pahalı versiyonlarına kadar kriptopara topluluğunda yaygın olarak kullanılan botlar, piyasa trendlerini belirlemekten, alım satım kararlarına kadar işlemleri otomatik gerçekleştirmek üzere programlanmış varlıklardır[53].

IV. DERİN PEKİŞTİRMELİ ÖĞRENME

Derin Pekıştirmeli Öğrenme, pekıştirmeli öğrenmenin derin öğrenmeyle birlikte kullanılmasından oluşmaktadır [55]. Pekıştirmeli öğrenme ve derin yapay sinir ağlarını birleştirmenin temel motivasyonlarından biri, PÖ'de bulunan büyük boyuttaki durumlar uzayını derin yapay sinir ağlarının ihtiva edebilme potansiyelidir. Makine öğrenmesi, Gözetimli Öğrenme, Gözetimsiz öğrenme ve Pekıştirmeli Öğrenme olmak üzere 3 temel başlık altında ele alınmaktadır. Tablo 4.1'de özet olarak bu makine öğrenmesi yöntemlerinden bahsedilmektedir. Şekil 4.1'de bu üç yöntemin birbirleriyle ve Derin Öğrenme yöntemiyle ilişkileri gösterilmektedir.

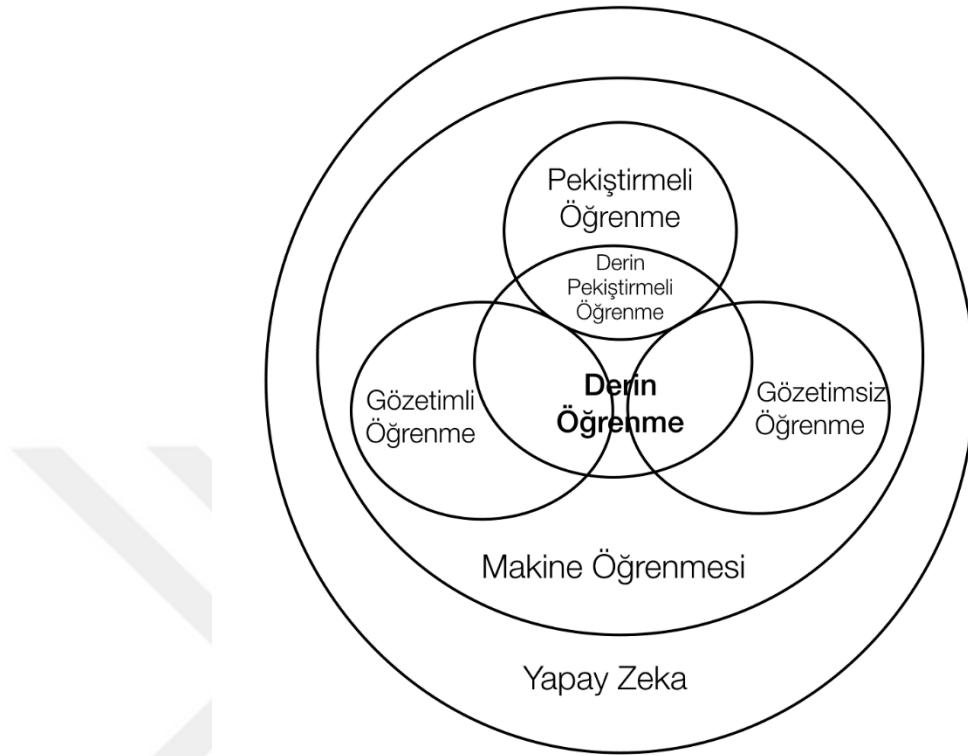
Tablo 4.1. Gözetimli Öğrenme, Gözetimsiz Öğrenme ve Pekıştirmeli Öğrenme

Gözetimli Öğrenme	Gözetimsiz Öğrenme	Pekıştirmeli Öğrenme
Veriler hazır bulunmaktadır.	Veriler hazır bulunmaktadır.	Veriler, öğrenme sürecinde türetilmektedir.
Öğrenme etiketli veriler ile sağlanmaktadır. Eğitim verisi içinde, doğru cevaplar bulunmaktadır.	Etiketli veriler kullanılmamaktadır.	Etkileşimle öğrenilmektedir. Ödüllerden faydalanılmaktadır.
Sınıflandırma, regresyon en çok bilinen gözetimli öğrenme yöntemlerindedir.	Kümeleme ve bileşen analizi başlıca Gözetimsiz öğrenme yöntemlerindedir.	Q-Öğrenme(Q-Learning), TD-Öğrenme (TD-Learning),Politika Gradyanları (Policy Gradients) Pekıştirmeli Öğrenme yöntemleridir
Ana görev, eğitim verileri içindeki doğru yanıtlara göre öğrenme faaliyetini gerçekleştirmektir.	Temel hedeflerden biri, veriler içindeki gizli veya açık örüntüleri/yapıları bulmaktır.	Etmten, aldığı ödül sinyalleri vasıtasıyla hedefe ulaşmaya veya kümülatif ödülü maksimuma çıkarmayı hedeflemektedir.

Gözetimli Öğrenme, veriler etiketlenilerek model oluşturulmaktadır. Sınıflandırma ve regresyon en çok bilinen gözetimli öğrenme yöntemleridir. Gözetimli öğrenmede, modeller eğitim verisi kullanılarak eğitilirler ve test verisi kullanılarak test edilmektedir. Sınıflandırma ve regresyon en çok bilinen gözetimli öğrenme sınıflarıdır.

Veriden anlamlı bilgiler elde etmeye çalışılan Gözetimsiz Öğrenme’de, gözetimli öğrenmenin aksine etiketlenmiş veriler olmadan öğrenme gerçekleşmektedir. En bilinen gözetimsiz öğrenme yöntemi kümelemedir.

Pekiştirmeli Öğrenme’de, Gözetimli öğrenmeden farklı olarak öğrenme sürecinde etmene rehberlik edilmez, etmen hangi aksiyonların kendisini maksimum ödüle götürüyor olacağını kendisi öğrenmektedir. Bu süreç ödül mekanizmasıyla desteklenmektedir. PÖ’nün, Gözetimli öğrenmeye göre bir diğer önemli farkı etmeni eğitmek için bütün veri setine ihtiyaç duyulmamasıdır. PÖ deneyimlerden öğrenirken, Gözetimli Öğrenme örneklerden öğrenmektedir.



Şekil 4.1. Yapay Zekâ, Makine Öğrenmesi, Derin Öğrenme, Gözetimli Öğrenme, Gözetimsiz Öğrenme, Pekiştirmeli Öğrenme ve Derin Pekiştirmeli Öğrenme Arasındaki ilişki¹⁶

Yapay sinir ağlarının rönesansı olarak görülen Derin Öğrenme son dönemde en yaygın kullanılan makine öğrenmesi yöntemlerinden biridir. Derin öğrenme’de gözetimli veya gözetimsiz öğrenme yöntemleri kullanılabilir. Dahası bu çalışmaya konu olan Pekiştirmeli Öğrenme yöntemleriye entegre olabilmektedir. Derin Öğrenmenin detaylarından Bölüm 4.2’de bahsedilmektedir.

¹⁶ Y. Li, “Deep reinforcement learning”, *arXiv preprint arXiv:1810.06339*, 2018.

4.1. Pekiştirmeli Öğrenme

Makine öğrenmesinin alt dallarından biri olan Pekiştirmeli Öğrenme, yapay zekânın gelişmesinde potansiyeli olan önemli alanlardan biridir. İnsan davranışlarından esinlenen pekiştirmeli öğrenmede temel endişe bulunulan durumdaki en iyi eylemi belirlemek olsa da, alınan aksiyonlar sadece o anki ödülü değil sonradan alınacak ödülleri de etkilemektedir. Bu sebeple, PÖ'de keşif (exploration) ve kullan(exploitation) kavramları arasında ödünleşim bulunmaktadır. Burada kullanım, o andaki iyi ödülü almak için önceden öğrenilen bilgileri kullanmayı, keşfet ise daha büyük ve iyi ödülleri almak için yenilikleri aramayı temsil etmektedir.

Pekiştirmeli öğrenme'de temel amaç, etmenin toplam ödülü(cumulative reward) maksimuma çıkarmasıdır [57]. Genel olarak, Pekiştirmeli öğrenme çatısı, aksiyonu gerçekleştir, yeni durumu gözlemler ve ödülü alır sıralı döngüsünden oluşmaktadır. Pekiştirmeli Öğrenme'de bazı anahtar kavramlar bulunmaktadır.

Etmen: *Etmen(agent)* çevreyle etkileşim içinde olup PÖ sürecinde aldığı sinyaller ile öğrenme faaliyetini gerçekleştiren temel öğelerden biridir. Başlangıçta rastgele hareketlerle başladığı süreci, her aşamada deneyime dönüştürmektedir [58]. Etmen elde ettiği deneyimler vasıtasıyla durumları ve aldığı ödülleri hafızasında tutarak toplam ödülü en üst düzeye çıkarmaktadır. Sürücüsüz araçlar, video oyun oyuncularını, satranç oyuncusu etmen için örneklerdir.

Çevre: Çevre(environment), ortam olarak da bilinmektedir, etmenle etkileşim içinde bulunan herhangi bir unsur olabilir. Ortam özünde etmenin iletişim halinde olduğu dış dünyadır. Ortam tam veya kısmi gözlemlenebilir olarak farklı sınıflandırmalar içermektedir. Etmen her zaman için sistemin durumunu belirleyebildiğinde, tamamen gözlemlenebilir olarak adlandırılır. Satranç oyununda sistemin durumu, daha açık ifadeyle satranç tahtasındaki tüm oyuncuların konumu, oyuncunun optimal bir karar vermesi için her zaman mevcuttur. Etmen, eğer her zaman için sistemin durumunu belirleyemiyorsa, ortam kısmi gözlemlenebilir olarak adlandırılmaktadır. Poker oyununda açık kartları gözlemleyebilirken, rakibin elindeki kartların bilinmemesi kısmi gözlemlenebilir ortam için bir örnektir [59]. Hisse senedi etmeni için Borsa veya sürücüsüz araç için yol birer ortamdır

Politika $\pi(s)$: Etmenin davranışının belirlenmesidir. Başka bir ifadeyle aksiyon seçimindeki kuraldır. Bazı durumlarda politika basit bir fonksiyon veya arama tablosu olabilirken, başka durumlarda da bir arama işlemi gibi kapsamlı bir hesaplama içerebilmektedir [60]. Stokastik veya deterministik şekilde olabilmektedir. Deterministik politika, doğrudan aksiyonla eşleşmektedir. Buna karşın Stokastik politika, aksiyonlar üzerindeki olasılık dağılımı kullanılarak rastgele aksiyonlar seçilmektedir.

Deterministik politika Denklem 4.1'de gösterilmektedir,

$$a = (s) \quad (4.1)$$

stokastik politika ise Denklem 4.2'de ,

$$(a | s) = P[At = a | St = s] \quad (4.2)$$

ifade edilmektedir. Burada a aksiyonu, s durumu temsil etmektedir. [57]

Durum: *Durum(state)*, etmenin algılayabildiklerinin temsilidir. Oyunlar için o anki ekran görüntüsü, finansal varlıklar için istatistiki bilgiler durum örneklerindedir.

Aksiyon: Aksiyon, etmenin aldığı kararlar veya gerçekleştirdiği eylemler olarak ifade edilmektedir. Borsada hisse senedi alımı veya satımı bir aksiyon olarak düşünülebilir.

Ödül: Etmenin gerçekleştirdiği aksiyon sonucunda elde edilen sonuçtur. Gerçekleştirilen eylemin pozitif veya negatif olarak elde ettiği ödüller ile etmenin politikası şekillenmektedir. Denklem 4.3'te gösterilen ödül fonksiyonu sadece duruma bağlı

$$r_t = R(s_t) \quad (4.3)$$

veya Denklem 4.4'deki gibi durum-aksiyon çiftine bağlı olarak,

$$r_t = R(s_t, a_t) \quad (4.4)$$

ifade edilmektedir [61]. Ödüllerin toplamı getiriye eşittir.

Gezinge (Trajectory): τ ile ifade edilen gezinge (trajectory) bir ortamdaki durum s ve aksiyon a dizisi olarak ifade edilmektedir [57]. Denklem 4.5'te gösterilmektedir.

$$\tau = (s_0, a_0, s_1, a_1 \dots) \quad (4.5)$$

Değer Fonksiyonu $V(s)$: Bir durumda olmanın veya bir aksiyonu gerçekleştirmenin ne kadar iyi olduğunu belirlemektedir. Değer fonksiyonu, ilk durumdan başlayarak

etmen tarafından alınan beklenen getiriye eşittir. Farklı değer fonksiyonu bulunmaktadır [61].

- **Politikada (On Policy) Değer Fonksiyonu:** $V^\pi(s)$ durum s de başlayıp, daima politika π uygulandığında beklenen getiriye vermektedir. Denklem 4.6'da gösterilmektedir.

$$V^\pi(s) = E_{\tau \sim \pi} [R(\tau) | s_0 = s] \quad (4.6)$$

- **Politikada (On-Policy) Aksiyon – Değer Fonksiyonu:** $Q^\pi(s, a)$, durum s de başlayıp, aksiyon a gerçekleşip ve sonra daima politika π 'ye göre hareket edildiğinde beklenen getiriye vermektedir. Denklem 4.7'de gösterilmektedir.

$$Q^\pi(s, a) = E_{\tau \sim \pi} [R(\tau) | s_0 = s, a_0 = a] \quad (4.7)$$

- **İdeal Değer Fonksiyonu:** $V^*(s)$, durum s de başlayıp, sonra her zaman ortamdaki ideal politikaya göre hareket edildiğinde beklenen getiriye vermektedir. Denklem 4.8'de gösterilmektedir.

$$V^*(s) = \max_{\pi} E_{\tau \sim \pi} [R(\tau) | s_0 = s] \quad (4.8)$$

- **İdeal Aksiyon-Değer Fonksiyonu:** $Q^*(s, a)$, durum s de başlayıp, aksiyon a gerçekleşip ve sonra daima en uygun politikaya göre hareket edildiğinde beklenen getiriye vermektedir[61]. Denklem 4.9'da gösterilmektedir.

$$Q^*(s, a) = \max_{\pi} E_{\tau \sim \pi} [R(\tau) | s_0 = s] \quad (4.9)$$

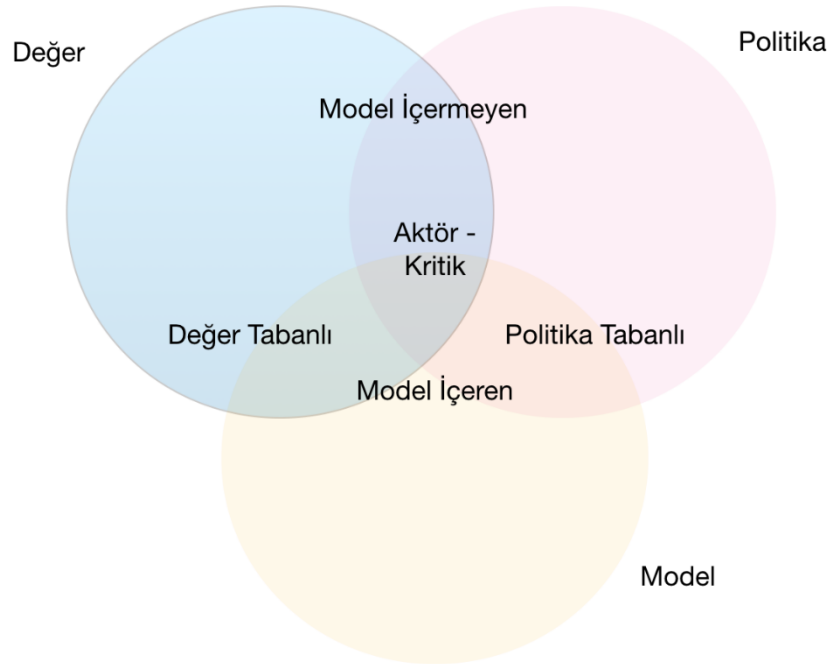
Avantaj Fonksiyonu: Pekiştirmeli Öğrenme'de bazı durumlarda aksiyonun mutlak manada ne kadar iyi olduğunu tanımlamak gerekmemektedir. Aksiyonun diğerlerinden

ne kadar iyi olduğunun göreceli olarak bilineceği zamanlarda Avantaj fonksiyonu kullanılmaktadır [61]. Avantaj Fonksiyonu $A^\pi(s, a)$ Denklem 4.10'da bulunmaktadır.

$$A^\pi(s, a) = Q^\pi(s, a) - V^\pi(S) \quad (4.10)$$

Model: Bazı pekiştirmeli öğrenme yöntemlerinde bulunan model, ortamın davranışını taklit eden veya ortamın hakkında çıkarımları tahminleyen unsurdur. Örneğin, modele aksiyon ve durum verildiğinde, sonraki durum ve ödülü tahminleyebilir[60].

Pekiştirmeli öğrenme çözüm yöntemleri, model tabanlı veya modelsiz olarak iki sınıfa, farklı öğrenme hedeflerine göre politika tabanlı(policy-based), değer tabanlı(value-based) ve her politika ve değer tabanlı yöntemlerin kombinasyonu ile oluşan aktör-kritik yöntemi olmak üzere 3 kategoriye ayrılmaktadır. Şekil 4.2'de yöntemlerin sınıflandırılması gösterilmektedir.



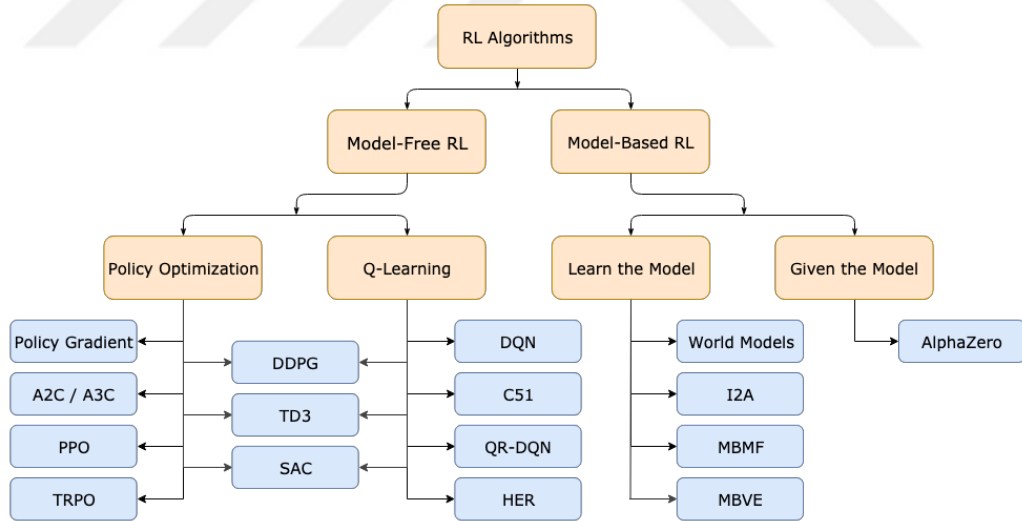
Şekil 4.2. Pekiştirmeli Öğrenme Yöntemleri

Politika Tabanlı Öğrenme: Sadece Aktör olarak da bilinen Politika Tabanlı öğrenme, politikadaki optimal politikayı doğrudan aramaya odaklanmaktadır [62]. Politika tabanlı Pekiştirmeli Öğrenme yöntemlerinin, genel olarak daha iyi yakınsama özelliklerine sahip olmanın yanında, yüksek boyutlu veriler ve sürekli hareket uzayında efektif kullanılabilirliği öne çıkmaktadır. Ek olarak stokastik politikaları öğrenebilmektedirler. Buna karşın politikanın değerlendirilmesi verimsiz ve yüksek değişkenlikte olabilmektedir [63].

Değer Tabanlı Öğrenme (Value Based Learning): Sadece-Kritik olarak da bilinen, değer tabanlı yaklaşımlara, örnek olarak TD-Öğrenme ve Q- Öğrenme verilebilir. Değer tabanlı yöntemler öncelikle ideal değer fonksiyonunu öğrenip, sonrasında bunun türeviyle ideal politikaya ulaşmaktadır [62]. Geçmiş yıllarda farklı bir çok alan için bu yöntemler üzerinde başarılı çalışmalar bulunmaktadır [19]. Sadece Kritik yöntemler, ayrık aksiyon-durum uzaylarında daha iyi sonuçlar vermesinin yanında bağlamları genel olarak daha hızlı öğrenmektedirler. Buna karşın, büyük boyutlu aksiyon—durum uzaylarında ölçeklenememektedirler.

Model Tabanlı Öğrenme (Model Based Learning): Model tabanlı yöntemlerde etmen, daha önceki deneyimlerinden elde ettiği bilgileri kullanmaktadır. Model kullanılarak, bir plan oluşturulmaktadır. Model tabanlı öğrenme de yanlılık büyük bir problem oluşturabilmektedir [61]. Bu tez kapsamında kullandığımız yöntem model içermemektedir.

Modelsiz Öğrenme (Model-Free Learnig): Model içermeyen öğrenme yöntemleri, model tabanlı öğrenmenin aksine sistem dinamikleri etmen tarafından bilinmemektedir veya ihtiyaç duyulmamaktadır. Deneyimleri öğrenmek için deneme-yanılma tabanlı bir süreç bulunmaktadır. Genel olarak model içermeyen pekiştirmeli öğrenme yöntemleri model içerenlere nazaran daha popüler olmasının yanında, daha çok üzerinde çalışılıp testler gerçekleştirilmiştir [64]. Modelsiz öğrenme de 2 temel yaklaşım bulunmaktadır. Bunlardan ilki Politika Optimizasyonur. A2C[65], PPO[66] gibi yöntemler Politika Optimizasyonunu benimsemektedirler[61], diğeri ise Q-Öğrenme'dir. Q-öğrenme ve Derin Q-Ağları Bölüm 4.1.3'de açıklanmaktadır. Her iki yöntem için de farklı ödüneşimler bulunmaktadır. Şekil 4.3'te modern Pekiştirmeli Öğrenme Algoritmalarının model bağlamında sınıflandırılması gösterilmektedir.




Şekil 4.3. Pekiştirmeli Öğrenme Algoritmalarının Model Bağlamında Sınıflandırılması¹⁷

¹⁷ https://spinningup.openai.com/en/latest/spinningup/rl_intro2.html (10.03.2019 tarihinde erişilmiştir.)

4.1.1. Markov karar süreçleri

Sıralı karar verme problemleri, markov karar süreçleriyle formüle edilebilmektedir. Şekil 4.4'te Markov Karar Süreçleri Etmen ve Çevre etkileşimi bulunmaktadır.



Şekil 4.4. Markov Karar Süreçlerindeki Etmen Çevre Etkileşimi¹⁸

Markov Karar Süreçleri (Markov Decision Process - MDP), durumlar, aksiyonlar, transition probability, ödüller ve indirim faktörüyle formüle edilmektedir.

Markov Karar Süreçlerinde;

- S durumlar kümesini
- A aksiyonlar kümesini
- $P(s' | s, a)$ hal değişimleri olasılık fonksiyonu
- $R: S \times A \rightarrow R$ Ödül fonksiyonu
- $\gamma \in [0,1]$ İndirim faktörü(discount factor)

olarak ifade edilmektedir.

¹⁸ A. Karadoğan, "Takviyeli öğrenme için yapay atom algoritması (A3) kullanımı", Yüksek Lisans Tezi, Bilgisayar Müh., İnönü Üni., Malatya, Türkiye, 2014.

4.1.2. Q-öğrenme ve derin q-ağları

Q öğrenmede, etmen için bulunduğu durumları ve gerçekleştirilen hareketleri tutan bir tablo kullanılır. Öğrenme işleminin her bir adımında Q değerleri güncellenmektedir. Etmenin bu tabloyu kullanarak en uygun hareketi seçmesi sağlanır. Model içermeyen Pekiştirmeli Öğrenme yöntemlerinden olan Q-Öğrenme, negatif veya pozitif ödüller ile durum-aksiyon çiftini kullanarak bir öğrenme süreci oluşturmayı hedeflemektedir. Q fonksiyonu denklem 4.11 de gösterilmektedir.

$$q(s_t, a_t) = q(s_t, a_t) + \alpha [r + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)] \quad (4.11)$$

Burada α öğrenme katsayısı, γ indirim faktörüdür [76].

Kriptopara alım satımı için örnek basit bir Q-Öğrenme sistemi şu şekilde tasarlanabilir. Bu örnekte tek bir şirketin hisse senedine odaklanılmaktadır. Alım-satım işlemi için al, sat ve tut şeklinde 3 farklı aksiyon bulunmaktadır. Durumlar ise, hisse senedine sahip olup olmama durumu, alım fiyatıyla şu anki fiyatın karşılaştırılması temsil edilmektedir. Ödül, kar veya zarar olarak gerçekleşmektedir. Tablo 4.2’de Kriptopara Alım-Satım Q-Tablosu örneği bulunmaktadır.

Tablo 4.2. Kriptopara Alım-Satım Örneği Q-Tablosu

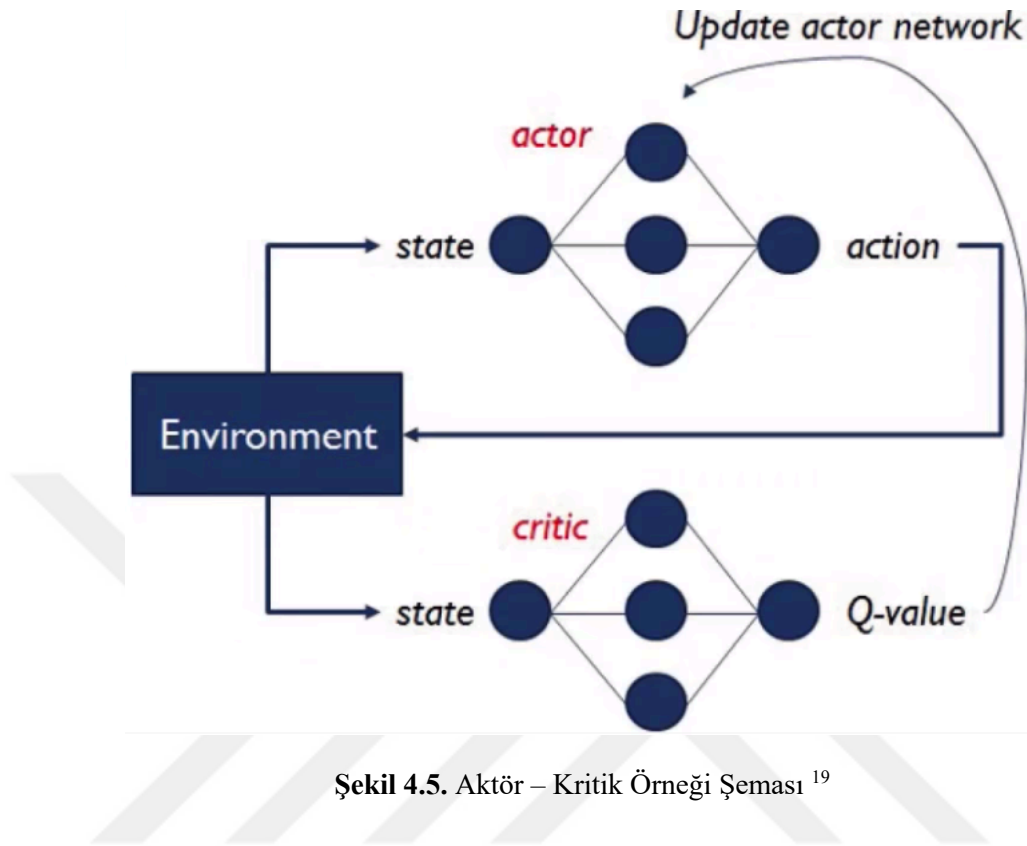
	Durum	Aksiyon	Ödül
d1	(kriptopara yok, fiyat eşit)	al	0
d2	(kriptopara var, fiyat yüksek)	sat	kar
d3	(kriptopara yok, fiyat eşit)	al	0
d4	(kriptopara var, fiyat eşit)	tut	0
d5	(kriptopara var, fiyat düşük)	sat	zarar

Derin Q-Ağları (Deep Q-Network - DQN) [77], yaygın olarak bilinen Derin Pekiştirmeli Öğrenme yöntemlerindedir. Google Deepminds araştırmacıları tarafından önerilen bu yöntem, insan seviyesinde atari oyunu oynamasıyla dikkatleri üzerine çekmiştir. DQN, aksiyonlar için ideal Q-değer fonksiyonunu tahminlemek amacıyla fonksiyon yakınlaştırıcısı (function approximator) olarak derin sinir ağlarını kullanmaktadır.

Deneyim Tekrarı (Experience Replay): Sinir ağı güncellemelerini daha stabil olarak yapmayı sağlamak amacıyla kullanılan tekniktir. Veri toplama işleminin her bir adımında geçişler (transitions) tekrarlama tamponu (replay buffer) olarak adlandırılan dairesel bir tampon (buffer) eklenmektedir. Daha sonradan eğitim sürecinde, son geçişin kayıp ve gradyanını hesaplamak yerine, tekrarlama tampon örnekleminde geçişleri mini yığınlar (mini-batch) şeklinde kullanarak kayıp ve gradyanlar hesaplanmaktadır [62].

4.1.3. Aktör – kritik

Aktör – Kritik yöntemlerde değer fonksiyonu ve politika ayrı kullanılmaktadır. Politika Aktör olarak temsil edilirken, değer fonksiyonu Kritik olarak temsil edilmektedir. Aktör, mevcut çevre durumunu gözeterek etmenin aksiyonunu belirlemektedirken, Kritik durum ve eylemleri bir değerlendirme sürecine tabi tutmaktadır. Aktör – kritik yöntemler, sınırsız girdi ve çıktı uzayı olan durumlarda kullanılabilir [79].



Şekil 4.5. Aktör – Kritik Örneği Şeması ¹⁹

Şekil 4.5'te örnek bir Aktör-Kritik şeması gösterilmektedir. Bölüm 4.1 de tanımlanan değer tabanlı ve politika tabanlı yöntemlerin kombinasyonu ile oluşan Aktör-Kritik yöntemler son zamanlarda Derin Pekiştirmeli Öğrenme çalışmalarında öne çıkmaktadır.

4.2. Derin Öğrenme

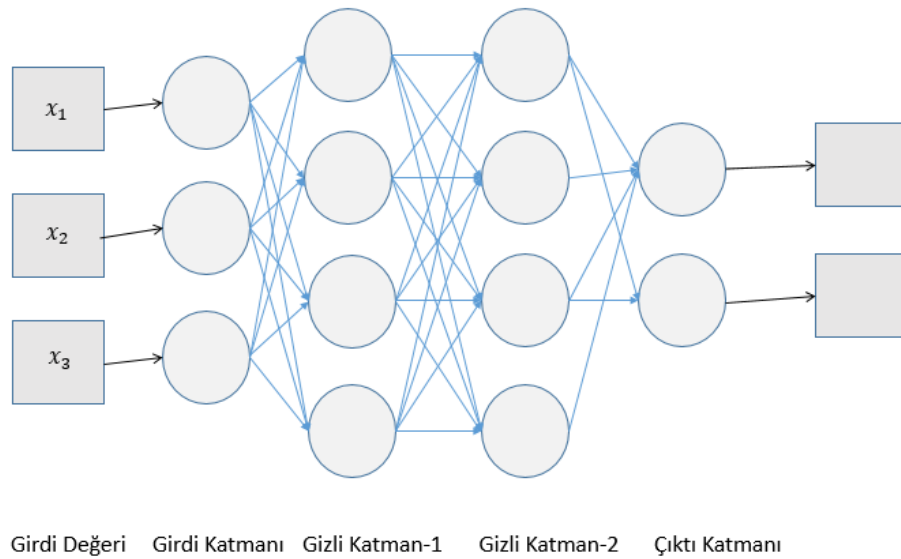
Makine Öğrenmesinin bir alt alanı olan Derin öğrenmede kullanılan farklı çok katmanlı derin yapay sinir ağları mimarileri bulunmaktadır. Takip eden kısımda, Çok Katmanlı

¹⁹S. Raval. Actor Critic Algorithms [Çevrimiçi]. Erişilebilir: https://www.youtube.com/watch?v=w_3mmm0P0j8&feature=youtu.be [Nisan 2019'da erişilmiştir.]

Derin Sinir Ağları(Multi Layer Deep Neural Network), Evrimsel Sinir Ağları(Convolutional Neural Network), Tekrarlamalı Sinir Ağları (Recurrent Neural Network) ve Uzun Kısa Vadeli Hafıza (Long Short Term Memory) yöntemleri açıklanmaktadır.

4.2.1. Yapay sinir ağları ve çok katmanlı yapay sinir ağları

Yapay sinir ağları(YSA), insan veya hayvan beynindeki nöronlardan esinlenen matematiksel modeller olarak özetlenebilir. YSA'da birçok basit birim, merkezi bir kontrol ünitesine bağlı olmadan paralel olarak çalışmaktadır. Birimler arasındaki ağırlıklar vasıtasıyla bilgi depolama işlemi gerçekleştirilir ve yeni bilgiler öğrenilmesi bu ağırlıkların sinir ağında güncellenmesiyle sağlanmaktadır. YSA'nın davranışı, nöron sayısı, katman sayısı ve katmanları arasındaki iletişim türünü içeren ağ mimarisine resmedilmektedir. YSA'da girdi, gizli ve çıktı katmanları bulunmaktadır. Şekil 4.6'da çok katmanlı sinir ağı örneği gösterilmektedir [80].



Şekil 4.6. Çok Katmanlı Sinir Ağı Örneği

4.2.1.1. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, bir katmanın çıktısını bir sonraki katmana iletmek için kullanılır [81]. Aktivasyon fonksiyonu, ağırlıklar ile çarpılan ve yanlılığa eklenen girişe uygulanmaktadır [59]. Aktivasyon Fonksiyonlarının farklı türleri mevcuttur. Bazı aktivasyon fonksiyonları şunlardır:

- **Doğrusal(Lineer):** Doğrusal dönüşüm, bağımlı değişkenin bağımsız değişkenle doğrudan orantılı bir ilişkiye sahip olduğu

$$f(x) = Wx \quad (4.11)$$

Denklem 4.11'de bulunan formül ile ifade edilmektedir Genel olarak, sinir ağlarının giriş katmanında kullanılır [80].

- **Sigmoid:** Sigmoid yöntemi verilerdeki aşırı değerlerini azaltmak için kullanılan aktivasyon yöntemlerinden biridir. Şekil 4.7'de görüldüğü üzere, Sigmoid fonksiyonu bağımsız değişkenleri 0 ile 1 arasında olasılıklara dönüştüren bir fonksiyondur, çıktıları 0 ile 1 arasında olmaktadır. Genel olarak çıktıların büyük çoğunluğu 0 veya 1 e yakın düzeyde seyretmektedir [81].

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4.12)$$

Sigmoid fonksiyonu Denklem 4.12'de bulunan formülle ifade edilmektedir.

- **Tanh:** Hiperbolik trigonometrik bir fonksiyon olan Tanh, Sigmoid fonksiyonundan farklı olarak -1 ile 1 arasında çıktı vermektedir. Tanh fonksiyonu kullanıldığında sağlanan temel fayda, negatif sayılarla kolayca

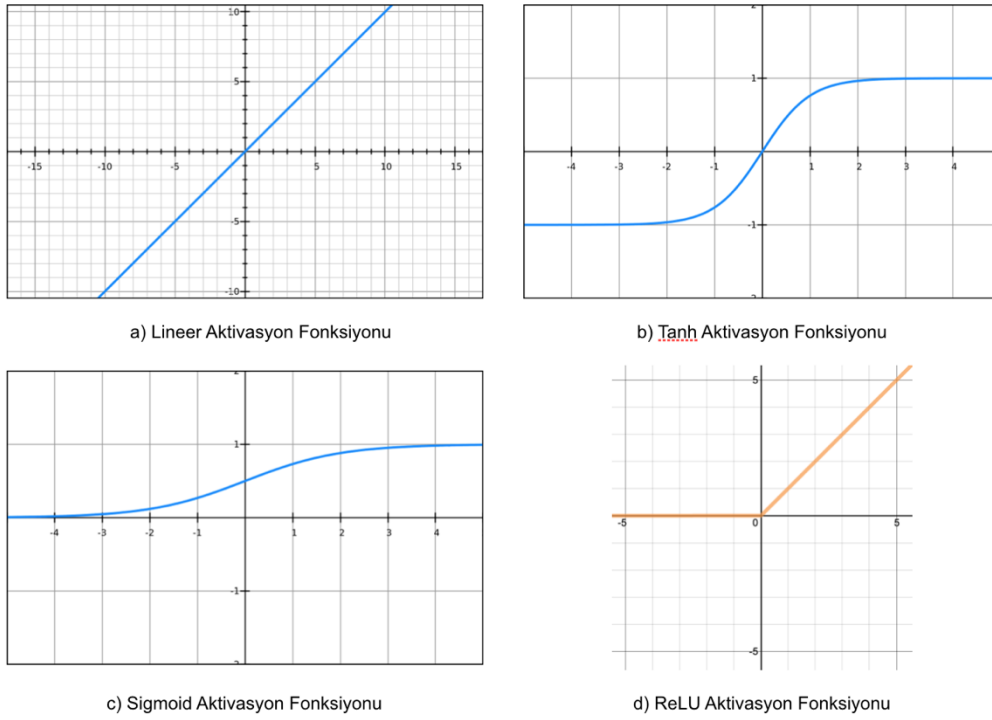
çalıřılabilmesidir. Őekil 4.7’de gsterilmekte olan Tanh, sıfır-temelli s-Őekilli bir fonksiyondur. Tanh, AŐađıdaki Denklem 4.13’teki formlle ifade edilmektedir [82].

$$f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (4.13)$$

- **ReLU:** ReLU olarak da bilinmekte olan Rectified Linear Fonksiyonu, giriŐ deđeri belirli bir miktarın zerinde olduđunda aktif olur. Girdi sıfırın altında iken, ıkıŐ sıfırdır, ancak girdi belirli bir miktarın zerinde olursa, bađımlı deđiŐkenle dođrusal bir iliŐkisi bulunmaktadır [81]. ReLU son zamanlarda en yaygın olarak kullanılan aktivasyon yntemlerinden biridir. ReLU,

$$f(x) = \max(0, x) \quad (4.14)$$

Denklem 4.14’deki formller ifade edilmektedir.



Şekil 4.7. Aktivasyon Fonksiyonları Grafikleri [80]²⁰

4.2.1.2. Hata Fonksiyonları

YSA'ların eğitimindeki temel hedeflerden biri ağın hata fonksiyonu değerini azaltmaktır. İyi eğitilen yapay sinir ağı mümkün oldukça düşük hataya sahiptir. Yapay sinir ağındaki bulunan hata, hata(loss or error) fonksiyonları ile ölçülmektedir. Bu hata fonksiyonları eğitim kümesindeki örneklerin hatalarının tümünü temsil eder. Problemin tipine ve yöntemin gerekliliklerine göre farklı hata fonksiyonları kullanılmaktadır.

²⁰ J. Patterson, A. Gibson, "Foundations of neural networks and deep learning," Getting Started with Deep Learning, O'Reilly Media, 2018.

4.2.1.3. Düzenleştirme (Regularization)

Sinir ağları eğitilirken, sahip oldukları parametlerden dolayı doğru olarak eğitilmediğinde eğitim versini ezberlemeye meyillidir. Düzenleştirmedeki veya cezanlandırma olarak da bilinir, temel amaç öğrenmedeki aşırı öğrenme/ezberleme problemini kontrol altında tutmaktır [83]. Literatürde farklı düzenleştirme yöntemleri bulunmaktadır. Problem ve gerekliliklere göre tercih edilen yöntemler değişebilmektedir.

Dropout [84]: Yeterli veri seti olmadan karmaşıklaşan ağ yapılarında aşırı öğrenmeyi engellemek için kullanılan bir düzenleştirme yöntemi Dropout, giriş katmanında veya gizli katmandan rastgele veya belirli bir eşik değeri kullanarak (genellikle 0.5), birimlerin sinir ağından kopartılmasıyla oluşan yöntemdir [80]. Bir diğer ifadeyle, alt ağlardan oluşan bir topluluğu orijinal ağdan rastgele çıkararak alt ağlar topluluğunu eğitmek için yapılan düzenleştirme stratejisidir [56].

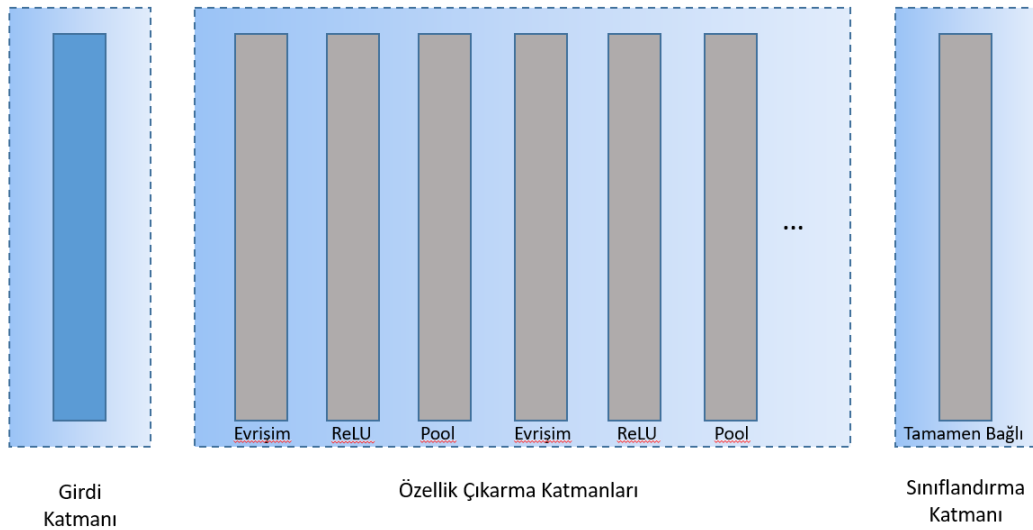
4.2.1.4. Optimizasyon

Derin öğrenme' de öğrenme işlemi özünde bir optimizasyon problemidir. Doğrusal (Linear) olmayan problemlerin çözümlerinde ideal değere ulaşmak için optimizasyon yöntemleri kullanılmaktadır. Literatürde ADAM[85], ADAgrad[86] ve RMSprop[87] gibi birçok farklı optimizasyon yöntemi bulunmaktadır.

4.2.2. Evrimsel sinir ağları

Özellikle bilgisayarlı görü alanında çalışılan evrimsel sinir ağları (Convolutional Neural Networks - CNN), ses işleme, doğal dil işleme gibi bir çok alanda kullanılan

bir YSA türüdür. Evrişimsel sinir ağlarındaki en temel katman, ağa da ismini veren envrişimsel (convolutional) katmandır. Genel olarak bir CNN'in amacı verilerdeki daha yüksek seviyedeki özellikleri konvolüsyonlar aracılığıyla öğrenmektir [80]. İleri yönlü sini ağlarından olan CNN, hayvanların görme merkezinden ilham alınarak oluşturulmuştur [88]. CNN, özellikle Evrişimsel (Convolutional), Pooling(Havuzlama), tam Bağlı 3 temel katmandan oluşmaktadır. Şekil 4.8'de CNN Mimarisi gösterilmektedir.



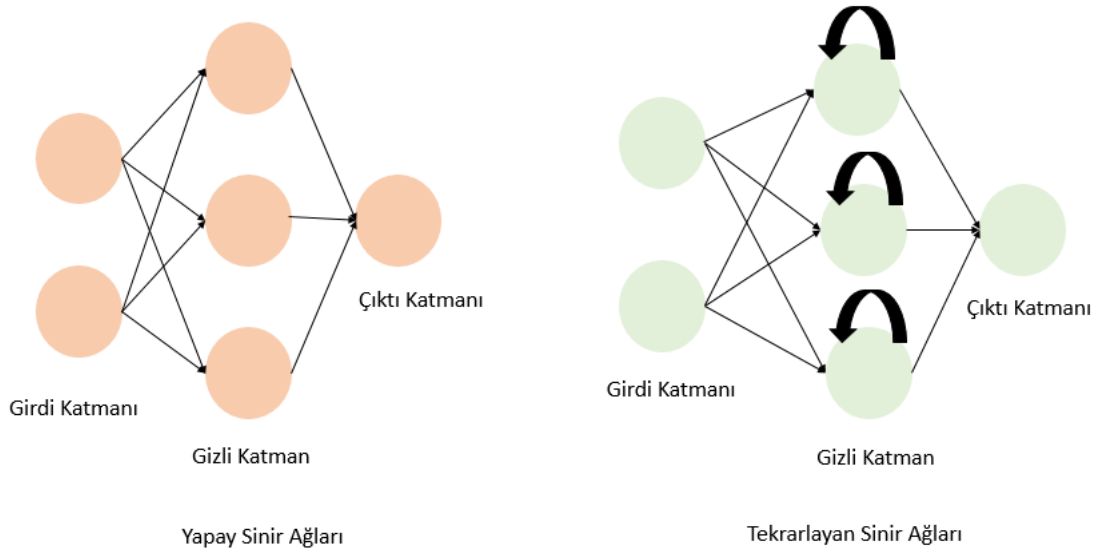
Şekil 4.8. Yüksek Seviye CNN Mimarisi²¹

²¹ J. Patterson, A. Gibson, "Foundations of neural networks and deep learning," Getting Started with Deep Learning, O'Reilly Media, 2018.

4.2.3. Yinelenen sinir ağıları

Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN), birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağı sınıfıdır. RNN'ler cümle üretmekten[89], melodi bestelemeye[90], finansal zaman serisi tahmin etmeye kadar birçok alanda kullanılmaktadır. Tekrarlayan sinir ağındaki (RNN) temel motivasyon sıralı bilgileri kullanmaktır. Diğer bir ifadeyle RNN, genel olarak sıralamanın önemsendiği veriler üzerinde kullanılmaktadır [59].

Yinelenen sinir ağlarında (recurrent neural network) veya tekrarlayan sinir ağı olarak da bilinen bu mimari de, sabit boyutlu girdiler yerine farklı uzunluktaki girdilerle çalışabilmektedir. Görüntü tabanlı verilerde tüm girdilerin (veya çıktıların) birbirinden bağımsız olduğu varsayılmaktadır. Fakat Doğal Dil İşleme gibi zaman değişkeni olan alanlar için bu durum mümkün değildir. Örneğin, bir cümle içinde bir sonraki kelimeyi tahmin etmek için, o anki kelimedenden önce hangi sözcüklerin geldiğini bilmek gerekmektedir. RNN mimarisinin tekrarlanan olarak adlandırılmasındaki sebep, bir dizinin her ögesi için aynı görevi önceki çıktılar bağlamında yerine getirmesidir [88]. RNN'ler, İleri beslemeli ağlardan farklı olarak, sıralı gelen girdilerin işlenmesi için dahili hafızalarını kullanırlar. Özetle, RNN'ler dinamik bir hafızaya sahiptirler. Şekil 4.9'da Sinir Ağları ve Tekrarlayan Sinir Ağları gösterilmektedir.



Şekil 4.9. Normal Sinir Ağları ve Tekrarlayan Sinir Ağları

Sinir Ağlarının eğitiminde kullanıldığı gibi RNN'lerin eğitiminde de geriye yayılım(backpropagation) kullanılabilir. Fakat RNN'lerde, tüm zaman adımlarına bağımlı olduğu için, her çıktıdaki gradyanlar yalnızca mevcut zaman adımına değil, önceki zaman adımına da bağlı olacaktır. Bu sebeple RNN'lerin eğitiminde Zaman İçinde Geriye Doğru Yayılım(BPTT – Backpropagation Through Time) kullanılmaktadır [59].

RNN'ler önceki verileri kullanarak zaman için oluşan örüntüleri yakalayabilmektedirler bu nedenle finans alanındaki zaman serisi verileri içinde tercih edildiği çalışmalar bulunmaktadır. Fakat RNN'ler yapısı gereği kaybolan gradyan problemleriyle baş etmek durumundadırlar bu nedenle takip eden kısımda bu problemin üstesinden gelmiş bir Tekrarlayan Sinir Ağı mimarisinin özel bir türü olan Uzun Kısa Vadeli Hafıza yönteminden bahsedilmektedir.

4.2.4. Uzun kısa vadeli hafıza

Uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türü olan Uzun Kısa Vadeli Bellek (Long Short Term Memory - LSTM) ağıları Hochreiter ve Schmidhuber tarafından 1997 yılında tanıtılmıştır [91]. Önceki bilgi kullanımına bağlı bir yaklaşım bulunan RNN mimarilerinde, bağlamlar arasında boşluk az olduğu durumlarda standart RNN'ler ile çıkarımda bulunmak problem olmasa da boşluklar arttığında bu durum geçmişten gelen bilgiyi kullanmayı zorlaştırmaktadır. Doğal dil işleme problemleri üzerinden örneklendirilen, “Latte bir kahve türüdür.” ifadesinde kahveyi tahmin etmek kolaydır. Fakat, “Ankara’da yaşıyorum. Yerel Seçimlerde Ankara’da oy verdim.” gibi cümlelerde Ankara kelimesini tahmin etmek için metnin başlangıcında bulunan yer bilgisinin veya bağlamının hafızada tutulması gerekmektedir. RNN’ler için teoride mümkün olan “uzun-vadeli bağımlılıklar”, pratikte büyük problemlere yol açtığı belirtilmiştir [88]. Bu problemi çözmek için, LSTM mimarisi giriş, unutma ve çıkış olmak üzere 3 kapı, blok girişi, Sabit Hata Döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme bağlantılarına sahiptir.

V. KULLANILAN TEKNOLOJİLER

Tez çalışması kapsamında, oluşturulan uygulama ve analizler sürecinde bir takım teknolojilerden faydalanılmıştır. Takip eden kısımda ilgili teknolojilerin detaylarından bahsedilmektedir.

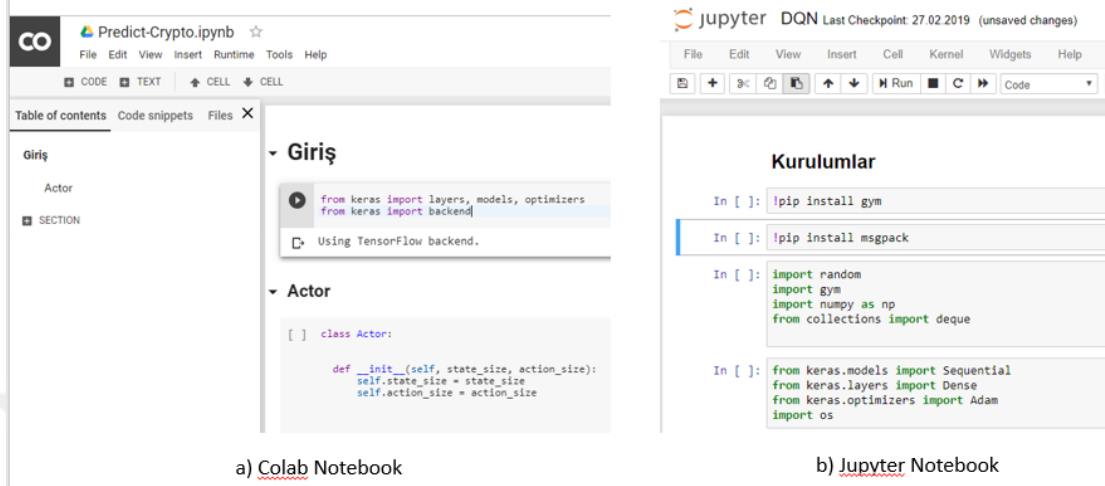
5.1. Jupyter notebook ve google colab

Jupyter Notebook²²; interaktif kodlar yazmaya, denklemler oluşturmaya, metinler yazmaya, görselleştirmeler yapmaya ve bunları paylaşmamıza olanak tanıyan açık kaynaklı bir web uygulamasıdır [93].

Colab²³, Google tarafından sunulan Jupyter Notebook alternatifi bulut tabanlı uygulamadır. Derin öğrenme veya python programlama diliyle interaktif uygulamalar geliştirmeye olanak sağlayıp, aynı zamanda geliştiricilere veya araştırmacılara yeniden kullanılabilirlik bağlamında katkı sağlamaktadır. Colab, ücretsiz GPU desteği vermesinin yanında herhangi bir indirme veya yükleme işlemi yapmadan notebookların çalıştırılmasına imkân vermektedir [92]. Şekil 5.1 de Colab ve Jupyter Notebook ortamları gösterilmektedir.

²² Jupyter (2019, Mart). Jupyter [Çevrimiçi]. Erişilebilir: <https://jupyter.org/> [Mart 2019'da erişilmiştir.]

²³ Colab (2019, Nisan). Colab [Çevrimiçi]. Erişilebilir: <https://colab.research.google.com/> [Nisan 2019'da erişilmiştir.]



a) Colab Notebook

b) Jupyter Notebook

Şekil 5.1. Jupyter ve Colab Notebook Örnekleri

5.2. Tensorflow

Google'ın açık kaynaklı yazılım haline getirdiği Tensorflow²⁴ (TF) uçtan uca makine öğrenmesi platformudur. TF ile kolayca makine öğrenmesi uygulamaları yazılabilir, bir çok sayısal hesaplama yapılabilir ve sunduğu eğitim materyalleriyle derin öğrenme gibi spesifik alanlarda modern araştırmalar için çalışılabilmektedir. Tensorflow'un web uygulamaları için TensorFlow.js ve Nesnelerin İnterneti ve mobil uygulamalar için Tensorflow Lite versiyonları bulunmaktadır. TF, sağlamış olduğu esnek mimarisiyle uygulamalar için CPU'ları, GPU'ları veya TPU'ları paralel olarak kullanmaya imkân tanımaktadır.

²⁴ Tensorflow, [Çevrimiçi]. Erişilebilir: <https://www.tensorflow.org> [Mart 2019'da erişilmiştir.]

Tensorflow mimarisinde, veri akış grafikleri kullanmaktadır. Tensorler, çok boyutlu veri dizilerini temsil eder iken, grafikteki düğümler matematiksel işlemleri temsil eder. Tensorler, graf düğümleri içindeki matematiksel işlemler vasıtasıyla bir hesaptan diğerine aktarılabilmektedirler [81], [94].

Tensorboard, Tensorflow üzerinde gerçekleştirdiğimiz hesaplamalar veya oluşturduğumuz uygulamalar, karmaşık boyutlara ulaşabilmektedir. Örneğin, oluşturduğumuz derin yapay sinir ağlarında hata ayıklamaktan, sinir ağlarını optimize etmeye kadar işlemleri görselleştirerek, kolay bir şekilde anlamamıza yardımcı olan bir araçtır. Şekil 5.2 de örnek bir TensorBoard üzerinde görselleştirme bulunmaktadır.



Şekil 5.2. TensorBoard Görselleştirme Örneği

Keras²⁵, Python programlama dili ile yazılmış, yüksek seviyeli bir sinir ağı API'dir. Keras, CPU ve GPU ile kolayca entegre olup çalışabilir, Evrimsel Sinir Ağları veya Yenilenen Sinir Ağları'nı desteklemenin yanında kolayca derin öğrenme uygulamaları için prototip geliştirmeye olanak tanımaktadır[95].

5.3. OpenAI Gym

Kar amacı gütmeyen yapay zekâ odaklı araştırmalar yapan OpenAI vakfı tarafından geliştirilen OpenAI-GYM²⁶, Pekiştirmeli Öğrenme algoritmaları geliştirmek ve test etmek için çeşitli ortamlar sunan bir araç kitidir. Bu ortamlar, robotik veya oyunlar gibi alanlarda farklı PÖ problemleri çözmek için hazır halde bulunmaktadır. Gym'in en büyük avantajlarından biri karşılaştırma ortamı sunmasıdır. Ek olarak, GYM Tensorflow gibi popüler hesaplama kütüphaneleriyle uyumlu olarak çalışabilmektedir.

Bunların yanında OpenAI vakfının açık kaynak kodlu, modern Pekiştirmeli Öğrenme algoritmalarının implementasyonlarını içeren Baselines²⁷ ve Derin Pekiştirmeli Öğrenme için eğitim kaynakları sunan SpinningUp²⁸ gibi farklı projeleri de bulunmaktadır.

²⁵ <https://keras.io> 01.04.2019 tarihinde erişilmiştir.

²⁶ <https://gym.openai.com/> 01.04.2019 tarihinde erişilmiştir

²⁷ <https://github.com/openai/baselines> 01.04.2019 tarihinde erişilmiştir.

²⁸ <http://spinningup.openai.com> 01.04.2019 tarihinde erişilmiştir.

5.4. Stable-Baselines

Açık kaynak kodlu, modern Pekiştirmeli Öğrenme algoritmalarının implementasyonlarını içeren Open-AI Baselines kütüphanesinden türetilerek oluşturulan Stable-Baselines²⁹, selefinden farklı olarak, daha iyi dökümente edilmiş ve ekstradan farklı algoritmaların implementasyonları da mevcuttur. Bu çalışmaya konu olan SAC algoritmasının [10], implementasyonu bulunmaktadır.

5.5. Backtrader

Backtrader³⁰, Python tabanlı geriye yönelik test kütüphanesidir. Beraberinde bir takım göstergeler ve alım-satım stratejileri bulunmaktadır. Backtrader, canlı veri aktarımı, çoklu strateji, kolay gösterge geliştirme, görselleştirme ve daha birçok ekstra özellik sunmaktadır [98]. Bunların yanında farklı finansal kütüphaneler ile entegrasyonları bulunmaktadır.

5.6. Dash

Dash³¹, analitik üzerine web uygulamaları geliştirmek için kullanılan bir web çatısıdır. Modern, Kullanıcı arayüzü elementleri kullanarak analitik uygulamalar geliştirmeye olanak tanımaktadır. Dash uygulama çatısı, React³² ve Flask³³ gibi uygulama çatılarının üstüne oluşturulmuştur [99].

²⁹ <https://stable-baselines.readthedocs.io> 05.04.2019 tarihinde erişilmiştir.

³⁰ <https://www.backtrader.com> 01.04.2019 tarihinde erişilmiştir

³¹ <https://dash.plot.ly/getting-started> 05.04.2019 tarihinde erişilmiştir.

³² <https://reactjs.org/> 15.04.2019 tarihinde erişilmiştir.

³³ <http://flask.pocoo.org/> 15.04.2019 tarihinde erişilmiştir.

VI. TEKNİK ANALİZ VE SOFT – ACTOR – CRITIC(SAC) İLE KRİPTOPARA TİCARETİ UYGULAMASI

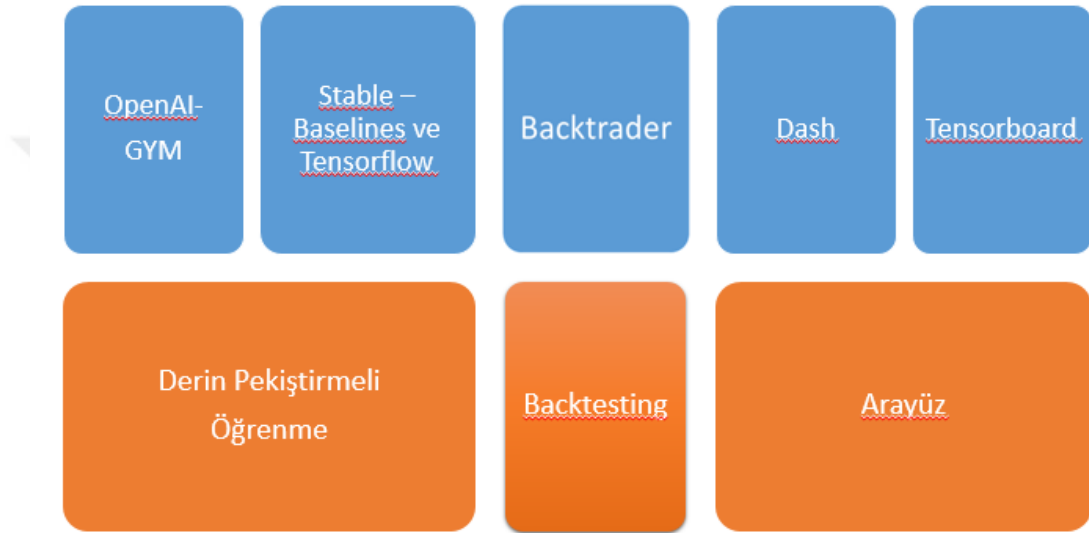
Uygulama geliştirme ve analizleri gerçekleştirme aşamasında izlenen yöntem Şekil 6.1’de bulunmaktadır.



Şekil 6.1. Teknik Analiz ve Derin Pekiştirmeli Öğrenme ile Kriptopara Alım – Satım Yöntemi

Uygulamanın Yüksek Seviye Mimarisi Şekil 6.2’de gösterildiği üzere 3 ana bileşen üzerinde ilerlemektedir. Derin Pekiştirmeli Öğrenme bileşeninde, uygulamanın 3 ana kısmından birincisi oluşmaktadır. Bu bileşende OpenAI-Gym, Stable – Baselines ve Tensorflow uygulama çatıları kullanılmaktadır. İkinci bileşende, Geriye yönelik testler(Backtesting), bir başka ifadeyle stratejilerin performanslarını ölçmek ve

karşılaştırmak adına Backtrader uygulama çatısı kullanılmaktadır. Son olarak kullanıcıya sağlanan arayüz ise Dash uygulama çatısı ve Tensorboard uygulaması entegrasyonu ile geliştirilmiştir. Detaylar takip eden bölümde açıklanmaktadır.



Şekil 6.2 Uygulama Bileşenleri ve Kütüphaneler

6.1. Soft Actor Critic(SAC) Algoritması

Haarnoja va. tarafından yazılan makalede[10] önerilen SAC(Soft-Actor-Critic) yöntemi, model içermeyen(model-free), politika dışı (off-policy) aktör-kritik Derin Pekiştirmeli Öğrenme algoritmasıdır. SAC algoritmasının[10], en temel özelliklerinden biri entropi düzenleştirmesidir. Politika beklenen getiri ve entropi arasındaki ödünleşimi en üst seviyeye çıkarmak üzere eğitilmektedir. Entropinin artırılması sonucunda daha fazla keşif olanağı bulunmaktadır [100]. Şekil 6.3'te SAC algoritmasının sözde kodu bulunmaktadır.

Algorithm 1 Soft Actor-Critic

Initialize parameter vectors $\psi, \bar{\psi}, \theta, \phi$.

for each iteration **do**

for each environment step **do**

$\mathbf{a}_t \sim \pi_\phi(\mathbf{a}_t | \mathbf{s}_t)$

$\mathbf{s}_{t+1} \sim p(\mathbf{s}_{t+1} | \mathbf{s}_t, \mathbf{a}_t)$

$\mathcal{D} \leftarrow \mathcal{D} \cup \{(\mathbf{s}_t, \mathbf{a}_t, r(\mathbf{s}_t, \mathbf{a}_t), \mathbf{s}_{t+1})\}$

end for

for each gradient step **do**

$\psi \leftarrow \psi - \lambda_V \hat{\nabla}_\psi J_V(\psi)$

$\theta_i \leftarrow \theta_i - \lambda_Q \hat{\nabla}_{\theta_i} J_Q(\theta_i)$ for $i \in \{1, 2\}$

$\phi \leftarrow \phi - \lambda_\pi \hat{\nabla}_\phi J_\pi(\phi)$

$\bar{\psi} \leftarrow \tau\psi + (1 - \tau)\bar{\psi}$

end for

end for

Şekil 6.3. Soft Aktör-Kritik Sözde Kodu [10]

Uygulamanın bu bölümü için Stable-Baselines kütüphanesindeki SAC implementasyonundan yararlanılmıştır [101]. Tablo 6.1’de Soft Actor-Critic yöntemine ait bir takım parametreler bulunmaktadır.

Tablo 6.1 Soft Actor Critic(SAC) Parametreleri [107]

Parametre	Tanım	Varsayılan Değerler
Policy	Kullanılan Politika Modelini Temsil Etmektedir. MlpPolicy, CnnPolicy, LnMlpPolicy, LnCnnPolicy gibi türleri bulunmaktadır.	MlpPolicy
Gamma	İndirim faktörü değeridir.	0.99
Buffer Size	Tekrarlama arabelleği boyutu	50000

Batch Size	Her grandyan güncellemesi için minibatch boyutu	64
Learning Rate	Adam optimize edicisi için öğrenme oranını temsil etmektedir. SAC içerisindeki tüm ağlar için (Q, aktör, değer) aynı öğrenme oranı kullanılmaktadır.	0.0003
Tau	Soft Güncelleme Katsayısı	0.005
Ent coef	Entropi Düzenleme Katsayısı, keşif ve kullanım arasındaki ödünleşimi belirlemektedir.	auto
Learning Starts	Modelin Öğrenmeye başlamadan önce, ne kadar durum değişikliği biriktirdiğini belirlemektedir.	100
Gradient Steps	Her adımdan sonra kaç adet gradyan güncellemesi olacağını belirlemektedir.	1

6.2. Verilerin Elde Edilmesi ve Ön Analizler

Doğası itibariyle kriptopara piyasalarında birçok piyasa verisi açık ve ücretsiz olarak bulunmaktadır. Bunun yanında profesyonel veri sağlayan uygulamalar veya şirketler bulunmaktadır. Bu çalışmada BTC, ETH, XRP verilerinin USD ve ETH, XRP verilerinin BTC çifti saatlik ve günlük olarak kullanılmaktadır. Tablo 6.2’de bu çalışma kapsamında kullanılan kriptopara meta verileri bulunmaktadır. Veriler Cryptocompare³⁴ üzerinden elde edilmiştir. Cryptocompare, kriptoparalar için tarihsel ve gerçek zamanlı olarak veri sağlayan bir platformdur.

³⁴ <https://min-api.cryptocompare.com/> 02.04.2019 tarihinde erişilmiştir.

Tablo 6.2. Çalışmada Kullanılan Kriptopara Verileri

Parite	İlk Tarih	Son Tarih	Tip	Mumlar
BTC-USD	17-07-2010	11.04-2019	Günlük	3191
ETH-BTC	07-08-2015	14.04-2019	Günlük	1347
XRP-BTC	20-01-2015	13.04-2019	Günlük	1545
ETH-USD	07-08-2015	11-04-2019	Günlük	1344
XRP-USD	21-01-2015	14-04-2019	Günlük	1545
BTC-USD	27.05-2015	17-07.2010	Saatlik	34001
ETH-USD	07-08-2015	13-04-2019	Saatlik	32267
XRP-BTC	27.05.2015	13.04-2019	Saatlik	34001
ETH-BTC	07-08.2015	13.04-2019	Saatlik	32267
XRP-USD	18.08-2015	13.04-2019	Saatlik	32001

Çalışmada kullanılan veriler finansal verilerde genel olarak kullanılan AKYDH(Açılış – Kapanış – Yüksek – Düşük -Hacim) formatında bulunmaktadır.

- **Açılış:** Kriptopara çiftinin belirli zaman dilimindeki başlangıç fiyatıdır.
- **Kapanış:** Kriptopara çiftinin belirli zaman dilimindeki kapanış fiyatıdır.
- **Düşük:** Kriptopara çiftinin belirli zaman dilimindeki en düşük fiyatı temsil etmektedir.
- **Yüksek:** Kriptopara çiftinin belirli zaman dilimindeki en yüksek fiyatı temsil etmektedir.
- **Hacim:** Kriptopara çiftinin belirli zaman biriminde gerçekleşen alım-satım miktarını göstermektedir.

Çalışma kapsamındaki veriler Pandas³⁵ kütüphanesinin sağladığı Veri Çerçevesi(dataframe) olarak tutulmaktadır. Tablo 6.3’de ETH-BTC verilerinin günlük bazda veri çerçevesi üzerinde örnek gösterimi bulunmaktadır.

Tablo 6.3. ETH-BTC Günlük Veri Çerçevesi Örneği

Zaman	Kapanış	Yüksek	Düşük	Açılış	Hacim
2019-04-10	0.03336	0.03471	0.03284	0.03389	4395604.92
2019-04-11	0.03271	0.03338	0.03221	0.03336	4106469.25
2019-04-12	0.03234	0.03282	0.03226	0.03271	3527639.38
2019-04-13	0.03230	0.03249	0.03202	0.03234	2556214.45
2019-04-14	0.03218	0.03236	0.03211	0.03230	1428975.04

Ek A’da, veri ön analizleri kapsamında BTC – USD, ETH – BTC, ETH – USD, XRP – BTC ve XRP - USD çiftlerinin saatlik grafiği bulunmaktadır. Bitcoin, USD karşısında 2017 yılının sonları 2018 başlarına doğru yaklaşık 19-20 bin dolar seviyelerini görmüş ve bu seviyeler tarihi zirvesi olmuştur. Sonrasında bir düşüş trendine girmiş ve 2019 Nisan ayı ortalarında 5000 dolar seviyelerinde bulunmaktadır.

Bir diğer kriptopara olan Ethereum (ETH), 2018 başlarında USD karşısında tarihi zirvesini görerek 1400 dolar seviyelerine ulaşmıştır. Bu tarihten sonra zaman zaman dalgalı yükselişler olsada uzun vadeli trendde düşüş eğilimine geçmiştir. Nisan 2019’da 170 dolar seviyelerinde işlem görmektedir. Buna karşılık ETH, BTC paritesinde Haziran 2017’de en yüksek seviyesini görmüştür.

³⁵ <https://pandas.pydata.org/> 01.04.2019 tarihinde erişilmiştir.

XRP Dolar karşısında diğer kriptoparalarla yakın tarihte Ocak 2018 başında en yüksek seviyesine ulaşmıştır. XRP, BTC karşısında ise 2017 ortalarında ilk tarihi zirvesine ulaşmış fakat 2018 başlarında bu zirveyi tekrardan aşarak en yüksek değerine ulaşmıştır.

6.3. OpenAI-Gym Ortamı

Soft-Actor-Critic etmeninin kriptopara alım-satımını öğrenebilmesi için OpenAI-Gym ile geliştirilen ortam sınıfları Tablo 6.4’de verilmektedir. Ek C’de `co_env.py` kodlarının örneği bulunmaktadır.

Tablo 6.4. OpenAI-Gym CryptOlrıc Uygulama Sınıfları

Uygulama	Sınıflar
CryptOlrıc Environment	<code>Co_env.py</code>
Render	<code>render.py</code>
Main	<code>Main.py</code>
Backtrader	<code>Gym-tester.py</code>

Gözlem uzayı (observation space), etmenin kripto alım-satım kararlarını vermeden önce göz önünde bulundurması gereken girdileri içermektedir. Bu çalışmada gözlem uzayı; açılış, kapanış, düşük, yüksek, hacim gibi finansal veriler ve bakiye, alınan miktar, satılan miktar gibi işlem verilerinden oluşmaktadır.

Oluşturulan kriptolara alım-satım ortamı için aksiyon uzayı(action space) al,sat ve işlem yapma aksiyonlarından oluşmaktadır.

Ödül(Reward) olarak ise, kriptoparanın bir önceki net değer ile şu andaki net değer arasındaki farkı verilmektedir. Bu değer negatif veya pozitif olarak gerçekleşebilmektedir.

6.4. Backtrader ile Geriye Yönelik Testler (Backtesting)

Uygulamanın son kısmını oluşturan Backtrader bölümünde, EMA Strateji, WMA Strateji, RSI Strateji, ve Bollinger Bantları(BB) Stratejileri oluşturulmuştur. Uygulama sınıfları ve parametre değerleri Tablo 6.4’de gösterilmektedir.

Tablo 6.5. Backtrader Uygulama Sınıfları

Backtester	Sınıflar	Parametreler
Ema Strateji	ema.py	EMA (5, 12) EMA (21, 55)
Wma Strateji	wma.py	WMA (5, 12) WMA (21, 55)
BB Strateji	bb.py	
RSI Strateji	rsi.py	RSI (SMA (14) , 30, 70)
Backtester	backtester.py	

Ema.py dosyası ema stratejisinin, bb.py dosyası BB Stratejisinin, rsi.py dosyası RSI stratejisinin ve rsi.py dosyası RSI stretejisinin kodlarını içermektedir. Backtester.py ise Backtrader uygulamasında verilerin alınmasından, stratejilerin eklenmesine, analiz, gözlemci ve sonuçlar gibi uygulamanın genel akışını içeren bileşenlerden oluşmaktadır. Şekil 6.4, RSI stratejisinin, Şekil 6.5, BB stratejisinin, Şekil 6.6, EMA stratejisinin ve Şekil 6.7, WMA stratejisinin işlem mantıklarının kodlarını içermektedir.

```
class RSIStrategy(bt.Strategy):
    alias = ('RSI_Strategy',)

    def __init__(self):
        self.rsi = btind.RSI_SMA(self.data.close, period=14,
                                safediv=True, safehigh=100.0, safelow=50.0)
        self.cash = []

    def next(self):
        self.cash.append(dict(tarih=self.datas[0].datetime.date(0).isoformat(),
                              cash=self.broker.get_value()))

        if not self.position:
            if self.rsi < 25:
                self.buy()
            else:
                if self.rsi > 75:
                    self.sell()
```

Şekil 6.4. Backtrader ile RSI Stratejisi

```

class BBStrategy(bt.Strategy):
    params = (('period', 20),)

    def __init__(self):
        self.ust_band = None
        self.alt_band = None
        self.cash = []
        self.bband = bt.indicators.BBands(self.datas[0],
                                         period=self.params.period)
        self.closed_data = self.datas[0].close

    def next(self):
        self.cash.append(dict(tarih=self.datas[0].datetime.date(0).isoformat(),
                              cash=self.broker.get_value()))

        if self.closed_data < self.bband.lines.bot and not self.position:
            self.alt_band = True

        if self.closed_data > self.bband.lines.top and self.position:
            self.ust_band = True

        if self.closed_data > self.bband.lines.mid and not \
            self.position and self.alt_band:
            self.log('Al, %.2f' % self.closed_data[0])
            self.buy()

        if self.closed_data > self.bband.lines.top \
            and not self.position:
            self.log('Al, %.2f' % self.closed_data[0])
            self.buy()

        if self.closed_data < self.bband.lines.mid and \
            self.position and self.ust_band:
            self.log('Sat, %.2f' % self.closed_data[0])
            self.ust_band = False
            self.alt_band = False
            self.sell()

```

Şekil 6.5. Backtrader ile Bollinger Bantları Stratejisi

```

class EMAStrategy(bt.Strategy):
    alias = ('EMA_Strategy',)
    params = (
        ('fast', 21),
        ('slow', 55),
        ('movav', btind.MovAv.EMA),
    )

    def __init__(self):
        ema_fast = self.p.movav(period=self.p.fast)
        ema_slow = self.p.movav(period=self.p.slow)

        self.crossover = btind.CrossOver(ema_fast, ema_slow)
        self.cash = []

    def next(self):
        self.cash.append(dict(tarih=self.datas[0].datetime.date(0).isoformat(),
                              cash=self.broker.get_value()))

        if self.position.size:
            if self.crossover < 0:
                self.sell()

            elif self.crossover > 0:
                self.buy()

```

Şekil 6.6. Backtrader ile EMA Stratejisi

```

class WMAstrategy(bt.Strategy):
    alias = ('WMA_Strategy',)

    params = (
        ('fast', 21),
        ('slow', 55),
        ('movingavg', btind.MovAv.WMA)
    )

    def __init__(self):
        wma_fast = self.p.movingavg(period=self.p.fast)
        wma_slow = self.p.movingavg(period=self.p.slow)

        self.sig = btind.CrossOver(wma_fast, wma_slow)
        self.cash = []

    def next(self):
        self.cash.append(dict(tarih=self.datas[0].datetime.date(0).isoformat(),
                              cash=self.broker.get_value()))

        if self.position.size:
            if self.sig < 0:
                self.sell()

            elif self.sig > 0:
                self.buy()

```

Şekil 6.7. Backtrader ile WMA Stratejisi

6.5. Arayüz

Dash uygulama çatısı kullanılarak hazırlanan kullanıcı arayüzü 3 ana kısımdan oluşmaktadır. Şekil 6.8’de uygulama arayüzünden bir kısım gösterilmektedir.

- **CryptOlrıc:** Kriptopara alım-satımı için oluşturulan OpenAI-Gym ortamının öğrenme sürecindeki simülasyonunu içermektedir.
- **Backtrader:** Oluşturulan stratejilerin, geriye yönelik testlerde elde edilen performans metriklerinin sonuçlarını ve grafiklerini içermektedir. 10 adet farklı finansal verilerin değerlendirme sonuçları ve 5 farklı strateji karşılaştırması sunulmaktadır.
- **SAC:** Arayüzün bu kısmında, Tensorboard entegrasyonu sayesinde SAC algoritmasının kayıp fonksiyonları, bölüm başına ödül vb. gibi metriklerin son kullanıcıya yaklaşık gerçek zamanlı olarak grafikleri sağlanmaktadır.



Şekil 6.8 Uygulama Arayüzü

VII. DEĞERLENDİRME

2018 yılı başlarında kısa sürede piyasa değerini 800 milyar dolar seviyelerine çıkaran kriptopara piyasaları dikkatleri üzerine çekmiştir. Henüz diğer finansal piyasalar kadar stabil olarak görülmesede 10 yıla yakın geçmişi olan bazı kriptoparalar bulunmaktadır. 2019 Nisan verilerine göre piyasa değeri en yüksek 3 kriptopara ile yapılan bu çalışmada, henüz çok yeni bir alan Derin Pekiştirme Öğrenme yöntemlerinden SAC etmeni ve çokça tercih edilen Teknik Analiz yöntemleriyle stratejiler oluşturularak, performansları karşılaştırılmıştır. Veri setleri, hem yükselen hem alçalan piyasa dinamiklerini de içermektedir. Derin Pekiştirmeli Öğrenme yöntemi diğer teknik analiz yöntemlerine kıyasla ETH – USD çifti dışında belirgin bir oranda daha iyi performans göstermemektedir.

Veri setlerinin artırılması, öğrenme parametrelerinin iyileştirilmesi veya en iyileme yöntemleri kullanılarak performans artışları sağlanabilir. Beklenen performanslar elde edilemese bile, yine de derin pekiştirmeli öğrenme yöntemleri doğası gereği finansal ticaret yapılarına uygun olarak modellenebilir. İleriki çalışmalarda çoklu-etmen yöntemleri, risk-getiri oranına göre alım-satım işlemlerinin gerçekleştirilmesi, alım-satım ortamına ekstra özellikler eklenmesi, kullanılan yöntemde parametre en iyilemesi gibi konular göz önünde bulundurularak yeni araştırmalar yapılmasının faydalı olacağı düşünülmektedir.

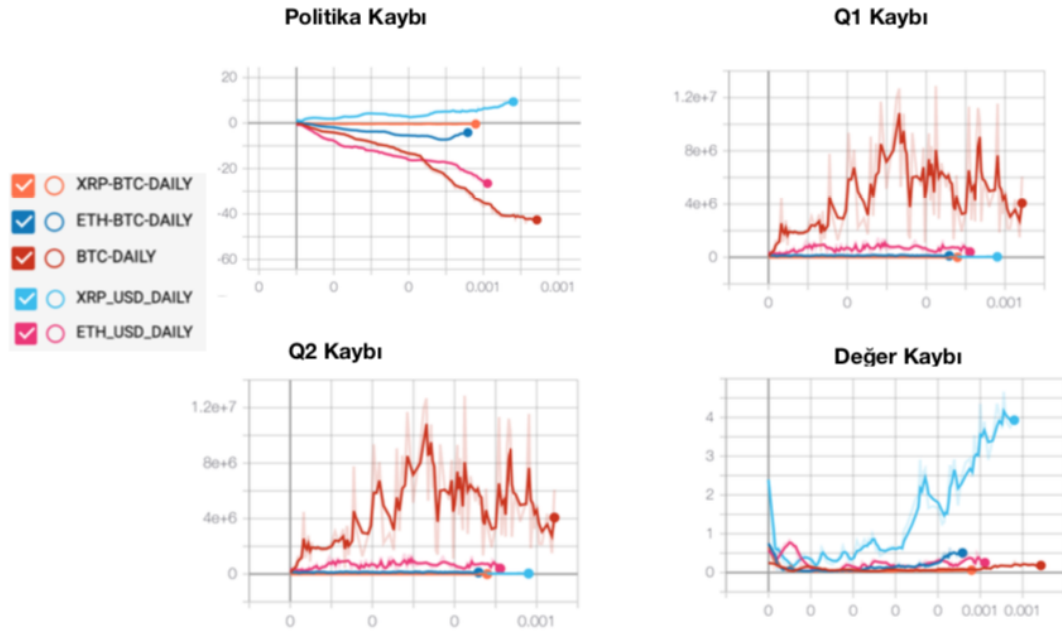
VIII. SONUÇLAR

Finansal verilerin performans, getiri ve strateji puanı gibi ölçümlerini yapabilmek için farklı metrikler bulunmaktadır. Bu çalışma kapsamında sonuçlar bölümü iki temel kısımdan oluşmaktadır. İlk kısımda, Soft Actor-Critic etmeninin öğrenme, kayıp, ödül gibi Derin Pekiştirmeli Öğrenme metrikleri ve sonuçları bulunmaktadır. İkinci kısımda ise Backtrader ile oluşturulan stratejilerin performansları sunulmaktadır.

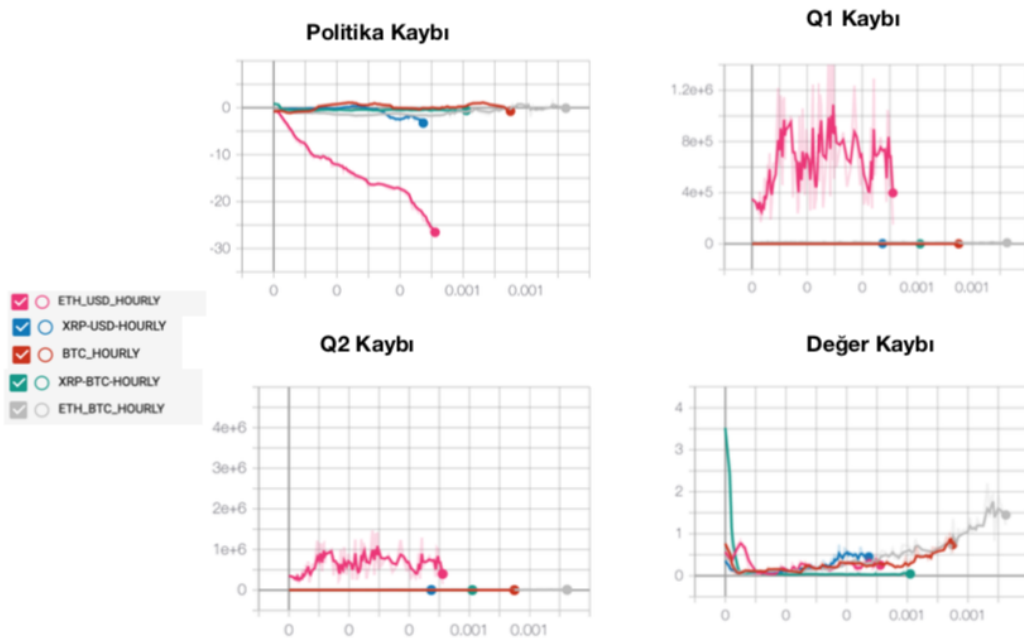
8.1. SAC Etmeni

Soft Actor Critic yöntemine ait entropi ve bölüm başına ödül değerleri, Şekil 8.1’de saatlik ve günlük olarak verilmektedir. SAC ağlarına ait kayıp fonksiyonları ise günlük ve saatlik olarak kategorize edilmiş olarak Şekil 8.2’de bulunmaktadır.

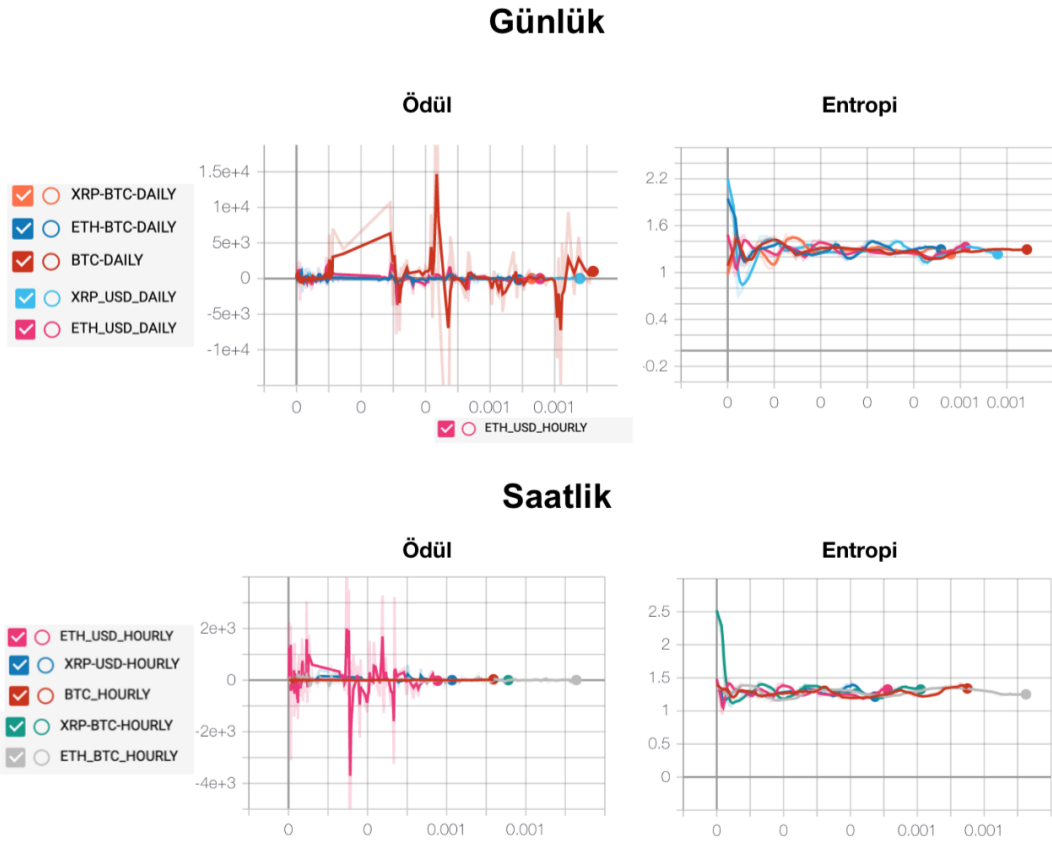
Günlük



Saatlik



Şekil 8.1 Soft Aktör Kritik Entropi ve Ödül



Şekil 8.2 Soft Aktör Kritik Kayıp Fonksiyonları

8.2. Strateji Sonuçları

Teknik analiz yöntemleri kullanılarak, yaygın olarak tercih edilen teknik göstergelerle oluşturulan stratejilerin ve Derin Pekiştirmeli Öğrenme yöntemiyle oluşturulan kriptopara alım-satım stratejisinin performans sonuçları takip eden bölümlerde bulunmaktadır. Başlangıç miktarı olarak USD çiftinde olan kripto-paralar için 10000 USD, BTC çiftinde olan kriptoparalar için 10 BTC belirlenmiştir. Sonuçlarda alım-satım stratejilerine, işlem başına 0.001 komisyon oranları dahil edilmiştir. Ek olarak,

stratejiler boyutlandırıcı(sizer) miktarı her işlem öncesi eldeki miktarın yarısı kullanılacak şekilde uygulanmaktadır. Örneğin, ilk alım, başlangıç miktarı olarak 10000 USD nin yarısı olan 5000 USD ile gerçekleştirilmiştir. Satım sonucunda 2000USD kar ile işlem kapandığında, bir sonraki alım işlemi 6000USD ile gerçekleştirilmektedir. Çalışmada kullanılan metrikler ve açıklamaları Tablo 8.1’de gösterilmektedir.

Tablo 8.1. Kullanılan Metrikler ve Açıklamaları

Metrikler	Açıklama
Alım Satım	
Alım-satım Sayısı	Bir strateji için ne kadar alım satım işlemi gerçekleştiğini belirten sayıdır.
Ortalama Kazanç	Gerçekleşen işlemlerden \$ veya BTC bazında elde edilen kazancın, kazançla sonuçlanan alım-satım sayısına bölünmesiyle bulunmaktadır.
Ortalama Kayıp	Gerçekleşen işlemlerden \$ veya BTC bazındaki zararın, kayıpla sonuçlanan alım-satım sayısına bölünmesiyle bulunmaktadır.
En iyi ticaret	Geriye yönelik testler sürecinde yapılan en iyi alım-satım işleminin \$ olarak gösterimini belirtir.
En kötü ticaret	Geriye yönelik testler sürecinde yapılan en kötü alım-satım işleminin \$ olarak gösterimini belirtir.
SQN	Sistem Kalite Numarası (System Quality Number - SQN), Temelde stratejinin başarısını ölçmektedir. 1.6 - 1.9 Ortalama altı, 2.0 - 2.4 Ortalama, 2.5 - 2.9 İyi, 3.0 - 5.0 Harika, 3.0-5.0 Mükemmel, 5.1 - 6.9 Muhteşem, 7.0 ve üstü En iyiyi ifade etmektedir.[104]
Kar Zarar	
Başlangıç Miktarı	Başlangıçta yatırılan sermayenin \$ veya BTC olarak gösterimidir.
Toplam Net Kar	Geriye yönelik testler sürecinde elde edilen toplam net karı temsil etmektedir.
Kazanılan Miktar	Alım satım işlemleri sürecinde kazanılan miktarı \$ veya BTC cinsinden belirtmektedir.

Kaybedilen Miktar	Alım satım işlemleri sürecinde kazanılan miktarı \$ veya BTC cinsinden belirtmektedir.
Toplam Getiri %	Alım satım işlemleri süreci sonunda toplam getiri yüzdesini ifade etmektedir.
Maks. Düşüş K. %	Alım-satım sürecinde sermaye değerleri arasında gerçekleşmiş olan en büyük düşüş yüzdesidir

- **WMA Strateji:** Ağırlıklı hareketli ortalama(WMA) yönteminden faydalanılarak oluşturulan bu stratejiye ait sonuçlar Tablo 8.2’te bulunmaktadır.
- **EMA Strateji:** Üssel Hareketli Ortalama (EMA) yönteminden faydalanılarak oluşturulan bu stratejinin alım-satım bilgileri ve performansına dair sonuçlar Tablo 8.3’de bulunmaktadır.
- **RSI Strateji:** Bağıl görelilik endeksi (RSI) kullanarak oluşturulan bu stratejinin alım-satım bilgileri ve performansına dair sonuçlar Tablo 8.4’de bulunmaktadır.
- **Bollinger Bantları Strateji:** Bollinger Bantları kullanılarak oluşturulan bu stratejinin alım-satım bilgileri ve performansına dair sonuçlar Tablo 8.5’de bulunmaktadır.

Tablo 8.2. WMA Strateji Sonuçları

	WMA(21,55) Strateji						WMA(5,12) Strateji							
	BTC-USD Saatlik	ETH-USD Saatlik	XRP-USD Saatlik	ETH-BTC Saatlik	XRP-BTC Saatlik	BTC-USD Günlük	ETH-USD Günlük	XRP-USD Günlük	ETH-BTC Günlük	XRP-BTC Günlük	ETH-USD Günlük	XRP-USD Günlük	ETH-BTC Günlük	XRP-BTC Günlük
Alım-Satım Sayısı	412.0	427.0	487.0	383.0	415.0	147.0	65.0	83.0	61.0	66.0	65.0	83.0	61.0	66.0
Ortalama_kazanç	997.65	801.02	12.54	6.27	2.43	896498.57	22963.35	12488.79	12.00	14.83	22963.35	12488.79	12.00	14.83
Ortalama_kayıp	-388.93	-308.04	-28.43	-1.84	-0.48	-263254.85	-7029.24	-1475.84	-2.41	-2.17	-7029.24	-1475.84	-2.41	-2.17
En-iyi-ticaret	9184.43	5863.58	162.21	60.79	45.88	11434030.26	124028.04	119754.58	45.12	138.57	124028.04	119754.58	45.12	138.57
En-kötü-ticaret	-3603.78	-2662.02	-1598.55	-13.04	-6.52	-2450860.89	-40016.13	-10894.32	-10.96	-11.09	-40016.13	-10894.32	-10.96	-11.09
Başlangıç miktarı	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC	10000 USD	10000 USD	10 BTC	10 BTC
Toplam Net Kar	57452.97	21515.06	-9709.65	356.03	106.63	28830490.25	322906.58	186203.02	140.98	247.73	322906.58	186203.02	140.98	247.73
Kazanılan Miktar	156631.23	110541.23	1267.17	821.90	257.75	51996917.09	597047.20	274753.56	240.15	341.17	597047.20	274753.56	240.15	341.17
Kaybedilen Miktar	-99178.26	-89026.16	-10976.82	-465.87	-151.11	-23166426.84	-274140.62	-88550.54	-99.16	-93.44	-274140.62	-88550.54	-99.16	-93.44
Toplam Getiri %	574.52	215.15	-97.09	3560.34	1066.37	288304.90	3229.06	1862.03	1409.88	2477.33	3229.06	1862.03	1409.88	2477.33
Maks. Düşüş K. %	26.15	92.10	99.87	32.51	58.81	50.08	44.55	77.89	45.75	50.79	44.55	77.89	45.75	50.79
Sqın Puanı	2.25	1.14	-3.98	2.62	1.50	1.77	1.52	1.30	1.65	1.49	1.52	1.30	1.65	1.49

Tablo 8.3. EMA Strateji Sonuçları

	EMA(21,55) Strateji					EMA(5,12) Strateji				
	BTC-USD Saatlik	ETH-USD Saatlik	XRP-USD Saatlik	ETH- BTC Saatlik	XRP- BTC Saatlik	BTC-USD Günlük	ETH-USD Günlük	XRP-USD Günlük	ETH-BTC Günlük	XRP-BTC Günlük
Alım-Satım Sayısı	287.0	294.0	379.0	244.0	47.0	93.0	43.0	70.0	39.0	47.0
Ortalama_kazanç	1363.24	181.99	21.90	6.47	13.62	1366157.73	117208.84	9969.34	15.48	13.62
Ortalama_kayıp	-341.61	-84.68	-33.51	-1.28	-1.11	-208162.49	-24911.05	-1551.64	-2.21	-1.11
En-iyi-ticaret	9206.57	1361.03	185.55	37.68	69.59	10993390.85	460612.0	108151.39	52.66	69.59
En-kötü-ticaret	-2491.24	-1500.73	-1860.71	-6.89	-6.25	-1795361.36	-101503.10	-11965.52	-7.23	-6.25
Başlangıç miktarı	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC
Toplam Net Kar	57099.86	-3562.81	-9599.85	229.64	124.58	34375938.39	943414.43	123356.56	143.85	124.58
Kazanılan Miktar	124055.63	14559.62	1226.75	452.96	163.46	46449362.98	1640923.84	199386.96	201.35	163.46
Kaybedilen Miktar	-66955.76	-18122.44	-10826.60	-223.31	-38.87	-12073424.59	-697509.41	-76030.39	-57.50	-38.87
Toplam Getiri %	570.99	-35.62	-95.99	2296.49	1245.82	343759.38	9434.14	1233.56	1438.51	1245.82
Maks. Düşüş K. %	23.51	98.34	99.89	35.86	53.00	61.25	45.21	66.73	39.16	53.00
Sqn Puanı	2.46	-0.84	-3.67	2.54	1.55	2.22	1.34	1.04	1.89	1.55

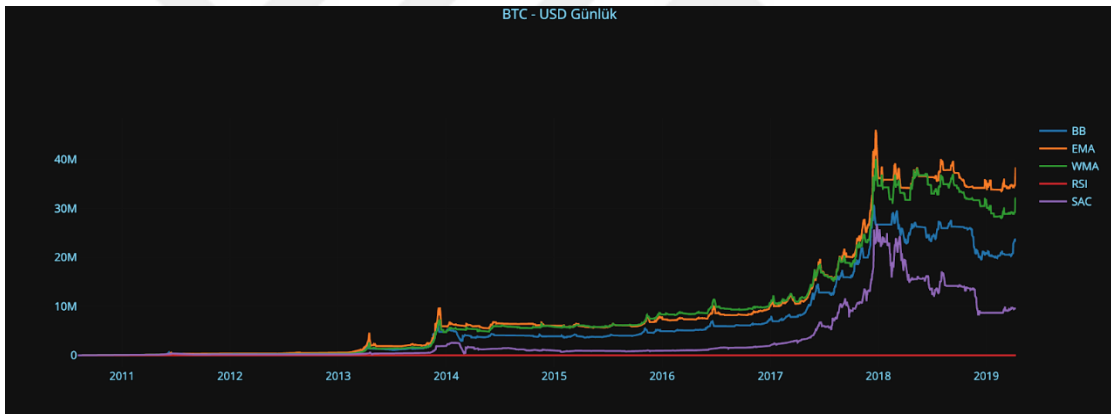
Tablo 8.4. RSI Strateji Sonuçları

	RSI Stratejisi												
	BTC-USD Saatlik	ETH-USD Saatlik	XRP-USD Saatlik	ETH-BTC Saatlik	XRP-BTC Saatlik	BTC-USD Günlük	ETH-USD Günlük	XRP-USD Günlük	ETH-BTC Günlük	XRP-BTC Günlük	BTC-USD Günlük	ETH-USD Günlük	XRP-USD Günlük
Alım-Satım Sayısı	197.0	229.0	301.0	216.0	158.0	24.0	8.0	13.0	11.0	12.0			
Ortalama_kazanç	99.44	2187.16	14622.54	0.11	0.16	681.54	1075.25	3389.45	1.30	0.55			
Ortalama_kayıp	-226.62	-3129.66	-23526.56	-0.22	-0.31	-791.93	-2271.73	-4430.04	-1.33	-0.99			
En-iyi-ticaret	659.58	28993.77	266784.67	0.89	1.58	2487.60	2630.07	7612.80	2.39	1.28			
En-kötü-ticaret	-867.21	-14901.85	-416144.84	-3.15	-1.54	-2976.23	-4859.60	-8210.46	-1.98	-1.54			
Başlangıç miktarı	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC			
Toplam Net Kar	-4312.12	36108.44	648150.31	-7.85	-7.19	-1324.61	-1438.92	20604.38	-4.17	-4.74			
Kazanılan Miktar	12231.48	308389.58	2953753.58	13.89	14.26	8178.56	5376.27	33894.52	5.20	2.21			
Kaybedilen Miktar	-16543.61	-272281.14	-2305603.27	-21.74	-21.45	-9503.18	-6815.19	-13290.13	-9.37	-6.95			
Toplam Getiri %	-43.12	361.08	6481.50	-78.57	-71.96	-13.24	-14.38	206.04	-41.72	-47.43			
Maks. Düşüş K. %	44.88	77.10	69.10	79.31	80.86	63.11	46.46	51.89	59.06	65.61			
Sqın Puanı	-1.44	0.54	0.89	-1.65	-1.58	-0.25	-0.24	1.43	-0.87	-1.65			

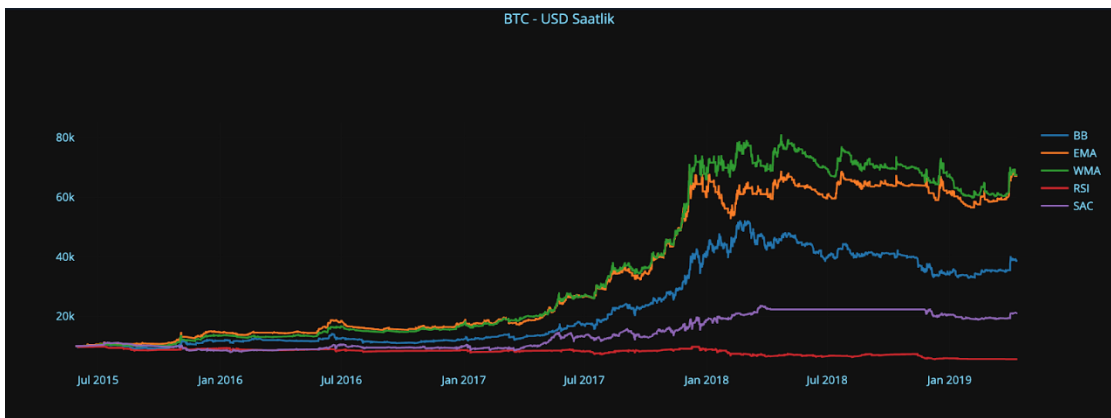
Tablo 8.5. Bollinger Bantları Strateji Sonuçları

Bollinger Bantları Stratejisi											
	BTC-USD Saatlik	ETH-USD Saatlik	XRP-USD Saatlik	ETH-BTC Saatlik	XRP-BTC Saatlik	BTC-USD Günlük	ETH-USD Günlük	XRP-USD Günlük	ETH-BTC Günlük	XRP-BTC Günlük	
Alım-Satım Sayısı	554.0	487.0	457.0	446.0	471.0	40.0	20.0	25.0	20.0	18.0	
Ortalama_kazanç	422.12	174.18	45.09	2.38	0.56	1066918.30	76710.60	18474.37	15.60	16.30	
Ortalama_kayıp	-319.90	-154.98	-53.53	-1.70	-0.21	-691022.79	-68364.76	-3689.93	-8.18	-2.70	
En-iyi-ticaret	5474.12	2134.21	928.51	22.71	12.62	6735042.85	358066.85	136711.23	47.39	122.79	
En-kötü-ticaret	-5249.34	-1806.13	-1610.43	-27.47	-2.75	-5743932.96	-269667.27	-19055.89	-42.83	-3.36	
Başlangıç miktarı	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC	10000 USD	10000 USD	10000 USD	10 BTC	10 BTC	
Toplam Net Kar	28633.88	2691.02	-8728.87	100.43	17.56	20514520.69	587049.31	133084.67	106.16	220.15	
Kazanılan Miktar	116927.38	41282.44	7169.56	500.54	85.58	28806794.23	997237.90	184743.74	171.66	228.26	
Kaybedilen Miktar	-88293.49	-38591.41	-15898.43	-400.11	-68.01	-8292273.53	-410188.58	-51659.06	-65.50	-8.10	
Toplam Getiri %	286.33	26.91	-87.28	1004.32	175.62	205145.20	5870.49	1330.84	1061.62	2201.59	
Maks. Düşüş K. %	37.14	94.78	98.73	50.34	81.46	68.91	53.46	61.24	38.77	47.94	
Sqn Puanı	1.58	0.38	-2.89	1.24	0.89	1.75	1.16	0.95	1.34	1.83	

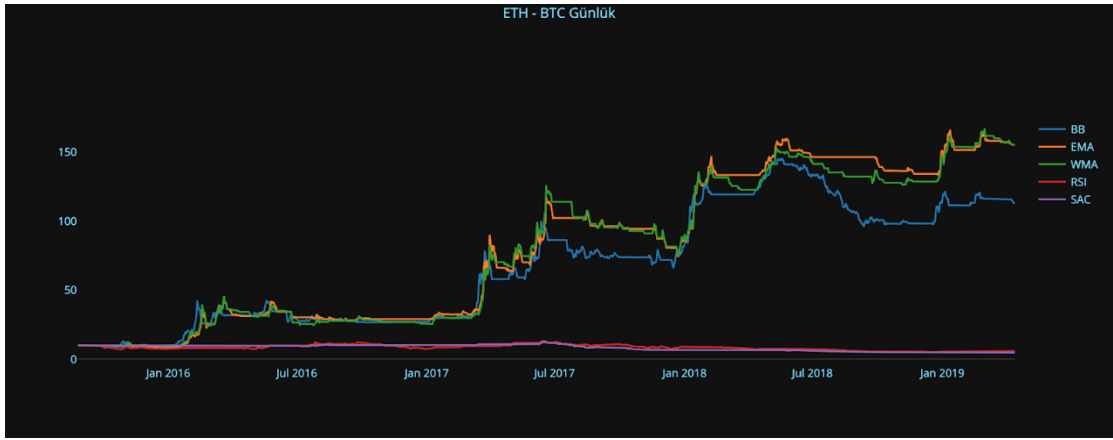
Çalışmada oluşturulan stratejilerin kriptopara çiftlerine göre toplam elde ettiği karların karşılaştırıldığı grafikler takip eden kısımda gösterilmektedir. Şekil 8.3’de BTC – USD Günlük verilerinin, Şekil 8.4 BTC – USD Saatlik verilerinin, Şekil 8.5 ETH – BTC Günlük verilerinin, Şekil 8.6 ETH – BTC Saatlik verilerinin, Şekil 8.7 ETH – USD Günlük verilerinin, Şekil 8.8 ETH – USD Saatlik verilerinin, Şekil 8.9 XRP – USD Saatlik verilerinin, Şekil 8.10 XRP – USD Günlük verilerinin, Şekil 8.11 XRP – BTC Saatlik ve son olarak Şekil 8.12 XRP – BTC Günlük verilerinin sonuçlarını içermektedir.



Şekil 8.3 Stratejilerin BTC – USD Günlük Alım – Satım Toplam Karları




Şekil 8.4 Stratejilerin BTC – USD Saatlik Alım – Satım Toplam Karları



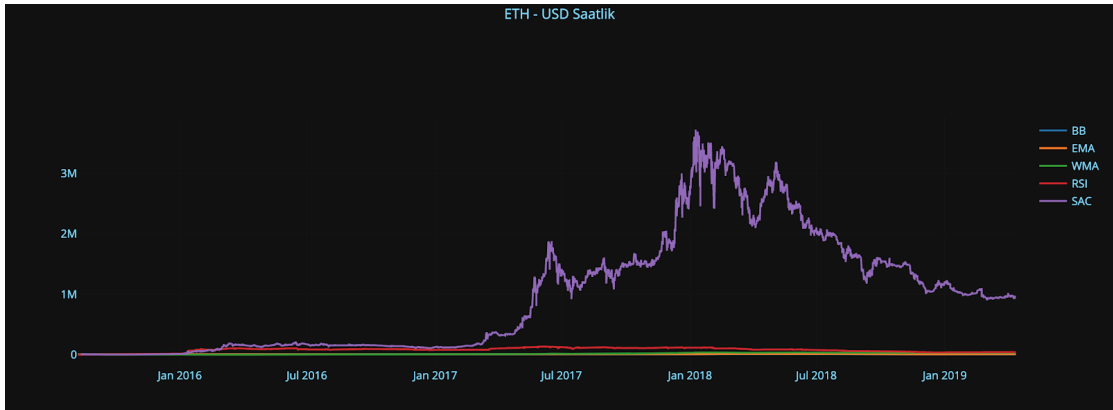
Şekil 8.5 Stratejilerin ETH – BTC Günlük Alım – Satım Toplam Karları



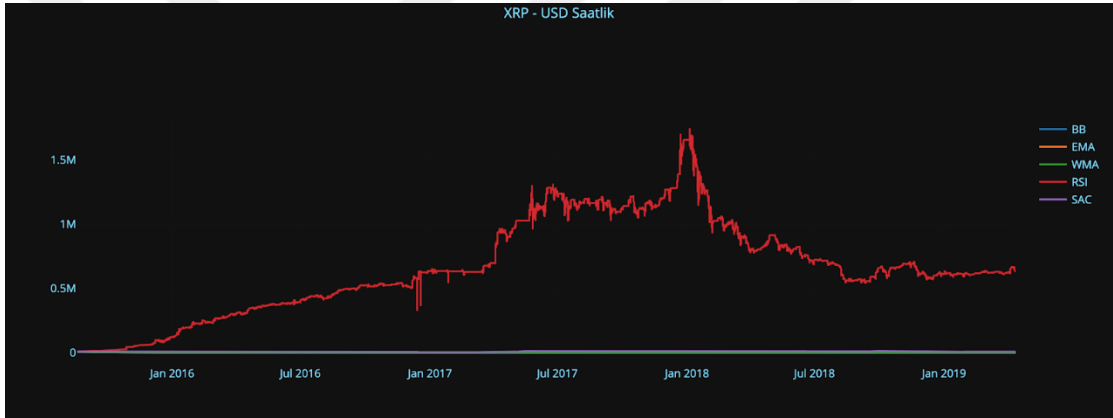
Şekil 8.6 Stratejilerin ETH – BTC Saatlik Alım – Satım Toplam Karları



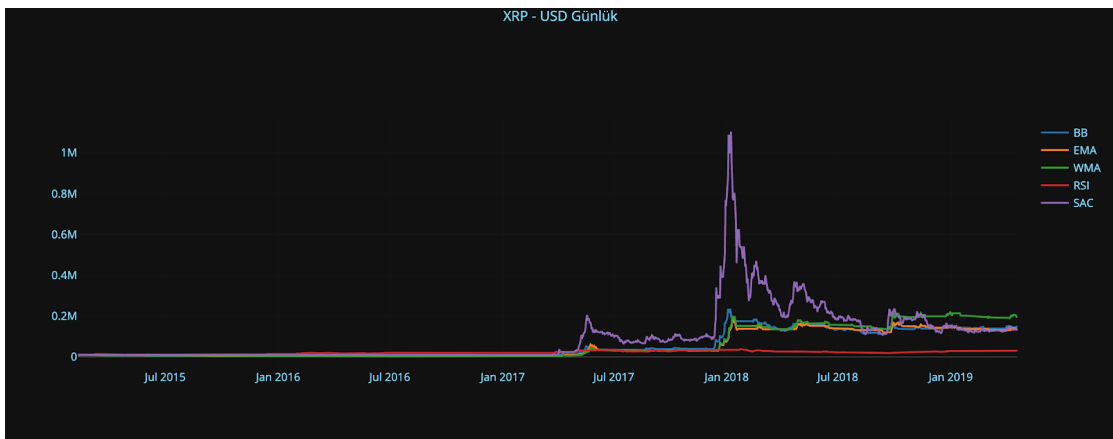
Şekil 8.7 Stratejilerin ETH – USD Günlük Alım – Satım Toplam Karları




Şekil 8.8 Stratejilerin ETH – USD Saatlik Alım – Satım Toplam Karları



Şekil 8.9 Stratejilerin XRP – USD Saatlik Alım – Satım Toplam Karları



Şekil 8.10 Stratejilerin XRP – USD Günlük Alım – Satım Toplam Karları



Şekil 8.11 Stratejilerin XRP – BTC Saatlik Alım – Satım Toplam Karları



Şekil 8.12 Stratejilerin XRP – BTC Günlük Alım – Satım Toplam Karları

KAYNAKÇA

- [1] Coinmarketcap., top 100 cryptocurrencies [Çevrimiçi]. Erişilebilir: www.coinmarketcap.com [Mart 2019'da erişilmiştir.]
- [2] M. B. Juchli, "Limit order placement optimization with Deep Reinforcement Learning", Yüksek Lisans Tezi, Delft Üni., Delft, Hollanda, 2018.
- [3] Franceschetti, Andrea, et al. "Robotic Arm Control and Task Training through Deep Reinforcement Learning."
- [4] M. Bekar, "Oyun Teorisi ve Ekonomik Modelleme", Yüksek Lisans Tezi, Matematik, Dumlupınar Üni., Kütahya, Türkiye, 2008.
- [5] A. Nowé, P. Vrancx ve Y. M. De Hauwere, "Game theory and multi-agent reinforcement learning", *Reinforcement Learning*, Berlin, Almanya, Springer, 2012, syf. 441-470.
- [6] CY Huang,. "Financial trading as a game: A Deep Reinforcement Learning approach." *arXiv preprint arXiv:1807.02787*, 2018.
- [7] A. Stelmaszczyk, A deep dive into reinforcement learning [Çevrimiçi]. Erişilebilir: <https://www.toptal.com/machine-learning/deep-dive-into-reinforcement-learning> [Mart 2019'da erişilmiştir.]
- [8] Alphago, Deepmind [Çevrimiçi]. Erişilebilir: <https://deepmind.com/research/alphago/> [Mart 2019'da erişilmiştir.]

- [9] Alphago Zero, Learning from scratch [Çevrimiçi]. Erişilebilir: <https://deepmind.com/blog/alphago-zero-learning-scratch/> [Mart 2019’da erişilmiştir.]
- [10] Haarnoja, T., Zhou, A., Abbeel, P. and Levine, S., “Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor.” arXiv preprint arXiv:1801.01290, 2018
- [11] J. Huang, W. Huang, and J. Ni. "Predicting Bitcoin returns using high-dimensional technical indicators", *The Journal of Finance and Data Science*, 2018.
- [12] S. Kaur, *Algorithmic Trading using Sentiment Analysis and Reinforcement Learning*, 2017
- [13] L. Alessandretti, A. ElBahrawy, L. M. Aiello ve A. Baronchelli, “ Anticipating cryptocurrency prices using machine learning,” *Complexity*, 2018.
- [14] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Computation*, vol. 9, no. 8, sayfa 1735–1780, 1997.
- [15] D.W. Lu, "Agent inspired trading using Recurrent Reinforcement Learning and LSTM Neural Networks." *arXiv preprint arXiv:1707.07338* (2017).
- [16] E. W. Piotrowski, J. Sladkowski ve A. Szczypinska, "Reinforcement learning in market games", *arXiv preprint arXiv: 0710.0114*, 2007.

- [17] YS Lim ve D. Gorse, "Reinforcement Learning for High-Frequency Market Making", European Symposium on Artificial Neural Networks, *ESAAN 2018 Computational Intelligence and Machine Learning*. Brugge (Belgium), 2018.
- [18] Z. Liang, K. Jiang, H. Chen, J. Zhu, Y. Li, "Deep Reinforcement Learning in portfolio management". *arXiv preprint arXiv:1808.09940*, 2018
- [19] X. Du, J Zhai, and L. Koupin "Algorithm trading using q-learning and recurrent reinforcement learning." *positions* 1, 2016.
- [20] E. Uzel, "Makine öğrenmesi ile forex piyasalarında alım satım kararları uygulanması", Yüksek Lisans Tezi, İşletme, Atılım Üni., Ankara, Türkiye, 2018.
- [21] Z. Jiang, ve J. Liang. "Cryptocurrency Portfolio Management with Deep Reinforcement Learning", *arXiv preprint arXiv: 1612.01277*, 2016.
- [22] B Li, P. Zhao, S.C. Hoi, V. Gopalkrishnan, "PAMR: Passive aggressive mean reversion strategy for portfolio selection." *Machine learning*, 87(2), 2012 syf. 221-258.
- [23] Y. Deng, F. Bao, Y. Kong, Z. Ren, Q. Dai, "Deep direct reinforcement learning for financial signal representation and trading". *IEEE transactions on neural networks and learning systems*, 28(3), 2017, syf. 653-664.
- [24] P. G. Necchi, "Reinforcement Learning for automated trading.", [Çevrimiçi]. https://pdfs.semanticscholar.org/f94b/ea4efc52acf695131c3128294a0f039629a8.pdf?_ga=2.51517920.871156032.1555789260-25035177.1555666646 [Mart, 2019'da erişilmiştir.]

[25] F. Sehnke, C. Osendorfer, T. Rückstieb, A. Graves, J. Peters, and J. Schmidhuber, “Policy gradients with parameter-based exploration for control,” *Artificial Neural Networks-ICANN 2008*, Springer, 2008., syf. 387–396.

[26] A. Miyamae, Y. Nagata, I. Ono, S. Kobayashi. “Natural policy gradient methods with parameter-based exploration for control tasks.” *Advances in neural information processing systems*, 2010, syf. 1660–1668.

[27] J. Cumming, “An investigation into the use of reinforcement learning techniques within the algorithmic trading domain”, Yüksek Lisans Tezi, Bilgisayar, Imperial College London, Londra, İngiltere, 2015.

[28] Bitfinex (2019, Mart). Professional Trading now open to everyone [Çevrimiçi]. Erişilebilir: www.bitfinex.com [Mart 2019’da erişilmiştir.]

[29] Sfox, How to Trade a Cryptocurrency: A Glossary of Terms [Çevrimiçi]. Erişilebilir: <https://blog.sfox.com/how-to-trade-cryptocurrency-a-glossary-of-terms-459aec6cfd3> [Mart 2019’da erişilmiştir.]

[30] M. Ivanov (2019, Mart). Machine Learning Part 0: Bars [Çevrimiçi]. Erişilebilir: <https://towardsdatascience.com/financial-machine-learning-part-0-bars-745897d4e4ba> [Mart 2019’da erişilmiştir.]

[31] C. Rosenbloom, *The Complete Trading Course: Price Patterns, Strategies, Setups, and Execution Tactics*, New Jersey, Wiley, 2011

[32] Tradingview (2019, Mart). Destek ve Direnç [Çevrimiçi]. Erişilebilir: <https://tr.tradingview.com/scripts/supportandresistance/> [Mart 2019’da erişilmiştir.]

[33] Ö. B. Sezer, “Zaman serisi verilerinin derin yapay sinir ağları ile analizi ve eniyilemesi: finansal tahmin algoritmaları”, Doktora Tezi, Bilgisayar Müh., TOBB Ekonomi ve Teknoloji Üni., Ankara, Türkiye, 2018.

[34] Paragaranti, Hareketli Ortalama Yakınsama-Iraksama Göstergesi [Çevrimiçi]. Erişilebilir: <https://www.paragaranti.com/detay-kutuphane-hareketli-ortalama-yakinsama-iraksama-gostergesi> [Mart 2019’da erişilmiştir.]

[35] K. Fr3762. (2019, Mart). Bollinger Bantları 1 – Kullanım ve Hesap Mantığı [Çevrimiçi]. Erişilebilir: <https://www.youtube.com/watch?v=2OI9i0871sE> [Mart 2019’da erişilmiştir.]

[36] Tradingview (2019, Mart). Bollinger Bands [Çevrimiçi]. Erişilebilir: [https://www.tradingview.com/wiki/Bollinger_Bands_\(BB\)](https://www.tradingview.com/wiki/Bollinger_Bands_(BB)) [Mart 2019’da erişilmiştir.]

[37] B. Bayramlı, Geriye Dönük Testler [Çevrimiçi]. Erişilebilir: https://burakbayramli.github.io/dersblog/tser/tser_back/geriye_donuk_testler__backtesting_.html [Mart 2019’da erişilmiştir.]

[38] Investopedia (2019, Mart). What is a good Sharp ratio? [Çevrimiçi]. Erişilebilir: <https://www.investopedia.com/ask/answers/010815/what-good-sharpe-ratio.asp> [Mart 2019’da erişilmiştir.]

- [39] Btctürk, Kripto Para Alım Satım Platformu [Çevrimiçi]. Erişilebilir: www.btcturk.com [Mart 2019’da erişilmiştir.]
- [40] Coinbase (2019, Mart). Buy and sell cryptocurrency [Çevrimiçi]. Erişilebilir: www.coinbase.com www.coinbase.com [Mart 2019’da erişilmiştir.]
- [41] Ç. Aktepe, “Algorithmic trading on cryptocurrency markets using machine learning techniques”, Yüksek Lisans Tezi, Endüstri Müh., Boğaziçi Üni., İstanbul, Türkiye, 2018.
- [42] IDEX, Decentralized Ethereum Exchange [Çevrimiçi]. Erişilebilir: <https://idex.market> [Mart 2019’da erişilmiştir.]
- [43] Ethereum, Ethereum Project [Çevrimiçi]. Erişilebilir: <https://www.ethereum.org/> [Mart 2019’da erişilmiştir.]
- [44] Ripple, Ripple [Çevrimiçi]. Erişilebilir: <https://ripple.com/xrp/> [Mart 2019’da erişilmiştir.]
- [45] Bitcoin, Bitcoin: A Peer-to-Peer Elektronik Cash System [Çevrimiçi]. Erişilebilir: <https://bitcoin.org/bitcoin.pdf> [Mart 2019’da erişilmiştir.]
- [46] Y. Gültekin, “Kripto para birimleri ve yatırım aracı olarak kullanımı: tarihsel volatiliteleri bağlamında bir değerlendirme”, Yüksek Lisans Tezi, İşletme, On Dokuz Mayıs Üni., Samsun, Türkiye, 2017.

[47] Blokzincir Araştırma Laboratuvarı. Blokzincir [Çevrimiçi]. Erişilebilir: <http://blokzincir.bilgem.tubitak.gov.tr/bz-calistay/blok-zincir.html> [Mart 2019’da erişilmiştir.]

[48] Uzmancoin, Ripple bugün resmen Akbank Direkt’e geldi [Çevrimiçi]. Erişilebilir: <https://uzmancoin.com/ripple-akbank-direkt/> [Mart 2019’da erişilmiştir.]

[49] S. Jansen, “Machine learning for trading”, *Hands-on machine learning for algorithmic trading*, Birmingham, İngiltere, Packt Publishing, 2018.

[50] Github. Github [Çevrimiçi]. Erişilebilir: www.github.com [Mart 2019’da erişilmiştir.]

[51] PacktPublishing, *Machine-Learning-for-Algorithmic-Trading-Bots-With-Python* [Çevrimiçi]. Erişilebilir: <https://github.com/PacktPublishing/Machine-Learning-for-Algorithmic-Trading-Bots-with-Python> [Mart 2019’da erişilmiştir.]

[52] Enigmampc, *An Algorithmic Trading Library for Crypto-Assets in Python* [Çevrimiçi]. Erişilebilir: <https://github.com/enigmampc/catalyst> [Mart 2019’da erişilmiştir.]

[53] J. Chan, *Are Bots Controlling Crypto Markets?* [Çevrimiçi]. Erişilebilir: <https://medium.com/datadriveninvestor/are-bots-controlling-crypto-markets-5bab6f61534d> [Mart 2019’da erişilmiştir.]

[54] Y. BAYAR., "Yatırımcı Davranışlarının Davranışçı Yaklaşım Çerçevesinde Değerlendirilmesi." *Girişimcilik ve Kalkınma Dergisi* 6.2: 133-160.

[55] SpinningUp, Introduction [Çevrimiçi]. Erişilebilir: <https://spinningup.openai.com/en/latest/user/introduction.html> [Mart 2019'da erişilmiştir.]

[56] Y. Li, "Deep reinforcement learning", *arXiv preprint arXiv:1810.06339*, 2018.

[57] J. Achiam. (2019, Mart). Introduction to Reinforcement Learning [Çevrimiçi]. Erişilebilir: https://github.com/jachiam/rl-intro/blob/master/Presentation/rl_intro.pdf [Mart 2019'da erişilmiştir.]

[58] S. Erol (2019, Mart). Pekiştirmeli Öğrenmeye Giriş Serisi-1 [Çevrimiçi]. Erişilebilir: <https://medium.com/deep-learning-turkiye/peki%CC%87%C5%9Fti%CC%87rmeli%CC%87-%C3%B6%C4%9Frenmeye-gi%CC%87ri%CC%87%C5%9F-seri%CC%87si%CC%87-1-8f5c35b6044> [Mart 2019'da erişilmiştir.]

[59] S. Ravichandiran, "Hands-on Reinforcement Learning with Python", , Birmingham, İngiltere, Packt Publishing, 2018.

[60] R. S. Sutton and A. G. Barto, "Reinforcement Learning: An Introduction", MIT press, 2018.

- [61] Openai. Key Concepts in RL [Çevrimiçi]. Erişilebilir: http://spinningup.openai.com/en/latest/spinningup/rl_intro.html [Mart 2019'da erişilmiştir.]
- [62] Juanudacity. Deep Reinforcement Learning [Çevrimiçi]. Erişilebilir: <https://github.com/udacity/deep-reinforcement-learning/blob/master/finance/DRL.ipynb> [Nisan 2019'da erişilmiştir.]
- [63] T. Haarnoja, A. Zhou, P. Abbeel, S. Levine, "Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor". *arXiv preprint arXiv:1801.01290.*, 2018.
- [64] SpinningUp, Kinds of RL Algorithms [Çevrimiçi]. Erişilebilir: https://spinningup.openai.com/en/latest/spinningup/rl_intro2.html [Mart 2019'da erişilmiştir.]
- [65] V. Mnih, A. P. Badia, M. Mirza, A. Graves, T. Lillicrap, T. Harley, K. Kavukcuoglu, "Asynchronous methods for deep reinforcement learning". *International conference on machine learning*. 2016, syf. 1928-1937.
- [66] J. Schulman, F. Wolski, P. Dhariwal, A. Radford, O. Klimov, "Proximal policy optimization algorithms". *arXiv preprint arXiv:1707.06347*, 2017.
- [67] A. Karadoğan, "Takviyeli öğrenme için yapay atom algoritması (A3) kullanımı", Yüksek Lisans Tezi, Bilgisayar Müh., İnönü Üni., Malatya, Türkiye, 2014.

[68] S. Adarsh ve S. Asharaf , “Smart Contracts and Smart Properties Over Blockchains ”, *Decentralized Computing Using Blockchain Technologies and Smart Contracts: Emerging Research and Opportunities*, Hershey, ABD, IGI Global, 2017.

[69] A. Aslan, “Kripto para olgusu ve blockchin teknolojisi: ekonomik aktörlerin tepkisi, maliyet analizi, var modeli ve granger nedensellik test”, Yüksek Lisans Tezi, Yüksek Lisans Tezi, İşletme, Hacettepe Üni., Ankara, Türkiye, 2018.

[70] Makerdao, CDP Portal [Çevrimiçi]. Erişilebilir: <https://cdp.makerdao.com/> [Mart 2019’da erişilmiştir.]

[71] 0x, Decentralized Exchange [Çevrimiçi]. Erişilebilir: <https://0x.org> [Mart 2019’da erişilmiştir.]

[72] Adex, Decentralized ad network [Çevrimiçi]. Erişilebilir: <https://www.adex.network/> [Mart 2019’da erişilmiştir.]

[73] Thetatoken, Theta Token [Çevrimiçi]. Erişilebilir: <https://www.thetatoken.org> [Mart 2019’da erişilmiştir.]

[74] Cryptodozer, CryptoDozer [Çevrimiçi]. Erişilebilir: <https://cryptodozer.io/> [Mart 2019’da erişilmiştir.]

[75] Cryptokitties, Collect and breed furrever friends! [Çevrimiçi] Erişilebilir: <https://www.cryptokitties.co> [Mart 2019’da erişilmiştir.]

[76] E. Emekligil “The effect of game complexity on deep reinf EFFECT OF GAME COMPLEXITY ON DEEP REINFORCEMENT LEARNING”, Yüksek Lisans Tezi, Bilgisayar Müh., Boğaziçi Üni., İstanbul, Türkiye, 2018.

[77] V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves, I. Antonoglou, D. Wierstra, M. Riedmiller, “Playing atari with deep reinforcement learning”. *arXiv preprint arXiv:1312.5602.*, 2013.

[78] D. Silver. Policy Gradient [Çevrimiçi]. Erişilebilir: http://www0.cs.ucl.ac.uk/staff/d.silver/web/Teaching_files/pg.pdf [Nisan 2019’da erişilmiştir.]

[79] S. Raval. Actor Critic Algorithms [Çevrimiçi]. Erişilebilir: https://www.youtube.com/watch?v=w_3mmm0P0j8&feature=youtu.be [Nisan 2019’da erişilmiştir.]

[80] J. Patterson, A. Gibson, “Foundations of neural networks and deep learning,” Getting Started with Deep Learning, O’Reilly Media, 2018.

[81] A. M. O. Anwer “Derin öğrenme yöntemleri ile göğüs kanseri teşhisi”, Yüksek Lisans Tezi, Elektrik ve Bilgisayar Müh., Türk Hava Kurumu Üni., Ankara, Türkiye, 2017.

[82] S. Amidi. Deep Learning Cheatsheet [Çevrimiçi]. Erişilebilir: <https://stanford.edu/~shervine/teaching/cs-229/cheatsheet-deep-learning> [Mart 2019’da erişilmiştir.]

- [83] F. Longueira, ve S. Keene. "A fully Convolutional Neural Network approach to end-to-end speech enhancement." *arXiv preprint arXiv:1807.07959*, 2018.
- [84] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting,." *The Journal of Machine Learning Research*, 15(1), 2014, syf.1929-1958.
- [85] D. P. Kingma ve J. Ba. "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [86] J. Duchi, E. Hazan, Y. Singer Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, 2011, syf.2121-2159.
- [87] T. Tieleman ve G. Hinton, "RMSProp." *COURSERA: Lecture, 7017*, 2012.
- [88] A. Şeker, B. Diri, H. H. Balık. "Derin Öğrenme yöntemleri ve uygulamaları hakkında bir inceleme." *Gazi Mühendislik Bilimleri Dergisi (GMBD)* 3, no. 3, 2017, syf. 47-64.
- [89] A. Karpathy. The Unreasonable Effectiveness of Recurrent Neural Networks [Çevrimiçi]. Erişilebilir: <http://karpathy.github.io/2015/05/21/rnn-effectiveness/> [Mart 2019'da erişilmiştir.]
- [90] Magenta (2019, Mart). Demos [Çevrimiçi]. Erişilebilir: <https://magenta.tensorflow.org/demos> [Mart 2019'da erişilmiştir.]

- [91] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput.*, vol. 9, no. 8, Kas. 1997., syf. 1735–1780.
- [92] Jupyter (2019, Mart). Jupyter [Çevrimiçi]. Erişilebilir: <https://jupyter.org/> [Mart 2019’da erişilmiştir.]
- [93] Colab (2019, Nisan). Colab [Çevrimiçi]. Erişilebilir: <https://colab.research.google.com/> [Nisan 2019’da erişilmiştir.]
- [94] B. Bayramlı., Tensorflow [Çevrimiçi]. Erişilebilir: https://burakbayramli.github.io/dersblog/algs/tensorflow/tensorflow_tf_.html [Mart 2019’da erişilmiştir.]
- [95] Keras, The Python Deep Learning Library [Çevrimiçi]. Erişilebilir: <https://keras.io/> [Mart 2019’da erişilmiştir.]
- [96] OpenAI, Gym [Çevrimiçi]. Erişilebilir: <https://gym.openai.com/> [Mart 2019’da erişilmiştir.]
- [97] OpenAI, OpenAI-Baselines, Baselines [Çevrimiçi]. Erişilebilir: <https://github.com/openai/baselines> [Mart 2019’da erişilmiştir.]
- [98] Backtrader, Backtrader [Çevrimiçi]. Erişilebilir: <https://www.backtrader.com/docu/introduction.html> [Nisan 2019’da erişilmiştir.]
- [99] Stable-Baselines, Welcome to Stable-Baselines [Çevrimiçi]. Erişilebilir: <https://stable-baselines.readthedocs.io> [Nisan 2019’da erişilmiştir.]

[100] Openai, Soft – Actor Critic [Çevrimiçi]. Erişilebilir: <http://spinningup.openai.com/en/latest/algorithms/sac.html> [Nisan. 2019’da erişilmiştir.]

[101] Dash, Dash Layout, [Çevrimiçi]. Erişilebilir: <https://dash.plot.ly/getting-started> [Nisan 2019’da erişilmiştir.]

[102] React, A javascript library for building user interfaces, [Çevrimiçi]. Erişilebilir: <https://reactjs.org/> [Nisan 2019’da erişilmiştir.]

[103] Flask, Flask, [Çevrimiçi]. Erişilebilir: <http://flask.pocoo.org/> [Nisan 2019 tarihinde erişilmiştir.]

[104] Cryptocompare The Ultimate (API) Solution [Çevrimiçi]. Erişilebilir: <https://min-api.cryptocompare.com/> [Nisan 2019’da erişilmiştir.]

[105] Pandas Python Data Analysis Library [Çevrimiçi]. Erişilebilir: <https://pandas.pydata.org/> [Nisan 2019’da erişilmiştir.]

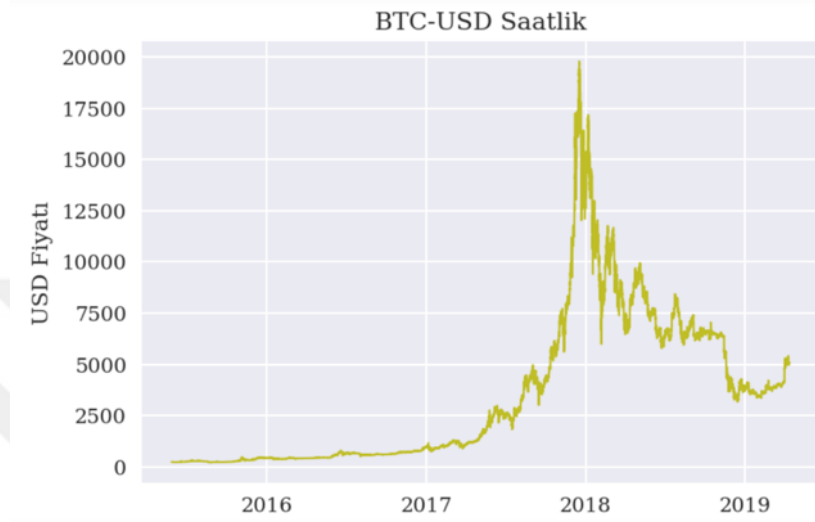
[106] Backtrader, <https://www.backtrader.com/docu/analyzers/analyzers.html> [Nisan 2019’da erişilmiştir.]

[107] Stable-Baselines, SAC [Çevrimiçi]. Erişilebilir:


<https://stable-baselines.readthedocs.io/en/master/modules/sac.html> [Nisan 2019’da erişilmiştir.]

EKA

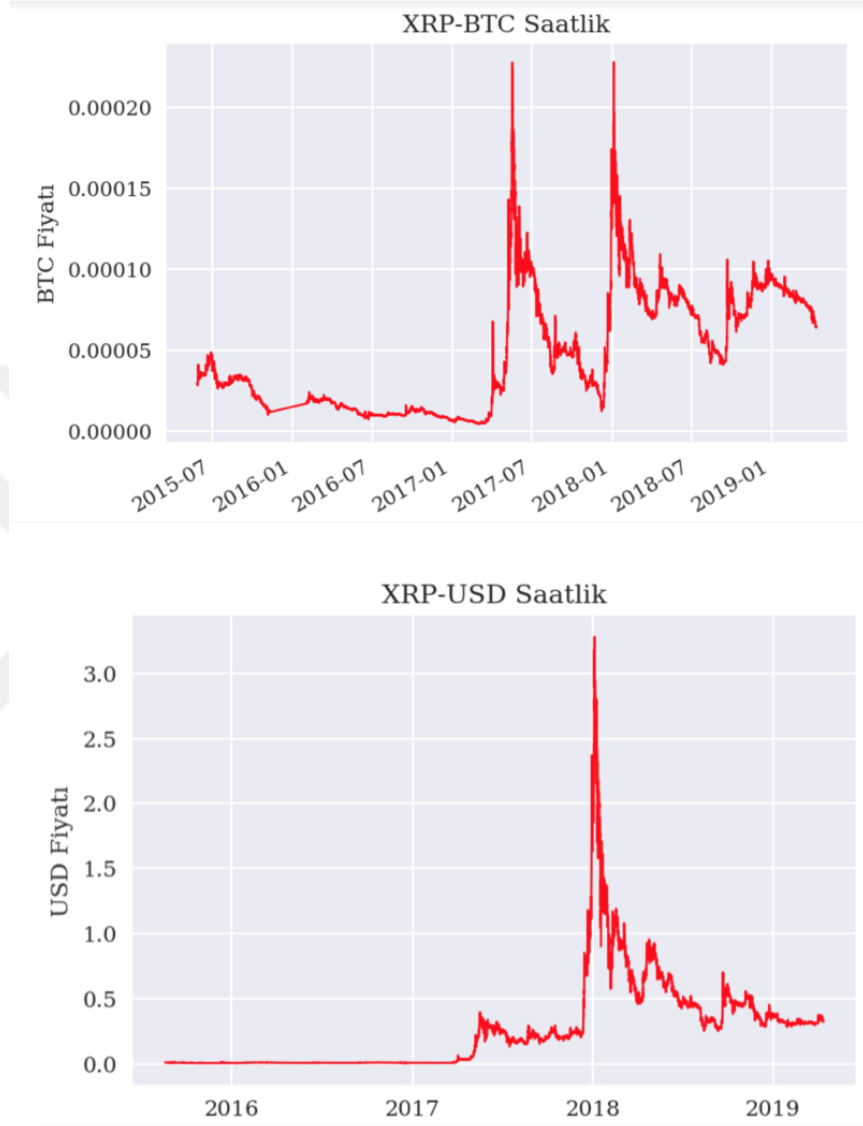
A.1. BTC-USD Saatlik Grafiđi



řekil A.2. ETH – BTC ve ETH – USD Saatlik Grafiđi



Şekil A.3. XRP – BTC ve XRP – USD Saatlik Grafiği



EK B

Backtester.py Dosyası

```

import backtrader as bt
import pandas as pd
import matplotlib
from matplotlib import interactive
interactive(True)
from datetime import datetime, time
from rsi import RSIStrategy
from bb import BBStrategy
from ema import EMAStrategy
from wma import WMAStrategy
import backtrader.analyzers as btanalyzers
import backtrader.sizers as btsizers

btc_daily = pd.read_json("data/btc-daily.txt")
btc_daily['time'] = pd.to_datetime(btc_daily["time"],unit='s')
btc_daily = btc_daily.set_index("time")

if __name__ == '__main__':

    cerebro = bt.Cerebro()

    data = bt.feeds.PandasData(dataname=btc_daily, volume='volumefrom')

    cerebro.adddata(data)
    cerebro.addstrategy(EMAStrategy)
    #cerebro.addstrategy(WMAStrategy)
    #cerebro.addstrategy(BBStrategy)
    #cerebro.addstrategy(RSIStrategy)

    cerebro.broker.setcash(10000)
    cerebro.broker.setcommission(commission=0.001)
    cerebro.addsizer(btsizers.PercentSizer, percents=50)

    cerebro.addanalyzer(btanalyzers.TradeAnalyzer, _name="TradeAnalysis")

    cerebro.addanalyzer(btanalyzers.DrawDown, _name="DrawDown")
    cerebro.addanalyzer(btanalyzers.SQN, _name="SqN")
    cerebro.addobserver(bt.observers.Cash)

    results = cerebro.run()
    bt_strategies = results[0]

    old_analyzer = bt_strategies.analyzers.getbyname('TradeAnalysis')
    trade_analysis = old_analyzer.get_analysis()

    dtime = bt_strategies.data._dataname['open'].index

    realized = trade_analysis.pnl.net.total
    total_return = realized / bt_strategies.broker.startingcash
    total_number_trade_history = trade_analysis.total.total
    trade_history_closed = trade_analysis.total.closed

```

```

drawdown = bt_strategies.analyzers.DrawDown.get_analysis()
sqn_score = bt_strategies.analyzers.Sqn.get_analysis()['sqn']

metrics = {
    'Alım-satım Sayısı': total_number_trade_history,
    'Ortalama kazanç': trade_analysis.won.pnl.average,
    'Ortalama kayıp': trade_analysis.lost.pnl.average,
    'En-iyi-ticaret': trade_analysis.won.pnl.max,
    'En-kötü-ticaret': trade_analysis.lost.pnl.max,
    'Başlangıç miktarı':bt_strategies.broker.startingcash,
    'Toplam Net Kar': realized,
    'Kazanılan Miktar': trade_analysis.won.pnl.total,
    'Kaybedilen Miktar': trade_analysis.lost.pnl.total,
    'Toplam Getiri %': 100 * total_return,
    'Maks. Düşüş K. %': drawdown['max']['drawdown'],
    'Sqn Puanı': sqn_score,
}
metrics = pd.Series(metrics).to_frame()
#metrics.to_csv('/Users/msu/DRL-
CryptoTrading/UI/backtrader_results/BH/BTC/btc-daily.csv')
print(a)

cash=pd.DataFrame(bt_strategies.cash)
#cash.to_csv('/Users/msu/DRL-
CryptoTrading/UI/backtrader_results/BH/BTC/btc-daily-cash.csv')
print(cash)

```

EK C

co_env.py Dosyası

```

import gym
import pandas as pd
import numpy as np
from gym import spaces
from sklearn import preprocessing

from render import Renderer

class CryptOlrlicEnv(gym.Env):
    """A Cryptotrading environment inspired from
    https://github.com/notadamking/Bitcoin-Trader-RL """
    minmax_scaler = preprocessing.MinMaxScaler()

    def __init__(self, df, gps=200, init_cash=10000, commission=0.0001):
        super(CryptOlrlicEnv, self).__init__()

        self.df = df
        self.gps = gps
        self.init_cash = init_cash
        self.commission = commission
        self.buy_count = 0
        self.sell_count = 0
        self.balance = init_cash
        self.net_worth = init_cash
        self.crypto_asset = 0
        self.current_step = 0
        self.history = np.repeat([
            [self.balance],
            [0],
            [0],
            [0],
            [0]
        ], self.gps + 1, axis=1)
        self.mode = "LEARN"
        self.trade_history = []

        self.action_space = spaces.Box(low=-3, high=3, shape=(1,))

        self.observation_space = spaces.Box(
            low=-3, high=3, shape=(10, gps + 1))

        self.backtrader = []

    def next (self):
        end = self.current_step + self.gps + 1

        adjusted_df = self.current_df.values[:end].astype('float64')
        adjusted_df = self.minscaler.fit_transform(adjusted_df)
        adjusted_df = pd.DataFrame(adjusted_df, columns=self.df.columns)

        obs = np.array([
            adjusted_df['open'].values[self.current:end],

```

```

        adjusted_df['high'].values[self.current_step:end],
        adjusted_df['low'].values[self.current_step:end],
        adjusted_df['close'].values[self.current_step:end],
        adjusted_df['volumefrom'].values[self.current_step:end],
    ])

    df_new = self.scaler.fit_transform(self.history)
    size = self.gps + 1

    if self.mode == "PREDICT" and len(obs[0]) < size:
        return None

    obs = np.append(obs, df_new[:, -(size):], axis=0)

    return obs

def init_session(self):
    self.left = len(self.df) - self.gps - 1
    self.frame_start = self.gps

    start = self.frame_start - self.gps
    end = self.frame_start + self.left

    self.current_df = self.df[start:end]

def reset(self):
    self.init_session()
    return self.next()

def init(self):
    self.balance = self.initial_balance
    self.net_worth = self.initial_balance
    self.crypto_held = 0
    self.current_step = 0
    self.init_session()
    self.history = np.repeat([
        [self.balance],
        [0],
        [0],
        [0],
        [0]
    ], self.gps + 1, axis=1)
    self.trade_history = []
    self.mode = "PREDICT"
    self.buy_count = 0
    self.sell_count = 0
    return self.next()

def action(self, action, current_price):
    if isinstance(action, np.ndarray) and len(action) > 0:
        action_type = action[0]
        amount = 0.5

        crypto_bought = 0
        crypto_sell = 0
        cost = 0
        sales = 0
        has_action = 0

        if action_type < -1:
            crypto_bought = self.balance / current_price * amount
            cost = crypto_bought * current_price * (1 + self.commission)

```

```

if self.balance > cost:
    print("*****")
    print(self.mode, "- ALIŞ")
    print("*****")
    print("Bakiye: %s Toplam Masraf: %s" % (self.balance,
cost))
    print("%s fiyatından %s adet kriptopara aldı" %
(current_price, crypto_bought))
    self.buy_count = self.buy_count + 1
    self.crypto_held+= crypto_bought
    self.balance -= cost
    net_worth = self.balance + self.crypto_held*
current_price
    has_action = 1;
    print("Eldeki kriptopara: %s" % (self.btc_held))
    print("Yeni Bakiye: %s" % (self.balance))
    print("Net Değer: %s" % (net_worth))

elif action_type < 1:
    crypto_sell = self.crypto_held* amount
    sales = crypto_sell * current_price * (1 - self.commission)

if self.crypto_held> crypto_sell:
    print("*****")
    print(self.mode, "- SATIŞ")
    print("*****")
    print("Eldeki kriptopara: %s" % (self.btc_held))
    print("%s fiyatından %s adet kriptopara sattı" %
(current_price, crypto_sell))
    self.sell_count = self.sell_count + 1
    self.crypto_held-= crypto_sell
    self.balance += sales
    net_worth = self.balance + self.crypto_held*
current_price
    has_action = 1;
    print("Eldeki kriptopara: %s" % (self.btc_held))
    print("Bakiye: %s" % (self.balance))
    print("Net Worth: %s" % (self.net_worth))

if has_action > 0:
    self.trade_history.append({'step': self.frame_start +
self.current_step,
'miktar': crypto_sell if crypto_sell > 0 else crypto_bought,
'toplam': sales if crypto_sell > 0 else cost,
'type': "sell" if crypto_sell > 0 else "buy",
'değer': net_worth})

self.history = np.append(self.history, [
self.balance],
[crypto_bought],
[cost],
[crypto_sell],
[sales]
], axis=1)

self.net_worth = self.balance + self.crypto_held* current_price

return has_action
return 0

```

```

def step(self, action):
    current_price = self.df['close'].values[self.frame_start +
        self.current_step] + 0.01
    prev_net_worth = self.net_worth
    has_action = self.action(action, current_price)

    self.left -= 1
    self.current_step += 1

    if self.left == 0:
        self.balance += self.crypto_held* current_price
        self.crypto_held= 0
        self.init_session()

        obs = self.next()
        done = has_action
        reward = self.net_worth - prev_net_worth

        return obs, reward, done, {"is_none": obs is None}

def render(self, **kwargs):

    self.renderer = Renderer( self.df)

    step = self.frame_start + self.current_step
    net_worth = self.net_worth
    trade_history = self.trade_history
    window_size = self.gps

    self.renderer.render(step, net_worth, trade_history, window_size)

def print_summary(self):
    print("Alım Sayısı:", self.buy_count)
    print("Satım Sayısı:", self.sell_count)
    print("Bakiye:", self.balance)
    print("Net Değer:", self.net_worth)
    df = pd.DataFrame(self.trade_history)
    print(df)
    df.to_csv('/Users/msu/DRL-
    CryptoTrading/gcryptolric/gym_cryptolric/data/btc-daily-sac.csv')

def close(self):
    self.renderer.close()

```


EK D

Arayüz için index.py Dosyası

```

import dash
from app import app
from dash.dependencies import Input, Output
import dash_core_components as dcc
import dash_html_components as html
from backtrader import ema_table, bb_table, rsi_table, wma_table
from backtrader import backtrader, df, btc_hourly_div, btc_daily_div,
xrp_usd_hourly_div, xrp_usd_daily_div, xrp_btc_hourly_div,
xrp_btc_daily_div, eth_usd_hourly_div, eth_usd_daily_div,
eth_btc_hourly_div, eth_btc_daily_div

app.layout = html.Div(
    [
        html.Div([
            html.Span("Teknik Analiz ve SAC ile Kriptopara Alım-Satımı",
className='app-title'),
        ],
        className="row header"
        ),
        # tabs
        html.Div([
            dcc.Tabs(
                id="tabs",
                style={"height": "40", "verticalAlign": "middle"},
                children=[
                    dcc.Tab(label="CryptOlric", value="cryptolric_tab"),
                    dcc.Tab(label="SAC", value="sac_tab"),
                    dcc.Tab(id="backtrader_tab", label="Backtrader",
value="backtrader_tab"),
                ], value="tabs_tab",
            )
        ],),
        html.Div(id="tab_content", className="row"),
    ],
    className="row",
    style={"margin": "0%"},
)

buttons = html.Button('Submit', id='button'),
@app.callback(
    dash.dependencies.Output('output-container-button', 'children'),
    [dash.dependencies.Input('button', 'n_clicks')])
def update_output(value):
    return 'The input value was "{}" and the button has been clicked {}
times'.format(value,
)

@app.callback(Output("tab_content", "children"), [Input("tabs", "value")])
def render_content(tab):

```

```

    if tab == "cryptolric_tab":
        pass
        return
    elif tab == "sac_tab":
        return html.Div(html.Iframe(src='http://127.0.0.1:6006/#scalars',
height=800, width=1200,)),
                        style={'margin-top': '50'})
    elif tab == "backtrader_tab":
        return backtrader
    else:
        return backtrader

@app.callback(
    dash.dependencies.Output('output', 'children'),
    [dash.dependencies.Input('coins-dropdown', 'value')])
def update_output(value):

    if value == 'BTC-USD-HOURLY':
        return btc_hourly_div
    elif value == 'BTC-USD-DAILY':
        return btc_daily_div
    elif value == 'ETH-USD-DAILY':
        return eth_usd_hourly_div
    elif value == 'ETH-USD-DAILY':
        return eth_usd_daily_div
    elif value == 'XRP-USD-HOURLY':
        return xrp_usd_hourly_div
    elif value == 'XRP-USD-DAILY':
        return xrp_usd_daily_div
    elif value == 'XRP-BTC-HOURLY':
        return xrp_btc_hourly_div
    elif value == 'XRP-BTC-DAILY':
        return xrp_btc_daily_div
    elif value == 'ETH-BTC-HOURLY':
        return eth_btc_hourly_div
    elif value == 'ETH-BTC-DAILY':
        return eth_btc_daily_div
    return btc_hourly_div

@app.callback(
    dash.dependencies.Output('strategy-table', 'children'),
    [dash.dependencies.Input('strateji', 'value')])
def update_stratgy(value):

    if value == 'EMA':
        return ema_table
    elif value == 'WMA':
        return wma_table
    elif value == 'RSI':
        return rsi_table
    elif value == 'BB':
        return bb_table

    return ema_table

if __name__ == "__main__":
    app.run_server(debug=True)

```

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Ad Soyad: Muhammed Said ÜNLÜ

Doğum Tarihi - Yeri: 14.07.1993 / Demirci – Manisa

Yabancı Dil: İngilizce

Mail: m.saidunlu@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul	Mezuniyet Yılı
Y. Lisans	Bilgisayar Mühendisliği	Okan Üniversitesi	
Lisans	Bilgisayar Mühendisliği (İng.)	Okan Üniversitesi	2016
Lise	Fen Bilimleri	Şehitler Fen Lisesi	2011

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2018 - Halen	Bilge Adam/KoçSistem	Büyük Veri Mühendisi
2016 - 2018	REIDIN	Yazılım Mühendisi – Veri Bilimci
2016	INSENS	Yazılım Mühendisi

YAYINLAR

ÜNLÜ M.S. , YILDIRIM P. , Girişimcilik için Çizge Tabanlı Metin Madenciliği ,
8. Uluslararası Girişimcilik Kongresi, 2017, syf. 170-180