



**Sosyal Bilimler
Enstitüsü**

T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞ ANALİTİĞİ ANABİLİM DALI

DERİN PEKİŞTİRMELİ ÖĞRENME İLE KRİPTO PARA PORTFÖY YÖNETİMİ

Yüksek Lisans Tezi

HATİCE AŞIK

İSTANBUL, 2021

T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞ ANALİTİĞİ ANABİLİM DALI

**DERİN PEKİŞTİRMELİ ÖĞRENME İLE
KRİPTO PARA PORTFÖY YÖNETİMİ**

Yüksek Lisans Tezi

HATİCE AŞIK

Danışman: PROF. DR. MERT ERER

İSTANBUL, 2021

T.C.
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞ ANALİTİĞİ ANABİLİM DALI

TEZ ONAY BELGESİ

..... Anabilim Dalı.....Bilim Dalı Yüksek Lisans/Doktora öğrencisi’nın adlı tez çalışması, Enstitümüz Yönetim Kurulunun..... tarih ve sayılı kararıyla oluşturulan jüri tarafından oy birliği / oy çokluğu ile Yüksek Lisans/Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi/...../.....

Öğretim üyesi Adı Soyadı

İmzası

1	Tez Danışmanı		
2	Jüri Üyesi		
3	Jüri Üyesi		
4	Jüri Üyesi		
5	Jüri Üyesi		

ÖZET

DERİN PEKİŞTİRMELİ ÖĞRENME İLE KRİPTO PARA PORTFÖY YÖNETİMİ

Makine Öğrenmesi, günümüzde neredeyse her alanda uygulanabilir hale geldiğinden son zamanlarda oldukça yaygınlaşmıştır. Pekistirmeli Öğrenme ve Derin Öğrenme olarak adlandırılan Makine Öğreniminin alt alanları, bir araya geldiklerinde, Atari oyunlarında Go'da birden çok kez şampiyonu yenmek için insan düzeyindeki performansa ulaşmada veya bu performansı aşmada başarılı olan gelişmiş algoritmalar ortaya çıkardı. Makine Öğreniminin bu başarıları finans dünyasının da ilgisini çekmiş ve bu tekniklerin finansal piyasalardaki kalıpları tespit etmede de uygulanıp uygulanamayacağı sorusunu gündeme getirmiştir. Yakın zamana kadar, birçok finansal problemin çözümünde regresyon yöntemleri ve trend analizleri ön planda gelmekteydi. Ancak, Pekistirmeli Öğrenme sayesinde, portföy yönetimi stratejilerinin geliştirilmesi ve sürecin tıpkı robotik sistemlerdekine benzer şekilde kendi kendine öğrenen bir mekanizma yardımıyla alım-satım yapılmasının önü açılmıştır. Bu tezde, Pekistirmeli Öğrenme kullanarak Derin Öğrenme ticaret ajanının uzun vadeli servetini en üst düzeye çıkarmak için portföydeki belirli bir kripto para veri setindeki ağırlıkların en iyi şekilde nasıl dağıtılacağını araştırılmaktadır. Farklı hiper parametre testleriyle portföyün toplam getirisi hesaplanarak market dinamiğine en uygun parametreler tespit edilmeye çalışılmıştır.

Anahtar Kelimeler: Derin Pekistirmeli Öğrenme, Uzun Kısa Süreli Hafıza, Sinir Ağları, Kripto Para, Portföy Yönetimi

ABSTRACT

CRYPTO CURRENCY PORTFOLIO MANAGEMENT WITH DEEP REINFORCEMENT LEARNING

Machine Learning has become quite common lately, as it has become applicable in almost every field today. The subfields of Machine Learning, called Reinforcement Learning and Deep Learning, combined, revealed advanced algorithms that succeeded in achieving or exceeding human-level performance to beat the champion in Go multiple times in Atari games. These achievements of Machine Learning also attracted the attention of the financial world and raised the question of whether these techniques can be applied to identify patterns in financial markets. Until recently, regression methods and trend analysis were at the forefront in solving many financial problems. However, thanks to Reinforcement Learning, development of portfolio management strategies and trading with the help of a self-learning mechanism similar to the process in robotic systems were paved. This thesis explores how to best distribute the weights in a particular cryptocurrency dataset in the portfolio to maximize the long-term wealth of the Deep Learning trading agent using Reinforcement Learning. By calculating the total return of the portfolio with different hyper parameter tests, the most suitable parameters for market dynamics were tried to be determined.

Keywords: Deep Reinforcement Learning, Long Short Term Memory, Neural Networks, Crypto Currency, Portfolio Management

ÖNSÖZ

Tezin hazırlanma süreci boyunca desteğini hiçbir zaman esirgemeyen Danışman Hocam Prof. Dr. Mert Erer'e emek ve anlayışları için şükranlarımı sunarım. İş ve okul dengesini birlikte yürütmemde büyük desteği olan değerli yöneticim Recep Göktepe'ye teşekkürlerimi belirtmek isterim.

Bu tezi, akademik yaşamımı devam ettirmem için desteklerini hiçbir zaman esirgemeyen değerli eşime ve oğluma ithaf ediyorum.

Hatice AŞIK

İSTANBUL, 2021

İÇİNDEKİLER

ÖZET.....	1
ABSTRACT.....	2
ÖNSÖZ.....	3
İÇİNDEKİLER.....	4
KISALTMALAR	6
TABLolar LİSTESİ	8
ŞEKİLLER LİSTESİ.....	9
1. GİRİŞ	10
1.1. Tezin Konusu ve Amacı	11
1.2. Kaynakların Değerlendirilmesi	12
1.3. Tezde Uygulanan Yöntem.....	19
1.3.1. Tez Çalışma Süreci.....	19
1.3.2. Tezde Uygulanan Yöntem.....	21
2. FİNANSAL BİLGİLER VE KRİPTO PARALAR.....	22
2.1. Finansal Bilgiler	22
2.2. Kripto Paralar	28
3. DERİN ÖĞRENME VE DERİN PEKİŞTİRMELİ ÖĞRENME.....	35
3.1 Derin Öğrenme	35
3.1.1. Sinir Ağları (Neural Networks).....	38
3.1.2. Aktivasyon Fonksiyonu.....	40
3.1.3. Geribesleme (Backpropagation).....	42
3.1.4. Derin Öğrenme Mimarisi	42
3.1.5. Eğitim (Training).....	42
3.1.6. En İyileştiriciler (Optimizers).....	42

3.2 Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning-DPÖ)	43
3.2.1. Genel Bilgi	43
3.2.2. Pekiştirmeli Öğrenme Algoritmaları	46
4. KRİPTO PARA PORTFÖY YÖNETİMİ İÇİN LSTM TABANLI PEKİŞTİRMELİ ÖĞRENME YÖNTEMİNİN GELİŞTİRİLMESİ	49
4.1. Veri Hazırlık Süreci.....	49
4.2. Derin PÖ Süreci.....	50
4.2.1. Aksiyon Fonksiyonu.....	50
4.2.2. Ödül Fonksiyonu	51
4.2.3. Politika Fonksiyonu.....	51
4.2.4. Ağ Mimarisi	51
4.2.5. Öğrenme Oranı	52
4.3. Sonuçlar.....	52
4.3.1 Eğitim, Backtestler ve Performans Ölçümleri.....	52
5. SONUÇ	58
6. KAYNAKLAR.....	59
EKLER.....	63
Ek A.....	63
Ek B.....	64
Ek C.....	65
Ek D.....	66
Ek E	67

KISALTMALAR

ADAM	Uyarlanabilir Moment Tahmini
AI	Yapay Zekâ
AVA	Travala
BTC	Bitcoin
CNN	Evrişimsel Sinir Ağları
DASH	Dash
DDPG	Derin Deterministik Politika Gradyanı
DNN	Derin Sinir Ağı
DÖ	Derin Öğrenme
DPÖ	Derin Pekiştirmeli Öğrenme
DQN	Derin Q-Öğrenme Ağları
DRL	Direkt Pekiştirmeli Öğrenme
DRQN	Derin Tekrarlayan Q-Ağı
EIIE	Özdeş Bağımsız Değerlendiriciler Topluluğu
ETC	Ethereum Classic
ETH	Ethereum
FCL	Tam Bağlantılı Ağlar
FX	FOREX
GÖ	Gözetimli Öğrenme
HFT	Yüksek Frekanslı Ticaret
ICCAS	Uluslararası Kontrol, Otomasyon ve Sistemler Konferansı
IEEE	Elektrik ve Elektronik Mühendisleri Enstitüsü
LSTM	Uzun Kısa Süreli Hafıza
LTC	Litecoin
MDP	Markov Karar Verme Süreci

NN	Sinir Ağları
PG	Politika Gradyanı
PÖ	Pekiştirmeli Öğrenme
PPO	Yakın Politika Optimizasyonu
ReLU	Doğrultulmuş Doğrusal Birim
RNN	Tekrarlayan Sinir Ağları
RRL	Tekrarlayan Pekiştirmeli Öğrenme
RSI	Göreceli Güç Endeksi
STR	Staker
TRX	Tron
UCRP	Evrensel C-Reaktif Protein
XMR	Monero
XRP	Ripple
YSA	Yapay Sinir ağları
ZEC	Zcash

TABLÖLAR LİSTESİ

Tablo 1. Literatür Özet Tablosu.....	8
Tablo 2. Tez İş Planı.....	10
Tablo 3: Aktivasyon Fonksiyonları Matematiksel Gösterimleri.....	34
Tablo 4: Sonuç Tablosu.....	49



ŞEKİLLER LİSTESİ

Şekil 1. Portföy Optimizasyonu Karar Ağacı.....	23
Şekil 2. BTC Market Hacmi.....	30
Şekil 3. Ethereum Market Hacmi	31
Şekil 4. Chainlink Market Hacmi.....	32
Şekil 5. Farklı Piyasalara Göre Kripto Para Fiyatları.....	32
Şekil 6. BTC'nin Nisan 2013'ten 14 Nisan 2021'e kadar piyasa değeri (USD)	34
Şekil 7. Derin Öğrenme mimarisi.....	38
Şekil 8. Makine Öğrenmesi şeması	38
Şekil 9. Bir Sinir Ağının Matematiksel İfadesi	39
Şekil 10. Pekiştirmeli Öğrenmeyi Anlatan MDP Süreci.....	45
Şekil 11. PÖ Algoritmalarının Sınıflandırılması.....	47
Şekil 12. LSTM Mimarisi	49
Şekil 13. Backtest Aşamasında Gerçekleştirilen Örnek Portföy Ağırlık Dağılım Görseli.....	51
Şekil 14. Test Seti Portföy Değerleri.....	56
Şekil 15. Backtest Seti Portföy Değerleri.....	57

1. GİRİŞ

Günümüzde üretilen veri miktarındaki artış ile birlikte veriden anlamlı sonuçlar elde etmek isteyen çalışmalar önem kazanmıştır. Özellikle son on yıl içinde otonom araçlar, konuşma tanıma, arama motoru optimizasyonu, algoritmik alım-satım, duygu analizi ve insan genini tanıma gibi popüler konularda makine öğreniminin kullanımı oldukça yaygındır.

Makine öğrenmesi, elde edilen her türlü verilerden öğrenen ve zamanla öğrenme doğruluğunu en üst düzeye çıkarmayı hedefleyen bir Yapay Zekâ (Artificial Intelligence-AI) alt kümesidir.

Makine öğrenimi; Pekiştirmeli Öğrenme (PÖ), Gözetimli Öğrenme (GÖ) ve Gözetimsiz Öğrenme olarak üç gruba ayrılabilir. Pekiştirmeli Öğrenme, gözetimli öğrenmeye benzer bir model olmakla birlikte daha çok davranışsal bir öğrenme türüdür; ancak algoritma örnek veriler yardımıyla eğitilmeden sadece deneme ve yanılma yöntemleri ile öğrenmektedir.

Söz konusu tezin baz aldığı öğrenme metodu olan Pekiştirmeli Öğrenmede ortamdaki ajan, elde edeceği ödül miktarını maksimize etmeye çalışarak ödül-ceza mekanizması ile öğrenimini gerçekleştirir. Gözetimli Öğrenme ise etiketli verilerin modele girdi oluşturması yoluyla örnek veri seti üzerinden öğrenme yapmaya çalışır. Sınıflandırma algoritmaları Gözetimli Öğrenme için örnek sayılabilir. Gözetimsiz Öğrenme ise etiketlenmemiş veriler yoluyla gerçekleşen öğrenme metodudur. Yani eldeki verinin kaç sınıfa ayrıldığı bilinmeksizin ham veriden bilgi elde etmeye çalışmaktadır. Kümeleme yöntemi Gözetimsiz Öğrenme için iyi bir örnektir. Yine makine öğrenmesinin alt kümesi olan Derin Öğrenme, Pekiştirmeli Öğrenme yöntemi ile bir araya gelerek Go gibi oyunlarda insan seviyesinde başarı elde ederek yüksek performans sergilemiştir.

Bu ve bunun gibi başarılar ekonomi ve finans dünyasında da makine öğrenmesinin benimsenmesinin yolunu açmıştır. Hisse senedi piyasalarında Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning-DRL (DPÖ)) yoluyla portföy yönetimi çalışmalarına başlanmıştır. Blok zincir teknolojisinin de gelişmesi ve merkeziyetsiz yapı ile birlikte kripto para piyasalarında da portföy yönetimi ve optimizasyonu için DPÖ yöntemleri kullanılmaya başlanmıştır. Kârını maksimize etmeye çalışan bireysel ve kurumsal yatırımcılar için bu alan daha cazip hale gelmeye başlamıştır.

Bu bölümde tezin konusu ve amacı, kaynakların değerlendirilmesi ve tezde uygulanan yöntemler ile ilgili genel bilgiler verilmektedir.

1.1. Tezin Konusu ve Amacı

Kripto paralar merkeziyetsiz bir yapıya sahip olmaları ve piyasaya giriş çıkış kolaylığı nedeniyle finans dünyasının dikkatini çekmeye başlamıştır. Geçtiğimiz on yılda geleneksel finansal varlıkların yanında dijital varlıklar olarak kripto paralar da portföylerde yerini almaya başlamıştır. Profesör Aleh Tsyvinski'ye göre, "kripto para konusunda istekli olunmasa da Bitcoin (BTC) finansal portföylerin zorunlu bir parçası haline gelmelidir" (Reiff, 2019). Goldman Sachs'tan sonra JP Morgan da yüksek varlıklı özel müşterileri için BTC yatırım fonu servisi sunmayı planlamakta ve Tesla gibi dünyanın önde gelen teknoloji şirketleri de kripto varlıklarla mal alım satım işlemleri gerçekleştirmektedir. Akademik araştırmalarda kendine önemli bir yer bulmayı başaran Derin PÖ metotları ile kripto para varlık alım satım işlemleri tezin konusunu oluşturmaktadır. Tez çalışmasında, Markov Karar Verme Sürecine dayalı PÖ'nin Derin Öğrenme (DÖ) yöntemlerinden Uzun Kısa Süreli Hafıza (Long Short Term Memory-LSTM) ile sentezlenmesi amaçlanmaktadır. Bu sayede PÖ ile kripto para portföy yönetimi sağlayabilmek ve portföy değerini maksimize ederek kayıp miktarını en aza indirebilmek araştırılmaktadır. Ödül (reward) mekanizması yardımıyla ortamda (environment) aksiyon (action) sergileyen ajanın (agent) kendi kendini eğiterek portföy değerini artırması hedeflenmektedir. Portföy yönetimi ajanı, piyasası ortamı ile etkileşime girerek, kendisine yeni durumlar sunulduğunda aksiyonlar almaktadır. Her eylemde, ortam, artan veya kaybedilen portföy değerine göre ajana geri bildirimini göndermektedir.

Çalışmada, yüksek volatiliteye sahip olan bir piyasa olan Coinmarketcap piyasa verileri kullanılmaktadır. BTC tabanlı 10 adet kripto para Derin PÖ ile portföy yönetiminde kullanılmakta ve çeşitli hiper parametre değişiklikleri sonucunda önemli finansal indikatörlerin değişimi incelenmektedir. Nispeten daha volatil bir dönem olan 2019-2021 döneminde 10 adet kripto para çifti, açılış, kapanış ve en yüksek fiyat ve hacim değerleri market verileri olarak kullanılmıştır. Coinmarketcap piyasa verilerine göre en yüksek hacimli toplam 1,4 milyar dolar BTC hacmine sahip 10 adet kripto para çifti 30 dakikalık ticaret periyotlar ile modele girdi oluşturmuştur.

Kripto paraların yüksek hacimde olmasının portföy kârlılığını artırması ve gittikçe bu piyasalara olan ilginin artması nedeniyle ilgili tez çalışması bu konu üzerine inşa edilmiştir. Portföy yönetim stratejileri genellikle "kazanana takip et", "kaybedeni takip et", "desen eşleştirme" ve "meta öğrenme algoritmaları" (HOI ve LI, 2014, A:2) gibi geleneksel mekanizmalar yoluyla gerçekleştirilmekte ve PÖ'ye dayalı alım-satım mekanizmalarının yaygın olmaması da tez konusunun seçiminde rol oynamıştır.

1.2. Kaynakların Değerlendirilmesi

Finansal varlık alım-satımı konusunda farklı ticaret yöntemleri bulunmaktadır. Son on yıl çalışmaları incelediğinde temel analiz, teknik analiz ve algoritmik alım-satım gibi tekniklerin mevcut olduğu görülmüştür. Temel analiz yönteminde, bir menkul kıymetin içsel değerini inceleyerek ölçmeyi amaçlamaktadır. Ekonomik verileri inceleyerek yatırımcılar menkul kıymetin anlık fiyatını tahmini fiyatlar ile kıyaslayarak değerine karar vermektedir. Temel analizde işlemlere giriş ve işlemden çıkış zamanı net olarak bilinemediğinden hatalı bir piyasa girişi durumunda büyük kayıplar yaşanabilmektedir. Temel analizin aksine Teknik analiz yöntemi ise bir menkul kıymetin geçmiş fiyat verisinin fiyat kalıplarını incelemek için kullanılmaktadır.

Alım-satım işlemleri için bazı temel göstergelerin kombinasyonundan yararlanılır. Göreceli Güç Endeksi (Relative Strenght Index-RSI) ve Bollinger Bantları gibi indikatörlerden yardım alınır. Ancak, ekonomik veya piyasa koşullarındaki analiz eksikliği veya hatasından dolayı bu sinyallerin öngörülebilirliği güçlü sayılmaz ve genellikle hatalı sonuçlara yol açmaktadır. Temelinde matematiksel modeller yer alan algoritmik ticaret yaklaşımı ise otomatize edilmiş adımlar yardımıyla varlık alım-satımlarını gerçekleştirir.

Algoritmik ticareti araştıran çalışmalar incelendiğinde model tabanlı, model tabanlı olmayan ve derin öğrenme yöntemlerine dayananlar olmak üzere gruplara ayrıldığı görülmüştür. Bunlar içerisinde PÖ ve Derin Öğrenme yaklaşımlarını birlikte kullanan akademik çalışmanın sınırlı sayıda olduğu gözlemlenmiştir. Derin PÖ Robotik, Otomotiv, Tıp, Bilgisayar Oyunları ve Finans gibi birçok alana uygulanabilmektedir. Bu alanlarda PÖ'nin birçok başarılı uygulamasının yapıldığı gözlemlenmiştir. Borsasının dinamiklerini anlayacak ve bireysel veya kurumsal yatırımcıların kârlarını en az insan müdahalesi ile maksimize etmelerine yardımcı olacak bir ajan yapısı oluşturmak önemli bir mesele haline gelmiştir.

Moody ve Saffell (2001) yaptıkları çalışmada (Moody ve Saffell, 2001) PÖ'nin finansal piyasalara uyarlanması konusunda öncü kişilerdir. Doğrudan PÖ veya Tekrarlayan PÖ (Recurrent Reinforcement Learning-RRL) olarak adlandırılan konuda yalnızca bir varlık için alım satım yapmak üzerine strateji geliştirmişler. Geliştirdikleri algoritma ayırık (Zangre, 2019) ticaret sinyallerine dair çıktı vermektedir. Yalnızca bir finansal varlık ile sınırlı kaldığından bu çalışmada geliştirilen yaklaşım genel bir portföy yönetim probleminin çözümünde yetersiz kalacaktır.

Jiang ve Liang kripto para portföyünün yönetimi altında gerçekleştirdikleri state-of-the-art sayılabilecek çalışmalarında (Jiang ve Liang, 2017) direkt pekiştirmeli öğrenme algoritmalarından yararlanmadan Markov Karar Verme süreci (Markov Decision Process-MDP) ile DÖ yaklaşımlarını sentezlemişlerdir. Çalışmalarında geriye dönük testlerle algoritma performansını test ederek, geleneksel

portföy seçim teknikleri ile karşılaştırma yapmışlardır. Özdeş Bağımsız Değerlendiriciler Topluluğu (Ensemble of Identical Independent Evaluators-EIIE) olarak adlandırdıkları metod altında Evrimsel Sinir Ağı (Convolutional Neural Network-CNN), Tekrarlayan Sinirsel Ağ (Recurrent Neural Network-RNN) ve LSTM üçlüsünü kullanarak portföy değerini hesaplamışlardır. Sonuç olarak çalışmaları diğer portföy yönetim tekniklerine göre çok daha iyi sonuçlar elde etmiştir. Tez çalışmasının da mimari açıdan baz aldığı ana kaynak olan bu çalışma deterministik politika gradyanı metodu ile portföy yönetim süreci için bir ödüllendirme yöntemini önermektedir.

Liang ve arkadaşları Çin Hisse Senedi Borsa'ndan elde ettikleri verilerle gerçekleştirdikleri çalışmada (Liang, 2018) Sürekli PÖ'nin state-of-the-art sayılan üç adet algoritmasının implemantasyonunu gerçekleştirmiştir. Derin Deterministik Politika Gradyanı (Deep Deterministic Policy Gradient-DDPG), Yakın Politika Optimizasyonu (Proximal Policy Optimization-PPO) and Politika Gradyanı (Policy Gradient-PG) olan bu algoritmalar video oyunlarında ve robot kontrol sistemlerinde yaygın olarak kullanılmaktadır. Çalışmada portföy yönetimine ve hiperparametre optimizasyonuna ışık tutması açısından farklı öğrenme oranları, amaç fonksiyonu (objective function) ve öznitelik kombinasyonları denenmiştir. Sonuç olarak PPO'nun finansal piyasalara uyarlanabilirliğinin daha uygun olduğu anlaşılmıştır. Çekişmeli Eğitim metodu (Adversarial Training) olarak nitelendirdikleri çalışmanın Algoritmaların eğitim performansını büyük ölçüde arttırarak geriye dönük testlerde günlük ortalama getiriye ve sharpe oranını (sharpe ratio) iyileştirdiğini gözlemlemişlerdir. Sonuç olarak yapmış oldukları modifikasyonlar ile PPO algoritmasının Evrensel C-Reaktif Protein (Universal C-Reactive Protein-UCRP) metoduna göre daha iyi sonuç verdiğini kanıtlamışlardır; ancak çalışmanın temel olarak baz aldığı Q Öğrenme (Q Learning) algoritmasının boyutsallık laneti (curse of dimensionality)'ne (Choudhury, 2019) neden olması ve yüksek kapasitede veri depolama alanı gerektirmesinden ötürü bir dezavantaj sayılabilir. İlgili çalışma tez çalışmasına farklı hiper parametre kombinasyonlarının denenmesi açısından ışık tutmuştur.

Lu tarafından S&P 500, EURUSD, ve vadeli işlemler emtia piyasasına yönelik gerçekleştirilen çalışma (Lu, 2017), RNN ve LSTM yapıları kullanılarak geliştirilmiştir. Çalışma kapsamında Direkt Öğrenme (Direct Reinforcement Learning-DRL) ya da RRL yöntemlerine odaklanılarak politika türetmek için bir değer fonksiyonu ile öğrenmek zorunda olmayan bir algoritma tasarlanmıştır. Geliştirilen algoritma sayesinde kendi kendine karar alarak finansal piyasalarda işlem gerçekleştiren bir yapı literatüre kazandırılmıştır. Değer fonksiyonu odaklı yapılan çalışmalar Q-Öğrenme modeline dayalı olduğundan boyutsallık laneti gibi nedenlerle kısıtlamalarla karşılaştığından Lu'ya ait çalışma değer fonksiyonuna odaklanmamaktadır. Bunun nedeni değer fonksiyonunda oluşan küçük bir değişim politikada büyük değişime neden olarak ajan tarafından alınan ticaret kararlarında hataya neden olmaktadır. Buna karşılık Tekrarlayan PÖ yöntemi stratejiyi optimize edebilmek için anlık

geribildirimler sağlayarak sinir ağlarındaki ağırlık dağılımlarında doğal dağılımlar oluşturarak ayrıklaştırmanın (discretization) önüne geçmektedir. Çalışmada kullanılan Tekrarlayan PÖ yöntemi Gradient Vanishing (Gradyan Kaybolması) (Gonzalez ve Yu, 2018) problemine yol açarak modelin öğrenmemesine neden olduğundan bu problem LSTM mimari yapısı entegre edilerek aşılmıştır. İlgili çalışma tez çalışmasında kullanılan LSTM mimarisine girdi oluşturarak akademik olarak alt yapısını güçlendirmiştir. Lu'ya ait çalışma nispeten daha az volatil olan piyasalarda gerçekleştirilmiş olduğundan kripto para piyasası gibi yüksek hacim ve volatilitiye sahip piyasalarda test edilmediği gözlemlenmiştir.

Lillicrap ve arkadaşları, Derin Q-Öğrenme metodunun başarısını sürekli fiziksel aktivite alanına adapte etmek için bir çalışma (Lillicrap, 2019) gerçekleştirmiştir. Sürekli fiziksel alana yönelik DDPG'ye dayalı aktör kritik metodu ile çalışan ve modelden bağımsız (model-free) bir algoritma sunmuşlardır. Öğrenmeyi gerçekleştiren aynı algoritma, aynı ağ mimarisi ve aynı hiper parametre değerleri ile simule edilmiş 20'den fazla fiziksel görevi başarılı bir şekilde yerine getirmiştir. Bu görevler arasında ters sarkaç hareketi (cartpole swing-up), mahir manipülasyon (dexterous manipulation), bacaklı hareket (legged locomotion) ve araba sürme gibi klasik eylemler bulunmaktadır. Geliştirilen algoritma, ham piksel girdilerine dayalı birçok görevde politikaları uçtan uca öğrenerek yüksek performans sergilemiştir. Bununla birlikte, Q-Öğrenmenin araştırılması amacıyla incelenen bu çalışma DDPG'nin doğası gereği yüksek miktarda model eğitimi gerektirmektedir. Daha verimli bir model yapısıyla bu problemin de aşılması öngörülmektedir.

Huang ve arkadaşlarınca yapılan çalışmanın (Huang, 2020) amacı, yapay zeka teknolojisinin beraberinde getirdiği Derin PÖ'nin portföy yönetimine uygulanabileceğini doğrulamaktır. Çalışma kapsamında mevcut Derin PÖ portföy modeli geliştirilerek birtakım farklılaştırmalar yapılmıştır. Bu alanda yapılan birçok çalışma ayrık (discrete) alım-satım sinyalleri üzerine yapılmıştır; ancak Huang'a ait çalışmada ajanın piyasada kısa pozisyonlar olarak arbitraj fiyatlama teorisine göre aksiyon alması sağlanmıştır. Aktivasyon fonksiyonu ve sinir ağı mimarisinde farklılaştırmalar yapılarak CSI500 (China Securities Index 500) ve CSI300'de rastgele seçilen bazı portföylerde testler gerçekleştirilmiştir. Çalışma sonucunda hangi portföy seçilmiş olursa olsun markettekinden daha yüksek getiri oranı elde edilmiştir. Markettekinden daha yüksek getiri elde edilemeyeceğini belirten birçok çalışmanın aksine market performansının ötesinde bir başarı sağlanmıştır. MDP'ye dayalı olarak gerçekleştirilen çalışma yalnızca short alım-satım yöntemi ve arbitraj teorisine göre bina edildiğinden kripto para piyasalarında ne derecede başarılı sonuçlar elde edeceği bilinmemektedir.

Zhang ve arkadaşları çalışmalarında (Zhang, 2019) sürekli futures sözleşmeleri (Angoshtari, 2019) için Derin PÖ yöntemine dayalı bir ticaret stratejisi geliştirmiştir. Hem ayrık hem de sürekli aksiyon uzayları dikkate alınarak market volatilitesine göre alım-satım pozisyonlarını ölçen bir ödül fonksiyonu tasarlanmıştır. 2011-2019 yılları arasında likiditesi en yüksek 50 farklı futures sözleşmeleri

seçilmiştir. Bu sözleşmeler emtia, hisse senedi endeksleri, sabit gelir ve döviz piyasalarından oluşturulmuş ve test edilmiştir. Klasik zaman serisi stratejileri ile kıyaslama yaptıklarında yüksek komisyon oranlarına rağmen geliştirilen algoritma pozitif kâr sağlayarak çok daha iyi performans göstermiştir. Çalışmanın temelini state-of-the-art PÖ algoritmalarından Derin Q-Öğrenme Ağları (Deep Q-Learning-DQN), PG ve Avantaj Aktör Kritik (Advantage Actor-Critic-A2C) metotları oluşturmaktadır. Geliştirilen algoritma, pozisyon değişimi yapmaksızın geniş piyasa trendlerini takip ederek konsolidasyon periyotları doğrultusunda pozisyonu aşağı yönlü kaydırmış veya elinde tutmuştur. Farklı PÖ algoritmalarının entegrasyonlarının futures piyasalarında uygulamalarının incelenmesi açısından Zhang'e ait çalışmadan yararlanılmıştır.

Rundo tarafından yapılan çalışmada (Rundo, 2019) gözetimli DÖ ve PÖ algoritmalarından yararlanılmıştır. Yüksek Frekanslı Ticarete (High Frequency Trade-HFT) yatırımdan elde edilecek getiriyi maksimize etmek için döviz piyasasında kısa dönemli trend tahmini yapılmıştır. Önerilen algoritma ortalama %85 doğruluk ile bir para biriminde orta-kısa vadeli eğilimi tahmin edebilmiştir. 2004-2018 dönemine dair Tickstory internet sitesinden elde edilen EUR/USD, GBP/USD, EUR/GBP çapraz kur çiftleri üzerinden gerçekleştirilen tahmin ile %99 oranında yüksek bir başarı sağlanmıştır. Elde edilen başarıda haricen entegre edilen donanımların da etkisi büyüktür. Algoritmanın LSTM ve RNN mimarisinde daha verimli çalışması için STM32 mikro kontrolörü mimarisinden yararlanılmıştır. Bu portatif yapı sayesinde finansal operatörler isterlerse farklı lokasyonlarda mobil olarak trend analizlerini takip edebilecektir. Rundo'ya ait olan bu çalışma donanım eklentisi ile muadil çalışmalara göre farklılaşmaktadır.

Yang ve arkadaşları tarafından yapılan çalışmada (Yang, 2019) PÖ kullanımına dayalı farklı bir ticaret yaklaşımı önerilmiştir. Modifiye edilmiş DQN ve aktör kritik (A3C) yaklaşımına göre otomatik olarak kendi kendine alım-satım kararları alan bir ticari ajan modeli geliştirmişlerdir. Yığılmış gürültü azaltma otomatik kodlayıcılar (stacked denoising Autoencoders-SDAEs) ve LSTM kullanımı ile derin bir çerçeve oluşturmuşlardır. Bu sayede kendi kendine kararlar alan ajan daha efektif bir mekanizma yardımıyla gerçek zamanlı Ticaret ortamında yüksek getiri elde edebilecektir. LSTM mimarisinin daha verimli çalışması için yapılabilecek iyileştirme fikirleri için ilgili çalışma incelenmiştir.

Ma ve Han tarafından Uluslararası Kontrol, Otomasyon ve Sistemler Konferansı'nda (ICCAS) bildiri olan sunulan çalışmada (Ma, 2018) Şangay Bileşik Endeksi alım-satımı için DÖ'ye dayalı bazı ticaret stratejilerini analiz edilmiştir. Araştırma sonucunda derin sinir ağı kullanımı ile en iyi stratejinin düşük volatilitelere sahip piyasada yüksek tahmin oranına sahip olduğu kanıtlanmıştır. PÖ ajanı ile düşük volatiliteli piyasa yatırımcılar riski minimize ederek yüksek getiri elde edebilecektir. Önceki finansal kayıtlarında yer alan alım-satıma ait stratejinin kopyalanması ile kârlı bir ticaret ortamı oluşturabilecektir. Böyle bir kârlı ortam için çok yüksek miktardaki finansal verinin alınması

gerektiğinden bunun ancak PÖ'ya dayalı bir yapı ile sağlanacağı öngörülmüştür. Söz konusu PÖ ajanı uzmanların alım-satım stratejilerini taklit ederek anlık politika gradyanı metodunu ile kârlı alım-satım yapabilecektir. Önerilen PÖ veri hattı (pipeline) neredeyse %80 oranında doğrulukla eğitim ve test aşamalarında çalışacaktır.

Chien-Yi tarafından gerçekleştirilen çalışmada (Chien-Yi, 2018) DÖ algoritmalarının finansal piyasalara uyarlanması verimlilik düzeyi araştırılmıştır. Çalışmaya göre finansal piyasalar, Robotik ve video oyunu alanlarına göre bazı zorluklara ya da farklılıklara sahiptir. Bu farklılıklar; finansal piyasadaki ajanların ayırık zaman dilimlerinde piyasa ile etkileşimde bulunması bazen bunun mili saniye düzeyinde olabilmesi, finansal piyasaların piyasa emri gibi bazı resmi aksiyonlara sahip olması, piyasa tarafından ajan ile paylaşılan yeni bilgiler konusunda ajanın bilginin nasıl üretildiğine dair bir ipucuna sahip olmaması ve son olarak da ajanın tam kontrolle yetkili olmamasına rağmen kararlarda değişiklik yapma yetkisine sahip olmasıdır. Çalışma kapsamında MDP'ye dayalı ve sinyal tabanlı bir mimari yapı oluşturulmuştur. Robotik veya video oyunlarına uyarlanmış olan DÖ mimarisinde bazı değişiklikler yaparak Derin Tekrarlayan Q-Ağı (Deep Recurrent Q-Network- DRQN) algoritmasını finansal görev için uyarlamışlardır. DRQN algoritmasının MDP kanalıyla finansal ticareti gerçekleştirerek başarılı olması Chien'i şaşırtmıştır. Ayrıca rastgele araştırma ihtiyacını karşılamak için aksiyon çoğaltma (action augmentation) tekniğini geliştirmiştir. Çalışmada 12 farklı para çifti (AUDJPY, AUDNZD, AUDUSD, CADJPY, CHFJPY, EURGBP, EURJPY, EURUSD, GBPJPY, GBPUSD, NZDUSD ve USDCAD) kullanılmış ve pozitif getiri elde edilmiştir. Araştırmada risk faktörünün dikkate alınmaksızın salt kâra odaklanılmış olması bir dezavantaj sayılabilir.

Tablo 1: Literatür Özet Tablosu

Çalışma	Amaç	Metot	Yıl
Moody ve Saffell	PÖ ile alım-satım öğrenimi gerçekleştirmek	Direkt PÖ	2001
Jiang ve Liang	Derin PÖ ile kripto para alım-satımına yönelik bir çerçeve oluşturmak	Evrişimsel Sinir Ağları (Convolutional neural network -CNN) Derin Deterministik Politika Gradyanı	2017

		(Deep Deterministic Policy Gradients - DDPG)	
Lu	Ajan odaklı RNN ve LSTM mimarisi geliřtirmek	Direkt PÖ (Direct Reinforcement Learning-DRL) Tekrarlayan PÖ (Recurrent Reinforcement Learning-RRL)	2017
Chien-Yi	PÖ tabanlı finansal ticaret mimarisi oluřturmak	Derin Tekrarlayan Q-Ağı (Deep Recurrent Q-Network-DRQN) Markov Karar Verme (Markov Decision Process-MDP)	2018
Liang	Portföy yönetimi için uçtan uca PÖ algoritmaları yaklaşımı geliřtirmek	Derin Deterministik Politika Gradyanı (Deep Deterministic Policy Gradient-DDPG), Yakın Politika Optimizasyonu (Proximal Policy Optimization-PPO) and Politika Gradyanı (Policy Gradient-PG)	2018
Ma	DÖ tabanlı hisse senedi alım-satım stratejisi geliřtirmek	Derin Sinir Ağları (Deep Neural Network-DNN) PÖ	2018
Lillicrap	DDPG'ye dayalı aktör kritik metodu ile çalışan ve modelden bağımsız (model-free) bir algoritma tasarlamak	Derin Deterministik Politika Gradyanı (Deep Deterministic Policy Gradient-DDPG) Q-Öğrenme (Q-Learning)	2019
Rundo	FX (Forex) piyasasında yüksek frekanslı ticarete LSTM ile PÖ katmanında finansal trend tahminlemesi sağlamak	LSTM ve RNN mimarileri STM32 mikro kontrolörü ile donanımdan yararlanma	2019

Yang	Algoritmik ticaret için daha verimli çalışan bir PÖ modeli kurgulamak	Yığılmış gürültü azaltma otomatik kodlayıcılar (stacked denoising Autoencoders-SDAEs) ve LSTM	2019
Zhang	Futures sözleşmelerinde PÖ yöntemi ile alım-satım stratejisi geliştirmek	Derin Q-Öğrenme Ağları (DQN), Politika Gradyanları (PG) ve Avantaj Aktör Kritik (Advantage Actor-Critic-A2C)	2019
Huang	Çin hisse senedi piyasasında PÖ'ye dayalı ticaret ortamı geliştirmek	Derin PÖ ve Markov Karar Verme Süreci (MDP)	2020

Literatür incelemeleri sonucunda Pekiştirmeli Öğrenmenin, Tıp, Robotik ve Finans dahil olmak üzere bir çok alana uygulanabilir olduğu anlaşılmıştır. Bu alanlarda PÖ'nin birçok başarılı uygulaması olmuştur. Bu ve bunun gibi başarılarından yola çıkarak, kripto para borsasının dinamiklerini anlayacak ve alım satım işlemini gerçekleştiren ajanların modele müdahalelerini en aza indirecek ve ticari kârlarını en üst düzeye çıkarmasına destek olacak bir model oluşturulmuştur. Tez çalışmasında literatürde örneğine ender rastlanan kripto para borsası seçilmiştir. Çalışmaların birçoğu hisse senedi veya Forex piyasalarını tercih etmiştir. Bu tür borsalar PÖ metotlarının daha stabil sonuçlar vermesine neden olmakta ve ticaret ajanını yanıltmaktadır. Genel olarak sair çalışmalarda yer alan model dışarıdan müdahale yoluyla eğitime çalışılmıştır. Oysaki teze konu olan çalışmada ajan borsa ile etkileşime kendisi girmektedir. Yeni fiyat girdileri ile karşılaşması durumunda otonom olarak alım satım kararlarını farklı setler oluşturarak vermektedir.

Finansal piyasalarda farklı türde varlıkların alım satımına yönelik çeşitli makine öğrenimi metotları ve yaklaşımlarının yer aldığı yukarıda çeşitli çalışmalar ışığında özetlenmiştir. Bununla birlikte birçok yaklaşım varlıkların fiyat hareketlerini veya eğilimleri tahmin etmeye çalışmaktan öteye geçememektedir. Tez çalışması ile birlikte literatürde yer alan çalışmaların eksik yönü olan kripto paraların geçmiş fiyatları ile bir sinir ağı modeli oluşturularak gelecek dönem için tahmini bir kripto para fiyatı vektör olarak modele sunulmuştur. Alım satım işlemini gerçekleştiren ajan elde ettiği fiyat verileri ile ticaret stratejisini belirleyerek çalışmıştır. Gözetimli öğrenme veya regresyon problemlerinin aksine fiyat eğilimleri lineer olarak tahmin edilmeksizin ajan için gerçekleştireceği aksiyonlar için bir girdi oluşturmuştur. Literatürde yer alan çalışmalarda modele sağlanan girdilerin manuel olarak

sağlandığı gözlemlenmiştir. Bu durum söz konusu çalışmaların tam anlamıyla makine öğrenmesi olup olmayacağı sorusunu gündeme getirmiş ve bu doğrultudaki metodların genel piyasa koşulları altında uyarlanmasının pek mümkün olmadığını göstermiştir.

Tez çalışmasının mimari açıdan örnek aldığı çalışma olan Jiang ve Liang’a ait çalışmada (Jiang ve Liang, 2017) bağımsız değerlendiriciler topluluğu olan RNN, CNN ve LSTM ayrı ayrı değerlendirilerek sonuçlar incelenmiştir. Bununla birlikte bu çalışma kripto para borsasının nispeten daha az volatil olduğu ve piyasa hacminin daha düşük olduğu bir dönemde gerçekleştirilmiştir. Böylesi bir piyasada PÖ ajanının aşırı öğrenme yaşamış olması ve bunun sonucunda başarılı görünen sonuçlar üretmiş olması ihtimal dahilindedir. Tez çalışmasında ise LSTM yöntemi farklı hiper parametre çiftleri ile denenerek sonuçlar gözlemlenmiş ve alım satım işlemleri nispeten daha volatil bir dönem olan 2019-2021 dönemleri için test edilmiştir. Piyasa koşullarını öğrenmenin daha zor olması ve çeşitli öğrenme oranlarının da teste konu edilmesi ilgili modelin başarısını artırmıştır

1.3. Tezde Uygulanan Yöntem

1.3.1. Tez Çalışma Süreci

Tez çalışmasının tamamlanması için 6 aylık bir iş planı hazırlanmıştır. Öngörülen iş paketleri ve çalışma takvimi aşağıdaki gibi gerçekleşmiştir:

Tablo 2: Tez İş Planı

İş No	Yapılan İşler	Aylar					
		1	2	3	4	5	6
1	Literatür taraması	x	x				
2	Veri toplama araçlarının geliştirilmesi		x	x			
3	Veri toplama				x		
4	Veri analizi				x		
5	Tezin yazılması					x	x

Tez çalışması, iş paketleri üzerinden belli zaman dilimlerine ayrılmış olmakla birlikte araştırmaya daha önce başlanmıştır. Her bir iş paketiyle ilgili çalışmalar yapılmış olup detaylı olarak aşağıda belirtilmiştir.

1 nolu iş paketi olan literatür taramasında öncelikle yurt dışı kaynaklarından olan Elektrik ve Elektronik Mühendisleri Enstitüsü (Institute of Electrical and Electronics Engineers-IEEE) Xplore sisteminden canlı olarak kitaplar, konferans bildirileri, dersler, akademik dergiler ve standartlar taranmıştır. Researchgate portalı üzerinden konuyla ilgili yazılmış ilintili makaleler incelenerek arşivlenmiştir. Birçok farklı alanda bilimsel makale hizmeti sunan açık ve ücretsiz bir online kaynak olarak sunulan ArXiv sisteminde tez konusu ile ilişkili olabilecek makaleler taranarak arşivleme yapılmıştır. Bilimsel araştırmalar için sunulan kaynaklardan olan Semantics Scholar sisteminde akademik çalışmalar ve uygulamaları incelenmiştir. Investopedia, Analytics India Magazine ve Springer Link gibi popüler bilimsel ve teknik kaynaklarda yer alan araştırmalar ve yazılar gözden geçirilmiştir. Tez çalışması kripto para konusu üzerine tasarlandığından Coinmarketcap, Binance, Investing.com ve Tradingview gibi kanallarda verilerin alınma yöntemleri araştırılmıştır.

2 nolu iş paketi olan veri toplama araçlarının geliştirilmesi bölümünde tez çalışmasında eğitim ve test veri seti olarak kullanılacak bilgilerin canlı ortamlardan temin edilebilmesi ile ilgili bir fizibilite araştırması yapılmıştır. Araştırma sonucunda Coinmarketcap tarafından sağlanan ücretsiz api anahtarı ile 2019-2021 yıllarına ait 10 adet kripto para verisinin alınabilmesi için alt yapı oluşturulmuştur. Pycharm ve Jupyter Lab ortamlarında oluşturulan proje ile market verileri bu ortamlara aktarılmıştır.

3 nolu iş paketi olan veri toplama aşamasında Coinmarketcap sisteminden BTC karşılıklı olan 10 adet kripto paraya ait 2019-2021 dönemine ait günlük hacim, açılış fiyatı, kapanış fiyatı ve gün içi en yüksek fiyat verileri elde edilmiştir.

4 nolu iş paketi olan veri analizi bölümünde marketten elde edilen verilerin analizi gerçekleştirilmiştir. Piyasan elde edilen veri yüksek hacimde olduğundan veri işlenmesi ve analizi için yine Python kütüphanelerinden faydalanılmıştır. Marketten elde edilen verinin formatı ham olarak elde edildiğinden birtakım veri ön işleme tekniklerinden geçirilerek veri işlemeye uygun hale getirilmiştir.

5 nolu ve son iş paketi olarak tezin yazılması aşamasında daha önce literatür taraması ve araştırmalar sonucunda elde edilen veriler ve akademik olarak tez çalışmasının dolduracağı boşluklar göz önüne alınarak bilgilerin yazıya aktarılması sağlanmıştır. Tez konusunda yeterli düzeyde yerli kaynak olmadığından state-of-the-art çalışmaların incelenmesi ve tez çalışmasına girdi oluşturması için çoğunlukla yabancı kaynaklardan faydalanılmıştır.

1.3.2. Tezde Uygulanan Yöntem

Kripto para marketlerinin birçoğunun 7/24 ticarete açık olması ve küçük miktarda bedellerle yatırımcıların piyasaya kolaylıkla giriş yapabilmesi marketin önemli özellikleridir. Yalnızca en popüler para olan BTC değil aynı zamanda küçük hacimlerde birçok kripto para da piyasada mevcut olduğundan alım-satım için daha likit bir ortam oluşmuştur. Bu özellikler makine öğrenmesi ile eğitilen algoritmalar için de iyi bir öğrenme ortamı sağlamıştır. Diğer geleneksel finansal piyasalara göre nispeten daha volatil ve dinamik bir piyasa olan kripto para piyasası bu yönüyle yatırımcılara portföy getirisinin artırılması açısından daha kârlı bir ortam sağlamaktadır.

Tez konusuna karar verilmeden önce akademik araştırmalar sonucunda finansal piyasalarda özellikle Forex ve hisse senedi piyasalarında gerçekleştirilen geleneksel veya PÖ tabanlı yaklaşımların bulunduğu; ancak dijital varlıklar olan kripto paralar konusunda otonom olarak alım-satım kararları verebilecek AI yöntemlerin tam olarak yaygınlaşmadığı gözlemlenmiştir. Kripto para ticaretinin gelişime açık olan bir alan olduğuna karar verilerek tez konusu seçilmiştir.

Tez çalışmasında gerçekleştirilen DPÖ tabanlı model geliştirilirken Jiang ve arkadaşlarının derin öğrenme mimarilerinden oluşan çerçeve yaklaşımından esinlenilmiştir. İlgili çerçeve yaklaşımda CNN, RNN ve LSTM üçlüsünden oluşan bir grup (ensemble) algoritma tasarlanarak geleneksel portföy yönetim metotları ile kıyaslama gerçekleştirilmiştir. Tez çalışmasında ise state-of-the-art olarak tasarlanan PÖ algoritmaları yerine derin öğrenme mimarilerinden olan LSTM tabanlı MDP içeren bir yaklaşım geliştirilmiştir. İlerleyen bölümlerde değinilecek olan farklı hiper parametre bileşenleri ile portföy değeri artırılarak sharpe Oranında iyileştirmeler sağlanmıştır. Tez çalışmasında tasarlanan ve yatırımcı niteliğinde olan ajan, piyasan aldığı geribildirimler ile ödül-ceza mekanizmasına dayalı olarak kendi kendine alım-satım kararları alması sağlanmıştır.

Tezin deneysel ortamının oluşturulması amacıyla Pandas, Sklearn, Keras, Numpy ve Tensorflow kütüphanelerinin implementasyonu yapılmıştır. Sonuçların Görsel olarak izlenmesi için Tensorboard'dan faydalanılmıştır. Çalışma kapsamında geliştirilen metodoloji için sinir ağı temelli mimari yapı oluşturularak süreç başlatılmıştır. Evrimsel sinir ağı katmanı (Convolution Layer) kullanılarak LSTM tabanlı bir ağ mimarisi kullanılmıştır. Söz konusu sinir ağı için kripto para fiyat değerleri girdi oluşturmuştur ve softmax katmanı sayesinde Brownlee'nin de belirtildiği şekilde "çıktıların olasılıksal ağırlıklara dönüştürülmesi" (Brownlee, 2020) ve çıktıların dağılımının 0 ve 1 arasında olasılıksal dağılıma sahip olması sağlanmıştır. Entegre edilen LSTM mimarisinin hesaplama için yüksek kapasitede hafıza gerektirmesinden ötürü bu problem terk (dropout) metodu ile bazı sinir ağlarının ve girdilerin olasılıksal olarak kullanılmaması ile çözülmüştür. Yine Brownlee'nin de belirttiği gibi "terk yöntemi ile düzenleyici işlem olarak LSTM mimarisinin aşırı öğrenmeye neden olarak hatalı sonuca varması"

engellenmiş olacaktır. Tez çalışmasında baz alınan LSTM mimarisinde farklı öğrenme oranları ve hiper-parametre kombinasyonları ile portföy değeri ve sharpe oranları gibi temel göstergeler kıyaslamalı olarak sunulmuştur.

Sözde (pseudo) katman yapısı:

```
{ "neuron_layers": [{ "shape_of_filtering": [1, 2], "number_of_filtering": 3, "layer_type": "convolution_layer"},  
  { "number_neuron": 120, "layer_type": "LSTM", "percentage_dropout": 0.5 },  
  { "type": "output_withw", "type_regularizer": "L2", "decay_of_weight": 4e-7 } ] }
```

2.1. Finansal Bilgiler

Varlıklar

Finansal varlıklar, ekonomik değeri olan yatırım araçlarıdır. Varlık türlerine örnek olarak; dijital paralar, elde tutulan ya da bankaya yatırılan nakit, hisse senetleri, krediler ve avanslar, tahakkuk eden gelirler vb. verilebilir. Bu çalışmaya konu varlık türü dijital bir varlık ve yatırım aracı olan kripto paralardır.

Hisse Senetleri

Hisse senetleri, ihracı gerçekleştiren şirkette hisse oranında sahipliği ifade eden bir menkul kıymet türüdür. Hisse senetleri ağırlıklı olarak borsalarda alınıp satılmaktadır. Mosavi'nin de belirttiği gibi "hisse senedi piyasaları diğer marketlere oranla daha hızlı ve daha yüksek oranda getiri sağlamaktadır" (Mosavi ve arkadaşları, 2020, sayfa:11)


Portföy Kavramı

Portföy; hisse senetleri, tahviller, emtialar, döviz ve nakit benzerleri ve dijital varlıklar gibi finansal varlıkların yanı sıra borsada işlem gören fonlar da dahil olmak üzere finansal varlıklar bütünüdür. Elton ve arkadaşlarının da "yatırımcılar portföylerinde tek bir varlık tutmamalıdır" şeklinde kitaplarında belirttiği gibi (Elton ve arkadaşları, 2014) portföyler farklı finansal yatırım araçlarının toplamından oluşmalıdır ve portföy riski bir varlık türüne yüklenmemelidir. Portföyler bireysel yatırımcılar tarafından tutulabileceği gibi finans alanında uzman kişi ve kurumsal vasıtası ile de oluşturulabilir. Uzun yıllar boyunca finans dünyası istatistiksel metotlar kullanarak portföy yönetimi gerçekleştirmekteydi. Son zamanlarda ise portföy yönetimi için geleneksel metotlar yerine makine öğrenmesi teknikleri portföy yöneticileri tarafından daha çok kullanılır hale gelmiştir.

Portföy Optimizasyonu

Portföy optimizasyonu, belirli varsayımlar altında yatırımcılar tarafından gerçekleştirilen diğer portföyler arasından en iyi portföyü seçme sürecidir. Buradaki amaç beklenen getiriyi arttırmak ve finansal risk gibi maliyetleri en aza indirmektir. Etkin bir portföy optimizasyonu için Erdogan ve arkadaşlarının da araştırmalarında belirttiği gibi "ekonomik değerlendirme teknikleri kullanılarak ülkelerin nakit akışlarına dair riskler göz önüne alınmalıdır" (Erdogan, 2001). Resolve Asset Management sunuş belgesindeki aşağıdaki görsel portföy optimizasyonu sağlanırken

Referans alınabilecek bir karar ağacı yapısı bulunmaktadır:



Şekil 1. Portföy Optimizasyonu Karar Ağacı

Kaynak: ReSolve Asset Management, <https://investresolve.com/file/pdf/Portfolio-Optimization-Whitepaper.pdf>

Fiyatlar

Varlık fiyatları piyasada genel denge teorisinin de içerdği şekilde arz ile talebin kesiştiği noktada belirlenir. Fiyat tahminlemesi için çeşitli makine öğrenmesi yöntemleri uygulanabilir. Gözetimli ve gözetimsiz makine öğrenmesi metotlarıyla kripto para fiyat tahminlemesinin yapılması güç olduğundan PÖ yöntemi ile tahmindeki başarı oranı arttırılmaktadır.

Fiyat Türleri

- Yüksek fiyat

Varlığın gün içi işlem gören en yüksek fiyatını ifade etmektedir.

- Düşük fiyat

Varlığın gün içi işlem gören en düşük fiyatını ifade etmektedir.

- Kapanış fiyatı

Varlığın günün sonundaki fiyatını ifade etmektedir.

- Açılış Fiyatı

Varlığın günün başlangıcındaki fiyatını ifade etmektedir.

Hacim

Hacim, belirli bir süre boyunca bir menkul kıymet veya piyasanın tamamında işlem gören hisseler veya sözleşmelerin sayısıdır. Her alıcı için bir satıcı vardır ve piyasada gerçekleşen her işlem toplam hacmin sayısına katkıda bulunur. Yani, alıcılar ve satıcılar belirli bir fiyattan bir işlem yapmayı kabul ettiklerinde, bu tek işlem olarak kabul edilir. Bir günde sadece on işlem gerçekleşirse, o günün hacmi ondur.

Getiri

Mutlak varlık fiyatları, bir yatırımcı için doğrudan karar verme için yeterli değildir. Varlığın zaman içindeki fiyat değişiklikleri büyük önem taşımaktadır, çünkü yatırım kar ve zararı ifade etmektedir. Kâr veya zarar sonucunda da varlığın getirisi belirlenmiş olur.

- **Basit Getiri**

Varlık fiyatındaki (t-1) zamanından t zamanına kadar olan yüzde değişim varlığın basit getirisi olarak adlandırılır. Bir dönemlik basit getiri formülü şu şekildedir:

$$R_{[0,T]}^S[1] := \frac{P_T - P_0}{P_0} = \frac{P_T}{P_0} - 1.$$

- **Brüt Getiri**

Brüt getiri R_t , bir varlığa yapılan yatırımın zamandaki ölçeklendirme faktörünü temsil eder (t-1). Örneğin, (t - 1) zamanında bir varlığa A dolarlık yapılan bir yatırım, t zamanında AR_t doları değerinde olacaktır. Bir varlık fiyatının t ve (t - 1) zamanlarındaki oranıyla belirlenir. Bir dönemlik brüt getiri hesaplaması şu şekildedir:

$$GrR_{[0,T]}^S[1] := 1 + R_{[0,T]}^S[1] = \frac{P_T}{P_0}$$

- **Günlük Getiri**

Brüt getirinin günlük değeridir. Basit getiri, getirileri hesaplamanın daha basit bir yolu olsa da, asimetriktir. Günlük getiriler ise, varlığın gelecekteki değerini hesaplamak için simetrik bir yol sağlar.

İşlem Maliyeti (Transaction Cost)

İşlem maliyetleri, bir mal veya hizmet alırken veya satarken ortaya çıkan giderlerdir. İşlem maliyetleri, bir ürünü veya hizmeti piyasaya sürmek için gereken emeği temsil etmektedir. Finansal anlamda, işlem maliyetleri, satıcının bir menkul kıymet için ödediği fiyat ile alıcının ödediği fiyat arasındaki farklar olan komisyoncu komisyonlarını içermektedir.

Portföy Değeri

Varlıkların ağırlıklarının günlük fiyatlarla çarpılmasıyla elde edilen portföyün toplam parasal değeridir.

Geleneksel Portföy Yönetimi Stratejileri

Portföy yönetimi temelinde yatırımları barındırır. Amaç olarak bu yatırımlardan en yüksek fayda yani kâr elde etmektir. Portföy yönetimi stratejileri, bir portföydeki varlıkların en iyi şekilde dağıtılması için portföy yöneticileri tarafından izlenen kurallar kümesidir. Geleneksel portföy yönetim teknikleri dört kategoride incelenebilir, "Kazananı Takip Et", "Kaybedeni Takip Et", "Desen Eşleştirme" ve "Meta Öğrenme" (Li and Hoi, 2014).

- **Kazananı Takip Et**

Kazananları Takip Et yaklaşımı, portföy ağırlıklarının düşük performans gösteren varlıklardan daha iyi performans gösterenlere aktarılmasıyla ifade edilir.

- **Kaybedeni Takip Et**

Kaybedenleri İzle yaklaşımı, düşük performans gösteren varlıkların geri döneceğini ve sonraki dönemlerde diğerlerinden daha iyi performans göstereceğini varsaymaktadır. Böylece genel eğilimi, portföy ağırlıklarını daha iyi performans gösteren varlıklardan daha düşük performans gösteren varlıklara taşımaktır.

- **Desen Eşleştirme (Pattern Matching)**

Wang ve arkadaşlarının yazmış oldukları makalede belirttiği gibi "kazananı ve kaybedeni takip etme yöntemleri market trendlerine dayandığından trend varsayıldığı gibi değilse eğer bu durum büyük kayıplara yol açabilir" (Wang, 2018, sayfa:1). Bununla birlikte desen eşleştirme metodu piyasadaki geçmiş ve o anki trendleri kıyasladığından diğer iki yönteme göre daha güvenilir sayılabilir. Korelasyon katsayısı ya da öklid uzaklığı kullanılarak hesaplanabilmektedir.

- **Meta Öğrenme (Meta Learning)**

Bu öğrenme türünde aynı strateji sınıfından veya farklı sınıflardan bir portföy oluşturulur ve gelecekteki döneme girdi oluşturacak vektörler elde edilir. Li'nin de çalışmasında açıkladığı üzere "meta-öğrenme yaklaşımı birçok algoritmayı bir araya getirebildiğinden daha geniş bir perspektif sağlamaktadır" (Li, 2013, sayfa:21).

Teknik Göstergeler

Geçmiş eğilimleri görmek ve gelecekteki hareketleri tahmin etmek için teknik göstergelerden yararlanılır. Hareketli ortalamalar, göreceli güç indeksi ve stokastik osilatörler teknik göstergelerden bazılarıdır. Piyasaya giriş, piyasadan çıkış ve alım-satım yönetimi kuralları dahil olmak üzere alım satım stratejileri, günlük kararları yönlendirmek için genellikle bir veya daha fazla gösterge kullanır. Stratejiler (ve bu stratejiler içinde kullanılan göstergeler) yatırımcının risk toleransına, deneyimine ve hedeflerine bağlı olarak değişecektir.

Teknik göstergeler, finans analistleri ve portföy yöneticileri tarafından ilgilendikleri varlıkların performansını ölçmek için kullanılır. Kısacası bir menkul kıymet veya sözleşmenin fiyatı, hacmi ve getirisi tarafından üretilen sezgisel veya model tabanlı sinyallerdir. Finansal alanda çok sayıda gösterge bulunmaktadır, ancak bu bölümde sadece aşağıdaki göstergelerden bahsedilecektir:

- **Ortalama Günlük Getiri**

Ortalama getiri, belirli bir süre boyunca üretilen bir dizi getirinin basit matematiksel ortalamasıdır. Ortalama bir getiri, herhangi bir sayı kümesi için basit bir ortalamanın hesaplandığı şekilde hesaplanır. Sayılar tek bir toplamda toplanır ve ardından toplam, kümedeki sayıların sayısına bölünür. Ortalama getiri, bir yatırımcıya veya analiste, bir hisse senedi veya menkul kıymetin getirilerinin geçmişte ne olduğunu veya bir şirket portföyünün getirilerinin hangi oranda olduğunu ifade eder. Ortalama getiri, bileşik getiri hesaplamasını göz ardı ettiği için yıllık getiri ile aynı değildir. Ortalama Günlük Getiriyi hesaplama formülü şu şekildedir:

$$\text{Average Return} = \frac{\text{Sum of Returns}}{\text{Number of Returns}}$$

- **Sharpe oranı**

Sharpe oranı, Nobel ödüllü William F.Sharpe tarafından geliştirilmiştir ve yatırımcıların riskine kıyasla bir yatırımın getirisini anlamalarına yardımcı olmak için kullanılır. Fernando'nun da web sitesinde belirttiği gibi "sharpe oranı, birim başına risksiz oranın üzerinde kazanılan ortalama getiridir" (Fernando, 2021).

Sharpe oranı, bir finansal portföyün riske göre ayarlanmış getirisinin ölçüsüdür. Daha yüksek sharpe oranına sahip bir portföy, benzerlerine göre daha kârlı kabul edilir. Risksiz oranı ortalama getiriden çıkarmak, bir yatırımcının risk alma faaliyetleriyle ilişkili kârları daha iyi izole etmesine olanak tanır. Risksiz getiri oranı, sıfır riskli bir yatırımın getirisi, yani yatırımcıların risk almamak için bekleyebilecekleri getiri olarak kabul edilir. Örneğin bir ABD Hazine bonosunun getirisi risksiz oran olarak kullanılabilir. Düşük ile negatif korelasyona sahip varlıklarla portföy çeşitlendirmesi yapmak, genel portföy riskini azaltmaya yardımcı olmaktadır ve sonuç olarak sharpe oranını arttırmaktadır. Genel olarak, sharpe oranının değeri ne kadar büyükse, riske göre ayarlanmış getiri o kadar caziptir.

Genellikle 1'den büyük bir sharpe oranı, yatırımcılar tarafından iyi olarak kabul edilir. 2'den yüksek bir oran çok iyi olarak derecelendirilir. 3 veya daha yüksek bir oran mükemmel kabul edilir. Bununla birlikte 1'in altındaki bir oran, optimalin altında bir değer olarak kabul edilir.

$$Sharpe\ ratio = \frac{\bar{r}_p - r_f}{\sigma_p}$$

$\bar{r}_p$ = expected return of the portfolio or investment

r_f = risk free rate

σ_p = standard deviation of portfolio returns

- **Göreceli Güç Endeksi (RSI)**

Göreceli güç endeksi, aşırı alım ve aşırı satım koşullarını belirleme girişiminde bir menkul kıymetin hızını ve fiyat hareketlerindeki değişikliği ölçmek için belirli bir süre boyunca yakın zamandaki kazançların büyüklüğünü yakın zamandaki kayıplarla karşılaştıran bir momentum göstergesidir. RSI değerleri 0-100 arasında değişir, 70'in üzerinde bir değer aşırı alım seviyelerini gösterdiği düşünülür ve 30'un altında bir değer aşırı satım seviyelerini gösterir.

Hisse senetleri aşırı alım ve aşırı satım koşullarını endekslerden daha sık gösterdiğinden, RSI endekslerin aksine bireysel hisse senetleri üzerindeki opsiyonlar için en iyi şekilde çalışır. Yüksek oranda likit, yüksek beta hisse senedi opsiyonları, RSI bazlı kısa vadeli alım satım için en iyi adayları oluşturur.

- **Bollinger Bantları**

Tüm yatırımcılar piyasada oynaklığın önemini farkında olarak işlem gerçekleştirir ve Bollinger bantları bu oynaklığı ölçmenin en bilindik yoludur. Bantlar, volatilité arttıkça genişler ve volatilité azaldıkça büzülür. Fiyat üst banda ne kadar yakın hareket ederse, finansal varlık o kadar fazla satın alınmış olabilir ve fiyat alt banda ne kadar yakın olursa, o kadar fazla satılmış demektir.

Bantların dışındaki bir fiyat hareketi, finansal varlığın fiyatının tersine çevrilmeye hazır olduğuna işaret edebilir ve varlık yatırımcıları kendilerini buna göre konumlandırabilirler. Örneğin, üst bandın üzerinde bir kopuştan sonra, yatırımcı uzun bir alım veya kısa bir alım pozisyonu başlatabilir. Tersine, alt bandın altındaki bir kırılma, uzun bir bekleyiş veya kısa satış stratejisi kullanma fırsatını temsil edebilir.

2.2. Kripto Paralar

Bir kripto para birimi, kriptografi ile güvence altına alınan dijital veya sanal bir para birimidir. Bu da sahteciliği veya çifte harcama yapmayı neredeyse imkânsız hale getirir. Birçok kripto para birimi, blok zinciri teknolojisine dayalı merkezi olmayan ağlardır yani farklı bir bilgisayar ağı tarafından uygulanan dağıtılmış bir dijital defterdir. Kripto para birimlerinin en belirgin özelliği, genellikle

herhangi bir merkezi otorite tarafından sağlanmamaları ve teorik olarak hükümet müdahalesine veya manipülasyonuna karşı bağımsızlıklarının olmasıdır.

Kripto para birimi, çok sayıda bilgisayara dağılmış bir ağa dayalı bir dijital varlık biçimidir. Bu merkeziyetçi olmayan yapı, hükümetlerin ve merkezi otoritelerin kontrolü dışında var olmalarına izin verir. "Kripto para" kelimesi, ağı güvenli hale getirmek için kullanılan şifreleme tekniklerinden türetilmiştir. İşlem verilerinin bütünlüğünü sağlamaya yönelik organizasyonel yöntemler olan blok zincirler, birçok kripto para biriminin önemli bir bileşenidir. Pek çok uzman, blockchain ve ilgili teknolojinin finans ve hukuk dahil birçok sektörü etkileyeceğine inanmaktadır. Kripto para birimleri, yasadışı faaliyetler için kullanımları, döviz kuru dalgalanmaları ve bunların altında yatan altyapının güvenlik açıkları dahil olmak üzere bir dizi nedenden ötürü eleştirilere maruz kalmaya devam etmektedir. Bununla birlikte, taşınabilirlikleri, bölünebilirlikleri, enflasyon direnci ve şeffaflıkları nedeniyle de çok rağbet görmektedirler.

İlk blok zinciri tabanlı kripto para birimi, hala en popüler ve en değerli olan BTC'dir. Bugün, çeşitli işlevlere ve özelliklere sahip binlerce alternatif kripto para birimi vardır. Bunlardan bazıları BTC'nin kopyaları veya türevleri iken diğerleri ise çeşitli blok zincir teknolojilerine dayalı olarak sıfırdan oluşturulmuş yeni para birimleridir.

BTC, 2009 yılında "Satoshi Nakamoto" takma adıyla bilinen bir kişi veya grup tarafından piyasaya sürüldü. 1 Mart 2021 itibarıyla, dolaşımda 18.6 milyondan fazla bitcoin vardır ve toplam piyasa değeri yaklaşık 927 milyar dolardır. BTC'nin etkisi ile ortaya çıkan ve "altcoin" olarak bilinen kripto para birimlerinden bazıları arasında Ethereum, Doge Coin, Binance Coin, Tron, Litecoin gibi yeni nesil paralar yer almaktadır. Bugün, var olan tüm kripto para birimlerinin toplam değeri 1,5 trilyon dolar civarındadır. BTC şu anda toplam piyasa değerinin % 60'ından fazlasına karşılık gelmektedir.

Kripto Para piyasalarında yatırımcılar için en büyük zorluklardan biri kâr etme güdüsü ile aldatmacaya kapılmamaktır. Dijital para birimleri, birçok bireysel ve kurumsal yatırımcının portföylerinde hızla öne çıkan bir yere yükselmiştir. Analistler yatırımcıları piyasanın değişken yapısı ve öngörülemezlikleri konusunda uarmaya devam etmektedir. Diğer yatırımlarda olduğu gibi kripto para piyasasına yatırım yapmaya karar verildi ise, herhangi bir işlem yapmadan önce araştırma yapılması önem arz etmektedir.



Şekil 2. BTC Market Hacmi

Kaynak: <https://coinmarketcap.com/currencies/bitcoin/>



Şekil 3. Ethereum Market Hacmi

Kaynak: <https://coinmarketcap.com/currencies/ethereum/>



Şekil 4. Chainlink Market Hacmi

Kaynak: <https://coinmarketcap.com/currencies/chainlink/>

Piyasa derinliğine göre kripto para fiyatları bazı borsalarda farklılık göstermektedir. Örnek olarak Coinmarketcap'ten edinilen aşağıdaki veri gösterilmektedir:

#	Source	Pairs	Price	+2% Depth	-2% Depth	Volume	Volume %	Confidence	Liquidity
1	Binance	BTC/USDT	\$57,921.15	\$12,352,761.65	\$30,100,481.38	\$4,319,185,025	6,63%	High	951
2	Huobi Global	BTC/USDT	\$57,907.83	\$15,319,942.28	\$12,901,420.22	\$1,765,746,644	2,71%	Moderate	938
3	Binance	DOGE/BTC	\$57,951.56	\$1,442,924.90	\$5,297,154.72	\$1,387,182,840	2,13%	High	777
4	Binance	ETH/BTC	\$57,951.56	\$10,548,965.17	\$4,652,008.24	\$1,070,993,970	1,64%	High	765
5	Coinbase Pro	BTC/USD	\$58,046.48	\$9,308,731.51	\$13,362,988.80	\$962,979,088	1,48%	High	829
6	Binance	BTC/BUSD	\$58,031.56	\$6,502,864.91	\$12,594,796.40	\$888,928,018	1,36%	High	867


Şekil 5. Farklı Piyasalara Göre Kripto Para Fiyatları

Kaynak: <https://coinmarketcap.com/currencies/bitcoin/>

Kripto para birimlerinin fiyatlarını tahmin etmek için nicel analiz araçları ve teknikleri eksikliği bulunmaktadır. Matematiksel analiz, belirli bir şirketin hisselerinin beklenen getirilerini veya tüm portföyün performansını değerlendirmek için finans endüstrisinde köklü bir yere sahiptir. Bununla birlikte, makine öğrenimi ve derin öğrenme yöntemleri, stok analiz tekniklerinin kripto para birimleri için geçerli olup olmadığını ve eğer öyleyse, nasıl değiştirilebileceğini doğrulamaktan yoksun sayılabilir. Yani, fiyat tahmini için temel olarak hangi özelliklerin kaldırılması veya eklenmesi gerektiği, mevcut makine öğrenmesi algoritmalarının ve derin öğrenmenin kripto para birimleri için uygun olup olmadığı ve hangi yaklaşımın en iyi sonuçları verdiği henüz net olarak bilinmemektedir. Bu tez çalışmasında, bu soruna çözüm olarak LSTM ve PÖ bileşimi ile çözüm bulunmaya çalışılmaktadır. Çalışmada öngörülen yaklaşım makine öğrenmesi ve derin öğrenme algoritmaları, gelecekteki fiyat hareketlerini tahmin etmek için kripto para birimi verilerine uygulanabilir. Bununla birlikte, fiyat değişiminin gerçek yönü ile algoritmaların tahmini arasında güçlü bir korelasyon göz önüne alındığında, matematiksel analizin yatırımcıların karar vermelerine önemli ölçüde yardımcı olabileceğini ve kripto para birimleri ticareti yaparak kâr etme şansını artırabileceği söylenebilir. Kripto para birimlerinin fiyatlarının nicel tahmini, tarihsel fiyat bilgilerine, güncel haberlere, duyarlılık analizine ve gerçek zamanlı verilere dayanarak yatırımcı adına işlem yapan bağımsız bir ajan oluşturmak için de kullanılabilir.

Kripto para birimlerinin piyasa fiyatıyla ilişkili yüksek volatilitesi nedeniyle, tahmin modelleri yatırımcıların yatırım kararlarını doğru bir şekilde tahmin etmesi için giderek daha önemli hale gelmiştir. Vaddi ve arkadaşlarının da araştırmalarında belirttiği gibi "birçok yatırımcının tahmin metriği olarak kullandığı tipik bir yaklaşım olan borsa yatırımı ile ilgili olarak fibonacci eğrileri kullanılmaktadır" (Vaddi, 2020, 6604). Bununla birlikte, bu tür tahmin modellerindeki problem, geçmiş değerleri izleme seviyelerinin statik olması ve sabit hesaplanan değerler ile analizler yapılmasıdır. Bununla birlikte, BTC gibi kripto para birimleri ile borsa arasında önemli farklılıklar vardır ve bu da makine öğrenmesi algoritmalarının klasik metotlardan farklılaşmasını gerekli kılmaktadır. BTC büyük borsaların çoğuna kıyasla çok daha küçük bir işlem hacmine sahiptir.

Volatilitesi yüksek olduğundan kripto para piyasaları daha yüksek performans potansiyeline sahiptir. Yeterince risk iştahına sahip olan yatırımcıların tercihi genelde kripto para piyasaları olmaya başlamıştır. Ayrıca daha düşük likiditeye sahip olan ve daha düşük hacme sahip olan piyasalarda kâr elde etmek daha kolaydır.



Şekil 6. BTC'nin Nisan 2013'ten 14 Nisan 2021'e kadar piyasa değeri (USD)

Kaynak: <https://www.statista.com/statistics/377382/bitcoin-market-capitalization/>

Statista.com verilerine göre Ocak 2021'de BTC piyasa değeri tüm zamanların en yüksek seviyesine ulaşmıştır ve yaz aylarına kıyasla 400 milyar ABD dolarının üzerinde büyümüştür. Piyasa değeri şu anda 600 milyar ABD dolarının üzerindedir. Piyasa değeri, dolaşımdaki toplam BTC sayısı ile BTC fiyatı çarpılarak hesaplanmıştır. BTC piyasa kapitalizasyonu, 2013'te yaklaşık bir milyar ABD dolarından, 2017'deki popüleritesindeki artıştan bu yana bu miktarın birkaç katına yükselmiştir.

2.3. Blok Zincir Teknolojisi (Blockchain)

Blok zincir teknolojisi mevcut finansal piyasa koşullarının tersine merkeziyetsiz bir yapı sunması ile gündeme gelmiştir. Dağıtık bir sistem olarak tasarlanmış ve şeffaflık prensibine göre hareket edilmektedir. Tedarik zinciri, sağlık, bankacılık, hukuk ve finans gibi çok çeşitli alanlarda kullanılmaktadır. Uçtan uca süreçlerin otomatikleştirilmesi ve işlemlerin güvenli bir ağda onaylanması sağlanmaktadır. Hassan ve arkadaşlarının çalışmalarında da belirttiği gibi (Hassan ve arkadaşları, 2020, sayfa:2) “SHA2 hash algoritması sayesinde blok zincirlerinin güvenli bir şekilde onaylanması sağlanmaktadır”.

3. DERİN ÖĞRENME VE DERİN PEKİŞTİRMELİ ÖĞRENME

3.1 Derin Öğrenme

DÖ, yapay zekâ alt kümesinde en etkili ve en hızlı büyüyen alanlardan biri haline gelmiştir. Derin öğrenme aynı zamanda genel olarak makine öğrenmesinin bir alt disiplindir, bu nedenle derin öğrenmeyi anlamak için öncelikle makine öğrenmesi kavramının bilinmesi faydalı olacaktır.

Makine öğrenmesi, sistemde açık olarak programlanmadan ve insan müdahalesine gerek duymadan deneyim yoluyla otomatik olarak öğrenme ve gelişme olanağı sağlayan bir yapay zekâ uygulamasıdır. Makine öğrenimi, verilere erişebilen ve kendileri için öğrenmek adına bu verileri kullanabilen bilgisayar programlarının geliştirilmesine odaklanır. Birçok farklı makine öğrenimi algoritması vardır, ancak en yaygın kullanılan algoritmalarından biri çok katmanlı bir algılayıcıdır (multilayer perceptron). Çok katmanlı bir algılayıcı aynı zamanda sinir ağı olarak da adlandırılır ve birbirine bağlı bir dizi düğüm / nörondan oluşur. Çok katmanlı bir yapıda üç farklı katman vardır: giriş katmanı, gizli katman ve çıktı katmanı. Giriş katmanı, verileri ağıya götürür ve burada orta/gizli katmandaki düğümler tarafından işlenir.

Gizli katmandaki düğümler, giriş katmanından gelen verileri işleyebilen ve giriş verilerinden ilgili desenleri ayıklayan matematiksel işlevlerdir. Sinir ağı bu şekilde öğrenme denilen durumu gerçekleştirir. Sinir ağları isimlerini insan beyninin yapısından ve işlevinden ilham almaktadır. Ayrıca insan beyninin verileri nasıl anlamlandırdığı da yine derin öğrenme metotlarıyla artık anlaşılır hale gelmiştir. Örneğin Güçlü'nün akademik çalışmasında da değindiği gibi "RNN'ler insan beyninin sensör verilerini nasıl işlediğine dair tahminde bulunabilirler" (Güçlü, 2016, sayfa:15).

Sinir Ağındaki düğümler arasındaki bağlantıların ağırlık (weight) değerleri bulunmaktadır. Bu değerler, temel olarak bir katmandaki verilerin bir sonraki katmandaki verilerle nasıl ilişkili olduğuna ilişkin varsayımlardır. Ağda eğitim gerçekleştikçe ağırlıklar ayarlanır ve veri için amaçlanan değerler elde edilmiş olur. Aktivasyon fonksiyonları ağındaki düğümlerinde bulunur ve bu fonksiyonlar verileri doğrusal olmayan bir şekilde dönüştürerek sinir ağının verilerin karmaşık gösterimlerini öğrenmesini sağlar. Aktivasyon fonksiyonları giriş değerlerini ağırlık değerleriyle çarpar ve bir sapma terimi (bias term) ekler.

DÖ, birçok çok katmanlı algılayıcıyı bir araya getirmektedir, böylece sadece bir gizli katman değil, birçok gizli katman bulundurulur. Derin sinir ağı ne kadar derin olursa, ağ o kadar karmaşık kalıplar öğrenebilir ve iyi sonuçlar elde edilebilir. Nöronlardan oluşan derin katman ağları bazen tam bağlantılı ağlar (fully connected layers -FCL) veya tam bağlı katmanlar olarak adlandırılmaktadır. FCL'da, belirli

bir nöron, etrafındaki tüm nöronlarla sürekli bir bağlantı kurmaktadır . Tamamen bağlı ağlar, farklı derin öğrenme mimarileri oluşturmak için diğer makine öğrenimi işlevleriyle birleştirilebilirler.

Farklı özelliklere sahip çeşitli derin öğrenme mimarileri bulunmaktadır. CNN, RNN/LSTM, Otomatik Kodlayıcılar (Autoencoders) ve Üretken Düşman Ağları (Generative Adversarial Networks) bilinen yöntemlerdir.


Evrişimsel Sinir Ağları veya CNN'ler, bilgisayar görüş sistemlerinin oluşturulmasında yaygın olarak kullanılan sinir ağı mimarisidir. CNN ağlarının yapısı, görüntü verilerini yorumlamalarını sağlar ve bunları tam bağlı bir ağı yorumlayabilir olduğu sayılara dönüştürür. Bir CNN'in dört ana bileşeni vardır: evrişimsel katman, alt örnekleme/havuzlama katmanı, aktivasyon fonksiyonu, tam bağlantılı katmanlar. Evrişimsel katmanlar, görüntüleri ağı giriş olarak alan, görüntüleri analiz eden ve piksellerin değerlerini alan katmandır. Alt örnekleme veya havuzlama, görüntülerin gösterimini basitleştirmek ve görüntü filtrelerinin gürültüye duyarlılığını azaltmak için görüntü değerlerinin dönüştürüldüğü/azaltıldığı yerdir. Aktivasyon fonksiyonu, verilerin bir katmandan bir sonraki katmana nasıl aktığını denetler ve tam olarak bağlantılı katmanlar, görüntüyü temsil eden değerleri analiz eden ve bu değerlerde tutulan desenleri öğrenen katmandır.

Tekrarlayan Sinir Ağları veya RNN'ler, verilerin sırasının önemli olduğu, ağı bir veri dizisi hakkında bilgi edinmesi gereken görevler için önem arz ederler. RNN'ler genellikle doğal dil işleme gibi konularda uygulanır, çünkü bir cümlemin anlamını çözerken kelimelerin sırası önemlidir. Tekrarlayan Sinir Ağları teriminin tekrarlayan bölümü, belirli bir ögenin çıktısının önceki hesaplamaya ve geçerli hesaplamaya bağlı olarak bir dizideki çıktısından gelir. Diğer derin sinir ağlarının formlarının aksine, RNN'lerin hafızaları vardır ve dizideki farklı zaman adımlarında hesaplanan bilgiler son değerleri hesaplamak için kullanılır. Bir ögenin değerini hesaplarken önceki ögelere ek olarak, sıradaki gelecekteki ögeleri dikkate alan çift yönlü RNN'ler de dahil olmak üzere birden çok RNN türü vardır. Başka bir RNN türü de tez çalışmasına konu olan Uzun Kısa Süreli Bellek veya LSTM ağıdır. LSTM'ler, uzun veri zincirlerini işleyebilen RNN türleridir. Li ve arkadaşlarının da araştırmalarında söz ettikleri gibi "normal RNN'ler patlayan gradyan sorunu adı verilen yani gradyanların kullanılamaz hale gelmesine neden olan bir problemle karşı karşıya kalabilmektedirler" (Li, 2018, sayfa:2). Bu sorun, giriş verileri zinciri uzun olduğunda oluşmaktadır, ancak LSTM'lerin kullanımı bu probleme bir çözüm olabilmektedir.


Otomatik Kodlayıcılar (Autoencoders), ham verilerin sıkıştırılmış bir gösterimini öğrenmek için kullanılabilecek bir sinir ağı türüdür. Arden'in de websitesinde bildirdiği gibi "otomatik kodlayıcı, kodlayıcı ve kod çözücü alt modellerinden oluşmaktadır" (Dertat, 2017). Kodlayıcı girişi sıkıştırır ve kod çözücü, kodlayıcı tarafından sağlanan sıkıştırılmış sürümden girişi yeniden oluşturmayı dener.

Eğitimden sonra kodlayıcı modeli kaydedilir ve kod çözücü atılır. Kodlayıcı daha sonra farklı bir makine öğrenimi modelini eğitmek için kullanılabilecek ham verilerde özellik ayıklama (feature extraction) gerçekleştirmek için bir veri hazırlama tekniği olarak kullanılabilir. Otomatik kodlayıcılar denetimsiz verileri denetimli bir biçime dönüştürerek sinir ağlarının sorunda kullanılmasına izin verir. Otomatik kodlayıcılar, veri kümelerindeki anormallikleri algılamak için sıklıkla kullanılır. Bu tür anormallik algılama örnekleri arasında finansal kurumlar için sahtekârlık tespiti örnek verilebilir. Bu bağlamda, bir otomatik kodlayıcının amacı, verilerdeki normal desenlerin bir taban çizgisini belirlemek ve anomalileri veya aykırı değerleri tanımlamaktır. Otomatik kodlayıcının yapısı genellikle simetriktir, gizli katmanlar ağın çıktısının girişe benzeyecek şekilde dizilir. Sıklıkla kullanılan dört tür otoenkoder şunlardır: Normal/düz otoenkoderler, çok katmanlı kodlayıcılar, evrimsel kodlayıcılar ve düzenli kodlayıcılardır. Düzenli/düz otoenkoderler tek bir gizli katmana sahip sinir ağlarıdır, çok katmanlı otoenkoderler ise birden fazla gizli katmana sahip derin ağlardır.

Üretken Düşman Ağları (GAN' ler) aslında tek bir ağ yerine birden fazla derin sinir ağından oluşur. Gan'de, iki derin öğrenme modeli aynı anda eğitilir ve çıktıları diğer ağa beslenir. Ağlar birbirleriyle rekabet halindedir ve birbirlerinin çıktı verilerine erişebildiklerinden hem bu verilerden öğrenirler hem de kendilerini geliştirirler. GAN'ler bilgisayarla görme alanında popüler hale gelmiştir.



Şekil 7. Derin Öğrenme mimarisi




Şekil 8. Makine Öğrenmesi şeması

3.1.1. Sinir Ağları (Neural Networks)

Sinir ağları (Neural Networks) yapay olarak Sinir ağının doğasını ve işlevini taklit ederler ve Yapay Sinir ağları (YSA) olarak da adlandırılır. YSA'lar, belirli problemleri çözmek için birlikte çalışan çok sayıda birbiriyle bağlantılı işleme unsurlarından (nöronlar) oluşur. YSA'lar, tıpkı insanlar gibi, çocuklar gibi, hatta örnek yoluyla da öğrenirler. YSA'lar bir öğrenme süreci aracılığıyla, örüntü tanıma

veya veri sınıflandırma, görüntü tanıma, ses tanıma gibi belirli bir uygulama için konfigüre edilip kullanılabilirler.

Sinir ağları, karmaşık veya kesin olmayan verilerden anlam çıkarma konusundaki olağanüstü yetenekleriyle, kalıpları çıkarmak ve insanlar veya diğer bilgisayar teknikleri tarafından fark edilemeyecek kadar karmaşık olan eğilimleri tespit etmek için kullanılabilir. Eğitilmiş bir sinir ağı, analiz etmesi için verilen bilgi kategorisinde bir uzman olarak düşünülebilir. Bu uzman daha sonra yeni ilgi durumlarında öngörüler sağlamak ve eğer öyleyse sorularını yanıtlamak için kullanılabilir. Uyarlanabilir öğrenme özellikleri ile eğitim veya ilk deneyim için verilen verilere dayalı olarak görevlerin nasıl yapılacağını öğrenme yeteneğine sahiptirler. Kendi kendine organizasyon yoluyla bir YSA kendi organizasyonunu veya öğrenme süresi boyunca aldığı bilginin temsili oluşturabilir. Bir sinir ağındaki temel hesaplama birimi, genellikle düğüm veya birim olarak adlandırılan nörondur. Diğer bazı düğümlerden veya harici bir kaynaktan girdi alır ve bir çıktıyı hesaplar. Her girişin, diğer girişlere göreceli önemini temsilen bir ağırlığı (weight) vardır.



Şekil 9. Bir Sinir Ağına Matematiksel İfadesi

Kaynak: <https://purnasaigudikandula.medium.com/a-beginner-intro-to-neural-networks-543267bda3c8>

Büyük finans kurumları, tahvil derecelendirme, kredi puanlama, hedef pazarlama ve kredi başvurularını değerlendirme gibi alanlarda performansı artırmak için YSA'ları kullanmaktadır. YSA'lar artık olası dolandırıcılık durumlarını tespit etmek için kredi kartı işlemlerini analiz etmek için de kullanılmaktadır.

Gudikandula'nın da belirttiği gibi "YSA'lar başka tür suçları keşfetmek için de kullanılabilir" (Gudikandula, 2019). Birçok ABD havalimanındaki bomba dedektörleri, patlayıcı kimyasalların varlığını algılamak için havadaki iz elementleri analiz etmek için YSA kullanır. Chicago Polis Departmanının personel ofisi, polis memurları arasındaki yolsuzluğu ortadan kaldırmaya çalışmak için YSA'ları kullanmaktadır.

3.1.2. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, ağırlıklı toplamı hesaplayarak ve buna daha fazla önyargı (bias) ekleyerek bir nöronun aktive edilip edilmeyeceğine karar vermektedir. Aktivasyon fonksiyonunun amacı, bir nöronun çıktısına doğrusal olmama durumu katmaktır. Aktivasyon fonksiyonu olmayan bir sinir ağı yapısı, aslında sadece doğrusal bir regresyon modelidir ve sinir ağları doğrusal bir fonksiyon ile etkili bir öğrenme işlemi gerçekleştirememektedir. Aktivasyon fonksiyonu, girdiye doğrusal olmayan dönüşümü gerçekleştirerek daha karmaşık görevleri öğrenip gerçekleştirmesini sağlar. Aktivasyon fonksiyonu türleri;

Doğrusal Fonksiyon: Sadece çıkış katmanında kullanılır. $Y = ax$ şeklinde doğrusal bir ifadedir. Sinir ağlarına beslenen olağan verilerin karmaşıklığına veya çeşitli parametrelerine yardımcı olması güçtür. **Doğrusal Olmayan Fonksiyon:** Doğrusal Olmayan Aktivasyon fonksiyonu en çok kullanılan aktivasyon fonksiyonu türleridir. Modelin genelleştirmesini veya çeşitli verilerle uyum sağlamasını ve çıktılar arasında ayırım yapmasını kolaylaştırır. Doğrusal Olmayan Aktivasyon Fonksiyonları, aralıklarına veya eğrilerine göre ayrışmaktadır:

Sigmoid/Lojistik Fonksiyon: Sigmoid fonksiyonunun kullanmasının ana nedeni, değerinin (0 ile 1) arasında olmasıdır. Bu nedenle, özellikle olasılığın bir çıktı olarak tahmin edilmesi gereken modeller için kullanılır. Herhangi bir şeyin olasılığı yalnızca 0 ile 1 aralığı arasında olduğundan, sigmoid doğru bir seçimdir.

Bunlarla birlikte, lojistik sigmoid fonksiyonu, eğitim sırasında bir sinir ağının takılıp kalmasına neden olabilir. Softmax fonksiyonu, çok sınıflı sınıflandırma için kullanılan daha genelleştirilmiş bir lojistik aktivasyon fonksiyonudur. Tez çalışmasında çıkış katmanına softmax aktivasyon fonksiyonu uygulanmaktadır.

Tanh veya hyperbolic tanjant fonksiyonu: tanh aynı zamanda lojistik sigmoid fonksiyonu gibidir; ancak daha iyi sonuçlar sağlar. Tanh fonksiyonunun aralığı (-1 ile 1) arasındadır ve tanh ayrıca sigmoidaldır (s şeklindedir). Avantajı, negatif girişlerin güçlü bir şekilde negatif olarak eşleneceği ve sıfır girişlerinin tanh grafiğinde sıfıra yakın bir şekilde eşleneceğidir.

Doğrultulmuş Doğrusal Birim (Rectified Linear Unit-ReLU) Fonksiyon: ReLU şu anda dünyada en çok kullanılan aktivasyon fonksiyonudur ve kullanımına başlandığından itibaren neredeyse tüm evrişimli sinir ağlarında veya derin öğrenmede kullanılmaktadır. ReLU'nun dezavantajı, tüm negatif değerlerin anında sıfırlanması ve bunun sonucunda modelin verilere uygun şekilde uyması veya eğitilmesi yeteneğinin azalmasına neden olmaktadır. Tez çalışmasında giriş katmanında ReLU aktivasyon fonksiyonu kullanılmaktadır.

Sonuç olarak Bircanoğlu'nun da farklı veri kümelerinde test ettiği ve 11 adet aktivasyon fonksiyonunu ele aldığı çalışmasında (Bircanoğlu, 2018, sayfa:3) sigmoid türde aktivasyon fonksiyonun diğerlerine kıyasla çok daha iyi sonuç verdiği kanıtlanmıştır.

Tablo 3: Aktivasyon Fonksiyonları Matematiksel Gösterimleri

Fonksiyon İsmi	Denklemler f(x)
Doğrusal (Linear)	x (1)
Sigmoid [11]	$\frac{\exp(x)}{1 + \exp(x)}$ (2)
Hiperbolik Tanjant [12]	$\frac{2}{1 + \exp(-2x)} - 1$ (3)
Hard Sigmoid	$\max(0, \min(1, \frac{x+1}{2}))$ (4)
Softsign [13]	$\frac{x}{1 + x }$ (5)
ReLU (Rectified linear unit) [14]	$\begin{cases} x & \text{if } x > 0 \\ 0 & \text{if } x \leq 0 \end{cases}$ (6)
Softplus [5]	$\ln(1 + \exp(x))$ (7)
ELU (Exponential Linear Unit) [8]	$\begin{cases} \alpha(\exp(x) - 1) & \text{if } x > 0 \\ x & \text{if } x \leq 0 \end{cases}$ (8)
SeLU (Scaled Exponential Linear Unit) [15]	$\begin{cases} \lambda x & \text{if } x > 0 \\ \lambda(\alpha \exp(x) - \alpha) & \text{if } x \leq 0 \end{cases}$ (9)
Swish [16]	$x \text{sigmoid}(x)$ (10)
Kare	x^2 (11)

Kaynak:https://www.researchgate.net/publication/326280782_A_comparison_of_activation_functions_in_artificial_neural_networks

3.1.3. Geribesleme (Backpropagation)

Geriye besleme, sinir ağı eğitiminin özünü oluşturmaktadır. Bir sinir ağının ağırlıklarının, önceki dönemde elde edilen hata oranına (yani yineleme) dayalı olarak ince ayarlanması yöntemidir. Ağırlıkların doğru şekilde ayarlanması, hata oranlarının azaltılmasına ve genelleştirmesini artırarak modelin güvenilir hale getirilmesine olanak tanır.

Geri besleme, hataların geriye doğru yayılmasının için kısa bir yoldur. Yapay sinir ağlarını eğitmek için standart bir yöntemdir. Bu yöntem, ağıdaki tüm ağırlıklara göre bir kayıp fonksiyonunun gradyanının hesaplanmasına yardımcı olur.

3.1.4. Derin Öğrenme Mimarisi

DÖ mimarisi farklı topolojilerden yani derin / sinir ağlarından oluşmaktadır. Genel ilke, sinir ağlarının verileri ilerleten birkaç katmana dayanmasıdır. Giriş katmanı (ham veriler), gizli katmanlar (giriş verilerini işler ve birleştirirler) ve bir de çıktı katmanı (sonucu üretir: sonuç, tahmin vb.) bulunmaktadır. Tez çalışmasına konu olan LSTM tabanlı modelde bir giriş, bir çıkış ve üç adet de gizli katman bulunmaktadır.

3.1.5. Eğitim (Training)

DÖ sinir ağları, girdilerden çıktılara kadar bir haritalama işlevi ile öğrenmeyi gerçekleştirir. Bu, modelin eğitim veri setinde yaptığı hatalara yanıt olarak ağırlıklarının güncellenmesiyle elde edilir. Yeterince iyi bir model elde edilene veya öğrenme süreci durana kadar bu hatayı sürekli olarak azaltmak için güncellemeler yapılır.

Sinir ağlarını eğitme süreci, genel olarak tekniği kullanmanın en zor kısmıdır ve hem süreci yapılandırmak için gereken çaba hem de süreci yürütmek için gereken hesaplama karmaşıklığı açısından en çok zaman alan bölümdür.

3.1.6. En İyileştiriciler (Optimizers)

İyileştiriciler, kayıpları azaltmak için sinir ağınızın ağırlık ve öğrenme hızı gibi özelliklerini değiştirmek için kullanılan algoritmalar veya yöntemlerdir.

Kayıpları azaltmak için sinir ağının ağırlıklarının veya öğrenmenin oranlarının nasıl değiştirileceğini kullanan en iyileştiriciler tarafından belirlenir. Kayıpları azaltmak ve mümkün olan en doğru sonuçları sağlamaktan optimizasyon algoritmaları veya stratejileri sorumludur. İyileştiricilerden bazıları:

- **Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation-ADAM)**

Tez çalışmasında kullanılan yöntem olan Adam, geçmiş gradyan değerlerinin katlanarak azalan ortalamasını hafızasında tutmaktadır. Hata yüzeyinde düz minimum değerleri tercih etmekte ve öğrenme oranının sıçramalar yapmasını engellemektedir. Adam yöntemi, hız açısından ve öğrenme oranını düzenlemesi açısından son derece kullanışlıdır. En iyi en iyileştirici olduğu söylenebilir.

- **Gradyan İniş (Gradient Descent)**

En temel ancak en çok kullanılan optimizasyon algoritmasıdır. Doğrusal regresyon ve sınıflandırma algoritmalarında yoğun olarak kullanılır. Sinir ağlarında geri yayılım ayrıca bir gradyan iniş algoritması kullanır. Bu yöntemde hızlı hesaplama, hızlı implementasyon gibi avantajlarla birlikte yüksek hafıza gerektirmesi gibi dezavantajı da bulunmaktadır.

- **RMSprop**

RMSprop, sinir ağlarının eğitiminde kullanılan gradyan tabanlı bir optimizasyon tekniğidir. Sinir ağları gibi çok karmaşık işlevlerin gradyanları, veriler işlev boyunca yayılırken kaybolma ya da patlama eğilimindedir (kaybolan gradyan sorunu). Rmsprop, mini toplu öğrenme için stokastik bir teknik olarak geliştirilmiştir.

3.2 Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning-DPÖ)

3.2.1. Genel Bilgi

Günümüzde yapay zekânın en ilgi çekici alanlarından biri haline gelmiş olan DPÖ kavramı, makinelerin kendi eylemlerinin sonuçlarına göre kendi kendilerine öğretebilecekleri bir sisteme karşılık gelmektedir.

DPÖ, akıllı makinelerin, insanların deneyimlerden öğrendiklerine benzer şekilde kendi eylemlerinden öğrenebildikleri bir makine öğrenmesi ve yapay zekâ alt kümesidir. Bir ajanın (agent) eylemlerine göre ödüllendirilmesi veya cezalandırılması sistemine dayanmaktadır. Ajanı hedef sonuca

götüren eylemler ödüllendirilir yani pekiştirilir. Deneme yanılma yoluyla, makine ya da algoritma öğrenmeye devam eder ve sürekli değişen dinamik ortamlar için ideal aksiyon kümesini elde etmeye çalışır. PÖ uzun süredir bilinmesine rağmen, ancak yakın zamanda derin öğrenme ile birleştirilerek ikisinin sentezi olan çalışmalara başlanmıştır.


DPÖ, gözetimli öğrenme ve gözetimsiz öğrenmenin ötesinde karmaşık problemleri çözebilmektedir. Bunun sonucunda kendine farklı uygulama alanları bularak robotik, sağlık hizmetleri, akıllı sistemler, sosyal medya, finans ve daha birçok alanda kullanımı artmıştır. Pekiştirmeli öğrenmenin derin kısmı, bir insan beyninin yapısını kopyalayan çok sayıda (derin) yapay sinir ağı katmanını ifade eder. Derin öğrenme, büyük miktarda eğitim verisi ve önemli hesaplama gücü gerektirir. Son birkaç yılda, veri hacimlerinde tabiri yerinde ise patlama görülürken, bilgi işlem gücü maliyetleri önemli ölçüde azalmış ve bu da derin öğrenme uygulamalarının yaygınlaşmasını mümkün kılmıştır.

Bu sentez öğrenme yönteminde PÖ'nin amacı, herhangi bir durum için en iyi bilinen eylemi seçmektir; bu durum eylemlerin sıralanması ve birbirine göre değerler atanması gerektiği anlamına gelir. Bu eylemler duruma bağlı olduğundan gerçekte ölçülen şey durum eylem çiftlerinin değeridir. PÖ, çok sayıda durum-eylem çiftiyle ilişkili olarak ödüllerin karmaşık bir olasılık dağılımını modellemektedir. PÖ'nin MDP eşleştirilmesinin nedeni karmaşık bir dağılımdan özelliklerini çıkarmak için örnekleme yöntemi sunmasıdır. MDP sürecinde, durum (state) temel durum uzayını, aksiyon(action) eylemlerin kümesini, maliyet (cost) veya anlık ödül (immediate reward) fonksiyonunu ifade eder. Amaç, toplam (beklenen) maliyetleri en aza indirmek veya eşdeğer olarak, toplam (beklenen) ödülleri maksimize etmektir. Edelkamp'ın kitabında belirttiği gibi "MDP'ler, sınırlı sayıda durum ve eylemi varsayar. Ajan her seferinde bir durumu gözlemler ve minimuma indirilmesi gereken (veya ters senaryoda maksimize edilecek ödülleri) ortaya çıkan bir eylemi yürütür. Maliyet ve tersi durumu yalnızca mevcut duruma ve seçilen eyleme bağlıdır." (Edelkamp, 2012, 35)

DPÖ'nin diğer bileşeni olan sinir ağları, durum alanı veya eylem alanı tamamen bilinemeyecek kadar büyük olduğunda pekiştirmeli öğrenmede fonksiyon tahmin edicileridir.

Bir sinir ağı, bir değer fonksiyonu veya bir politika fonksiyonuna yaklaşmak için kullanılabilir. Yani, sinir ağları olası tüm durumları ve değerlerini depolamak, indekslemek ve güncellemek için bir arama tablosu kullanmak yerine, durumları değerlere veya durum-eylem çiftlerini Q değerlerine eşlemeyi öğrenebilir. PÖ'deki asıl hedef olarak bunların göreceli olarak ne kadar değerli olduğunu tahmin etmeyi öğrenmek için durumdan veya eylem alanından alınan örnekler üzerinde bir sinir ağı eğitilebilir. Tüm sinir ağları gibi, girdileri çıktılarla ilişkilendiren fonksiyonu yaklaşık olarak belirlemek için katsayıları kullanırlar ve öğrenmeleri, daha az hata vaat eden gradyanlar boyunca bu ağırlıkları yinelemeli olarak ayarlayarak doğru katsayıları veya ağırlıkları bulmayı içerir.

PÖ'de, evrişimli ağlar, girdi görsel olduğunda bir ajanın durumunu tanımak için kullanılabilir. Yani, tipik görüntü tanıma görevlerini yerine getirirler. PÖ'nin başlangıcında, sinir ağı katsayıları stokastik veya rastgele olarak başlatılabilir. Çevreden gelen geri bildirimi kullanarak sinir ağı, beklenen ödül ile yer gerçeği (ground truth) ödül arasındaki farkı, ağırlıklarını ayarlamak ve durum-eylem çiftlerini yorumlamasını iyileştirmek için kullanılabilir.



Şekil 10. Pekiştirmeli Öğrenmeyi Anlatan MDP Süreci

MDP'de yer alan ve PÖ'de kullanılan temel kavramlar aşağıdaki gibidir:

3.2.1.2. Durum (State)

Durum (S): Durum, ajanın kendini içinde bulduğu somut ve anlık bir haldir; yani belirli bir yer ve an, ajanı araçlar, engeller, düşmanlar veya ödüller gibi diğer önemli şeylerle ilişkilendiren anlık bir konfigürasyondur. Çevrenin getirdiği mevcut durum veya gelecekteki herhangi bir durum olabilir. Tez kapsamında tasarlanan durum varlık fiyatlarıdır.

3.2.1.3. Politika Fonksiyonu (Policy Function)

Politika (π): ajanın mevcut duruma göre bir sonraki eylemi belirlemek için kullandığı stratejidir. Durumları en yüksek ödülü vaat eden eylemlerle eşleştirir ($S \rightarrow A$). Tez kapsamında tasarlanan politika algoritmanın öğrendiği alım-satım stratejisidir.

3.2.1.4. Ödül ve Getiri (Reward and Return)

Ödül (R): belirli bir durumda bir ajanın eylemlerinin başarısının veya başarısızlığının ölçüldüğü geri bildirimdir. Ödüller anında veya gecikmeli olabilir. Ajanın eylemini etkili bir şekilde değerlendirirler. Tez kapsamında tasarlanan ödül fonksiyonu portföydeki değişim değeridir.

Portföy getirisi, çeşitli yatırım türlerini içeren bir yatırım portföyü tarafından gerçekleştirilen kazanç veya zararı ifade eder. Çalışma kapsamındaki getiri toplam portföy değerine karşılık gelmektedir.

3.2.1.5. Aksiyon (Action)

Ajanın ayrı, olası eylemler listesinden seçim yaparak aksiyon almasıdır. Hisse senedi piyasalarında liste, bir dizi menkul kıymet ve türevlerinden herhangi birinin satın alınmasını, satılmasını veya elde tutulmasını içerebilir. Çalışmada yer alan aksiyonlar portföy ağırlık değerleridir.

3.2.1.6. Değer Fonksiyonu (Value Function)


Belirli bir politikaya göre hareket edilmesi sonucunda elde edilmesi beklenen getiri değeridir. Çalışmada değer fonksiyonu olarak beklenen getirinin maksimize edilmesi belirtilebilir.

3.2.1.7. Aktör ve Kritik Metodu

Politika yapısı aktör olarak ifade edilir, çünkü eylemleri seçmek için kullanılır ve tahmin edilen değer fonksiyonu, aktör tarafından yapılan eylemleri eleştirdiği için kritik olarak bilinir. Öğrenme her zaman politikaya bağlıdır: kritik, aktör tarafından hali hazırda izlenen politika hakkında bilgi edinerek onu eleştirir. Bu yöntem aktör-kritik yaklaşımı adı verilir.

3.2.2. Pekiştirmeli Öğrenme Algoritmaları

PÖ algoritmalarının sınıflandırılması akademik çalışmalar için genel bir bakış açısı sunmaktadır. Model tabanlı ve model tabanlı olmayan, değere dayalı ve politikaya dayalı yöntemler (veya ikisinin kombinasyonu), Monte Carlo yöntemleri ve zamansal fark yöntemleri, politika içi ve politika dışı yöntemler vb şeklinde sınıflandırılabilir. Zhang'e ait olan PÖ algoritmalarının ağaç olarak gösterimi (Zhang, 2020, 126) aşağıda verilmiştir:



Şekil 11. PÖ Algoritmalarının Sınıflandırılması

Kaynak: https://link.springer.com/chapter/10.1007/978-981-15-4095-0_3

En çok kullanılan metotlar olarak bu kısımda sadece model tabanlı ve model tabanlı olmayan PÖ yöntemleri açıklanmıştır:

3.2.2.1. Model Tabanlı vs Model Tabanlı Olmayan Pekiştirmeli Öğrenme

Model tabanlı olmayan PÖ'de model göz ardı edilir. Ödülleri tahmin etmek için örnekleme ve simülasyona bağlı kalınır, bu nedenle sistemin iç işleyişini bilmeye gerek kalmaz. Model tabanlı PÖ'de, bir maliyet fonksiyonu tanımlanabilirse, modeli doğrudan kullanarak optimum eylemler hesaplanabilir.

3.2.2.1.1. Model Tabanlı PÖ

Model tabanlı algoritmalar, ajanın ileriye düşünerek, bir dizi olası seçenek için ne olacağını görerek ve seçenekleri arasında açıkça karar vererek plan yapmasına olanak tanır. Ajanlar daha sonra sonuçları önceden planlamadan öğrenilmiş bir politikaya dönüştürebilir. Bu yaklaşımın özellikle ünlü bir örneği AlphaZero'dur. Başlıca dezavantajı, ortamın kesinlik modelinin genellikle ajan için mevcut olmamasıdır. Bir ajan bu durumda bir model kullanmak isterse, modeli tamamen deneyimden öğrenmesi

gerekir ki bu da çeşitli zorluklar yaratır. En büyük zorluk, modeldeki önyargının (bias) ajan tarafından kötüye kullanılabilmesidir, bu da öğrenilen modele göre iyi performans gösteren ancak gerçek ortamda yetersiz davranan bir ajan ve model ile sonuçlanır.


3.2.2.1.1. Model Tabanlı Olmayan PÖ

Ortamın bir modelini kullanmayan algoritmalara Model tabanlı olmayan PÖ yöntemleri adı verilmektedir. Bu algoritmalar, bir ajanın çevre ile nasıl etkileşimde bulunduğunu yöneten temel dinamikleri öğrenmek için çaba sarf etmez. Model, daha kolay uygulanabilmesi ve ayarlanması için bir modelin kullanılmasının örnek verimliliğindeki potansiyel kazanımlardan vazgeçer. Modelden bağımsız algoritmalar, politika yinelemesi veya değer yinelemesi gibi algoritmalar aracılığıyla en uygun politikayı veya değer fonksiyonunu doğrudan tahmin eder. Bu, hesaplama açısından çok daha verimlidir.



4. KRİPTO PARA PORTFÖY YÖNETİMİ İÇİN LSTM TABANLI PEKİŞTİRMELİ ÖĞRENME YÖNTEMİNİN GELİŞTİRİLMESİ

LSTM, uzun süreli bağımlılıkları öğrenebilen özel bir RNN türüdür. Eski zamandan beri farklı problemlerin çözümünde kullanılmaktaydı. Son yıllarda PÖ problemlerinde de kullanılır hale gelmiştir. Tez çalışmasında en az iki yıllık veri setleri kullanıldığından LSTM'in de veriler arasındaki uzun vadeli bağımlılıkları öğrenebilmesinden yola çıkılarak bu yöntem kripto para portföy yönetimi için tercih edilmiştir. LSTM'e ait örnek mimari çizimi aşağıda yer almaktadır:



Şekil 12. LSTM Mimarisi

Portföy yönetimi gerçekleştirecek olan algoritma ve verilerin oluşturulması süreci aşağıda özetlenmiştir:

4.1. Veri Hazırlık Süreci

Portföy yönetimini için kullanılacak veriler Coinmarketcap ortamından SQL ile alınmıştır. ETH, XRP, LTC, XMR, TRX, ETC, STR, AVA, DASH, ZEC paralarının BTC cinsinden karşılığı olan

hacim verileri ile günlük en yüksek, en düşük ve kapanış fiyatı verileri 01.01.2019 - 01.01.2021 tarihleri için alınmıştır. Örneklem kümesi sayısı toplamda 17.569 adettir. Gün olarak verilerin karşılıkları:

Elde edilen veriler toplam gün: 730 gün

Eğitim günleri: 671 gün (%92)

Test Günleri: 59 gün (%8)

Backtest Günleri: 59 gün (%8)

Fiyat verisi olmayan günler için bir önceki günün en yakın fiyatı kullanılmıştır. Alım-satım işlemine başlarken bir BTC başlangıç varlık değeri olarak alınmıştır. Alım satım komisyon oranı olarak % 0,25 kullanılmıştır.

Tablo ve grafiklerde yer alan bazı kavramların karşılıkları şu şekildedir:

80K Adım Sayısı = 80.000 epoch a karşılık gelmektedir.

Test ve eğitim için örneklem kümesi oluşturulmuştur. %8 test %92 si eğitim olmak üzere bölünmüştür. Daha sonraki aşamalarda belirlenen test ve training kümeleri network ü eğitmek ve performansını ölçmek için kullanılmıştır. Giriş, çıkış ve portföy ağırlık değerleri ile ilgili kullanılan veriler aşağıdaki gibidir:

Girdi (Input) = number of test/train samples x number of features (close, high, low) x number of coins x window size $[1374 \times 3 \times 11 \times 31]$, $1374 = 17.569 \times \%8$

Çıktı(Output) = number of test/train samples x number of features (close, high, low) x number of coins $[1374 \times 3 \times 11]$

Ağırlık(Weight) = number of test/train samples x number of coins $[1374 \times 11]$

4.2. Derin PÖ Süreci

4.2.1. Aksiyon Fonksiyonu

Aksiyon fonksiyonu belirli bir zamanda portföydeki varlıkların ağırlıklarını ifade etmektedir. $at-1 = (a_{0,t,1}, a_{1,t,1}, \dots, a_{t,1})^T$. Portföy ağırlıkları toplamı 1'e eşit olacak şekilde her alım-satımda ajan tarafından aksiyonlar alınmakta ve ağırlıklar 10 adet kripto para için dağıtılmaktadır.

```

the step is 499
the raw omega is [2.2119486e-28 3.5467163e-14 1.4833951e-14 9.6438021e-15 8
7909910e-18
2.1720699e-15 9.9867434e-14 1.5974957e-15 3.9970102e-17 3.7376003e-14
2.6544115e-15 1.0000000e+00]
the portfolio change this period is : 0.9999999999723049
a new experience, indexed by 32748, was appended

```

Şekil 13. Backtest Aşamasında Gerçekleştirilen Örnek Portföy Ağırlık Dağılım Görseli

Şekil 9’da backtest aşamasının 499. adımında ajanın alım-satım işleminde farklı para birimlerine farklı ağırlıklarda yatırım yaptığı gözlemlenmektedir.

4.2.2. Ödül Fonksiyonu

Tez çalışmasındaki ödül fonksiyonu elde edilen ortalama getiriyi ifade etmektedir. Başlangıç durum ve aksiyon değerleri ve bitişteki aksiyon ve durum verilerinin

Girdisi sonuçta ödül miktarı belirlenmektedir:

$$R(s_1, a_1, \dots, s_{t_f}, a_{t_f}, s_{t_f+1})$$

4.2.3. Politika Fonksiyonu

Derin sinir ağı mimarisi (LSTM) ve PÖ yapılarının bir araya gelmesi ile alım-satım stratejisi yani politika fonksiyonu oluşmuştur.

$V(s)$ değer fonksiyonu yani politika fonksiyonu olmak üzere:

$$V(s) \leftarrow \sum_a \pi(a|s) \sum_{s',r} p(s',r|s,a)[r + \gamma V(s')]$$

4.2.4. Ağ Mimarisi

Tez çalışmasındaki network yapısı için Jiang ve Liang’ın (2017) tasarladığı çerçeve yaklaşımdan esinlenilmiştir. Onlar çalışmalarında EIIE yapısını geliştirmişlerdir. Ağlar varlıklar için bağımsız olarak akarken bu ağlara ait parametreleri de akış içinde paylaşılmaktadır. Ağ, her seferinde bir parayı değerlendirir ve bu kripto paraya yatırım yapıp yapmama tercihini değerlendirir. Kripto Para verileri

daha sonra Softmax fonksiyonu ile normalize edilir ve sonraki dönemler eylemi olarak bir ağırlık vektörüne sıkıştırılır. Katmanlara dair sinir ağırları ve hiper parametre iyileştirmeleri ile gerçekleştirilen testlere dair çıktılar sonuçlar bölümünde belirtilmiştir.

4.2.5. Öğrenme Oranı

Öğrenme oranı hiper parametresi sinir ağlarının eğitilmesinde büyük rol oynamaktadır. Öğrenme oranındaki küçük bir değişiklik dahi ağırlık öğrenme hızında ve performansında büyük etki ve değişiklik oluşturabilir. Düşük veya yüksek oranlı öğrenme oranları yerine optimal öğrenme oranının tespit edilmesi önem arz etmektedir.

Sonuçlar tablosunda farklı öğrenme oranları değerleri de gösterilmiştir.

4.3. Sonuçlar

Market verileri farklılaştırılmış hiper parametre setleriyle öncelikle modelin eğitiminde kullanılmış ve toplam portföy değeri ile sharpe oranı hesaplanmıştır. Toplamda 10 farklı set ile hem eğitim hem de backtest ve testler gerçekleştirilerek farklı parametre kombinasyonlarının ajanın toplam portföyüne olan etkisi izlenmiştir.

4.3.1 Eğitim, Backtestler ve Performans Ölçümleri

Başlangıç yatırım değeri olan bir BTC ile markette alım satım yapılmaya başlanmıştır. Ajan, eğitim verilerinden öğrendiği deneyim ile gelecek periyotlar için portföy ağırlıklarını girdi olarak kullanmıştır. Her bir eğitim basamağında (step) elde ettiği portföy değişimini ödül olarak algılamış ve portföy kaybını da ceza olarak algılayarak gelecek dönem için stratejisini belirlemiştir.

10 farklı sette gerçekleştirilen alım-satımlarda gözlemlenen sonuçlara göre LSTM'in performansını arttırmak için uygulanan drop-out metodunun yani bazı atıl kalan sinir ağlarının kullandırılmaması durumunun modelin öğrenmesini zorlaştırdığı yani modelin öğrenmeyi gerçekleştiremediği ve başlangıç yatırım değeri olan bir BTC ile alım-satım işlemini sonlandırdığı gözlemlenmiştir. Sinir ağı sayısı ve eğitim basamak sayısı yüksek tutulmuş olsa bile bu durum negatif sharpe oranına neden olmuştur. Ayrıca, eğitim aşamasında belirlenen adım sayısının çok düşük tutulması durumunda ajan market dinamiğini öğrenemediğinden alım-satım sonucunda oluşan performans son derece düşük kalmıştır. Bunun nedeni olarak her epochta modelin daha kripto para verisine maruz kalmış olması söylenebilir.

Eğitim ve backtestlerde ulaşılan en iyi sonuç 6. Nolu sette gerçekleşmiştir. Bu setin performansının diğerlerine oranla daha iyi olmasının nedenlerinin market dinamiğine en uygun olan öğrenme oranı, sinir ağı sayısı ve eğitim/test verilerinin dağılımının yapılmış olduğu düşünülmektedir.

Öğrenme oranı 0,00015 ve eğitim adım sayısı 90K olarak ayarlanmış olan bu setin sonucuna göre bir BTC ile başlanılan alım-satım işleminde komisyon oranının düşülmesinden sonra backtest aşamasında toplamda 160 BTC tutarında bir portföy değerine ulaşılmıştır.

Eğitim aşamasında ağıın başarısını ölçmek için izlenen adımlar aşağıda verilen pseudo kodda belirtildiği gibidir:

```
for i = 1:number of epoch  
    agent.evaluate(train)  
    if i mod 1000=0  
        agent.evaluate(test)  
        .....
```

Önerilen ağ yapısı belirlenen epoch sayısı kadar eğitime tabi tutulmuş ve her 1000 epoch'ta test kümesinin değerleri hesaplanmıştır. Hesaplanan değerler arasında portföy değerinin vektörü, log-mean vektörü, kayıp (loss) vektörü, log-mean free ve weights (kripto paraların portföy ağırlıkları) bulunmaktadır. Metrikleri sağlayan konfigürasyona sahip ağ yapısı ile sonrasında rolling-train (orijinal verinin alt kümeleri ile test etmeye devam etme yani veri sayısının artırılması) aşamasına geçilmiştir.

Yapılacak rolling-train sayısı yine belirlenen rolling-training steps parametresine göre yapılmaktadır.

```
if indikatörler (portföy değeri ve sharpe ratio istenilen seviyede ise)  
    start trading  
        for i = 1:number of test samples  
            for 1:number of rolling training steps  
                rolling train  
                .....
```

Bunun sonucunda toplam portföy değeri BTC cinsinden hesaplanmaktadır.

Ağın eğitim, test ve rolling-training kısımlarında kullanılmak üzere oluşturulan batch sampling işlemi aşağıda anlatılmıştır:

Ağın ağırlıklarını güncellemesi her batch örneklemenin verilmesinden sonra sağlanmaktadır. Yeni ağırlıkların elde edilmesi için kullanılan batchler verinin içerisinden rastgele örnekleme yoluyla oluşturulmaktadır. Öncelikle test örneği sayısı aralığında rastgele bir sayı üzerinden batch in başlangıç noktası bulunur. Daha sonra konfigürasyon dosyasında belirlenen batch size değişkeni başlangıç noktasına eklenerek batch örnekleme oluşturulur. Bu aralık göz önüne alınarak girişler, çıkışlar ve ağırlık değişkenleri aşağıdaki gibi tanımlanmıştır:

Giriş $X = [\text{Batch Random Başlangıç Noktası: Batch Size} - 1 \times \text{öznitelik sayısı} \times \text{coin sayısı} \times \text{window size}]$

Çıkış $Y = [\text{Batch Random Başlangıç Noktası: Batch Size} - 1 \times \text{öznitelik sayısı}]$

Ağırlık $= [\text{Batch Random Başlangıç Noktası: Batch Size} - 1 \times \text{coin sayısı}]$, ağırlık değerleri toplamı başlangıçta 1'e eşit olacak şekilde kripto para sayısına bölünerek uniform olarak verilmiştir.

Örneğin batch size = 100, öznitelik sayısı 3, kripto para sayısı 10 ve window size (pencere aralığı) 16 için ve rastgele başlangıç noktası 17.400 için batch örnekleme aralığı 17.400 ile 17.499 arasındadır.

$X [17.400: 17.499 \times 3 \times 10 \times 16]$

$Y[17.400: 17.499 \times 3 \times 10]$

$W(\text{Ağırlıklar}) [17.400: 17.499 \times 10]$


Network ağı eğitmek için gerekli olan X , Y ve ağırlık parametreleri yukarıda belirtilen batch aralığı göz önüne alınarak oluşturulur.

Ağın yukarıda verilen örnek değerlerle eğitilmesi sonucunda portföy vektörü, log-mean vektörü, kayıp vektörü ve yeni ağırlıklar tekrar hesaplanır.


Tablo 4: Sonuç Tablosu

Bölümler	Hiper Parametreler	1	2	3	4	5	6	7	8	9	10
Katmanlar	LSTM Sinir Ağı Sayısı	70	100	120	110	100	140	100	100	100	100
	Dropout Oranı	-	-	-	-	-	-	0,1	0,5		
Eğitim Parametreleri	Adım Sayısı	90K	90K	80K	80K	100K	90k	100K	80K	100K	10K
	Öğrenme Oranı	0,0003	0,00025	0,0002	0,00025	0,00025	0,00015	0,00025	0,00025	0,0005	0,0005
	Batch Sayısı	100	100	100	100	90	80	100	100	100	100
	Eğitim Metodu	Adam	Adam	Adam	Adam	Adam	Adam	Adam	Adam	Adam	Adam
Girdiler	Window Size	30	30	45	60	30	60	30	30	15	15
	Kripto Para Sayısı	10	10	10	10	10	20	10	10	10	10
	Günlük Veri Hacmi	30	30	30	30	30	30	30	30	30	30
	Başlangıç ve Bitiş Tarihi	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021	01.07.2019 - 01.07.2020	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021	01.01.2019 - 01.01.2021
	Test Verisi Oranı	0,07	0,08	0,08	0,08	0,08	0,08	0,08	0,08	0,08	0,08
	Eğitim Verisi Oranı	0,93	0,92	0,92	0,92	0,92	0,92	0,92	0,92	0,92	0,92
	Komisyon Oranı	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025	0,0025
Alım-Satım	Sliding Window	70	80	80	90	80	90	80	80	1	1
Metrikler Test	Nihai Portföy Değeri	51,07 BTC	40,32 BTC	56,36 BTC	129,55 BTC	65,23 BTC	173,16 BTC	65,23 BTC	1,03 BTC	1,00 BTC	0,99 BTC
	Sharpe Oranı	0,079	0,074	0,086	0,092	0,087	0,096	0,083	-0,05	-0,04	-0,04
Metrikler Backtest	Nihai Portföy Değeri	37,28 BTC	44,32 BTC	58,68 BTC	122,13 BTC	80,58 BTC	160,16 BTC	11,94 BTC	1,00 BTC	1,00 BTC	1,00 BTC

Farklı hiper parametrelerle gerçekleştirilen eğitim ve testlere dair sonuçlara ait özet değerler yukarıdaki tablo 4’te belirtilmiştir. Her bir set numarası 1’den 10’a kadar olarak ifade edilmektedir. Tablodan da anlaşılacağı üzere market eğilimini en iyi öğrenen set 6 nolu set olmuştur. Bu setin diğerlerine görece başarısının yüksek çıkmasının nedenlerinin 90 olarak belirlenen sliding window sayısının (yani ajanın eğitim aşamasında ne kadar yüksek miktarda veriyi gördüğü), öğrenme oranı olan 0,00015 ve eğitim için belirlenen basamak sayısının yani 90.000 miktarının bunda etkili olduğu gözlemlenmiştir. Grafik 25 ve Grafik 26’da tüm setlerin portföy değerleri gösterilmiştir. Her bir setin eğitim ve backtest süreçleri boyunca sergilediği portföy artış ya da azalışları bireysel tablolarda Ek E bölümünde gösterilmiştir.



Şekil 14. Test Seti Portföy Değerleri



Şekil 15. Backtest Seti Portföy Değerleri

5. SONUÇ

Son yıllarda büyük gelişme sergileyen kripto para piyasaları ve blok zincir teknolojisi finansal karar verme sürecinde bu alanda yapılan çalışma sayısını arttırmıştır. Piyasada işlem oranı en yüksek 10 adet kripto para ile tez çalışması gerçekleştirilmiştir. Çalışma kapsamında MDP ve Derin Sinir ağlarından LSTM yöntemi ile DPÖ ile kripto para portföy yönetimi gerçekleştirilmiştir. Diğer benzer çalışmalarda geleneksel portföy yönetim stratejileri ile DPÖ ajanının performanslarında karşılaştırmalar yapılmıştır. Market verilerini ve dolayısıyla dinamiklerini de öğrenen model yani ajan elindeki bir BTC değerindeki varlığı önceki dönemden elde ettiği (öğrendiği) veriler yardımıyla farklı portföy ağırlıklarında konumlandırmıştır. Periyodik olarak ajanın elde ettiği portföy getirisi bir ödül fonksiyonu oluşturmuşken yaşadığı portföy kayıpları da ajan için bir ceza mekanizması sağlamıştır. Benzer çalışmaların aksine tezde farklı hiper parametre kombinasyonlarının final portföy değerine olan etkisi göz önüne alınmıştır. Yine benzer çalışmaların aksine tez çalışmasında daha dinamik bir dönem olan 2019-2021 dönemi ve kripto para piyasası tercih edilmiştir. Daha volatil bir piyasanın seçilmiş olması market dinamiğine uygun hiper parametre kombinasyonlarının belirlenebilmesi adına pek çok kere eğitim ve test çalışması yapılmasını gerekli kılmıştır. Bu durum GPU kullanımının önemini ortaya koymuştur. LSTM metodu yoğun bellek gücü ve hesaplama gücü gerektirdiğinden mevcut CPU kullanımı ile yapılan test ve eğitimlerde yüksek işlem gücü gerekliliği anlaşılmıştır.

Başlangıç değeri olan bir BTC değerinde finansal varlık ile piyasada alım-satım işlemi gerçekleştiren ajan testler sonucunda komisyon maliyeti düşüldükten sonra yüksek portföy değerine ulaşmıştır. Elbette eğitim verilerinin bir kısmı ajan tarafından öğrenilmiş olabileceğinden çalışmanın gerçek canlı ortamda validasyonunun yapılmasının gerekliliği gelecek çalışmalara ışık tutabilir. Çalışma yüksek getiri vaadinde bulunmamakla birlikte robotik kontrol sistemlerinde uygulanan DPÖ metodunun finansal piyasada market eğilimini öğrenip öğrenemeyeceği ve performansının başarılı olup olamayacağı konusuna odaklanmış ve sonucun başarılı olduğu gözlemlenmiştir.

Tezde duygu analizi ve insana bağlı diğer faktörler göz önüne alınmadığından gelecekteki çalışmalarda örneğin Twitter ile bütünleşik bir yapı oluşturularak ajanın web ortamından elde edeceği verileri de alım-satım stratejisine dahil ederek ticaret yapması sağlanabilir. Ayrıca kripto para piyasalarından birinden elde edilen verilerle çalışma gerçekleştirilmiştir. Yine gelecekteki çalışmalarda farklı piyasalara dair veriler ve veri setinin de arttırılmasıyla alım-satım işlemleri gerçekleştirilebilir.

6. KAYNAKLAR

Angoshtari, B. ve Leung, T.(2019, 10 Ekim), "Optimal trading of a basket of futures contracts", sayfa :2, <https://link.springer.com/article/10.1007/s10436-019-00357-w>

Bircanoğlu, C. ve Arica, N. (2018), "A comparison of activation functions in artificial neural networks ", sayfa:3, https://www.researchgate.net/publication/326280782_A_comparison_of_activation_functions_in_artificial_neural_networks

Brownlee, J. (2020, 19 Ekim), "Softmax Activation Function with Python", <https://machinelearningmastery.com/softmax-activation-function-with-python/> adresinden alındı.

Brownlee, J. (2020, 28 Nisan), "Dropout with LSTM Networks for Time Series Forecasting", <https://machinelearningmastery.com/use-dropout-lstm-networks-time-series-forecasting/> adresinden alındı.

Chien-Yi, H. (2018) ,"Financial Trading as a Game: A Deep Reinforcement Learning Approach", <https://arxiv.org/abs/1807.02787>

Choudhury, A. (2019, 22 Mayıs), "Curse Of Dimensionality And What Beginners Should Do To Overcome It", <https://analyticsindiamag.com/curse-of-dimensionality-and-what-beginners-should-do-to-overcome-it/#:~:text=According%20to%20him%2C%20the%20curse,in%20the%20number%20of%20features> adresinden alındı.

Coinmarketcap, "Today's Cryptocurrency Prices by Market Cap", www.coinmarketcap.com (Ocak 2021'de erişilmiştir.)

Dertat, A. (2017, 3 Ekim), "Applied Deep Learning - Part 3: Autoencoders", <https://towardsdatascience.com/applied-deep-learning-part-3-autoencoders-1c083af4d798> adresinden alındı.

Edelkamp, S. ve Schrödl, S. (2012), "Heuristic Search Theory and Applications", Roumeliotis, R (Ed), <https://doi.org/10.1016/C2009-0-16511-X>, Elsevier: 35

Elton, E. J., Grube, M. J., Brown, S. J. Ve Goetzmann, W. N. (2014), "Modern Portfolio Theory and Investment Analysis", Hollenbeck, J. (Ed.), sayfa: 42

Erdogan, M., Mudford, B., Chenoweth, G., Holeywell, R., Oil, M. Ve Jakubson, J. (2001), "Optimization of Decision Tree and Simulation Portfolios: A Comparison", sayfa: 1, https://www.researchgate.net/publication/254511208_Optimization_of_Decision_Tree_and_Simulation_Portfolios_A_Comparison

Fernando, J. (2021, 10 Nisan), "Sharpe Ratio", <https://www.investopedia.com/terms/s/sharperatio.asp#citation-2> adresinden alınmıştır.

Gonzalez, J. Ve Yu, W. (2018), "Non-linear system modeling using LSTM neural networks", 51/13: 485, https://www.researchgate.net/publication/327356232_Non-linear_system_modeling_using_LSTM_neural_networks

Gudikandula, P. (2019, 24 Mart), "A Beginner Intro to Neural Networks", <https://purnasaigudikandula.medium.com/a-beginner-intro-to-neural-networks-543267bda3c8> adresinden alınmıştır.

Güçlü, U. ve Gerven, M.V. (2016), "Modeling the dynamics of human brain activity with recurrent neural networks", sayfa:15, https://www.researchgate.net/publication/303879409_Modeling_the_Dynamics_of_Human_Brain_Activity_with_Recurrent_Neural_Networks

Hassan, F., Ali, A., Latif, S., Qadir, J., Kanhere, S., Singh, J. ve Crowcroft, J. (2020), "Blockchain And The Future of the Internet:A Comprehensive Review", sayfa:2, <https://arxiv.org/abs/1904.00733>

Huang, G., Zhou, X. ve Song, Q. (2020), "Deep Reinforcement Learning for Portfolio Management Based on The Empirical Study of Chinese Stock Market", https://www.researchgate.net/publication/347965298_Deep_reinforcement_learning_for_portfolio_management

Jiang, Z., Xu, D., Liang, J., (2017), "A Deep Reinforcement Learning Framework for the Financial Portfolio Management Problem", <https://arxiv.org/abs/1706.10059v2>

Liang, Z., Chen, H., Zhu, J., Jiang, K., Li, Y. (2018), "Adversarial Deep Reinforcement Learning in Portfolio Management", <https://arxiv.org/abs/1808.09940>

Li, B. ve Hoi, S. C.H. (2013), "Online portfolio selection: A survey" , sayfa: 2 ve 21. <https://arxiv.org/abs/1212.2129>

Lillicrap, T. P., Hunt, J. J. , Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D. ve Wierstra, D.(2019, 5 Temmuz),"Continuous Control With Deep Reinforcement Learning", <https://arxiv.org/abs/1509.02971>

Li, S., Li, W., Cook, C., Zhu, C. ve Gao, Y. (2018), "Independently Recurrent Neural Network (IndRNN): Building A Longer and Deeper RNN", sayfa:2, <https://arxiv.org/pdf/1803.04831.pdf>

Lu, W.D. (2017), "Agent Inspired Trading Using Recurrent Reinforcement Learning and LSTM Neural Networks", <https://arxiv.org/abs/1707.07338>

Ma, Y. Ve Han, R. (2018), "Research on stock trading strategy based on deep neural network", sayfalar: 92-96, ICCAS(18th International Conference on Control, Automation and Systems) konferans bildirisi, <https://www.semanticscholar.org/paper/Research-on-stock-trading-strategy-based-on-deep-Ma-Han/ad1d534505f064682d183d772db61125f5963ef7>

Moody, J. ve Saffell, M. (2001), "Learning to Trade via Direct Reinforcement", IEEE Transactions on Neural Networks dergisi, 12/4: 875-881

Mosavi, A., Ghamisi, P., Faghan, Y. ve Duan, P.(2020), "Comprehensive Review of Deep Reinforcement Learning Methods and Applications in Economics", sayfa:11, <https://arxiv.org/abs/2004.01509>

Reiff, N. (2019, 25 Haziran), "Every Portfolio Should Have 6% Bitcoin: Yale Study", <https://www.investopedia.com/news/every-portfolio-should-have-6-bitcoin-yale-study/> adresinden alındı.

Rundo, F. (2019), "Deep LSTM with Reinforcement Learning Layer for Financial Trend Prediction in FX High Frequency Trading Systems", https://www.researchgate.net/publication/336710575_Deep_LSTM_with_Reinforcement_Learning_Layer_for_Financial_Trend_Prediction_in_FX_High_Frequency_Trading_Systems

Vaddi, L., Neelisetty, V., Vallabhaneni, B.C. ve Prakash, K.B. (2020) ,"Predicting Crypto Currency Prices Using Machine Learning and Deep Learning Techniques", International Journal of Advanced Trends in Computer Science and Engineering, 9/4: 6604. <https://doi.org/10.30534/ijatcse/2020/351942020>

Wang, Y., Wang, D., Wang, Y., ve Zhang, Y. (2018), "Racorn-K: Risk-Aversion Pattern Matching-Based Portfolio Selection", sayfa: 1, <https://arxiv.org/pdf/1802.10244.pdf>

Yang, L. Zheng, W. Ve Zheng, Z. (2019) ,"Deep Robust Reinforcement Learning for Practical Algorithmic Trading", sayfalar:108014–108022, <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8786132>

Zangre, A. (2019, 10 Temmuz), "Discrete vs Continuous Data – What’s the Difference?", <https://learn.g2.com/discrete-vs-continuous-data> adresinden alındı.


Zhang, H. ve Yu, T. (2020), "Taxonomy of Reinforcement Learning Algorithms", sayfa: 126, https://www.researchgate.net/publication/342523772_Taxonomy_of_Reinforcement_Learning_Algorithms

Zhang, Z., Zohren, S. ve Roberts, S.(2019), "Deep Reinforcement Learning for Trading", <https://arxiv.org/abs/1911.10107>

EKLER


Ek A

Portföy Yönetimi için Takip Edilen Aşamalar



Ek B


Modele Ait Tensorboard Sınır Ağı Örnek Kesiti:



Ek C


Tensorboard Portföy Değeri, Portföy Kaybı ve Ortama Getiri Görselleştirme Örnek Kesit





Ek D

Tensorboard Evriřimli Sınır Ağı Katmanı Görsel Kesiti



Ek E


Sonuçlara dair grafikler:

1. Set Eğitim Sonucu

Öğrenme Oranı: 0,0003


Sharpe Oranı: 0,079

Grafik 5: 1. Set Eğitim Sonucu



1. Set Backtest Sonucu

Grafik 6: 1. Set Backtest Sonucu




2. Set Eğitim Sonucu

Öğrenme Oranı: 0,00025


Sharpe Oranı: 0,074

Grafik 7: 2. Set Eğitim Sonucu



2. Set Backtest Sonucu

Grafik 8: 2. Set Backtest Sonucu




3. Set Eğitim Sonucu

Öğrenme Oranı: 0,0002


Sharpe Oranı: 0,086

Grafik 9: 3. Set Eğitim Sonucu



3. Set Backtest Sonucu

Grafik 10: 3. Set Backtest Sonucu




4. Set Eğitim Sonucu

Öğrenme Oranı: 0,00025


Sharpe Oranı: 0,092

Grafik 11: 4. Set Eğitim Sonucu



4. Set Backtest Sonucu

Grafik 12: 4. Set Backtest Sonucu




5. Set Eğitim Sonucu

Öğrenme Oranı: 0,00025


Sharpe Oranı: 0,087

Grafik 13: 5. Set Eğitim Sonucu



5. Set Backtest Sonucu

Grafik 14: 5. Set Backtest Sonucu




6. Set Eğitim Sonucu

Öğrenme Oranı: 0,00015


Sharpe Oranı: 0,096

Grafik 15: 6. Set Eğitim Sonucu



6. Set Backtest Sonucu

Grafik 16: 6. Set Backtest Sonucu




7. Set Eğitim Sonucu

Öğrenme Oranı: 0,00025


Sharpe Oranı: 0,083

Grafik 17: 7. Set Eğitim Sonucu



7. Set Backtest Sonucu

Grafik 18: 7. Set Backtest Sonucu




8. Set Eğitim Sonucu

Öğrenme Oranı: 0,00025


Sharpe Oranı: -0,05

Grafik 19: 8. Set Eğitim Sonucu



8. Set Backtest Sonucu

Grafik 20: 8. Set Backtest Sonucu




9. Set Eğitim Sonucu

Öğrenme Oranı: 0,0005


Sharpe Oranı: -0,04

Grafik 21: 9. Set Eğitim Sonucu



9. Set Backtest Sonucu

Grafik 22: 9. Set Backtest Sonucu




10. Set Eğitim Sonucu

Öğrenme Oranı: 0,0005

Sharpe Oranı: -0,04

Grafik 23: 10. Set Eğitim Sonucu



10. Set Backtest Sonucu

Grafik 24: 10. Set Backtest Sonucu

