

KRİPTO PARALARIN GELİŞİMİ VE PARA PİYASALARINDAKİ YERİNİN ANALİZLERİ

Pamukkale Üniversitesi
Sosyal Bilimler Enstitüsü
Doktora Tezi
Uluslararası Ticaret ve Finansman Anabilim Dalı
Uluslararası Ticaret ve Finans Programı

Figen ALDI

Danışman: Prof. Dr. İlhan KÜÇÜKKAPLAN

Mart 2025
DENİZLİ

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bilimsel etiğe ve akademik kurallara özenle riayet edildiğini; bu çalışmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etiğe uygun olarak kaynak gösterildiğini ve alıntı yapılan çalışmalara atıfta bulunulduğunu beyan ederim.

Figen ALDI

ÖNSÖZ

Doktora tezimi, doktora sürecine başladığımda, 2010 yılından bu tarafa takip etmekte olduğum kripto paralarla çağımızın olmazsa olmazı yapay zekâyı harmanlayarak yazmak benim için en önde gelen hususlardan biriydi. Çünkü finansal teknolojinin sürekli olarak evrildiği ve geleneksel finansal sistemlere alternatif olarak ortaya çıkan kripto para birimleri, dijital varlık pazarının önemli bir parçası haline geldi. Öte yandan, yapay zekâ ve derin öğrenme teknikleri, büyük veri analizi, tahmin modeller gibi birçok alanda büyük ilerleme kaydetti. Dolayısıyla bu tez çalışmasında kripto para birimleri ve yapay zekânın kesişimindeki önemli konuları ele almaya çalıştım. Kripto paralar ve yapay zekâ teknolojilerini bir araya getirerek finansal inovasyon ve dijital ekonomi üzerindeki etkilerini anlatmaya çalıştım. Bu tez ile geleceğin finansal teknolojilerini şekillendirmede önemli bir rol oynayabilecek olan bu alanlardaki potansiyeli keşfetmeyi ve bu potansiyeli gerçekleştirmeyi hedefledim.

Bu tez YÖK Doktora 100/2000 Öncelikli Alanlar projesi kapsamında Yüksek Öğretim Kurumu tarafından desteklenmiş olup ilgili kuruma sonsuz teşekkürlerimi sunarım.

Doktora tez çalışmamda “Kripto Para ve Yapay Zekâ” ilişkisini kullanabilmem için bana fırsat veren ve her zaman bana güvenen Sayın tez danışmanım Prof. Dr. İlhan KÜÇÜKKAPLAN’a müteşekkirim. Her zaman kafama takılan tüm sorulara cevap veren ve sorunlara çözüm bulmama yardımcı olan Sayın Prof. Dr. Şaban NAZLIOĞLU’na teşekkür ederim. Bana her zaman yol gösterici olan ve ümidimi tüketmeme asla müsaade etmeyen Sayın Doç. Dr. Eyyüp Ensari ŞAHİN’e müteşekkirim. Doktora tez çalışmamda bana yol gösteren, değerli katkıları ve yapıcı eleştirileriyle sürecimi zenginleştiren Doç. Dr. Filiz Yıldız CONTUK 'a değerli rehberliği için şükranlarımı sunarım. Doktora tez sürecimde akademik rehberliği ve kıymetli değerlendirmeleriyle bana destek olan Dr. Öğr. Üyesi Nizamettin BAŞARAN’a içten teşekkürlerimi sunarım.

Bana yapay zekâyı, veri analizini sevdiren ve sağlam temellerini öğreten Sayın Prof. Dr. Sezai TOKAT ve Prof. Dr. Serdar İPLİKÇİ’ye katkıları için minnettarım. Bana yapay zekâ çalışmalarına ilk geçişimde çok yardımı dokunan ve her zaman yanımda olan Sayın Prof. Dr. İrfan ERTUĞRUL’a teşekkürü bir borç bilirim. Onlarca online eğitimlerine katıldığım ve kafamı karıştıran her soruma geri dönüş sağladıkları ve nezaketleri için DATAI TEAM ekibine teşekkürlerimi sunarım.

Doktora ders ve tez sürecimde doğup büyüyen, kendisinden istemeyerek çaldığım vakitlerde çalışmalarına müsaade eden, bana karşı büyük sabır, anlayış ve hoşgörü gösteren biricik kızım Melisa ALDI’ya sonsuz sevgi ve şükranlarımı sunarım.

ÖZET

KRİPTO PARALARIN GELİŞİMİ VE PARA PİYASALARINDAKİ YERİNİN ANALİZLERİ

Aldı, Figen

Doktora Tezi

Uluslararası Ticaret ve Finansman ABD

Uluslararası Ticaret ve Finans Doktora Programı

Tez Yöneticisi: Prof. Dr., İlhan Küçük Kaplan

Mart 2025, XI+147 Sayfa

Bu çalışmada, kripto para fiyat hareketlerini etkileyen temel faktörler, kısa ve uzun vadeli fiyat tahminlerinin uygulanabilirliği ve bu tahminlerin hangi değişkenlerden etkilendiği araştırılmıştır. Ek olarak, minimum hata ile en güvenilir tahmini elde edebilmek için hangi yapay zekâ yönteminin tercih edilmesi gerektiği sorusu ele alınmıştır. Bu doğrultuda, derin sinir ağları da kullanılarak gerçeğe en yakın tahmin aralığını belirlemeye yönelik bir model geliştirilmiş ve elde edilen bulguların yatırımcılar ile piyasa yapımcılar için rehber niteliğinde olması amaçlanmıştır. Çalışmada, kripto para piyasalarında fiyat tahminlerini iyileştirmek için farklı yapay zekâ tekniklerini entegre eden bir yaklaşım sunulmuştur. Zaman serisi verileri durağanlık açısından analiz edilmiş ve tahmin doğruluğu üzerindeki etkisini değerlendirmek amacıyla ADF, PP ve KPSS testleri uygulanmıştır. VAE-GAN modeli ile gerçekleştirilen tahminler, modelin durağanlaştırılmış verilerle eğitildiğinde değişken piyasa koşullarına daha iyi uyum sağladığını ortaya koyarken, durağanlaştırılmamış verilerle yapılan analizler, yüksek piyasa değeri ve işlem hacmine sahip varlıklar için daha yüksek doğruluk oranı sağlamıştır. Bulgular, yapay zekâ tabanlı modellemenin kripto para fiyat tahmini açısından güçlü bir yöntem sunduğunu göstermektedir.

Anahtar Kelimeler: Kripto para, dijital dönüşüm, yapay zekâ, derin öğrenme, VAE-GAN.

ABSTRACT

DEVELOPMENT OF CRYPTOCURRENCIES AND ANALYSIS OF THE THEIR PLACE IN THE CURRENCY MARKETS

Aldı, Figen
Doctoral Thesis
International Trade and Finance Department
International Trade and Finance Doctorate Programme
Adviser of Thesis: Prof. Dr., İlhan Küçükkaplan

March 2025, XI+147 Page

In this study, the basic factors affecting cryptocurrency price movements, the applicability of short-term and long-term price predictions, and from which variables affected these predictions were investigated. In addition, the question of which artificial intelligence method should be preferred in order to obtain the most reliable estimate with minimum error was addressed. In this context, a model was developed to determine the closest prediction range to the truth using deep neural networks, and the findings obtained were intended to be a guide for investors and market makers. In the study, an approach that integrates different artificial intelligence techniques to improve price predictions in cryptocurrency markets was presented. Time series data were analyzed for stationarity wise and ADF, PP and KPSS tests have been applied for the purpose evaluate the impact on forecast accuracy. Realized predictions with the VAE-GAN model revealed that the model adapts better to volatile market conditions when trained with stabilized data, while analyses made with non-stabilized data provided higher accuracy rates for assets with high market value and trading volume. The findings show that AI-based modeling offers a powerful method for cryptocurrency price prediction.

Keywords: Cryptocurrency, digital transformation, artificial intelligence, deep learning, VAE-GAN.

İÇİNDEKİLER

ÖNSÖZ	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER	iv
ŞEKİLLER DİZİNİ	vi
TABLolar DİZİNİ	vii
SİMGE VE KISALTMALAR DİZİNİ	viii
GİRİŞ	1

BİRİNCİ BÖLÜM PARANIN EVRİMİ

1.1. Paranın Tarihsel Gelişimi	3
1.2. Kuantum Finansal Sistem	6
1.3. Kripto Paralar	7
1.4. Para Piyasaları	9

İKİNCİ BÖLÜM KRİPTO PARALAR

2.1 Kripto Para ile ilgili Temel Kavramlar	10
2.2. Kripto Para Çeşitleri	16
2.3. Kripto Paraların Genel Özellikleri	25
2.4. Kripto Paraların Değerine Etki Eden Faktörler	29
2.5. Kripto Paraların Tarihsel Gelişimi	33
2.6. Ticaret ve Finans Sektörlerindeki Dijital Dönüşüm: Kripto Paralar	36
2.7. Kripto Para ve Fintech	44
2.8. Kripto Para Piyasası ve Halka Arzı	46
2.9. Kripto Para Endeksi	47
2.10. Kripto Paraların Hukuki Boyutu (Regülasyonlar)	50

ÜÇÜNCÜ BÖLÜM YAPAY ZEKÂ VE KRİPTO PARA

3.1. Yapay Zekâ (AI)	53
3.1.1. Yapay Zekâ Alanları	53
3.2. Yapay Zekâ Tahmin Yöntemleri	55
3.3. Kripto Para ile Yapay Zekâ İlişkisi	81
3.4. Kripto Para Tahmininde Yapay Zekânın Yeri	82
3.5. Kripto Paraların Yapay Zekâ ile Tahminine Dayalı Literatür Araştırması	83
3.5.1. Kripto Paraların Finans Sektöründeki Yerine Yönelik Çalışmalar	83
3.5.2. Kripto Paraların Değer Tahminine Yönelik Çalışmalar	87

DÖRDÜNCÜ BÖLÜM YÖNTEM VE UYGULAMA

4.1. Araştırmanın Amacı ve Önemi	98
4.2. Veri Seti	98
4.3. Araştırmanın Yöntemi	103
4.3.1. Veri Analizinde Kullanılan Teknik İndikatörler ve Veri Ön İşleme	106

4.3.1.1. Geniřletilmiř Dickey & Fuller (ADF) Birimkk Testi	109
4.3.1.2. Phillips & Perron (PP) Birimkk Testi	109
4.3.1.3. Kwiatkowski-Phillips-Schmidt-Shin (KPSS) Duraęanlık Testi	110
4.3.2. Aktivasyon Fonksiyonları	110
4.3.3. Optimizasyon	110
4.3.4. Kayıp Fonksiyonları.....	112
4.3.5. Performans Deęerlendirmesi.....	113
4.4. Uygulama	115
TARTIřMA	122
SONUÇ	124
KAYNAKLAR	126
ZGEÇMİř	147

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1. Dünya Geneline Kripto Para Regülasyonları (WEB_88)	50
Şekil 2. Yapay Zekâ Alt Alanları	55
Şekil 3. Kripto Para Kapanış Fiyat Grafikleri	100
Şekil 4. Kripto Para Temel Ölçüm Logaritmik Veriler	102
Şekil 5. VAE-GAN Mimarisi	106
Şekil 6. VAE-GAN İşleyiş Şeması	114
Şekil 7. Kripto Para Fourier Dönüşüm Grafikleri	116

TABLolar DİZİNİ

Sayfa

Tablo 1. Kripto Paraların Finans Sektöründeki Yerine Yönelik Çalışmalar	84
Tablo 2. Kripto Paraların Değer Tahminine Yönelik Çalışmalar	87
Tablo 3. ADF ve PP Birim Kök Testleri ile KPSS Durağanlık Testi Sonuçları.....	117
Tablo 4. Çıktı Raporları ve Gerçekleşen Fiyat Tablosu (ABD Doları)(USD).....	119

SİMGE VE KISALTMALAR DİZİNİ

FinTech	Finansal Teknoloji
CBDC	Merkez Bankası Dijital Para Birimleri
QFS	Kuantum Finansal Sistem
ISO 20022	Finansal Kurumlar Arasında Elektronik Veri Alışverişi Sağlayan ISO Standardı
SWIFT	Uluslararası Alanda Bankalararası Elektronik Fon Transferi
NFT	Değiştirilemez Jeton
BTC	Bitcoin Kripto Para Birimi
ETH	Ethereum Kripto Para Birimi
ETC	Ethereum Klasik Kripto Para Birimi
XRP	Ripple Kripto Para Birimi
LTC	Litcoin Kripto Para Birimi
XMR	Monero Kripto Para Birimi
DOGE	Dogecoin Kripto Para Birimi
XLM	Stellar Kripto Para Birimi
BCH	Bitcoin Cash Kripto Para Birimi
USDT	Tether Kripto Para Birimi
DASH	Dash Kripto Para Birimi
ZEC	ZCash Kripto Para Birimi
ADA	Cardano Kripto Para Birimi
BNB	Binance Coin Kripto Para Birimi
SOL	Solana Kripto Para Birimi
PoW	İş Kanıtı (Algoritması)
PoS	Hisse Kanıtı (Algoritması)
ICO	İlk Kripto Para Arzı
IPO	İlk Halka Arz
STO	Güvenlik Jetonu Arzı
IDO	İlk Dex Arzı
IEO	İlk Borsa Arzı
DeFi	Merkeziyetsiz Finans
DeX	Merkeziyetsiz Borsa
DAO	Merkeziyetsiz Otonom Organizasyon
DApps	Merkeziyetsiz Uygulamalar
RPCA	Ripple Protokolü Konsensüs Algoritması
ILP	İnterledger Protokolü
SCP	Stellar Konsensüs Protokolü
FBA	Federe Bizans Anlaşması
SDF	Stellar Geliştirme Vakfı
STK	Sivil Toplum Kuruluşları
P2P	Eşler Arası
HODL	Varlıkların Uzun Vadede Tutulması
SEC	ABD Menkul Kıymetler ve Borsa Komisyonu
RegTech	Regülasyon Teknolojileri
AML	Kara Para Aklamanın Önlenmesi
KYC	Müşterinizi Tanıyın
AMM	Otomatik Piyasa Yapıcı
ETF	Borsa Yatırım Fonu
FinTRAC	Kanada Finansal İşlemler ve Raporlar Analizi Merkezi

MAS	Singapur Para Otoritesi
AusTRAC	Avustralya İşlem Raporları ve Analiz Merkezi
FSA	Japonya Finansal Hizmetler Ajansı
FSS	Güney Kore Finansal Denetim Hizmetleri
FCA	Birleşik Krallık Finansal Davranış Otoritesi
SFTA	İsviçre Federal Vergi Dairesi
FINMA	İsviçre Finansal Piyasa Denetleme Otoritesi
DLT	Dağıtılmış Defter Teknolojisi
VFA	Malta Sanal Finansal Varlıklar
MFSA	Malta Finansal Hizmetler Otoritesi
GFSC	Cebelitarık Finansal Hizmetler Komisyonu
CCSF	Lüksemburg Finans Sektörü Denetleme Komisyonu
FATF	Finansal Eylem Görev Gücü
AI	Yapay Zekâ
GP	Genetik Programlama
NLP	Doğal Dil İşleme
FNN	İleri Beslemeli Sinir Ağları
GAN	Üretken Rekabetçi Ağlar
RBPNN	Radyal Temelli Olasılıksal Sinir Ağları
BPTT	Zaman İçinde Geri Yayılım
ReLU	Düzeltilmiş Doğrusal Birim
VGG	Görsel Geometri Grubu
SOM	Kohonen Özellik Haritası
SRN	Elman Ağları (Basit Tekrarlayan Ağlar)
JRNN	Jordan Ağları (Jordan Tekrarlayan Sinir Ağları)
LVQ	Vektör Nicemleme Öğrenmesi
CapsNets	Kapsül Ağları
NTM	Sinirsel Turing Makinesi
QNN	Kuantum Sinir Ağları
DAE	Derin Otomatik Kodlayıcılar
DQN	Derin Q Ağları
tanh	Hiperbolik Tanjant
MSE	Karesel Hata
TL	Transfer Öğrenimi
BERT	Transformatörlerden Çift Yönlü Kodlayıcı Gösterimleri
ML	Makine Öğrenmesi
YSA	Yapay Sinir Ağları
DL	Derin Öğrenme
MLP	Çok Katmanlı Algılayıcılar
SVM	Destek Vektör Makinesi
LR	Doğrusal Regresyon
LOR	Lojistik Regresyon
BLOR	Binom Lojistik Regresyon
RF	Rastgele Orman
ERF	Aşırı Rastgele Orman
AODE	Ortalama Tek Bağımlılık Tahmin Edicileri
RW	Rastgele Yürüyüş
EMA	Üstel Hareketli Ortalama
SVR	Destek Vektör Regresyonu
Box SVM	Kutu Destek Vektör Makinesi

VW-SVM	Hacim Ağırlıklı Destek Vektör Makinesi
BNN	Bayes Sinir Ağları
Deep RL (DRL)	Derin Pekiştirmeli Öğrenme
CNN	Evrişimli Sinir Ağları
RNN	Tekrarlayan Sinir Ağları
CRNN	Evrişimli Tekrarlayan Sinir Ağları
GMM	Gizli Markov Modeli
GASEN	Genetik Algoritma Tabanlı Seçici Sinir Ağı
GRU	Geçitli Tekrarlayan Birimler
LSTM	Uzun-Kısa Süreli Bellek
EEMD-ELMAN	Topluluk Ampirik Mod Ayrışımı- ELMAN Bazlı Model
PR	Polinom Regresyon
DT	Karar Ağacı Regresyonu
BR	Bayes Regresyonu
GLM	Genelleştirilmiş Doğrusal Model
CA	Korelasyon Analizi
GTB	Gradyan Ağaç Artırma
ETRF	Ekstra Ağaç Rastgele Ormanı
EVC	Topluluk Oylama Sınıflandırıcıları
FNN	İleri Beslemeli Sinir Ağı
GA	Genetik Algoritma
NARX	Doğrusal Olmayan Otoregresif Dışsal Model
NARMA	Doğrusal Olmayan Otoregresif Hareketli Ortalama
HMM	Gizli Markov Modeli
PSO	Parçacık Sürü Optimizasyonu
PSO-SVM	Parçacık Sürü Optimizasyonuna Dayalı Optimize Edilmiş Destek Vektör Makinesi
NNAR	Sinir Ağı Otoregresyon Modeli
DNN	Derin Sinir Ağları
ResNet	Derin Artık Ağ
GRNN	Genelleştirilmiş Regresyon Sinir Ağları
IMC	Dengesiz Çoklu Sınıflandırma
NRL	Ağ Temsili Öğrenimi
PCA	Temel Bileşen Analizi
BTA	Kuyrukta Beta Analizi
RL	Takviyeli Öğrenme
RR	Sırt Regresyonu
HARRV	Heterojen Otoregresif Gerçekleşmiş Oynaklık
RSM	Rastgele Örnekleme Yöntemi
NB	Naive Bayes
RBFNN	Radyal Tabanlı Fonksiyonel Sinir Ağları
PCF	Polinomsal Eğri Uydurma
ANFIS	Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi
HRP	Hiyerarşik Risk Paritesi
LDA	Doğrusal Diskriminant Analizi
SNN	Stokastik Sinir Ağları
SA	Duygu Analizi
GPR	Gaussian Poisson Regresyonları
RT	Regresyon Ağaçları
kNN	K En Yakın Komşular

FFNN	Yapay İleri Besleme
BRNN	Bayeşçi Tekrarlayan Sinir Ağı
LASSO	En Az Mutlak Büzölme Seçim Operatörü (Kement Regresyon)
BPRNN	Geri Yayılımlı Rastgele Sinir Ağı
SLSTM	Yığılmış Uzun-Kısa Süreli Bellek
BILSTM	Çift Yönlü Uzun-Kısa Süreli Bellek
SGD	Stokastik Gradyan İnişi
DE	Diferansiyel Evrim
MRC	Çok Ölçekli Artık Konvolüsyonel Sinir Ağı
RMSE	Kök Ortalama Karesel Hata
MAPE	Ortalama Mutlak Hata Yüzdesi
LSE	En Küçük Kareler Tahmincisi
ARV	Ortalama Göreli Varyans
RA	Rao Algoritması
CDD	Kopula Yönlü Bağımlılık
FLN	İşlevsel Sinir Ağı
TFLN	Trigonometrik İşlevsel Sinir Ağı
CFLN	Chebysheb İşlevsel Bağlantı Sinir Ağı
LFLN	Lagurre İşlevsel Bağlantı Sinir Ağı
LeFLN	Legendre İşlevsel Sinir Ağı
NMSE	Normalleştirilmiş Ortalama Kare Hatası
AMT	Alternatif Model Ağacı
MLR	Çoklu Doğrusal Regresyon
EN	Elastik Net Regresyon
TC	Ağaç Sınıflandırıcı
1DCNN	1 Boyutlu Konvolüsyonel Sinir Ağı
BWURO	Karadul Güncellenmiş Yağmur Optimizasyon Modeli
BWO	Karadul Optimizasyonu
ROA	Yağmur Optimizasyon Algoritması
FLRDS	Özellik Düzeyi Optimum Dönen Pencere Toplu Veri Standardizasyon Algoritması
DSR	Tasarım Bilimi Araştırması Yöntemi
DCN	Derin Çapraz Ağlar
QORA	Yarı Karşıtlık Tabanlı Rao Algoritmaları
WaveNet	CNN Mimarisine Dayalı Bir Sinir Ağı
LWS	Öğrenilebilir Pencere Boyutu
FuzzyCSA	Bulanık Karga Arama Algoritması
XGBoost	Aşırı Gradyan Artırma
AdaBoost	Uyarlanabilir Artırma
GBoost	Gradyan Artırma
LightGBM	Light Gradyan Artırma Makinesi

GİRİŞ

Dünya endüstrilerinin gelişimi ve bireylerin ihtiyaçlarının karşılanması, yaşamlarının kolaylaştırılması adına benimsenen Endüstri 4.0; makine, network ağları vb.. gibi yapay zekâ alanlarının kullanımının artmasıyla benimsenmiştir. Endüstri 5.0 devriminden itibaren ise kriptografi alanlarının yayılımında bir ivme kaydetmesiyle içinde bulunduğumuz dijital dönüşüm çağı gelişimini sürdürmeye devam etmektedir. Tüm bu olgular dijitalleşmedeki çeşitliliği de beraberinde getirmiş olduğundan, toplumlarda çok yönlü dijitalleşme giderek artmaktadır. Dolayısıyla içinde bulunduğumuz dijital dönüşüm çağında dijitalleşme olgusu, her alanda olduğu gibi ticaret ve finans sektörlerinde de kendini göstermiştir. Öyle ki Elon Musk'ın 14.01.2022'de Twitter sosyal ağından yaptığı "Tesla merch buyable with Dogecoin" (Dogecoin ile Tesla ürünü satın alınabilir) açıklamasıyla birlikte kripto paraların gündelik yaşamımızdaki yerinin gün geçtikçe artacağı kanısına ulaşılabilmektedir. Bu noktada kripto paraların insan hayatındaki öneminin zamanla daha da artacağı öngörülmektedir.

2009 yılında Satoshi Nakamoto tarafından oluşturulan ilk kripto para birimi Bitcoin'dir. Bir kripto paranın üretimi kriptografi adı verilen şifreleme teknikleriyle yapılmakta olup, kripto paralar herhangi bir kontrol ya da denetim mekanizmasına sahip değildir ve yüksek güvenlik düzeyinde korunmaktadırlar. Kripto paralara ilişkin olarak henüz uzun bir geçmişe sahip olmamaları ve hatta gelişmekte olan/gelişmemiş ülkeler açısından kripto paraların çok daha yakın geçmişte yayılmaya başlanmış olması bu konuya olan ilgiyi artırmaktadır.

Bu çalışmada, kripto para fiyatlarındaki aşağı ya da yukarı yönlü hareketlere etki eden etmenlerin ve bu etmenlerin etki derecelerinin araştırılarak, söz konusu kripto paraların gelecekteki beklenen değerine yönelik tahminlerde bulunulması amaçlanmıştır. Geçmiş verilerden hareketle gelecekteki verilerin yaklaşık olarak değerlerinin doğru tahmin edilebilmesi sonucunda maksimum standart sapmanın ne olacağı düşüncesinden yola çıkılmış ve dolayısıyla kripto paraların gelecekte yaşama ne yönde katkı sağlayacağı/sağlamayacağı ise merak konusu olmuştur. Söz konusu araştırmada, kripto para işlem hacimleri vb... kriterlerin kripto para fiyatlarına etkisi, pandemi sürecinin kripto paralar üzerindeki olumlu/olumsuz etkisi gibi hipotezlerin denenmesi üzerinde durulmuştur.

Araştırmada en eski kripto paralara ait geçmişten günümüze kadar olan tüm veriler bilgisayar ve internet ağı kullanılarak, bu verileri barındıran güvenilir kaynaklardan excell dosyasına aktarılacaktır. Gerekli düzenlemeler yapılarak uygun programa veri transferi gerçekleştirilecektir. İşlenecek olan verilerin yaklaşık olarak son 10 yıllık tarih aralığına ait günlük veriler olması amaçlanmıştır.

Araştırma aşamaları, uygulanacak olan yapay zekâ yöntemine uygun olarak ve gerektiği noktalarda ekonometriden de faydalanılarak sırasıyla aşağıdaki gibidir:

- 1- Araştırma sorusunun belirlenmesi
- 2- Yönteme ilişkin modelin belirlenmesi
- 4- Verilerin toplanması
- 5- Verilerin düzenlenip ilgili programa aktarılması
- 6- Tahmin
- 7- Çıkarım ve politika önerisi

Yukarıdaki ilk iki madde dahil olarak teorik aşamaların tamamlanmasını takiben ilk uygulamalı aşama olan veri toplamı işleminin Yahoo Finance, CoinGecko, CoinMarketCap gibi güvenilir web sitelerinin veri tabanından çekilerek, serinin birim kök içermesi yada durağan olması durumuna bakılarak analize yön verilmesi, ölçüm hatalarına neden olabilecek noktaların saptanması, yanlış değerlendirmeye sebebiyet verebilecek verilerden arındırıldıktan sonra yapay zekâ algoritmalarıyla desteklenerek en uygun yöntemle analiz edilip değerlendirilmesi amaçlanmıştır.

Daha çok veriye sahip olunmasının daha kesin sonuçlar getireceği düşünüldüğünden, en uzun geçmişe sahip kripto para birimleri (coin) örneklem olarak ele alınacaktır. Kripto paralara ait verilerin açılış-kapanış fiyatı ve işlem hacminden oluşması; yapay zekâ kullanılarak analiz edilip değerlendirilmesi planlanmaktadır.

BİRİNCİ BÖLÜM

PARANIN EVRİMİ

1.1. Paranın Tarihsel Gelişimi

Binlerce yıl boyunca aşamalı olarak gelişmekte olan ve karmaşık bir sürece sahip olan para, antik çağlarda insanların ellerinde bulunan mal ve hizmetleri ihtiyaçları doğrultusunda diğer mal ve hizmetler karşılığında değiş-tokuş ettikleri takas sisteminin sonrasında ortaya çıkmıştır. Takas işlemi sırasında her iki tarafın sahip olduğu ürün ve hizmetlerin her iki tarafın da ihtiyaçlarını karşılamıyor olma durumu, alım-satım değerine sahip, “para” olarak adlandırılan bir olguya olan gereksinimin ortaya çıkmasına neden olmuştur.

Takas sistemini takiben alım-satımın artıp ticaretin de genişlemesiyle birlikte doğal bir değere sahip olan madenler (altın, gümüş, vb...) ve değerli eşyalar (deniz kabuğu, balina dişi, vb...) para olarak kullanılmaya başlanmıştır (Davies, 2002: 36-38). Bu dönemde para yerine kullanılan değerli maden ve eşyaların kullanım sırasındaki alım-satım değeri doğal değerlerinin çok daha altında olduğundan izleyen parasal gelişim döneminde yani M.Ö. 6. Yüzyılın ortalarında eski Anadolu medeniyetlerinden biri olan Lidyalılar tarafından ilk madeni para icat edilmiştir (Davies, 2002: 62-63). Değerli metallere cinsine, saflık derecesine ve ağırlıklarına göre standartlar getirilip belirli bir kalıp içerisine sokularak ilk madeni paralar ortaya çıkarılmıştır. Bu şekilde antik çağdan orta çağa kadar (yaklaşık 7000 yıllık süreçte) kullanımı devam etmiştir. Böylelikle ticaret kolaylaştırılmış, sahtecilik azaltılmış ve ticarete tutarlı bir denge sağlanmıştır. Yaklaşık olarak M.S. 7. Yüzyılın başlarından itibaren ticaret geliştikçe büyük miktarlarda madeni para taşımının zorluklarından (hırsızlık ve gasp riski, nakil sıkıntısı gibi...) ötürü bu durum yerini, söz konusu değerli metallerin değerini temsil eden kağıt makbuz yada sertifika gibi değerli kağıtlar almaya başlamıştır. Bireylerin bol miktarda yanlarında taşıyabileceği şekilde hafif olan kağıt paralar ise daha dayanıklı olması açısından genellikle keten ve kenevir gibi bitki liflerinden üretilmiştir. Kağıt paralar ise M.S. 9. Yüzyılda ilk defa Çinliler tarafından kullanılmaya başlamıştır (WEB_19).

Tarih boyunca toplumların ve ekonomilerin değişen ihtiyaçlarına uyum sağlamak için dünyanın farklı bölgelerinde çeşitli paralar kullanılmış ve sürekli olarak gelişmiştir. Modern para sistemleri oldukça karmaşık olmakla birlikte, fiziksel para, elektronik işlemler ve çeşitli finansal araçların kombinasyonundan oluşur. 19. Yüzyıl sonları ve 20.

Yüzyıl başlarında merkez bankalarının kurulması, paranın nasıl düzenlendiği ve yönetildiği konusunda para sisteminde önemli bir değişime işaret etmiştir (WEB_20). Merkez bankalarına para basma, para politikası belirleme ve bankacılık sistemini denetleme yetkisi verilerek mevcut para sistemine istikrar ve esneklik sağlanmıştır. Modern para sistemiyle birlikte gerçek bir değeri olmayan ve fiziksel bir emtia tarafından desteklenmeyen ancak bir hükümetin yasal ödeme aracı olduğunu beyan etmesi nedeniyle değeri olan itibari (fiat) paraya geçiş yapılmıştır. Söz konusu sistem para politikaları yoluyla merkez bankaları ve hükümetlerin para arzını ve değerini düzenlemeleriyle yaygınlaşmıştır. Bu yeniliği 1950’li yıllarda ABD’de kullanılmaya başlanan kredi kartları takip etmiştir.

20. yüzyılın ortalarına doğru ticaret ve finansal işlemler küresel olarak genişledikçe, istikrarlı bir uluslararası para sistemine duyulan ihtiyaç ortaya çıkmıştır. Altın standardı ve Bretton Woods sistemi (1944) gibi sistemler, sabit döviz kurları oluşturmaya ve istikrarlı bir uluslararası para düzeni yaratmaya çalışmıştır. Ancak, bu sistemler gelişmiş ve sonunda mevcut dalgalı döviz kurları sistemine yol açmıştır.

1992 yılında banka/kredi kartı haricinde ilk olarak Finlandiya bankası tarafından hayata geçirilen merkez bankası dijital para birimi fikri 20 yılı aşkın bir süre boyunca, kimse tarafından ciddi olarak ele alınmaması sebebiyle sürüncemede kalmıştır.

Fintech (finansal teknoloji) şirketlerinin yükselişi, eşler arası (peer to peer) borç verme, kitle fonlaması, robo-danışmanlar ve dijital cüzdanlar dahil olmak üzere yenilikçi finansal ürün ve hizmetlere yol açmıştır. Bu gelişmeler, bireylerin mali durumlarını yönetme ve bunlara erişme şeklini değiştirerek para ve finansal sistemlerin gelecekteki görünümünü şekillendirmiştir.

2009 yılında piyasaya sürülen Bitcoin ve diğer kripto para birimleri blok zincir teknolojisini kullanarak, merkezi bir otorite tarafından kontrol edilemeyen (DeFi) finansal işlemler ve yatırımlar için para kavramında devrim yaratmıştır. Para dünyasında yeni bir paradigmayı beraberinde getiren kripto para birimleri, aracılara ihtiyaç duymadan güvenli, eşler arası işlemleri mümkün kılmak için merkezi olmayan blok zincir teknolojisini kullanmaktadır. Bir taraftan gelişirken düzenleyici zorluklarla da karşı karşıya kalan kripto para birimleri son yıllarda oldukça popülerlik kazanmış ve geleceğin para biçimi olarak görülmeye başlanmıştır.

2016 yılına gelindiğinde dijitalleşmenin yükselişiyle birlikte kripto para kullanımlarının da yaygınlaşmasına ve değişen finansal manzaralara yanıt olarak, birçok ülke merkez bankası dijital para birimlerini (CBDC) araştırmakta ve aktif olarak geliştirmektedir. Dolayısıyla her geçen yıl benimsenmeyle birlikte dünya genelinde CBDC kullanım oranı artmaktadır (WEB_21). CBDC'ler, bir ülkenin resmi para biriminin dijital temsilleridir ve merkez bankası tarafından verilmekte ve düzenlenmektedir. Elektronik bankacılık sistemleri, mobil uygulamalar, çevrimiçi platformlar aracılığıyla yürütülen işlemler dijital paraya örnek teşkil etmektedir. Söz konusu dijital para birimleri, işlemlerde finansal katılımı, verimliliği ve güvenliği artırmayı amaçlamaktadır. Özellikle yetersiz hizmet alan ve banka hesabı olmayan bölgelerde (Doğu Asya ve Pasifik, Güney Asya, Orta Doğu ve Kuzey Afrika, Sahra Altı Afrika'sı gibi bölgeler) finansal katılımı artırmak için çaba sarf edilmektedir (WEB_22). Mobil bankacılık ve dijital finansal hizmetler, daha önce erişimi olmayan bireylere bankacılık ve finansal hizmetler sağlamada çok önemli bir rol oynamaktadır. Bu durum ekonomik büyümeyi teşvik etmekte ve resmi finansal sisteme katılımı sağlamaktadır.

Günümüzde ödeme sistemleri, daha hızlı ve daha verimli işlemlere odaklanarak hızla gelişmeye devam etmektedir. Gerçek zamanlı ödeme sistemleri ve anında ödeme çözümleri, neredeyse anında transferlere olanak tanıyarak ve parasal işlemlerin genel hızını ve rahatlığını artırarak ilgi görmektedir. Bunun yanı sıra, sürdürülebilirlik ilkelerinin finansal sisteme dahil edilmesine yönelik artan bir vurgu olduğu görülmektedir. Yeşil finans girişimleri, çevresel açıdan sürdürülebilir projelere ve teknolojilere yapılan yatırımları teşvik edip iklim değişikliğini ele alarak, para ve kaynakların daha sorumlu ve sürdürülebilir kullanımını teşvik etmektedir.

Düzenleyici çerçeveler, teknolojik gelişmelere ve ortaya çıkan finansal araçlara sürekli olarak uyum sağlamaktadır. Hükümetler ve uluslararası kuruluşlar, tüketicinin korunmasını sağlamak, mali suçların önüne geçmek, finansal sistemlerin istikrarını ve bütünlüğünü korumak için net düzenlemeler oluşturma çabasıdadır. 9 Kasım 2023'te Dubai'de yapılan Ripple Swell etkinliği bu duruma örnek teşkil etmektedir.

Ekonomik değişimler, jeopolitik olaylar ve küresel ticaret dinamikleri her geçen gün paranın değerini ve algısını etkilemeye devam etmektedir. Döviz kurları, para politikaları, ticaret anlaşmaları ve jeopolitik istikrar, küresel sahnede farklı para birimlerinin değerini ve rolünü şekillendirmede kritik rol oynamaktadır. Paranın gelişimi,

teknolojideki hızlı ilerlemeden, değişen tüketici taleplerinden, düzenleyici gelişmelerden, sürdürülebilirliği ve finansal katılımı teşvik etme çabalarından etkilenmektedir. Finansal ortam gelişmeye devam ettikçe bireylerin, işletmelerin ve ekonomilerin gelişen ihtiyaçlarını karşılamak için uyum sağlamak ve yenilik yapmak yeni finansal sistemlere geçişte kilit rol oynamaktadır.

1.2. Kuantum Finansal Sistem

Yakın gelecekte tüm dünyada kullanılması muhtemel yeni finansal sistem olan Kuantum Finansal Sistem (QFS) ise küresel boyuttaki finansal işlemler için kuantum hesaplamalar ile birlikte blok zincir teknolojisini kullanmakta olan ultramodern parasal çerçevedir. Kısaca değinmek gerekirse kuantum hesaplama, karmaşık hesaplamaları inanılmaz bir hızda gerçekleştirmek için kuantum mekaniğinin ilkelerinden yararlanan ve hızla gelişen bir teknolojidir.

Finans bağlamında kuantum finans sistemi, çeşitli finansal süreçlerin verimliliğini, güvenliğini ve doğruluğunu artırmayı amaçlamaktadır. Ek olarak, henüz büyük ölçüde teorik olduğunu ve pratikte görülmediğini söylemek mümkündür. Merkez bankası dijital para birimleri (CDBC'ler), daha hızlı, güvenli, verimli ve şeffaf işlemlere olanak sağlamak açısından fiziksel para yerine dijital alternatifler geliştirmesi nedeniyle söz konusu bu değişimin önemli bir parçası haline gelmiştir. Kuantum bilişim teknolojisi, geniş finansal veri kümeleri üzerinde herhangi bir müdahalede bulunmadan verileri mimariden gerçek zamanlı olarak çekebilmektedir. Bununla birlikte ekonomilerin, piyasaların ve karmaşık olan finansal araçların daha da karmaşık simülasyonlarına olanak tanıyarak minimum sapmaya sahip risk kontrolü, kazançlı ticaret stratejilerinin geliştirilmesi ve portföy optimizasyonu gibi işlemleri üst düzey güvenlik, verimlilik ve şeffaflıkla yapabilmektedir. Kuantum Finansal Sistem'in diğer önemli yönü olan ISO 20022 ise, finansal işlemlerde verimliliğin ve birlikte çalışabilirliğin (küresel ödeme ve finansal mesajlaşma gibi) artırılabilmesi için yeni format bir elektronik veri alışverişi standardıdır (WEB_23). ISO 20022 standardı, her geçen gün CBDC'ler dahil olmak üzere dünya çapındaki diğer finans kurumları tarafından da benimsenmekte olup, bu durum "SWIFT" gibi maliyetli ve zaman sıkıntısı yaratan eski sistemleri etkilemektedir.

Finans alanında kuantum hesaplamanın genel uygulamaları şu şekilde sıralanabilir:

1. **Portföy Optimizasyonu:** Kuantum hesaplama, aynı anda birden fazla değişkeni dikkate alıp çok miktarda veriyi analiz ederek, yatırım portföylerini en iyi hale getirmektedir. Böylelikle daha etkili ve gelişmiş bir risk yönetimi sağlanabilmektedir (Buonaiuto vd., 2023: 1-14).
2. **Opsiyon Fiyatlaması:** Kuantum algoritmaları, opsiyon fiyatlamasında kullanılan karmaşık matematiksel modelleri potansiyel olarak klasik bilgisayarlara göre daha verimli bir şekilde çözebilir. Bu durum da finansal türevlerin daha hızlı ve daha doğru fiyatlandırılmasını sağlayabilir.
3. **Sahtekarlık Tespiti:** Kuantum bilişim, büyük veri kümelerinin hızlı bir şekilde analiz edip sahtekarlık faaliyetlerini gösterebilecek kalıpları belirleme ve dolayısıyla sahtekarlık tespit algoritmalarını geliştirme potansiyeline sahiptir.
4. **Risk Değerlemesi:** Kuantum algoritmaları, büyük miktarda veriyi analiz edip çeşitli senaryoları simüle ederek finansal kuruluşların riskleri daha etkili bir şekilde değerlendirmesine ve yönetmesine yardımcı olabilmektedir.
5. **Kriptografi:** Kuantum hesaplama, güvenli finansal işlemlerin temeli olan kriptografiyi önemli ölçüde etkileyebilir. Hassas finansal bilgileri kuantum bilgisayarların potansiyel saldırılarından korumak için kuantuma dayanıklı şifreleme algoritmaları geliştirilmektedir.

Bununla birlikte, kuantum finans sisteminin hala gelişiminin erken aşamalarında olduğunu ve yaygın biçimde benimsenmeden önce aşılması gereken önemli teknik ve pratik zorlukların bulunduğunu belirtmek bu anlamda önemlidir. Araştırmacılar ve uzmanlar, bu zorlukların üstesinden gelmek için kuantum algoritmaları, donanımları ve güvenlik önlemlerini geliştirmek için çalışmalarını aktif olarak sürdürmektedirler (WEB_24).

1.3. Kripto Paralar

Kripto para birimleri, işlemleri güvence altına almak, doğrulamak ve yeni birimlerin oluşturulmasını kontrol etmek için kriptografi kullanan dijital veya sanal para birimleridir. Merkeziyetsizdirler, yani herhangi bir hükümet veya finans kurumu tarafından kontrol edilmezler ve eşler arası bir ağ üzerinde çalışmaktadırlar.

İlk ve en iyi bilinen kripto para birimi, 2009 yılında Satoshi Nakamoto takma adlı bir grup tarafından yaratılan Bitcoin'dir. O zamandan günümüze kadar, yaygın şekilde altcoin olarak bilinen binlerce kripto para birimi geliştirilmiştir.

Kripto para birimleri, ağ üzerindeki tüm işlemleri kaydeden merkezi olmayan bir defter olan blockchain teknolojisine dayanmaktadır. Her işlem, güvenli ve siber saldırılara karşı dayanıklı bir kayıt oluşturan karmaşık matematiksel algoritmalar kullanılarak doğrulanmakta ve kaydedilmektedir.

Geleneksel para birimlerinin aksine, kripto para birimlerinin fiziksel bir formu yoktur ve herhangi bir hükümet veya kurum tarafından desteklenmemektedir. Bunun yerine, değerleri arz ve talep tarafından belirlenmekte ve fiyatları büyük ölçüde dalgalanabilmektedir. Kullanıcıların farklı kripto para birimleri ticareti yapmasına veya itibari para birimi ile takas etmesine olanak tanıyan kripto para borsalarında satın alınabilir ve satılabilir. Tüccarlar ve işletmeler tarafından kabul edilmeleri hala sınırlı olmasına rağmen, bu durum gün geçtikçe gelişmekte olup mal ve hizmet satın almak için de kullanılabilir. Bu duruma, bazı kripto paralarla Honda (WEB_25), Mercedes (WEB_26), Ferrari (WEB_27) gibi araçların satın alınabiliyor olması örnek teşkil edebilir.

Kripto para birimlerinin avantajlarından biri, işlemler kişisel bilgilerin ifşa edilmesini gerektirmediğinden anonimlik potansiyelidir. Ancak bu, kara para aklama ve uyuşturucu kaçakçılığı gibi yasadışı faaliyetlerde kullanılmalarına da yol açmıştır. Kripto para birimlerinin bir başka avantajı, internet bağlantısı olan herkesin küresel ekonomiye katılmasına izin verdikleri için finansal kapsayıcılık potansiyelidir. Bununla birlikte, oynaklıkları ve regülasyon eksikliği onları riskli yatırımlar haline getirebilir.

Hükümetler ve finans kurumları kripto para birimlerini düzenlemek için çeşitli yaklaşımlar benimsemiştir. Bazıları onları tamamen yasaklarken, diğerleri yasadışı faaliyetlerde kullanımlarını sınırlamak veya yatırımcıları korumak için düzenlemeler getirmiştir.

Genel olarak, kripto para birimleri hem fırsatlar hem de zorluklar sunan nispeten yeni ve hızla gelişen bir teknolojidir. Herhangi bir yatırımda olduğu gibi, kripto para birimlerine yatırım yapmadan önce riskleri ve potansiyel kazançları dikkatli bir şekilde araştırmak ve değerlendirmek önemli bir husustur.

1.4. Para Piyasaları

Para piyasası, likidesi yüksek ve kısa vadeli varlıkların alım satımına yönelik bir finans piyasasıdır (WEB_28). Bununla birlikte iç ve dış ticaret finansmanında önemli bir rol oynamaktadır. Toptan düzeye bakıldığında kurumlar ve tüccarlar arasındaki büyük hacimli işlemleri içerir. Perakende düzeyde ise, bireysel yatırımcılar tarafından satın alınan para piyasası yatırım fonlarını ve banka müşterileri tarafından açılan para piyasası hesaplarını içerir.

Para piyasası yatırımları, sıradan bir tasarruf hesabına göre daha yüksek faiz oranlarıyla güvenlik ve likidite ile karakterize edilir. Söz konusu yatırımlar gecelik rezervler veya ticari senetler gibi kısa vadeli borç ürünlerini kapsamaktadır. Bir birey para piyasası yatırım fonu satın alarak, Hazine bonosu satın alarak veya bir bankada para piyasası hesabı açarak para piyasasına yatırım yapabilmektedir (WEB_29).

Para piyasası küresel finansal sistemin temel dayanaklarından biridir. Merkez bankası politikalarını esnek hale getirmesiyle birlikte ticari bankaların kendi kendine yeterliliğini artırmaktadır (WEB_30).

Devlet iç borçlanma senetleri, menkul kıymetlerin ileriki bir tarihte belirli fiyat üzerinden geri satın alınması taahhüdüyle satılan repo işlemleri, fon toplamak amacıyla ihraç edilen kısa vadeli menkul kıymet olan bonolar para piyasası işlemlerine örnek teşkil etmektedir. Para piyasaları ve CBDC'ler arasındaki etkileşime kısaca değinmek gerekirse, CBDC'ler:

- Dijital ve programlanabilir bir para birimi biçimi sağlayarak para piyasalarındaki işlemleri hızlandırarak kolaylaştırabilmektedir (WEB_31).

- Merkez bankalarına finansal sistemdeki likiditeyi yönetmeleri için doğrudan araçlar sunabilmekte ve bu da potansiyel olarak para piyasalarındaki koşulları etkileyebilmektedir.

- Para piyasalarındaki takas sürecini iyileştirerek, geleneksel takas sistemleriyle ilişkili zaman ve karşı taraf riskini azaltabilmektedir (Blockchain Türkiye, 2022: 18-22).

İKİNCİ BÖLÜM

KRİPTO PARALAR

2.1 Kripto Para ile ilgili Temel Kavramlar

Kripto paraların karmaşık bir genetiğe sahip olması ve sürekli değişen piyasalar nedeniyle konuyla ilgili yapılacak ayrıntılı çalışmalara olan ihtiyaç her geçen gün artmaktadır. Bunun için ise konuyla ilgili teorik yapıtaşlarının sade bir dille anlatımı gerekmektedir. Kripto paralarla ilgili birtakım temel kavramlar ve ayrıntıları maddeler halinde şu şekilde incelemek mümkündür:

Kripto Para (Cryptocurrency): Adını şifreleme anlamına gelen kriptografiden alan, güçlü şifreleme yöntemiyle şifrelenmiş, para piyasalarında takas işlemlerinde kullanılan ve hatta yakın zamanda bazı fiziki ürünlerin (Dogecoin↔Tesla gibi...) de satın alımında kullanımının uygun olduğuna karar verilen dijital para birimine verilen addır. Blok zincir teknolojisine dayalı merkezi olmayan ağlarda çalışır.

Madeni Para (Coin): Bağımsız bir blok zincirine sahip olan kripto para türüdür.

Stabilcoin (Stablecoin): Stabilcoin'ler, itibari para birimi (örn, Türk Lirası) ve bir emtia (örn, altın) gibi bir dayanak varlığa bağlayarak sabit bir değeri korumak için tasarlanmış kripto para birimleridir. Diğer kripto para birimlerine kıyasla daha düşük fiyat oynaklığı sunarlar.

Jeton (Token): Hazırda varolan blok zincirlerinden birine entegre edilerek oluşturulan kripto para türüdür. Genellikle Ethereum blok zincirine entegre olmaktadır. Ürün, hizmet ya da değeri temsil edebilir (WEB_6).

Jeton Yakma: Jeton yakma, jetonların kalıcı olarak kilitlendikleri veya imha edildikleri bir adrese gönderilme durumunu kapsamaktadır. Bu, toplam jeton arzını azaltmak ve potansiyel olarak kıtlığı ve dolayısıyla da değeri artırmak için kullanılmaktadır.

Değiştirilemez Jeton (NFT): Belirli bir öğenin, sanat eserinin, koleksiyon parçasının veya içeriğin sahipliğini temsil eden benzersiz dijital varlıklardır. Dijital sanat ve oyunlarda kullanımından dolayı popülerlik kazanmıştır. Oyun endüstrisi, oyun içi

varlıklar için NFT'leri benimsemiş ve oyuncuların benzersiz öğelere, karakterlere ve deneyimlere sahip olmalarını, takas etmelerini ve satmalarını sağlamaktadır.

Altcoin: Bitcoin dışındaki tüm kripto para birimleridir. Örnekler arasında ilk altcoinler olan Ethereum (ETH), Ripple (XRP), Litecoin (LTC), Dash, Monero (XMR), Dogecoin (DOGE), Stellar (XLM), Bitcoin Cash (BCH) ve diğerleri sayılabilir.

Gaz ve Gaz Ücretleri: Ethereum ve diğer akıllı sözleşme platformlarında gaz, işlemleri gerçekleştirmek için gereken hesaplama çabasını temsil etmektedir. Gaz ücretleri, kullanıcıların işlemleri veya akıllı sözleşmeleri yürütmeleri için madencilere tazminat ödemek için verdikleri ücretlerdir.

Sanal Cüzdan (Virtual Wallet): Mobil cihaz (usb, akıllı telefon, laptop vb...) ve bilgisayarlar gibi elektronik ortamlarda var olan ve kripto para transferinin gerçekleşmesini ya da depolanmasını sağlayan yazılımsal, donanımsal ya da fiziksel bir araçtır. Sanal cüzdanlar büyük-küçük harf ve rakamların kombinasyonundan oluşan çok haneli özel anahtarlardır. İki tür sanal cüzdan vardır. Bunlar; sıcak cüzdan ve soğuk cüzdan olarak adlandırılmaktadır.

Sıcak cüzdan (Hot Wallet): İnternete bağlı, sık yapılan işlemler için uygun ancak daha az güvenli kabul edilen cüzdanlardır.

Soğuk cüzdan (Cold Wallet): Kripto para birimi özel anahtarlarını çevrimdışı olarak güvenli bir şekilde depolayan fiziksel (donanımsal) cihazlar olmakla birlikte, çevrimiçi saldırılara daha az duyarlı olduğu için daha yüksek güvenlik seviyesi sunan cüzdanlardır.

Çoklu İmza Cüzdanlar (Multisig Wallet): Çoklu imza cüzdanlar, işlemi başlatmak için birden fazla özel anahtar imzası gerektirir, bu da güvenliği artırarak yetkisiz erişim riskini azaltmaktadır.

Genel ve Özel Anahtarlar (Public and Private Keys): Genel anahtar, kripto para birimlerinin alındığı bir adrestir. Özel anahtar ise, sahibinin ilgili ortak anahtarla ilişkili kripto para birimlerine erişmesine ve kontrol etmesine izin veren gizli bir koddur.

Kuantum Dirençli Şifreleme: Kuantum bilgisayarların olası potansiyel tehdidine hazırlanmak, dolayısıyla blok zincir ağlarını güvence altına almak için kuantum dirençli kriptografi algoritmaları araştırılıp geliştirilmeye devam etmektedir.

Blokszinciri (Blockchain): Sanal bir ağda gerçekleştirilen ve tamamen şifrelenmiş olan işlemlerin kaydını, takibini, gerekli yerlere bu işlemlerle ilgili bilgi aktarımını sağlayan ve üzerinde herhangi bir müdahale barındırmayan yazılımsal bir sistemdir. Blokszinciri teknolojisi sayesinde yapılan bir işleme ait tüm risk ve maliyetlerin minimizasyonu sağlanmaktadır (Özkul ve Baş, 2020: 63). Blokszincirinde yapılan her türlü alım-satım, takas gibi işlemlerin artması mevcut blokları doldurarak yeni blokların oluşumuna sebebiyet vermektedir. Oluşan her yeni blok kendi ve kendinden önceki tüm bloklara ait olan kodları sisteminde barındırmaktadır. Böylelikle blok zinciri oluşmaktadır. Her bir blok tamamlandığında kendine ait bir “hash” kodu atamakta ve yeni oluşmaya başlayan blok kendinden bir önceki hash kodunu esas alarak kendini biçimlendirmektedir. Bundan dolayıdır ki her bir blok benzersizdir. Blokszinciri üzerinde dijital varlık alma ve gönderme işlemi yapılırken kripto paranın alıcının cüzdanından satıcının cüzdanına aktarılması işlemi (transaction) blokszinciri ağına kaydedilir. Aktarım işleminde transfer ücretleri düşüldükten sonraki bakiye kripto para cinsine göre bir ya da daha fazla onaydan geçerek satıcıya ulaştırılır. Bu aşamada işlem kimliği (transaction id) ile gönderimin durumu (kaç onaydan geçtiği, alıcı ve gönderici kimlikleri gibi bilgiler) kontrol edilebilmektedir.

Genel ve Özel Blok Zincirleri: Herkese açık blok zincirleri herkes tarafından erişilebilir olup, herkesin ağına katılabilmesine izin verir. Özel blok zincirler ise belirli bir grup ya da kuruluşla sınırlı olup kimlerin katılacağı konusunda daha fazla kontrole olanak sağlamaktadır.

İşlemler: Kripto para işlemleri eşler arasındadır, yani aracılara ihtiyaç duymadan doğrudan bir kişiden diğerine gönderilir. İşlemler blok zincirindeki madenciler tarafından doğrulanır ve doğrulandıktan sonra geri alınamaz.

Oynaklık (Volatility): Kripto para birimleri oynaklıkları ile bilinir, yani değerleri hızlı ve öngörülemez bir şekilde dalgalanabilir. Bu, piyasa arz ve talebi, düzenleyici değişiklikler, süregelen mahkemeler gibi faktörlerden kaynaklanmaktadır.

Düzenlemeler (Regülasyonlar): Kripto para birimleri büyük ölçüde düzenlenmemiştir, yani geleneksel para birimleriyle aynı yasa ve düzenlemelere tabi değildirler. Bununla birlikte, dünyanın dört bir yanındaki hükümetler yasadışı faaliyetleri önlemek ve tüketicileri korumak için kripto para birimlerini düzenlemenin yollarını araştırmaya devam etmektedir.

Madencilik (Mining): Madencilik, yeni kripto para birimlerinin oluşturduğu ve işlemlerin blok zincirine eklendiği süreci temsil etmektedir. Bir başka deyişle, blok zinciri üzerinde konumlanmış olan blokların farklı doğrulama yöntemleriyle çözülmesi işlemidir (WEB_32). İş ispatı (Proof of Work (PoW)) sistemlerinde madenciler karmaşık bulmacaları çözmek ve işlemleri doğrulamak için hesaplama gücünü kullanır.

Hash gücü (Hash Power): Madencilik (kazı) yapılarak kripto para bloklarının çözülmesi aşamasında hash gücü ne kadar fazla ise madencilik hızı da o kadar fazla anlamına gelmektedir. Yani bir bloğun kırılması için harcanması gereken saniye bazında hash gücü genel olarak Hash/Saniye olarak gösterilmektedir. Gerekli olan hash gücü, bloğun kırılma zorluğu (dayanıklılığı, direnci) ve madenci sayısı ile doğru orantılı olarak artmakta ya da azalmaktadır. Buna bağlı olarak madencilik yapımına elverişli teknik donanımı yüksek olan bu cihazların enerji tüketimi de doğru orantılı bir şekilde artmakta/azalmaktadır. Söz konusu cihazların hash oranları (hash rate) birbirinden farklı olabilmektedir. Hash oranları arttıkça saniyede yapılan işlem sayısı da artış göstermektedir (WEB_10).

Madencilik yapılan donanımsal cihazların işlemci güçleriyle doğru orantılı olarak hash oranları sırasıyla şu şekilde sınıflandırılmaktadır;

- 1 kH/s, saniyede 1.000 (bin) hash.
 - 1 MH/s, saniyede 1.000.000 (bir milyon) hash.
 - 1 GH/s, saniyede 1.000.000.000 (bir milyar) hash.
 - 1 TH/s, saniyede 1.000.000.000.000 (bir trilyon) hash.
 - 1 PH/s, saniyede 1.000.000.000.000.000 (bir katrilyon) hash.
 - 1 EH/s, saniyede 1.000.000.000.000.000.000 (bir kentilyon) hash.
 - 1 ZH/s, saniyede 1.000.000.000.000.000.000.000 (bir sekstilyon) hash
- (WEB_11).

Hisse İspatı (Proof of Stake (PoS)): Hisse ispatı, doğrulayıcıların teminat olarak pay aldıkları kripto para biriminin miktarına göre bloklar oluşturduğu ve onayladığı alternatif bir fikir birliği mekanizmasıdır. Enerji verimliliği PoW'dan daha yüksek olarak kabul edilir.

İlk Kripto Para Arzı (ICO): Yeni kripto para birimi jetonlarının bir projenin geliştirilmesini finanse etmek için yatırımcılara satıldığı bir bağış toplama yöntemidir. Geleneksel borsadaki halka arz (ilk halka arz) ile benzetilmektedir.

Piyasa Değeri: Bir kripto para biriminin toplam değeridir. Bir madeni paranın mevcut fiyatının toplam dolaşımdaki arzı ile çarpımı sonucu elde edilir.

Tokenomik: Tokenomikler, bir kripto para biriminin ve jetonun ekonomik modelini ve mekanizmalarını ifade eder. Paydaşlara yönelik ihraç, dağıtım, kullanım senaryoları ve teşvikler gibi hususları içerir.

Teknik Doküman (Whitepaper): Bir kripto para birimi projesi tarafından yayınlanan ve teknolojisini, amacını, hedeflerini ve bunlara nasıl ulaşmayı planladığını gösteren ayrıntılı belgedir.

Çatallanma (Fork): Blok zinciri ağları üzerinde beklenmeyen bir problemin ortaya çıkması durumuna karşı alınan tedbir anlamında blok zinciri sisteminin verimini artırmaya ve ağda herhangi bir tıkanıklık varsa gidermeye yönelik yeni fikirlerin ortaya atılmasıyla çatallanma işlemi yapılabilmektedir. Bunun için ağdaki katılımcıların önemli bir kısmının onayından geçmesi gerekmektedir. Çatallanma işlemi kripto paranın değerini direkt olarak etkilemekle kalmayıp aynı zamanda veri zincirinin ikiye ayrılmasına yani iki farklı işleyiş biçimine sahip, iki farklı para biriminin ortaya çıkmasına neden olmaktadır. Bu duruma blokzinciri ağında çatallanma işlemi adı verilmektedir. Çatallanma, veri zincirinin ikiye ayrılması sonucunda ortaya çıkan yeni zincirlerin mimarisine göre ikiye ayrılmaktadır. Bunlar; sert çatallanma (hard fork) ve yumuşak çatallanma (soft fork) olarak iki alt başlıkta incelenebilir (WEB_12).

Zorunlu Çatallanma (Hard Fork): Blok zinciri ağında iyileştirmeye yönelik güncelleme yapılmasının ardından atıl olan bloklar ayrıştırılıp yeni veri zinciri olarak karşımıza çıkmaktadır. Dolayısıyla veri zincirinin ikiye ayrıştırılmasıyla ortaya çıkan yeni veri zinciri (atıl blok) eğer diğerinden farklı ise buna zorunlu çatallanma adı

verilmektedir. Burada ayrışımından itibaren atıl olan blok aktif hale gelerek kendi ayrı sistemine sahip olmaktadır. Her iki veri zincirinde de farklı kurallar geçerli olup farklı işleyiş tarzlarına hakimdirler.

Gönüllü Çatallanma (Soft Fork): Blok zinciri ağındaki iyileştirmeye yönelik yapılan küçük çaptaki, eski sürüme uyumlu iyileştirme işlemine gönüllü çatallanma adı verilmektedir. Gönüllü çatallanmada zorunlu çatallanmada olduğu gibi birbirinden tamamen farklı iki veri zinciri oluşmayıp, çatallanma işlemi sonrasında oluşan yeni veri zinciri, ana blok zinciri ağı bir küme olarak varsayılırsa bu kümenin bir elemanıdır. Kullanıcılar (kripto cüzdan sahipleri ve madenciler gibi) blok zinciri ağındaki güncellemeyi benimsemezler ise eski sürümü kullanmaya devam edebilmekte ve istedikleri zaman yeni sürüme geçebilmektedir.

Yarılanma (Halving): Kripto para madenciliği sırasında kırılan blok başına kazanılan ödül, o madenci havuzunda kaç madenci bulunuyorsa söz konusu madenciler arasında paylaştırılmaktadır. Paylaşılan bu ödülün havuzdaki madenci sayısı belirli bir miktarda arttıkça yarıya düşürülmesine yarılanma adı verilmektedir.

DeFi (Decentralized Finance): Merkezi olmayan finansal yapılara verilen genel bir ad olan “DeFi” kavramı adından da anlaşılacağı üzere yalnızca para transferi olarak değil, herhangi bir otoriteye bağlı olmayan kısa ve uzun vadeli borç alıp verme, borsa, takas gibi işlemlerin yapıldığı finansal bir sistem olarak düşünülmelidir. Söz konusu sistemde merkezi bir otoriteye bağlı olma ihtiyacı duyulmaması yüksek güvenlik düzeyinde olan blok zinciri teknolojisi sayesinde. Fiziki finansal kurumlara ulaşmadaki güçlük ve bu kurumlara olan güvensizlik DeFi sistemlerinin oluşmasına büyük ölçüde katkı sağlamıştır (WEB_8).

Dex (Decentralized Exchange): Merkezi Olmayan Borsa’da yapılan her işlem akıllı sözleşmeler aracılığıyla blok zinciri üzerine kaydedilmektedir. Çünkü yatırımcıların ellerinde bulunan özel anahtarlar ile yapılan akıllı sözleşmeler vb... işlemlerin güvenilir bir şekilde korunması yeni dijital finansal varlıkların oluşumuna katkıda bulunmaktadır (WEB_8).

Fiat on/off Ramps: Kullanıcıların kripto para birimleri ile geleneksel fiat para birimleri arasında dönüşüm yapmalarını sağlayan ve kripto pazarına giriş ve çıkışı

kolaylaştıran platformlardır. Binance, Paribu gibi platformlar buna örnek teşkil etmektedir (WEB_33, WEB_34).

Merkeziyetsiz Otonom Organizasyon (DAO): DAO'lar akıllı sözleşmeler ve jeton sahiplerinin oylarıyla yönetilen kuruluşlardır. Merkezi olmayan karar vermeyi sağlayarak fonları, projeleri ve girişimleri yönetebilirler.

Merkez Bankası Dijital Para Birimleri (CBDCs): Merkez Bankası Dijital Para Birimleri, bir ülkenin merkez bankası tarafından ihraç edilen itibari para biriminin dijital temsilleridir. CBDC'ler kripto para birimlerinin faydalarını geleneksel fiat para birimlerinin istikrarıyla birleştirmeyi amaçlamaktadır (WEB_36).

Yükseltme ve Düşürme (Pump and Dump): Yükseltme ve düşürme şeması, koordineli satın alma yoluyla bir kripto para biriminin fiyatını yapay olarak şişirmeyi ve ardından kar elde etmek amacıyla satış yapmayı kapsamaktadır. Genellikle hileli ve manipülatif faaliyetlerle ilişkilendirilmektedir.

Web 3.0: Kullanıcıların verileri ve etkileşimleri üzerinde daha fazla kontrole sahip olduğu merkezi olmayan bir internet öngörür. Blok zincir ve merkeziyetsiz uygulamalar (Dapps) bu vizyonun temel bileşenleridir (WEB_37).

Kilitleme (Staking): Herhangi bir kripto parayı, sonunda bir ödül kazanmak için, bu ödülün büyüklüğüne doğru orantılı bir süre zarfında kripto cüzdanında bağlamak anlamına gelmektedir. Bağlanan kripto para miktarı dolaşımda olmayacağından arz/talep dengesini sağlamakta ve bu miktar ne kadar çok ise söz konusu kripto paranın fiyatını aynı oranda artırmaktadır. Bir başka açıdan bakıldığında enflasyonun önlenmesi açısından belli miktarlarda kripto paranın dolaşımının sağlanması gerekmektedir ve bu da kilitlenen kripto para miktarına üst sınır konmasını kaçınılmaz kılmaktadır (WEB_8).

2.2. Kripto Para Çeşitleri

Her birinin kendine özgü özellikleri ve amaçları olan binlerce kripto para birimi vardır. Bununla birlikte hepsi de birbirinden farklı temellere dayanmaktadır. Söz konusu temel dayanakları anlamak, bireylerin ve yatırımcıların kripto para ekosistemi üzerindeki amaç ve hedefleriyle birlikte bu amaç ve hedefler doğrultusunda yapacak oldukları potansiyel uygulamaları belirlemelerine bilinçli karar vermeleri hususunda rehberlik etmektedir.

Kripto para birimleri genellikle oluşturulmalarını, işlem doğrulamalarını ve güvenlik özelliklerini yöneten farklı kriptografik algoritmalarla dayanmaktadır. Kripto para ekosisteminde ilk oluşturulan algoritmalar şu şekildedir:

- **Bitcoin (BTC):** 2008 yılında Satoshi Nakamoto tarafından icat edilen ve 2009 yılında açık kaynak kodlu bir yazılım projesi olarak tanıtılan Bitcoin ilk ve en iyi bilinen kripto para birimidir. Kullanıcıların aracılara olmadan doğrudan işlem yapmalarını sağlayan merkezi olmayan, eşler arası bir dijital para birimi olarak oluşturulmuştur. Temeli, blok zincir teknolojisi, kriptografi ve 21 milyon jetonluk sınırlı bir arz sınırı ilkelerinde yatar. SHA-256 algoritmasına dayanmaktadır.

Bitcoin madenciliği sürecinde madenciler, karmaşık matematiksel şifreleri çözmek için güçlü işletim sistemine sahip bilgisayarlar kullanmakta ve sözkonusu şifreleri çözdüklerinde yeni Bitcoin'lerle ödüllendirilmektedir. Bununla birlikte madencilik süreci ağın güvenliğini sağlamaya ve işlemleri doğrulamaya hizmet etmektedir.

Bitcoin sekiz ondalık basamağa kadar bölünebilir ve mikro işlemlere izin verir. Bitcoin'in en küçük birimi, yaratıcısının adını taşımakla beraber "satoshi" olarak adlandırılır ve Bitcoin'in yüz milyonda birini temsil eder.

Bitcoin, tarihinde çeşitli protokol yükseltmeleri ve çatalları geçmiştir. Bu duruma, 2017'de tartışmalı bir forkta ortaya çıkan Bitcoin Cash (BCH) dikkate değer bir örnek teşkil etmektedir (WEB_38).

-**Bitcoin Cash (BCH):** Bitcoin Cash, Ağustos 2017'de ölçeklenebilirlik sorunlarını ele almayı amaçlayan Bitcoin'in zorunlu çatallanmasından ortaya çıkmıştır. Çatallanma, Bitcoin topluluğu içindeki ağı ölçeklenebilirliği ve blok boyutu sınırını artırma yaklaşımıyla ilgili anlaşmazlıklardan kaynaklanmıştır. Bitcoin Cash, blok boyutunu artırarak Bitcoin'in algılanan bazı sınırlamalarını ele almayı ve her blokta daha fazla işlemin yapılmasına izin vermeyi amaçlamıştır. BCH, işlemleri doğrulamak ve ağı güvence altına almak için bir İş Kanıtı mutabakat mekanizması kullanmakla birlikte tıpkı BTC gibi SHA256 algoritmasını kullanmaktadır. Temeli, daha hızlı işlemler ve daha düşük ücretler sağlamak için daha büyük blok boyutlarında yatmaktadır ve onu bir dijital nakit biçimi olarak konumlandırmaktadır (WEB_39).

Bitcoin Cash ve Bitcoin arasındaki temel farklılıklardan biri blok boyutudur. BCH, her blokta daha fazla işlem barındırmak için blok boyutu sınırını 1 MB'dan 8 MB'a ve daha sonra 32 MB'a yükseltmiştir. Böylelikle ağın hızının ve ölçeklenebilirliğinin iyileştirilmesi amaçlanmıştır.

Bitcoin Cash'i oluşturan ilk zorunlu çatallanmadan sonra, Kasım 2018'de başka bir çatallanma gerçekleşmiş ve Bitcoin Cash ABC (Değiştirilebilir Blok Boyutu Üst Limiti) ve Bitcoin Cash SV (Satoshi Vizyonu) arasında bölünme ile sonuçlanmıştır. BCH ABC, ölçeklenebilirliği geliştirmenin orijinal hedeflerini korurken, BCH SV blok boyutlarını daha da artırmaya ve Bitcoin'in ilk günlerinden gelen özellikleri geri yüklemeye çalışmıştır (WEB_40).

- **Ethereum (ETH):** Ethereum 2015 yılında Vitalik Buterin liderliğindeki bir geliştirici ekibi tarafından dünyaya tanıtılan merkezi olmayan bir blok zincir platformu ve kripto para birimidir. Ethereum, akıllı sözleşmelerin ve merkezi olmayan uygulamaların (DApps) oluşturulmasını sağlamak için tasarlanmıştır (WEB_41). Temeli, basit değer transferinin ötesine geçerek programlanabilir blok zinciri platformlarını etkinleştirmede yatar. DApp'lar finans, oyun, tedarik zinciri yönetimi ve daha fazlası gibi çeşitli amaçlara hizmet edebilir. Ethereum'un blok zinciri, kod yürütmeyi ve karmaşık uygulamaların oluşturulmasını desteklemek için tasarlanmıştır. 2022 yılına kadar İş Kanıtı (Proof-of-work(PoW)) mekanizmasıyla birlikte Ethash algoritmasını kullanan Ethereum 2022'den itibaren iş kanıtına kıyasla daha az enerji tüketmesi, daha güvenli olması gibi nedenlerle Hisse Kanıtı (Proof-of-stake(PoS)) algoritmasına geçiş yapmıştır (WEB_42).

Ethereum'un en devrim niteliğindeki özelliklerinden biri akıllı sözleşmeleri destekleme yeteneğidir. Akıllı sözleşmeler, sözleşmenin şartları doğrudan koda yazılmış kendi kendini yürüten sözleşmelerdir. Önceden tanımlanmış koşullar yerine getirildiğinde otomatik olarak yürütürler ve araçlara olan ihtiyacı ortadan kaldırır.

Ethereum Sanal Makinesi (EVM), Ethereum ağında akıllı sözleşmeler yürüten bir hesaplama yazılımıdır. Korunmalı bir ortamda kod çalıştırarak tüm düğümlerde tutarlılık ve güvenlik sağlar (WEB_43).

Ethereum, DeFi uygulamaları için bir merkez haline gelmiştir ve kullanıcıların kripto para birimi varlıklarından borç vermelerine, borç almalarına, ticaret yapmalarına ve faiz kazanmalarına olanak tanımaktadır. Aynı zamanda, benzersiz dijital varlıkların sahipliğini temsil eden NFT'ler için birincil platformdur (WEB_44).

Ethereum Vakfı, Ethereum ekosisteminin gelişimini ve büyümesini destekleyen kar amacı gütmeyen bir kuruluştur. Ethereum'un teknolojisini ve benimsenmesini ilerletmek için hibeler, kaynaklar ve eğitim girişimleri sağlamaktadır (WEB_45).

- **Ethereum Classic (ETC):** Ethereum Classic, 2016 yılında blok zincirinin değişmezliğini ve merkeziyetsizliğini korumaya odaklanan, Ethereum ağından çekışmeli bir çatallanma sonucu ortaya çıkan bir blok zinciri ve kripto para birimidir. Söz konusu çatallanma, merkezi olmayan özerk organizasyon saldırısından sonra meydana gelmiştir. Ethereum topluluğunun bazı üyelerinin, blok zincirinin değişmezliğinin ve sansüre karşı direncinin güvenlik ihlalleri karşısında bile sürdürülmesi gerektiğine inanırken, diğer üyelerle anlaşmazlığa düşmesi sonucu ortaya çıkmıştır. Ethereum Classic, çatallanmadan önce var olan orijinal blok zinciri üzerinde çalışmaya devam ederken, Ethereum yeni blok zincirinde çalışmaktadır. Temeli, orijinal blok zincirinin işlem geçmişinin korunmasına dayanmaktadır (WEB_46).

Ethereum Classic, çatallanma sürecinden sonra da İş Kanıtı (PoW) algoritmasını kullanmaya devam etmiştir. Ek olarak Etchash algoritmasını kullanmaktadır.

- **Ripple (XRP):** Ripple hem bir kripto para birimi hem de hızlı ve uygun maliyetli sınır ötesi işlemleri kolaylaştırmaya odaklanan bir ödeme protokolüdür. Ripple Protocol Consensus Algorithm (RPCA) adı verilen benzersiz bir fikir birliği algoritması üzerinde çalışmaktadır (Schwarz vd., 2018: 7). Temeli, finansal kurumlara uluslararası ödemeleri yerine getirmek için daha verimli bir yol sağlamaktır.

RippleNet, sınır ötesi ödemeleri ve havaleleri kolaylaştırmak için Ripple'ın teknolojisini kullanan finansal kurumlar, bankalar, ödeme sağlayıcıları ve diğer kuruluşlardan oluşan bir ağıdır. RippleNet gerçek zamanlı, güvenli ve uygun maliyetli sınır ötesi işlemler sağlamayı amaçlamaktadır (WEB_47).

Ripple Labs, Ripple platformunun arkasındaki şirkettir. 2012 yılında kurulmuş olup finans sektörü için blockchain tabanlı çözümlerin geliştirilmesi ve tanıtımında önemli bir oyuncu olmuştur.

XRP, Ripple ağının yerel dijital varlığıdır. Ağdaki işlemleri kolaylaştırmak için kullanılır ve farklı fiat para birimleri arasında likidite sağlamak için bir köprü para birimi olarak da kullanılabilir. XRP işlemleri hızlı bir şekilde çalışmakta ve Ripple'ın fikir birliği algoritması ağın bütünlüğünü sağlamaktadır. Söz konusu algoritmaya kısaca değinilecek olunursa Ripple,

işlemleri doğrulamak ve onaylamak için Ripple Protokolü Konsensüs Algoritması (RPCA) adı verilen bir fikir birliği algoritması kullanır. Bitcoin'in iş kanıtı ya da Ethereum'un hisse kanıtının aksine, RPCA kapsamlı hesaplama gücü gerektirmez ve hızlı işlem onayı sağlamak için tasarlanmıştır.

Ripple Labs (şirket) ve XRP (dijital varlık) arasında ayırım yapmak önemlidir. Ripple Labs teknoloji çözümleri geliştirip teşvik etmektedir, XRP ise Ripple ekosisteminde kullanılan yerel dijital varlıktır.

Ripple'in hedeflerinden biri finansal kurumlara likidite çözümleri sağlamaktır. Bu, kurumların farklı fiat para birimleri arasında hızlı ve verimli transferler sağlamak için XRP'yi köprü para birimi olarak kullanabileceği ve birden fazla ara bankaya olan ihtiyacı azalttığı anlamına gelmektedir.

Ripple, teknolojisini entegre etmek ve müşteriler için sınır ötesi ödeme deneyimlerini geliştirmek için dünyanın dört bir yanındaki çeşitli finans kurumları, bankalar ve ödeme sağlayıcıları ile ortaklıklar kurmuştur. Ripple'in teknolojisi, havale ve ödeme süreçlerinin verimliliğini artırmak için bankalar tarafından benimsenmiştir. Bazı finans kurumları, genellikle diğer üyelerle bağlantı kurmak ve uluslararası işlem süreçlerini kolaylaştırmak için RippleNet'i kullanmaktadır.

Ripple, blok zincirleri ve geleneksel ödeme sistemleri dahil olmak üzere farklı defterlerde ödemeleri kolaylaştırmak için tasarlanmış Interledger Protocol'ün (ILP) geliştirilmesinde de yer almıştır. ILP, çeşitli ödeme ağları arasında birlikte çalışabilirliği sağlamayı amaçlamaktadır (WEB_48).

- Litecoin (LTC): Litecoin, 2011 yılında eski bir Google mühendisi olan Charlie Lee tarafından oluşturulan eşler arası bir kripto para birimidir. 2011 yılında kurulmuş olan Singapur kayıtlı Litecoin vakfı, Litecoin'in benimsenmesini ve geliştirilmesini teşvik etme misyonunu benimsemiş kar amacı gütmeyen bir kuruluştur. Vakıf, kalkınma çabaları, eğitim kaynakları ve topluma erişim dahil olmak üzere çeşitli girişimleri desteklemektedir (WEB_49).

Litecoin'in, "Bitcoin'in altına gümüş" olarak yaratıldığı bilinmektedir. Bitcoin ile benzer olacak şekilde tasarlanmıştır, ancak kripto para deneyiminin belirli yönlerini iyileştirmeyi amaçlayan birkaç temel farklılık vardır. Örneğin; Bitcoin'e kıyasla daha hızlı işlem onay (blok oluşturma) sürelerine izin veren farklı bir karma algoritması olan Scrypt algoritmasını

kullanmaktadır. Bu algoritma madencilik için daha fazla bellek ve bilgi işlem gücü gerektirecek şekilde tasarlanmıştır. Litecoin'in temeli, daha hızlı ve daha verimli bir ödeme yöntemi olma fikri üzerine inşa edilmiştir (WEB_50).

Litecoin'in maksimum arzı 84 milyon jetondur. Litecoin'in toplam arzı, onu mikro işlemler ve günlük kullanım için daha uygun hale getirmeyi ve aynı zamanda bir az bulunurluk seviyesini korumayı amaçlamıştır.

Litecoin, blok zincirinin verimliliğini artırmayı ve Lightning Network'ün uygulanmasını sağlamayı amaçlayan Segregated Witness (SegWit) yükseltmesinin ilk benimseyenlerden biridir. Lightning Network, daha hızlı ve daha ucuz zincir dışı işlemleri sağlayan ikinci katman bir çözümdür (WEB_51).

- **Stellar (XLM):** Stellar, 2014 yılında Ripple'ın kurucu ortağı Jed McCaleb tarafından finansal kurumları, ödeme sistemlerini ve bireyleri birbirine bağlayan açık bir ağ oluşturmak amacıyla tasarlanmıştır. Özellikle gelişmekte olan ekonomilerde hızlı ve düşük maliyetli sınır ötesi ödemeleri ve finansal katılımı kolaylaştırmaya odaklanmaktadır. Stellar Consensus Protokolü (SCP) adı verilen bir fikir birliği mekanizması tarafından desteklenmekte olan açık kaynaklı bir blok zinciri üzerine kurulmuştur (WEB_52). Stellar'ın Federe Bizans Anlaşması (FBA), fikir birliği mekanizmasının önemli bir bileşenidir. Düğümlerin federasyonlar halinde gruplandırılmasını sağlayarak geleneksel iş kanıtı sistemlerine kıyasla daha hızlı ve daha verimli bir fikir birliği sağlar (WEB_53). Temeli, dağıtılmış bir borsa ve çeşitli varlıkları temsil eden jeton çıkarma yeteneğini içerir.

Genellikle XLM olarak adlandırılan Lümen, Stellar ağının yerel kripto para birimidir. Ağ içindeki işlemleri ve ödemeleri kolaylaştırmada hayati bir rol oynar ve sınır ötesi işlemler için bir köprü para birimi görevi görür.

Stellar, ağında varlıkların oluşturulmasını ve ihraç edilmesini sağlar. "Çapa" adı verilen kurumlar, fiat para birimleri veya emtialar gibi gerçek dünya varlıklarını temsil eden jetonlar çıkararak geleneksel finansal sistemler ile Stellar ağı arasında köprü görevi görmektedir (WEB_54). Bitstamp, Bittrex, Bybit, Coinbase ve Crypto.Com bu kurumlara örnek gösterilebilir (WEB_55).

Stellar, Stellar Lumens adlı yerleşik programlama dili aracılığıyla akıllı sözleşmeleri ve merkezi olmayan uygulamaları (DApps) destekler. Bu durum geliştiricilerin ağ üzerinde çeşitli finansal uygulamalar oluşturmaya olanak tanır.

Stellar ağının geliştirilmesini ve benimsenmesini destekleyen, kar amacı gütmeyen bir kuruluş olan Stellar Geliştirme Vakfı (SDF), ekosistemin büyümesini teşvik etmek için kaynaklar, rehberlik ve eğitim girişimleri sağlamak için çalışmaktadır.

StellarX, Stellar ağı üzerine kurulmuş ve kullanıcıların çeşitli varlıklarla doğrudan ticaret yapmasına olanak tanıyan, merkezi olmayan bir borsadır. Kullanıcıların ağda yayınlanan XLM ve diğer varlıkları stoklamasına, göndermesine ve almasına olanak tanıyan çeşitli Stellar cüzdanları da mevcuttur. Bunlardan bazıları; LOBSTR, Vibrant, Ledger Live, Trust Wallet (İndirilebilir Cüzdanlar), Kraken, Bitso (Web Cüzdanları), Ledger Nano S ve Trezor (Donanım Cüzdanları)'dır (WEB_56).

Stellar, blok zinciri teknolojisinin yetersiz hizmet alanlarına yardım ve finansal hizmetler sağlama konusunda nasıl yardımcı olabileceğini keşfetmek için Sivil Toplum Kuruluşları (STK'lar) ve insani girişimlerle ortaklık kurmuştur (WEB_57).

- **Dogecoin (DOGE):** Billy Markus ve Jackson Palmer tarafından 2013 yılı Aralık ayında tanıtılan Dogecoin'in temeli, hayır bağışları vb... amaçlara yönelik atılmıştır. Madencilik için "Scrypt hash" algoritmasını kullanmaktadır.

Dogecoin topluluğu, kripto para birimini kullanan bir kültürü, genellikle hayırsever amaçları desteklemek için benimsemiştir. Böylelikle, Dogecoin güçlü bir sosyal yönü olan kripto para birimi olarak tanınmıştır. Topluluğun Kenya'da bir kuyu inşası için, Jamaika kızak takımının kış olimpiyat oyunlarına yaptığı geziyi finanse etmek için ve Naskar yarış arabasına sponsor olmak için fon toplayıp bağışlaması bu duruma örnek gösterilebilir (WEB_58).

Litecoin'in bir çatalı olarak ortaya çıkmış ve başlangıçta standart bilgisayar donanımı kullanılarak madenciliği daha geniş bir kitle için erişilebilir hale getirmek üzere tasarlanmıştır (WEB_59).

Dogecoin piyasaya ilk sürüldüğünde, 100 milyar arza sahip iken madencilik yoluyla söz konusu arz artmıştır.

- **Monero (XMR):** Nisan 2014'te Bitcointalk forum kullanıcısı tarafından bir Bytecoin'in bir çatalı olarak piyasaya sürülmüştür. İlk olarak "BitMonero" ismiyle çatallanmış olup, sonrasında "Monero" adıyla anılmaya başlanmıştır. Monero blok zincirinde gizliliği, anonimliği ve değiştirilebilirliği vurgulamaktadır. Monero, işlemleri doğrulamak ve ağ güvence altına almak için bir İş Kanıtı (PoW) algoritması kullanır. Yani ağ, karmaşık şifreleri çözmek ve blok zincirine yeni bloklar eklemek için hesaplama güçlerini kullanan madenciler tarafından korunur. Temeli, gizli işlemleri sağlamak ve gizliliği ele almak için gelişmiş kriptografik tekniklere dayanmaktadır (WEB_60).

Monero, gönderenin kimliğini gizlemek için "halka imzaları" adı verilen bir teknoloji kullanır. Monero kullanılarak yapılan bir transfer işleminde, işlemi yapan kişinin cüzdanı blok zincirindeki diğer kullanıcıların anahtarlarından bir halka oluşturur. Dolayısıyla halka imzaları ile kimin anahtarının kullanıldığının bilinmemesi söz konusu bu işlemi isimsiz hale getirir. Bununla birlikte Monero, alıcının kimliğini gizlemek için "gizli adresler" kullanır. Bu adresler her işlem için oluşturulur ve kriptografik tekniklerle alıcının gerçek adresine bağlanır (WEB_61).

Monero'nun gizlilik özellikleri, gizliliğin çok değerli olduğu belirli darknet pazarlarında kullanılmasına yol açmıştır (WEB_62). Bununla birlikte, Monero'nun teknolojisinin yasadışı faaliyetlere özel olmadığını ve gizlilik bilincine sahip bireyler ve işletmeler için meşru kullanım durumlarına sahip olduğunu belirtmek gerekir (WEB_63).

- **Tether (USDT):** Tether Limited Şirketi, 2014 yılında Hong Kong merkezli Bitfinex'in yan kuruluşu olarak faaliyetine başlamıştır (WEB_64). Şirket, Tether jetonlarının çıkarılmasından ve bunları destekleyen USD rezervlerinin korunmasından sorumludur. Tether, ABD Doları gibi bir itibari para birimine bağlanarak sabit bir değeri korumak için tasarlanmış bir Stabilcoin'dir. Değişken kripto para piyasasında fiyat istikrarı sağlama ve sabitleme ana hatlarını oluşturur (WEB_65).

İlk olarak Bitcoin ağının üzerinde jeton verilmesine izin veren bir platform olan Omni Layer protokolü kullanılarak Bitcoin blok zincirinde başlatılmıştır. Bununla birlikte Tether, Ethereum (ERC-20) ve diğerleri dahil olmak üzere çeşitli blok zinciri platformlarında çalışacak şekilde genişlemiştir (WEB_66).

- **Dash (DASH):** Ocak 2014'te Evan Duffield tarafından piyasaya sürülen Dash, başlangıçtaki ismi "Darkcoin" dir. Sonrasında isminin daha kullanıcı dostu ve erişilebilir bir

dijital para biçimi olma hedefini yansıması amacıyla “Dash” olarak değiştirilmiştir. “Dijital nakit” kelimesinin kısaltması olan Dash, *anında* ve düşük maliyetli işlemlerle *gizlilik* odaklı bir kripto para birimi olmayı hedeflemektedir. Dash başlangıçta, madenciliği daha erişilebilir ve özel madencilik donanımına karşı dayanıklı hale getirmek için tasarlanmış olan ve birden fazla karma işlevini birleştiren X11 karma algoritmasını kullanmıştır (WEB_67). Algoritma geliştikten sonra ise X11 algoritması olarak bilinen hibrit bir İş Kanıtı (PoW) ve Hisse Kanıtı (PoS) konsensüs mekanizmasını kullanmaktadır. Temeli, ek ağ güvenliği ve yönetişimi için Masternodes gibi özellikleri içerir (WEB_68).

Dash hızlı işlem onayları sunmak için tasarlanmıştır. Bunun için işlem yapmayı işlem onayından ayıran iki katmanlı ağ mimarisinden faydalanmaktadır. Bu durum diğer bazı kripto para birimlerine kıyasla daha yüksek oranda işlem hızına izin vermektedir. Dash’ın sahip olduğu bu iki katmanlı ağ, normal düğümlerle birlikte “masternodes” içermektedir. Masternodes, PrivateSend (Gizlilik Özelliği) ve InstantSend (Anlık İşlem Özelliği) gibi ağa ek hizmetler sağlamaktadır. Masternode operatörleri, ağı destekledikleri için ödüllerle teşvik edilir.

PrivateSend ve InstantSend kavramları biraz daha açılacak olunursa; Dash, blok zincirinde onaylanmadan önce birden fazla kullanıcının işlemlerini karıştırarak kullanıcı gizliliğini artırmayı amaçlayan “PrivateSend” adı verilen bir gizlilik özelliği sunmaktadır. Bu özellik fonların nereden geldiğini ve varış noktasını izlemeyi zorlaştırır (WEB_69). PrivateSend, işlem izini gizlemek için birden fazla işlemi tek bir işlemde birleştirmeyi içeren CoinJoin yöntemine dayanmaktadır. Bu durum, diğer kripto para birimlerine kıyasla daha yüksek derecede gizlilik sağlamaktadır (WEB_70).

Dash’ın InstantSend özelliği ise, birkaç saniye içinde onaylanan, işlemlerin neredeyse anında gerçekleşmesine olanak tanımaktadır. Bu özellik, satış noktası işlemleri ve hızlı onaylamanın gerekli olduğu diğer durumlar için faydalı olabilmektedir.

- **ZCash (ZEC):** Zcash, 2016 yılında yılında Zooko Wilcox-O’Hearn tarafından piyasaya sürülen gizlilik odaklı bir kripto para birimidir (WEB_71). Bitcoin bazlı harf ve sayı kombinasyonlarından (kriptografik anahtarlardan) oluşan bir kod tabanı üzerine kurulmuş dijital altcoinlerden bir diğeridir. Kullanıcılara gelişmiş *gizlilik* ve *güvenlik* özellikleri sağlamak için tasarlanmıştır (WEB_72). Blok zinciri üzerindeki işlemlerin doğrulanmasını ve güvenliğinin sağlanması için Equihash algoritmasına dayalı olarak iş kanıtı (PoW) mekanizmasını kullanmaktadır.

Zcash, gelişmiş gizlilik sağlamak için zk-SNARKs adı verilen bir teknoloji kullanır. Bu, kullanıcıların göndereni, alıcı veya işlem tutarını açıklamadan işlem yapmasına olanak tanır (WEB_73).

Zcash, Bitcoin'e benzer bir arz sınırına sahiptir. Toplam arz, zaman içerisinde enflasyonu kontrol etmeye yardımcı olan 21 milyon madeni para ile sınırlıdır. Bununla birlikte, Zcash madencilik ile çıkarılabilir ve madenciler çabalarının karşılığında yeni oluşturulan ZEC paralarıyla ödüllendirilir. Madencilik süreci, işlemleri doğrulamak ve bunları blok zincirine eklemek için karmaşık matematiksel problemleri çözmeyi içerir.

Ekim 2018'de Zcash, Sapling olarak bilinen önemli bir yükseltme geçirmiştir. Bu yükseltme, güçlü gizlilik özelliklerini korurken verimliliği ve ölçeklenebilirliği artırmayı amaçlamıştır. Sapling, işlem sürelerini azaltmış ve korumalı işlemler için gereken hesaplama kaynaklarını düşürmeye yardımcı olmuştur (WEB_74).

Diğer bazı altcoinlere de kısaca değinmek gerekirse;

Cardano (ADA)'nın temel dayanağı; uzun vadeli sürdürülebilirliğe, güvenliğe ve ölçeklenebilirliğe odaklanmayı, merkezi olmayan uygulamaların ve akıllı sözleşmelerin geliştirilmesi için bir blok zinciri platformu sağlamayı amaçlayan hakemli akademik araştırmalardır (Araştırma odaklılığı olması) (WEB_75).

Binance Coin (BNB)'nin temel dayanağı; 2017 yılında Binance tarafından ilk kripto para arzı yoluyla piyasaya sürülen, borsa ekosistemindeki bir hizmet koinidir (WEB_76). İşlem ücreti indirimleri sunar ve çeşitli kullanım durumlarını destekler (Yardımcı değişim programı olması).

Solana (SOL)'nın temel dayanağı; blok zincirindeki karmaşık akıllı sözleşmeler için, Tarih Kanıtı (Proof of History (PoH)) ile elde edilen yüksek hızlı işlem verimidir (Hızlı işlem gücü olması) (WEB_77).

2.3. Kripto Paraların Genel Özellikleri

Kripto para birimleri, onları geleneksel para birimi biçimlerinden ve finansal sistemlerden ayıran birçok genel özelliği paylaşmaktadır. Bazı temel özellikleri avantaj ve dezavantajlar olarak ayırarak aşağıdaki şekilde sıralamak mümkündür.

Avantajlar

- **Merkeziyetsizlik:** Kripto para birimleri, genellikle blokzincir teknolojisine dayanan merkezi olmayan ağlar üzerinde çalışır. Bu durum, para birimini kontrol eden merkezi bir otoritenin (hükümet veya merkez bankası gibi) olmadığı anlamına gelir. Dolayısıyla işlemler, dünya geneline yayılmış bir düğüm (bilgisayar) ağı tarafından doğrulanır.

- **Blokzincir Teknolojisi:** Kripto para birimleri, bir bilgisayar ağındaki tüm işlemleri kaydeden dağıtılmış bir defter olan blokzincir teknolojisine dayanır. Zincirdeki her blok bir işlem listesi içerir ve bir blok eklendiğinde öncekine bağlanarak güvenli ve şeffaf bir işlem geçmişi oluşturulur.

- **Kriptografi:** Kripto para birimleri, işlemleri güvence altına almak ve yeni birimlerin oluşturulma aşamasını kontrol etmek için şifreleme teknikleri kullanır. Genel ve özel anahtarlar, güvenli işlemleri kolaylaştırmak, verilerin bütünlüğünü ve gizliliğini sağlamak için kullanılır. Bu durum, bilgisayar korsanlarının kripto para birimini çalmasını veya hükümetlerin para birimini manipüle etmesini zorlaştırır.

- **Sınırlı Arz:** Çoğu kripto para biriminin sınırlı bir arzı vardır. Bu durum, oluşturulabilecek maksimum sayıda madeni para veya jeton olduğu anlamına gelir. Örneğin, Bitcoin'in maksimum arzı 21 milyon, Ripple'nin maksimum arzı 100 milyar jetondur. Bu sınırlı arz genellikle enflasyonu kontrol etmek ve değerli metal kıtlığı benzerliğiyle ilişkilendirmek için tasarlanmıştır.

- **Eşler Arası (P2P) İşlemler:** Kripto para birimleri, bankalar gibi aracılara ihtiyaç duymadan kullanıcılar arasında doğrudan işlem yapılmasını sağlar. Bu eşler arası yapı, işlemlerin daha hızlı ve daha uygun maliyetli olmasını kolaylaştırmaktadır.

- **Küresel Erişilebilirlik:** Kripto para birimleri, herhangi bir coğrafi kısıtlamayla karşı karşıya kalmadan, finansal katılımı sağlamakta ve sınır ötesi ticareti kolaylaştırmaktadır. Bununla birlikte 7/24 erişilebilir ve açık kaynak kodlu bir altyapıya sahip olması yatırımcılar açısından şeffaflık ve güven sağlamaktadır.

- **Anonimlik:** Kripto para birimleri, kullanıcıların işlem yaparken anonim kalmasına olanak tanır. İşlemler blokzinciri üzerine kaydedilir ancak kullanıcının kimliği açıklanmaz (WEB_78).

- **Sürekli inovasyon:** Kripto para birimi dünyası süregelen yeniliklerle özdeşleşmiştir. Tüm ekosistemin gelişimine katkıda bulunan yeni projeler, teknolojiler ve uygulamalar sürekli olarak geliştirilmektedir.

Bitcoin için Lightning Network ve Ethereum için çeşitli ölçeklendirme çözümleri gibi Katman-2 çözümleri, ölçeklenebilirlik sorunlarını gidermeyi ve işlem ücretlerini azaltmayı amaçlamaktadır.

Hisse Kanıtı (PoS) ve diğer fikir birliği mekanizmaları, İş Kanıtı (PoW)'na alternatif olarak araştırılmış, enerji tüketimini azaltmayı ve ölçeklenebilirliği geliştirmeyi amaçlamıştır.

Farklı blok zincir ağları arasında sorunsuz iletişim ve varlık transferi sağlamak için çapraz zincir protokolleri ve köprüler geliştirilmektedir.

Dezavantajlar

- **Fiyat Dalgalanmasından Kaynaklanan Dezavantajlar:** Kripto para fiyat dalgalanması, Bitcoin, Ethereum ve diğer kripto para birimlerinin değerindeki hızlı ve öngörülemeyen değişiklikleri ifade eder. Kripto para birimlerinin fiyatları kısa bir süre içinde, hatta bazen dakikalar veya saatler içinde olağanüstü şekilde dalgalanabilir. Bu dalgalanma, piyasa talebi, arz ve talep dengesizlikleri, mevzuat değişiklikleri ve yatırımcı duyarlılığı gibi çeşitli faktörlerden kaynaklanmaktadır. Kripto para birimindeki dalgalanma, yatırımcılar için hem bir fırsat hem de bir risk doğurabilir. Bir yandan kısa sürede önemli kazanımlar elde etme imkanı da sağlayabilir. Öte yandan yatırımcıların dikkatli olmaması halinde önemli kayıplara da yol açabilmektedir. Tesla CEO'su Elon Musk'ın, Dogecoin hakkında birkaç kez tweet atması, söz konusu kripto para birimi için artan ilgiye ve piyasa oynaklığına katkıda bulunmuştur.

- **Enerji Tüketiminden Kaynaklanan Dezavantajlar:** Kripto para madenciliği yüksek işletim sistemleri ve dolayısıyla çok fazla enerji gerektirir. Bu durum da çevre üzerinde olumsuz etkiye sahip olabilmektedir.

- **Eğitim ve Farkındalık Yoksunluğundan Kaynaklanan Dezavantajlar:** Kripto para ekosistemi daha karmaşık hale geldikçe, kullanıcıları riskler, en iyi uygulamalar ve potansiyel ödüller konusunda eğitmek çok önemlidir.

- **Birlikte Çalışabilirlik Karmaşıklığından Kaynaklanan Dezavantajlar:** Farklı blok zincirleri arasında kesintisiz birlikte çalışabilirliğin sağlanması teknik olarak karmaşıktır ve projeler arasında standardizasyon ve iş birliği gerektirir.

- **Ölçeklenebilirlik Sorunlarından Kaynaklanan Dezavantajlar:** Kripto para birimleri popülerlik kazandıkça, bazı blok zincir ağlarında çok sayıda işlemin gerçekleştirilmesindeki sınırlamalar nedeniyle ölçeklenebilirlik sorunları ortaya çıkmaktadır. Parçalama, katman-2 protokolleri ve geliştirilmiş konsensüs mekanizmaları gibi çözümler bu sorunu çözme amaçlamaktadır.

- **Gizlilik ve Düzenleme Uyumsuzluğundan Kaynaklanan Dezavantajlar:** Kullanıcı gizliliği ile mevzuata uygunluk arasında bir denge kurmak, özellikle gizlilik odaklı kripto para birimleri ve platformlar için hâlâ zorlu bir görev olmaya devam etmektedir.

- **Güvenlik Açıklarından Kaynaklanan Dezavantajlar:** Kripto para borsalarının, cüzdanların ve akıllı sözleşmelerin güvenliği, saldırılar ve güvenlik açıkları nedeniyle kritik bir sorun olmaya devam etmektedir. Saldırıları ve güvenlik açıklarını önlemek için sağlam siber güvenlik önlemlerinin ve en iyi uygulamaların sağlanması çok önemlidir.

- **Düzenleme Yetersizliğinden Kaynaklanan Dezavantajlar:** Kripto para birimleri, kara para aklama, dolandırıcılık ve yatırımcıların korunmasıyla ilgili endişeler nedeniyle çeşitli yargı bölgelerinde düzenleyici zorluklarla karşı karşıya kalmıştır. Aynı zamanda yargı bölgeleri arasında büyük farklılıklar bulunması, işletmeler ve kullanıcılar arasında belirsizlik yaratmaktadır. İnovasyon ve tüketicinin korunması arasında bir denge kurmak, düzenleyiciler açısından zorluk oluşturmaktadır.

Kripto para birimlerinin kara para aklama, uyuşturucu kaçakçılığı vb... yasa dışı faaliyetlerde kullanılması dezavantajlarından bir diğeridir. Yasadışı faaliyette bulunan kişi yada grupların platformda faaliyet gösterdiği gerekçesiyle, 21 Kasım 2023'te Binance kurucusu Changpeng Zhao'nun ABD bölge yargıcı Richard Jones tarafından suçlu bulunması sonucu Zhao'nun kripto borsasındaki CEO'luk görevinden istifa etmesi bu duruma örnek gösterilebilir (WEB_79).

Kripto para birimleri herhangi bir merkezi otorite veya hükümet tarafından düzenlenmemektedir; bu da onları dolandırıcılık ve dolandırıcılığa karşı daha duyarlı hale getirebilir.

2.4. Kripto Paraların Değerine Etki Eden Faktörler

Kripto para birimlerinin değerini etkileyebilecek çok fazla faktör bulunmakla birlikte dikkate alınması gereken bazı temel faktörler şu şekildedir:

-Piyasa Talebi ve Arzı: Diğer varlıklar gibi, kripto para birimleri de arz ve talebin temel ilkelerine bağlıdır. Herhangi bir kripto para biriminin arzı sınırlı kalırken o kripto para birimine olan talep artarsa, değer artması kaçınılmazdır. Tam tersi durumda, talep azaldığında ya da arz arttığında ise değer düşeceği öngörülebilir.

-Piyasa Duyarlılığı ve Fomo: Kripto para fiyatları, piyasa duyarlılığından ve yatırımcı psikolojisinden büyük ölçüde etkilenmektedir. Olumlu haberler, ortaklıklar, yetkili otoriteler tarafından sağlanan onaylar gibi durumlar yükseliş duygusu yaratarak fiyat artışlarına yol açabilir. Tam tersi durumda ise, olumsuz haberler, yetkili otoriteler tarafından yapılan kısıtlamalar, bilgisayar korsanlığı ve siber saldırı gibi olayları yada piyasa çöküşleri kullanıcılarda düşüş duygusu yaratarak panik satışı yapmalarına sebep olabilir ve bu durum da fiyat düşüşlerine yol açabilir. Özetle, kaçırma korkusu (FOMO) ve sürü davranışı, spekülatif satın alma nedeniyle hızlı fiyat artışlarına yol açabilir. Benzer şekilde, korku, belirsizlik ve şüphe panik satış ve fiyat düşüşlerini tetikleyebilir.

Düzenleyici Gelişmeler: Hükümet düzenlemeleri ve politikaları kripto para birimlerinin değerini önemli ölçüde etkileyebilir. Bir ülke kripto para birimlerinin kullanımını kısıtlayan ya da yasaklayan düzenlemeler uygularsa, bu durum kripto paraların değerini önemli ölçüde olumsuz etkileyebilir. Öte yandan, hükümetler ya da finansal kurumlar tarafından kabul edilip onaylanması gibi olumlu gelişmeler de kripto para değerinin artmasına yol açabilir.

Teknolojik Güncellemeler ve Yenilik: Bir kripto para biriminin teknolojisinin temelindeki büyük atılımlar, yükseltmeler ve yeni özellikler değerini olumlu yönde etkileyebilir. Ölçeklenebilirlik, güvenlik ve işlevsellikteki iyileştirmeler daha fazla kullanıcı ve yatırımcı çekebilir.

Gerçek Dünya Entegrasyonu: Ödeme işleme, havale, tedarik zinciri yönetimi, kimlik doğrulama ve merkezi olmayan uygulamalar (DApps) gibi gerçek dünya uygulamalarına entegre edilen bir kripto para biriminin benimsenmesi, talebini ve değerini artırabilir.

Geleneksel Finans ile Entegrasyon: Kripto para birimleri ile bankalar gibi geleneksel finans kurumları arasındaki iş birlikleri, kripto paraların geleneksel finansal sistemlere entegrasyonu güvenilirliği, benimsenmeyi ve talebi artırarak değeri etkileyebilir.

Ekonomik Faktörler: Kripto para fiyatları enflasyon, faiz oranları ve ekonomik istikrar dahil olmak üzere makroekonomik eğilimlerden etkilenebilir. Ekonomik kargaşa yaşayan bölgelerde, bazı bireyler devalüasyona karşı bir koruma olarak kripto para birimlerine başvurabilir.

Medya Etkisi: Medyada yer alan haberler ve sosyal medya platformlarındaki tartışmalar, kripto para birimi fiyatlarını önemli ölçüde etkileyebilir. Sosyal medya platformlarındaki haber makaleleri, trendler vb... piyasa duyarlılığında hızlı değişimler yaratabilir. Etkili kaynaklardan gelen olumlu kapsama ve onaylar talebi artırabilir ve fiyatları yükseltebilir.

Piyasa Manipülasyonu ve Balina Faaliyetleri: Kripto para piyasaları, geleneksel finansal piyasalara kıyasla nispeten küçük boyutları nedeniyle manipülasyona karşı hassastır. Pompalama ve indirme planları, koordineli ticaret faaliyetleri ve diğer manipülatif uygulamalar ani fiyat artışlarına ve ardından çökmelere yol açabilir. Bununla birlikte genellikle “Balina” olarak adlandırılan büyük kripto para sahipleri, büyük alım satım emirleri uygulayarak fiyatları etkileme yeteneğine sahiptir. Bu durum ise kısa vadeli fiyat dalgalanmalarına yol açabilir ve piyasa duyarlılığını etkileyebilir.

Rekabet: Kripto para birimleri rekabetçi bir piyasada çalışır. Bir kripto para biriminin başarısı ve yenilikleri diğerlerinin değerini etkileyebilir. Benzersiz özelliklere sahip yeni projeler yatırımcıların dikkatini çekebilir ve fonları diğer kripto para birimlerinden söz konusu yeni projelere aktarabilir.

Makro Piyasa Eğilimleri: Kripto para piyasaları, geleneksel finansal piyasalardaki risk alma ya da riskten kaçınma duyguları gibi daha geniş piyasa eğilimlerinden etkilenebilir. Piyasa belirsizliği zamanlarında yatırımcılar kripto para birimleri gibi güvenli limanlar arayabilir.

Piyasa Oynaklığı: Kripto para piyasalarının doğal oynaklığı, fiyat hareketlerinin daha fazla alım ya da satımı tetiklediği, kendi kendini güçlendiren döngüler yaratabilir. Örneğin; Kripto para piyasasında düşük likidite, daha yüksek fiyat oynaklığına yol açabilir. Büyük alış ya da satış emirleri, likit olmayan piyasalarda önemli fiyat dalgalanmalarına neden olabilir.

Madencilik ve Ağ Güvenliği: İş kanıtı (PoW) kripto para birimlerinde madencilik faaliyeti ve ağ güvenliği fiyatları etkileyebilir. Yüksek madencilik faaliyeti, güçlü ağ katılımını ve güveni yansıtarak fiyatları olumlu yönde etkileyebilir.

Teknolojik Ortaklıklar ve İş Birlikleri: Kripto para projeleri ile teknoloji şirketleri, yeni başlayanlar, yerleşik şirketler ve endüstri liderleriyle yapılan iş birlikleri ya da kurumlar arasındaki ortaklıklar, bir kripto para biriminin potansiyel kullanım durumlarını, güvenilirliğini ve benimsenmesini artırabilir ve bu durum da fiyat artışlarına yol açabilir.

Küresel Olaylar: Yatırımcılar alternatif ararken jeopolitik olaylar, ekonomik krizler ve küresel makroekonomik eğilimler, kripto para birimleri gibi alternatif varlıklara olan talebi, dolayısıyla kripto para birimlerinin değerini etkileyebilir.

Bilgisayar Korsanlığı ve Siber Saldırıları: Kripto para borsalarındaki ya da platformlarındaki güvenlik ihlalleri, saldırılar ve güvenlik açıkları yatırımcıların güvenliğini sarsabilir ve bu da keskin fiyat düşüşlerine yol açabilir.

Ölçeklenebilirlik ve Ağ Tıkanıklığı: Ölçeklenebilirlik sorunları ağ tıkanıklığına ve daha yüksek işlem ücretlerine yol açarak kullanıcı deneyimini etkileyebilir. Dolayısıyla kullanıcılar duruma tepki gösterdikçe potansiyel olarak fiyat değişikliklerine yol açabilir.

Teknolojik Güvenlik Açıkları: Bir kripto para biriminin altında yatan teknolojiye ilişkin güvenlik açıklarının keşfedilmesi, yatırımcıların ağın güvenliği konusunda endişe duymasına, dolayısıyla fiyat düşüşlerine yol açabilir.

Tokenomik ve Dolaşımdaki Arz: Enflasyon oranı ve jeton yakma gibi faktörler de dahil olmak üzere bir kripto para biriminin arzının yönetilme şekli değerini etkileyebilir. Kontrollü enflasyon mekanizmalarına sahip kripto para birimleri daha istikrarlı fiyat artışı yaşayabilir.

Piyasa Borsaları ve Listeleme: İtibarlı kripto para borsalarında listelenmek, bir kripto para biriminin görünürlüğünü ve erişilebilirliğini artırarak potansiyel olarak talebin artmasına ve fiyatların değer kazanmasına yol açabilir.

Geliştirici Etkinliği, İtibarı ve Topluluk Katılımı: Aktif gelişim ve güçlü bir topluluk, bir kripto para biriminin değerine katkıda bulunur. Kendini adanmış bir geliştirici ekip yeni özellikler ve geliştirmeler sunmakla birlikte, bu durum söz konusu ekibin itibarı ve güvenilirliği ile bütünleştiğinde kripto para biriminin değerini olumlu yönde etkileyebilir.

Piyasa Erişilebilirliği ve Kullanım Kolaylığı: Çeşitli platformlar, cüzdanlar ve ödeme yöntemleri aracılığıyla satın alınması, kullanılması ve saklanması kolay kripto para birimleri, erişim ve kullanım kolaylığı nedeniyle daha fazla kullanıcıyı çekerek talebin artmasına ve potansiyel olarak daha yüksek fiyatlara yol açabilir.

CBDC'ler: CBDC'lerin hükümetler ve merkez bankaları tarafından geliştirilmesi ve benimsenmesi, benzer işlevler sunabilecekleri için özel kripto para birimlerine olan talebi etkileyebilir.

Çevresel Faktörler: Belirli iş kanıtı (PoW) kripto para birimlerinin enerji tüketimiyle ilgili çevresel kaygılar, piyasa duyarlılığını ve benimsenmesini etkileyebilir.

Eğitim Girişimleri ve Sosyal Yardımlar: Kripto para birimleri ve blok zinciri teknolojisi hakkındaki eğitim girişimleri ve sosyal yardım çabaları, kripto para birimlerine ilişkin farkındalığı artırarak potansiyel olarak benimsenme ve değer artışını sağlayabilir.

DeFi'ye Katılım: DeFi ekosisteminin ayrılmaz bir parçası olan kripto para birimleri, merkezi olmayan finansal hizmet platformu ve uygulamalarının büyümesine ve benimsenmesine bağlı olarak fiyat değişiklikleri yaşayabilir.

Ağ Yükseltmeleri ve Çatallar: Bir kripto para biriminin temelindeki teknolojinin planlı yükseltmeleri ya da çatalları piyasada belirsizliğe yol açabilir. Bu olayların sonucuna bağlı olarak fiyatlarda dalgalanmalar yaşanabilir.

Jeton Yardımcı Programı ve Kullanım Durumları: Bir kripto para biriminin pratik kullanım durumları ve faydası onun değerini etkileyebilir. Akıllı sözleşmelerin veya sınır ötesi ödemelerin etkinleştirilmesi gibi açık ve çeşitli kullanım alanlarına sahip kripto para birimleri daha fazla talep çekebilir.

Kıtlık ve Yarılanma Durumları: Bitcoin gibi sabit veya azalan arza sahip kripto para birimleri, madenciler için blok ödülünün azaldığı yarılanma (halving) olayları yaşar. Kıtlık kaynaklı bu olay arz ve talep dinamiklerini etkileyebilir.

Riskten Kaçınma: Bazı yatırımcılar kripto para birimlerini geleneksel piyasa risklerine, ekonomik istikrarsızlığa ya da para birimindeki devalüasyona karşı bir koruma olarak kullanır. Buna istinaden geleneksel piyasalar değişken olduğunda kripto para birimlerine olan talep artabilir.

Uzun Vadeli Yatırım Eğilimleri: "HODLing" (varlıkların uzun vadede tutulması) gibi uzun vadeli yatırım stratejilerine artan ilgi, yatırımcıların kripto para birimlerini alıp "tutması" nedeniyle fiyat eğilimlerini etkileyebilir.

Blok zinciri Birlikte Çalışabilirliği: Farklı blok zincirler arasında birlikte çalışabilirliği kolaylaştıran kripto para birimleri, sorunsuz entegrasyon arayan geliştiricilerin ve kullanıcıların dikkatini çekebilir. Bu durum da söz konusu kripto para birimlerine olan talebin dolayısıyla da değerin artmasına yol açabilir.

İlk Kripto Para Arzları (ICOs) ve Jeton Satışları: ICO'lar ve jeton satışları, yatırımcılar yeni jetonların potansiyel değeri hakkında spekülasyon yaptıkça fiyat dalgalanması yaratabilir.

2.5. Kripto Paraların Tarihsel Gelişimi

Kripto para birimlerinin tarihi, Amerikalı bir kriptograf olan David Chaum'un dijital nakit kavramını tanıttığı 1980'lerin başlarına kadar uzanabilir (WEB_80). Ancak ilk kripto para 2009 yılına kadar oluşturulmamıştır. Bundan dolayıdır ki günümüzde, kripto para birimi denildiğinde ilk akla gelen, 2009 yılında ortaya çıkarılan ilk merkezi olmayan dijital para birimi olan Bitcoin'dir. Satoshi Nakamoto takma adını kullanan bir kişi tarafından oluşturulduğu bilinmektedir. Bununla birlikte Quora'dan elde edilen bilgiye göre Ripple CTO'luğu görevini yürüten David Schwartz (JoelKatz takma adlı)'ın ilk Bitcoin geliştiricisi ve topluluk üyesi olduğu görülmektedir (WEB_81)?!

Bitcoin'in bir para biçimi olarak ortaya çıkması, insanların finansal sistemleri algılama ve onlarla etkileşim kurma şeklini değiştirmiştir. Bitcoin, merkezi olmayan, sınırları olmayan ve yenilikçi blok zincir teknolojisine dayanan yeni dijital para kavramlarını ortaya çıkarmıştır.

Bitcoin'in ortaya çıkmasından sonraki yıllarda, her biri kendine özgü özelliklere ve kullanım alanlarına sahip binlerce başka kripto para birimi ortaya çıkmıştır. En popüler kripto para birimlerinden bazıları Bitcoin, Ethereum, Ripple, Tether ve Litecoin'dir.

Bitcoin, herhangi bir aracıya ihtiyaç duymaksızın eşler arası bir elektronik nakit sistemi olarak tasarlanmıştır. Bitcoin'in arkasındaki blok zincir olarak bilinen teknoloji, tüm işlemleri güvenli, şeffaf ve gizliliği koruyabilen bir şekilde kaydeden merkezi olmayan bir defterdir. Bu teknoloji, herhangi bir merkezi otorite tarafından kontrol edilemeyen dijital bir para biriminin oluşturulmasına olanak tanır.

Kripto para birimleri, anonim olmaları nedeniyle yasa dışı faaliyetlerde kullanılmaları, oynaklıkları ve düzenleme eksiklikleri dahil olmak üzere birçok zorlukla karşı karşıya kalmıştır. Buna rağmen, birçok işletme ve bireysel kullanıcının kripto para birimlerini bir ödeme şekli olarak kabul etmesiyle, genel kabul görmeye devam etmektedir. Bunun nedeni ise, kripto para birimlerinin geleneksel finansal sistemleri bozup bireylere daha fazla finansal özgürlük sağlamış olmasıdır. Bundan dolayı birçok ülke kimlik doğrulama, tedarik zinciri yönetimi ve oylama sistemleri de dahil olmak üzere çeşitli uygulamalar için blok zincir teknolojisinin potansiyelini araştırmaktadır. Kronolojik sıralamaya göre kripto para birimlerinin tarihine genel bir bakış:

Öncü Çalışmalar

1980'ler: Kriptografik para ve dijital para birimi fikri araştırmacılar ve bilgisayar bilimcileri tarafından tartışılmıştır. Dikkate değer bir örnek, David Chaum'un elektronik işlemlerde gizliliği sağlamayı amaçlayan "eCash" kavramıdır.

1992 - Şifrepunklar ve İlk Çabalar: Çevrimiçi işlemlerde gizliliği ve güvenliğini sağlamak amacıyla "kriptografi" kullanmakla ilgilenen gizlilik savunucularını, kriptografileri ve teknoloji meraklılarını bir araya getiren "cypherpunk hareketi" ortaya çıkmıştır (WEB_82).

1998: Wei Dai, oluşturma ve işlemleri kontrol etmek için kriptografiyi kullanan bir dijital para sistemi konsepti kavramı olan "b-money" i tanıtmıştır.

1998: Bilgisayar bilimcisi Nick Szabo, yeni birimler oluşturmak için hesaplamalı iş kanıtını kullanan, merkezi olmayan bir dijital para sistemi olan "bit gold" u tanıtmıştır.

Bitcoin'in Doğuşu

2008: Satoshi Nakamoto tarafından "Bitcoin: Eşler Arası Elektronik Nakit Sistemi" başlıklı Bitcoin teknik incelemesi" yayınlanmıştır. Bu yayında, blockchain defterine dayalı merkezi olmayan bir dijital para birimi kavramı tanıtılmıştır.

2009: 3 Ocak'ta, Nakamoto'nun Bitcoin blok zincirinin "Blok 0" olarak da bilinen "Genesis bloğunu" nu çıkarmasıyla "Bitcoin ağı" yayına girmiştir. Bu, ilk kripto para birimi olan Bitcoin (BTC) ağının oluşturulmasına işaret etmiştir.

Altcoinlerin ve Yeniliklerin Yaygınlaşması

2011: Alternatif kripto para birimleri ya da diğer adıyla "altcoinler" ortaya çıkmaya başlamıştır. "Namecoin", alan adı kaydını merkeziyetsiz hale getirmeyi amaçlayan ilk altcoin olarak tanıtılmıştır.

2011: Scrypt algoritmasını kullanan Litecoin Charlie Lee tarafından oluşturulmuştur.

2013: Ripple (XRP), "Ripple Protokolü Konsensüs Algoritması (RPCA)" olarak bilinen, iş kanıtı ve hisse kanıtından farklı olan yeni bir fikir birliği mekanizması tanıtmıştır.

2013: Vitalik Buterin, akıllı sözleşmelere ve merkezi olmayan uygulamalara (DApps) olanak tanıyan bir blok zincir platformu olan "Ethereum" fikrini ortaya atmıştır.

2015: Ethereum'un gelişimi, projenin gelişimini finanse etmek için başarılı bir "toplu satış" (ilk para teklifi veya ICO) ile sonuçlanmıştır.

2017: Kripto para piyasası, Bitcoin'in tüm zamanların en yüksek fiyatına ulaşması ve birçok yeni projenin ICO'ları başlatmasıyla büyük bir boğa koşusu yaşamıştır.

2020'ler – Devam Eden Büyüme ve Evrim

- Kripto para birimleri, şirketler, finans kurumları ve hükümetlerin blok zincir teknolojisini keşfetmesiyle daha fazla benimsenmeye başlamıştır.

- "DeFi" ve "NFT" lerin büyümesi, kripto para birimi alanında yeniliklere yol açmıştır.

2021: Tesla gibi şirketlerin Bitcoin'i bir ödeme şekli olarak kabul ettiklerini duyurmasıyla kripto para birimleri genel ilgi ve benimsenme kazanmıştır. Bununla birlikte Bitcoin madenciliğinde enerji tüketimine ilişkin endişeler de öne çıkmıştır.

2021: DeFi sektörü, blok zincir platformlarında borç verme, borçlanma, likidite madenciliği ve DEX'ler gibi çeşitli finansal hizmetler sunarak genişlemeye devam etmiştir.

2021: NFT piyasasının, dijital sanat, koleksiyonlar ve diğer benzersiz varlıkların tokenize edilip blok zincir platformlarında satılmasıyla birlikte popüleritesi artmıştır.

2021: Ülkeler ve merkez bankaları, kendi ulusal para birimlerinin dijital versiyonları olan CBDC'ler fikrini keşfetmeye başlamıştır.

2022: Bitcoin için ikinci katman çözümü olan Lightning Network, 2022'de düğüm sayısının %50'nin üzerinde artmasıyla önemli bir büyüme kaydetmiştir.

2023: Aralık 2020'de ABD Menkul Kıymetler ve Borsa Komisyonu (SEC) tarafından Ripple'a karşı açılan dava, Temmuz 2023'te yargıç Analisa Torres tarafından XRP'nin bir menkul kıymet olmadığına karar vermesi ve Ripple'ın galibiyetiyle son bulmuştur.

2024: Ocak 2024'te ABD Menkul Kıymetler ve Borsa Komisyonu (SEC), birden fazla spot Bitcoin ETF başvurusunu onaylamıştır. Temmuz 2024'te ise Ethereum ETF'leri onaylanarak borsalarda işlem görmeye başlamıştır. Söz konusu düzenleyici gelişmeler, kurumsal yatırımcıların kripto varlık piyasasına erişimini kolaylaştırmış ve piyasa likiditesinin artmasına katkı sağlamıştır.

2024: Kasım 2024'te gerçekleştirilen ABD Başkanlık seçimlerini kazanan Donald Trump, kripto varlıklar konusunda olumlu bir tutum sergileyerek sektöre yönelik destekleyici açıklamalarda bulunmuştur. Trump yönetiminin "Ulusal Bitcoin Rezervi" oluşturma planı ve kripto varlık ekosistemine yönelik düzenleyici politikaları, piyasalarda güven ortamını pekiştirmiştir. Bu gelişmeler, yatırımcı duyarlılığını artırarak Aralık 2024 itibariyle Bitcoin'in rekor seviyelere ulaşmasına ve XRP gibi bazı ABD merkezli kripto paraların destek seviyelerinin güçlenmesine katkıda bulunmuştur.

2024: Aralık 2024'te Ripple, New York Finansal Hizmetler Departmanı'ndan (NYDFS) RLUSD adlı, ABD doları ile desteklenen stablecoin için düzenleyici onay almıştır. Söz konusu gelişme, XRP ekosisteminin genişlemesine ve kullanım alanlarının çeşitlenmesine katkı sağlama potansiyeline sahip olma niteliğindedir.

2.6. Ticaret ve Finans Sektörlerindeki Dijital Dönüşüm: Kripto Paralar

Ticaret ve finans sektörlerindeki dijital dönüşüm, ticari operasyonların ve finansal hizmetlerin çeşitli yönlerini optimize etmek, geliştirmek ve daha çağdaş hale getirmek için dijital teknolojilerin ve yenilikçi çözümlerin stratejik entegrasyonunu kapsamaktadır. Devam eden bu süreç, geleneksel uygulamaları yeniden şekillendirip; verimliliği, şeffaflığı ve erişilebilirliği teşvik etmektedir.

Giderek dijitalleşen dünyada ticaret ve finans sektörlerinde rekabetçi kalabilmek için yapay zekâ iş birliğiyle birlikte blok zincir teknolojisinden yararlanmak gerektiği kaçınılmaz bir gerçektir. Blok zincir, merkezi olmayan ve şeffaf bir defter sağlayarak ticaret ve finansta devrim yaratmaktadır. Güvenli ve sabote edilmeye karşı dayanıklı kayıt tutmak, işlemlere olan güveni kolaylaştırmak ve dolandırıcılığı azaltmak için kullanılmaktadır. Uygulamalar arasında akıllı sözleşmeler, tedarik zinciri yönetimi ve dijital para birimleri bulunmaktadır. Dijital ödeme çözümleri ve finansal teknoloji (FinTech) şirketlerinin yükselişi, işlemlerin yürütülme şeklini değiştirmiştir. Hız, kolaylık ve erişilebilirlik sunan mobil cüzdanlar, temassız ödemeler, eşler arası transferler ve dijital bankacılık hizmetleri yaygın hale gelmiştir.

Bitcoin ve Stabilcoin'ler gibi kripto para birimleri de dahil olmak üzere dijital para birimlerinin yükselişi, geleneksel fiat para birimlerine alternatiftir. Dijital para birimleri sınır ötesi işlemleri kolaylaştırıp daha yüksek verimlilik ve daha düşük işlem maliyetleri sunmaktadır.

Dijital ticaret çözümleri, işletmelerin küresel ticaret yapma biçimini değiştirmiştir. Dijital ticaret platformları süreçleri ve sınır ötesi işlemleri kolaylaştırmaktadır.

Yapay zekâ (AI) ve makine öğrenimi (ML), tahmine dayalı analitik, kredi puanlaması, dolandırıcılık tespiti ve müşteri hizmetleri için ticaret ve finans alanında uygulanmaktadır. Bu teknolojiler karar verme süreçlerini iyileştirir, risk yönetimini geliştirir ve kişiselleştirilmiş finansal hizmetler sunar.

Büyük veri analitiği, kuruluşların anlamlı içgörüler elde etmek için geniş veri kümelerini işlemesine ve analiz etmesine olanak tanır. Finans alanında risk değerlemesi, müşteri profili oluşturma, dolandırıcılığı önleme ve pazar trendi analizi için kullanılır. Bu bağlamda yapay zekâ algoritmalarından büyük ölçüde yararlanılabilmektedir.

Düzenleyici kurumlar, düzenleyici süreçleri modernize etmek, gözetimi geliştirmek ve finans sektöründe uyumluluğu sağlamak için dijital teknolojileri benimsemektedir. Özellikle finans sektörü karmaşık ve sürekli gelişen düzenleyici ortamlarla karşı karşıyadır. Bu durum regülasyonlar bağlamında özelleştirilen teknolojilerin ortaya çıkarılmasına neden olmuştur ve Regülasyon Teknolojileri (RegTech) çözümleri uyumluluk süreçlerini kolaylaştırmayı, riskleri azaltmayı ve düzenleyici raporlamayı geliştirmeyi amaçlamaktadır (WEB_83).

Kripto para birimleri, ticaret ve finans sektörlerinin dijitalleşmesinde önemli bir rol oynamaktadır. Bu konuyu biraz daha açarak, konuyla ilgili birkaç püf noktaya değinmek gerekirse:

- **Dijital ve Sınır Ötesi İşlemler:** Blok zincir teknolojisi üzerine inşa edilen kripto para birimleri, hızlı ve güvenli dijital işlemlere olanak tanır. Geleneksel bankacılık sistemlerine göre daha hızlı ve potansiyel olarak daha uygun maliyetli bir alternatif sağlayarak sınır ötesi ödemeleri kolaylaştırıp, aracılara olan ihtiyacı azaltmaktadır. Bu durum, özellikle işlem hızının ve maliyet verimliliğinin çok önemli olduğu uluslararası ticarete geçerlidir.

Ticaret ve finans sektörlerinde dijitalleşme bağlamında dijital ve sınır ötesi işlemler, dijital yöntem ve teknolojiler kullanılarak elektronik değer alışverişini veya finansal faaliyetlerin tamamlanmasını ifade etmektedir. Bu, elektronik cihazlar, çevrimiçi platformlar ve dijital finansal araçlar aracılığıyla kolaylaştırılan geniş bir faaliyet yelpazesini kapsar. Dijital ve sınır ötesi işlemlere maddeler halinde kısaca değinmek gerekirse;

- Finansın dijitalleşmesi, çevrimiçi bankacılık hizmetlerinin ve mobil finans uygulamalarının kullanımını kapsar. Kullanıcılar bu dijital platformlar aracılığıyla fon transferleri, fatura ödemeleri ve yatırım faaliyetleri dahil olmak üzere çeşitli finansal işlemleri gerçekleştirebilmektedir.

- Kredi kartları, banka kartları, banka transferleri, çevrimiçi havale hizmetleri, dijital cüzdanlar ve kripto para birimleri dahil olmak üzere çeşitli ödeme yöntemlerini kapsar. Kullanıcı tercihlerine, güvenlik hususlarına ve işlemin niteliğine göre farklı ödeme araçları kullanılır. Yakın Alan İletişimi (NFC) ve QR kodları gibi temassız ödeme yöntemleri de, ödeme cihazları ve terminaller arasında fiziksel temasa gerek kalmadan güvenli ve kullanışlı dijital işlemlere olanak sağlar.

- Para birimi, varlık ya da verilere ilişkin değer elektronik araçlarla transferini içerir. Bu da dijital olarak gerçekleştirilen ödemeleri ve transferleri içerebilir.

- Öncelikle bilgisayarlar, akıllı telefonlar, tabletler ve diğer bağlı cihazlar gibi elektronik cihazlar aracılığıyla gerçekleşir. Çevrimiçi platformlar, web siteleri ve mobil uygulamalar bu işlemlerin gerçekleştiği ortamlar olarak hizmet vermektedir.

- E-ticaret platformları dijital ve sınır ötesi ödemeleri kolaylaştırır ve ticaretin küresel genişlemesine katkıda bulunur.

Sınır ötesi ödemelere yönelik dijital platformların düzenleyici standartlara uyması gerekir. Kara para aklamanın önlenmesi (AML) ve müşterinizi tanıyın (KYC) gerekliliklerine uyum, işlemlerin meşruluğunu ve güvenliğini sağlamak için çok önemlidir.

Dijitalleşme, sınır ötesi işlemleri dolandırıcılıktan ve yetkisiz erişimden korumak için güçlü güvenlik önlemlerinin uygulanmasını vurgular. Şifreleme ve güvenli kimlik doğrulama yöntemleri yaygın olarak kullanılmaktadır.

Genel olarak dijitalleşme, sınır ötesi ödemelerin hızında, verimliliğinde ve erişilebilirliğinde önemli gelişmeler sağlayarak uluslararası finansal işlemleri daha sorunsuz ve kapsayıcı hale getirmiştir. Dijital ödeme altyapısının gelişimi, sınır ötesi finans ortamını şekillendirmeye devam etmektedir.

- Ticaret Finansmanı için Blok Zinciri Kullanımı: Kripto para birimlerinin temelindeki teknoloji olan blok zincir, ticaret finansmanı uygulamaları için kullanılmaktadır. Blok zincir üzerindeki akıllı sözleşmeler, ticari anlaşmaların şartlarını otomatikleştirip uygulayabilmekte, evrak işlerini ve dolandırıcılık riskini azaltabilmektedir. Örneğin; dış ticarete kullanılan mal mukabili, vesaik mukabili, akreditif gibi ödeme yöntemlerine benzer şekilde, ödemelerin hızlandırılması ya da alındıktan sonra malların serbest bırakılması gibi önceden tanımlanmış koşullar yerine getirildiğinde belirli eylemlerin yürütülmesini otomatikleştirip uygulamaktadır. Blok zincir teknolojisinin ticaret finansmanı açısından diğer önemli faydalarına kısaca göz atmak gerekirse;

-Ticaret finansmanı geleneksel olarak akreditifler, konşimentolar ve faturalar dahil olmak üzere önemli miktarda kağıt dokümantasyonu içerir. Blok zincir, bu belgelerin dijitalleştirilmesine ve güvenli bir şekilde saklanmasına olanak tanıyarak kayıp, sahtekarlık ve gecikme riskini azaltır. Bilgiler bir blok zincirine kaydedildiğinde değiştirilemez ve sabote edilmeye karşı dayanıklı hale gelir. Bu özellik, ticaret finansmanı verilerinin bütünlüğünü artırır ve net, değiştirilemez bir işlem geçmişi sağlar.

-Blok zincir, tedarik zinciri ve ticaret finansmanı süreçlerine uçtan uca görünürlük sağlar. Alıcılar, satıcılar, bankalar ve lojistik sağlayıcılar da dahil olmak üzere bir işleme dahil olan tüm taraflar, paylaşılan, senkronize bir deftere erişim sağlayarak bilgi asimetrisini azaltıp iş birliğini geliştirebilmektedir.

-Blok zincirin şeffaflık ve izlenebilirlik özellikleri, ticaret finansmanı işlemlerindeki dolandırıcılık, hatalar ve tutarsızlıklarla ilgili risklerin azaltılmasına yardımcı olmaktadır. Bu, özellikle tarafların farklı yargı bölgelerinde bulunabileceği uluslararası ticarete oldukça önemlidir. Bununla birlikte blok zincir üzerindeki akıllı sözleşmeler uyumluluk süreçlerini otomatikleştirerek işlemlerin ilgili düzenleyici gerekliliklere uymasını sağlayabilir. Bu, belgelerin doğruluğunun onaylanmasını ve uluslararası ticaret kanunlarına uygunluğun sağlanmasını içerebilir.

-Blok zincir teknolojisi, ticaret finansmanı süreçlerini düzene sokarak manuel doğrulama ve mutabakat ihtiyacını azaltabilir. Bu, işlemsel verimliliğe, maliyet tasarrufuna ve daha hızlı ödeme sürelerine yol açabilir.

-Blok zincir daha bağlantılı ve birlikte çalışabilir bir küresel ticaret ağını teşvik eder. Ticaret finansmanında yer alan taraflar ortak bir platformda etkileşime girerek fireyi azaltıp verimliliği artırabilmektedir.

Ticaret finansmanı ekosistemindeki katılımcıları bir araya getirmek için çeşitli blok zincir tabanlı platformlar ve konsorsiyumlar kurulmuştur. Bu platformlar standartlaştırılmış süreçler oluşturmayı, iş birliğini geliştirmeyi ve ticaret finansmanı işlemlerindeki anlaşmazlıkları azaltmayı amaçlamaktadır.

Blok zincirin ticaret finansmanında uygulanması, sektörde uzun süredir devam eden zorluklara çözümler sunan dönüştürücü bir güç olarak görülmektedir. Benimseme devam ederken, endüstriyel anlamda daha geniş uygulamayı kolaylaştırmak için standardizasyon, birlikte çalışabilirlik ve düzenleyici hususlara yönelik çaba sarf edilmektedir.

- **DeFi:** Ticaret ve finans sektörlerinde dijitalleşme bağlamında sıklıkla DeFi olarak anılan Merkezi Olmayan Finans, geleneksel finansal hizmetleri merkezi olmayan bir şekilde yeniden oluşturmak ve yenilemek (dönüştürmek) için blok zincir ve kripto para birimi teknolojilerinin kullanılmasını ifade eder. DeFi, bankalar ve diğer finansal kurumlar gibi geleneksel araçlara güvenmeksizin, onlara olan ihtiyacı ortadan kaldırmayı amaçlar ve bunun yerine finansal işlemleri otomatikleştirmek ve kolaylaştırmak için akıllı sözleşmelere ve blok zincir protokollerine güvenmektedir. Borçlanma, borç verme, ticaret ve diğer finansal hizmetleri sunmaktadır. DeFi'nin konuyla ilgili ayrıntılarını biraz daha genişletecek olursak;

- Finansal varlıkların ve işlemlerin kontrolünün ve sahipliğinin katılımcılardan oluşan bir ağ boyunca dağıtıldığı, öncelikle blok zincir platformları olmak üzere merkezi olmayan ağlarda çalışır. Bu, merkezi kurumlara dayanan geleneksel finansla çalışmaktadır.

- Finansal işlemlerin şeffaflığını, güvenliğini ve izlenebilirliğini sağlamak için dağıtılmış ve değişmez bir defter olan blok zincir teknolojilerinden yararlanır. Blok zincir, önceden tanımlanmış kurallara sahip, sözleşme şartlarının doğrudan koda yazıldığı, kendi kendini yürüten anlaşmaların (akıllı sözleşmelerin) oluşturulmasına olanak tanır.

- Akıllı sözleşmeler DeFi'nin önemli bir özelliğidir. Bu programlanabilir sözleşmeler, önceden tanımlanmış koşullar yerine getirildiğinde bir sözleşmenin şartlarını otomatik olarak yürütür ve uygular. DeFi'ta akıllı sözleşmeler, güvenilir olmayan işlemleri kolaylaştırmakla birlikte geleneksel finansal araçların yerini alabilir, manuel müdahale ihtiyacını azaltarak çeşitli finansal işlevleri otomatikleştirebilir.

- Araçlara ihtiyaç duymadan eşler arası işlemleri teşvik eder. Kullanıcılar, merkezi bir otoriteye bağlı kalmadan finansal varlıklar ile borç verme, borç alma, ticaret yapma veya yatırım yapma işlemlerini gerçekleştirmek için akıllı sözleşmelerle doğrudan etkileşime girebilir.

- DeFi platformları merkezi olmayan borç verme ve borç almayı mümkün kılar. Kullanıcılar, akıllı sözleşmeler aracılığıyla güvenilir ve otomatik bir şekilde teminat sağlayarak faiz kazanmak ya da varlıkları ödünç almak için kripto para birimi varlıklarını ödünç verebilir.

- Kullanıcıların merkezi bir borsaya ihtiyaç duymadan doğrudan birbirleriyle kripto para ticareti yapabilecekleri merkezi olmayan borsaları kapsar. DEX'ler blok zincir ağları üzerinde çalışır ve ticareti kolaylaştırmak için akıllı sözleşmeler kullanır.

- Stabilcoin'ler, genellikle ABD Doları gibi itibari bir para birimi olan istikrarlı bir varlığın değerine sabitlenmiş kripto para birimleridir. DeFi platformları, istikrar sağlamak ve birçok kripto para birimiyle ilişkili oynaklığı önlemek için sıklıkla Stabilcoin'leri kullanır.

- Otomatik Piyasa Yapıcı (AMM)'lar, DeFi platformlarında varlıkların değişimini kolaylaştıran algoritmalarıdır. Likidite havuzlarını ve otomatik fiyatlandırma mekanizmalarını kullanarak çalışır. Aynı zamanda kullanıcıların geleneksel emir defterine güvenmeden ticaret yapmalarına olanak tanırırlar.

- Ticaret ve finans sektörlerindeki dijitalleşme bağlamında, varlıkların jetonlaştırılması, gerçek dünyadaki bir varlığın mülkiyetini veya haklarını bir blok zincir üzerinde dijital jetonlar olarak temsil etme sürecini ifade eder. DeFi bu yenilikçi yaklaşıma, bu yenilikçi yaklaşım da geleneksel olarak likit olmayan varlıkların parçalara ayrılmasına, aktarılabilirliğine ve potansiyel olarak artan likiditesine olanak tanır.

- DeFi platformlarının çoğu, kullanıcıların platformun karar alma sürecine katılmasına izin veren yönetim jetonları yayımlar. Jeton sahipleri, merkezi olmayan protokollerin geliştirilmesi ve yönetimi ile ilgili tekliflere oy verebilir.

- DeFi platformları genellikle internet bağlantısı olan herkes tarafından erişilebilir olup, geleneksel bankacılık altyapısına erişimi olmayanlar da dahil olmak üzere dünyanın dört bir yanındaki bireylere finansal hizmetler sunar.

DeFi yenilikçi çözümler sunarken, akıllı sözleşmelerdeki güvenlik açıkları, düzenleyici belirsizlikler ve açıklardan yararlanma ya da hacklenme potansiyeli gibi zorluklar ve riskleri de beraberinde getirir. Bununla birlikte finansal hizmetlere daha kapsayıcı, açık ve otomatik bir yaklaşım sunarak finans sektöründe bir paradigma değişimini temsil eder. Ancak hızlı büyümesi ve evrimi, aynı zamanda mevzuat, güvenlik ve ölçeklenebilirlik sorunlarının da dikkatli bir şekilde değerlendirilmesini gerektirir.

Blok Zinciri'nin Çeşitli Endüstrilere Potansiyel Etkisi (Gelecek Öngörülleri)

Kripto para birimleri her geçen gün ana akım finansal sistemlere ve kurumlara daha fazla entegre hale gelmektedir. Böylelikle özellikle gelişmekte olan bölgelerde, bankacılığı olmayan ve banka yetersizliği olan nüfuslar için finansal hizmetlere erişim sağlayabilmekle birlikte söz konusu bölgelere sınır ötesi havale göndermek için daha verimli ve uygun maliyetli bir yol sunabilir. Dolayısıyla büyük şirketler, finansal kurumlar ve hükümetler, blok zincir teknolojisini operasyonlarına dahil etmenin yollarını araştırmaktadır. Hükümetler ve merkez bankaları, geleneksel itibari para birimlerine dijital alternatifler olarak merkez bankası dijital para birimlerini (CBDC'ler) aktif olarak araştırmakta ve pilot uygulamalar yapmaktadır.

Dünya genelindeki güncel haberler dikkate alındığında, DeFi ekosisteminin, araçlar olmadan çeşitli finansal hizmetler sunarak büyümeye devam etmesi beklenmektedir. Borç verme, borç alma, merkezi olmayan borsalar ve likidite madenciliği (yield farming) alanındaki yeniliklerin devam etmesi muhtemel görünmektedir. Çünkü DeFi protokolleri, finansal hizmetleri demokratikleştirmeyi amaçlar, kredi verme, borçlanma, likidite madenciliği ve

aracilar olmadan ticarete erişim sağlar. Bu bağlamda DeFi, geleneksel bankacılık sektörünü yeniden şekillendirebilme potansiyeline sahiptir.

NFT'ler büyük bir popülerlik kazanmıştır ve uygulamaları sanatın ötesine geçerek oyun, müzik, koleksiyonlar ve daha fazlasını içerecek şekilde genişlemiştir. NFT'ler, oyuncuların benzersiz oyun içi öğelere, dijital sanat eserlerine, müziğe ve koleksiyonlara sahip olmalarını sağlayarak oyun ve eğlence endüstrilerinde devrim yaratmaktadır. NFT'ler, içerik oluşturuculara ve sanatçılara dijital içerikten para kazanma şeklini değiştirerek dijital eserleri satma ve sahipliği koruma olanağı sağlar. Aynı zamanda blok zincir, fiziksel sanat eserlerinin ve koleksiyon parçalarının kaynağını güvence altına alarak sahtecilik riskini azaltır ve alıcılar ile satıcılar arasındaki güveni artırır. NFT pazarının daha da gelişip çeşitlenmesi beklenmektedir.

Birlikte çalışabilirlik çözümleri giderek daha önemli hale gelecek ve farklı blok zincirlerin sorunsuz bir şekilde iletişim kurmasını ve veri paylaşmasını sağlayacaktır. Çapraz zincir platformları ve köprüler bu birlikte çalışabilirliği kolaylaştıracaktır.

Merkezi olmayan kimlik çözümleri, bireylere kişisel verileri üzerinde daha fazla kontrol sağlama ve merkezi kimlik sağlayıcılarına olan bağımlılığı azaltma konusunda yardımcı olabilir. Ek olarak, devlet hizmetlerine erişimi basitleştirebilir ve kişisel verileri güvence altına alabilir. Bununla birlikte blok zincir tabanlı oylama sistemleri seçimlerde şeffaflığı, güvenliğini ve erişilebilirliği artırarak dolandırıcılık riskini azaltabilir.

Kripto para madenciliğinin çevresel etkisi endişeleri artırmıştır. Enerji açısından daha verimli konsensüs mekanizmalarına geçiş ve yenilenebilir enerji kaynaklarının kullanılması gibi çözümler araştırılmaktadır. Bununla birlikte blok zincir teknolojisi, karbon emisyonlarını izlemek ve doğrulamak, çeşitli sektörlerde sürdürülebilirliği ve hesap verebilirliği teşvik etmek amacıyla kullanılabilir.

Blok zincir teknolojisi, tedarik zincirindeki her adımın değişmez bir kaydını sağlayarak, dolandırıcılığı ve sahteciliği azaltarak tedarik zinciri şeffaflığını artırabilir. Bununla birlikte blok zincir, ürünlerin kökenini ve geçmişini izleyerek tüketicilerin satın alımlarının arkasındaki asıl nedeni ve etik uygulamaların doğrulanmasına olanak tanır.

Blok zincir, sağlık hizmeti sağlayıcıları arasında tıbbi kayıtların güvenli ve izlenebilir şekilde paylaşılmasını sağlayarak hasta verilerinin güvenliğini ve gizliliğini artırabilir. Ek olarak,

araştırmanın bütünlüğünü sağlayarak klinik deney verilerinin yönetilmesi ve doğrulanması sürecini kolaylaştırıp güvence altına alabilir.

Blok zincir mülk sahipliği kayıtlarını basitleştirebilir, evrak işlerini azaltabilir ve hileli işlemleri en aza indirgeyebilir. Bunun yanı sıra, gayrimenkul varlıklarının jetonlaştırılması, bireylerin varlığın tamamını satın almadan mülklere yatırım yapmasına olanak tanıyarak kısmi mülkiyetin yolunu açmış olur.

2.7. Kripto Para ve Fintech

Kripto paralar, kullanıcıların geleneksel finans kurumlarına güvenmeden, internet üzerinden ödeme gönderip almalarını sağlayan bir elektronik nakit biçimi olarak hizmet etmektedir.

Kripto paralar finans ve teknoloji dünyasında çığır açan bir yeniliği temsil etmektedir. Paranın geleceği, merkez bankalarının rolü ve finansal sistemleri yeniden şekillendirme potansiyeli hakkında tartışmalara yol açmıştır. Bununla birlikte, kripto paraların nispeten yeni bir teknoloji olduğunu ve devam eden gelişmelere, düzenleyici değişikliklere ve piyasa dinamiklerine tabi olduğunu kabul etmek önemli bir husustur.

Kripto para birimleri ve Fintech, her iki kavram da finans sektöründeki yenilikçi gelişmeleri temsil etmesinden dolayı birbirine çok yakındır. Fintech, finansal hizmetleri geliştirmek ve kolaylaştırmak için tasarlanmış çok çeşitli teknolojik çözümleri kapsarken, kripto para birimleri değer aktarmanın ve işlemlerin yürütülmesinin yeni bir yolunu sunmaktadır.

Kripto para birimleri, geleneksel ödeme sistemlerine kıyasla genellikle daha hızlı ve daha düşük maliyetlerle, küresel olarak fon transferi için yeni yöntemler sunar. Fintech şirketleri, daha verimli sınır ötesi ödeme çözümleri sağlamak için kripto para birimlerini entegre etmektedir.

Fintech, geleneksel para birimlerini yönetmek için dijital cüzdanları popüler hale getirmiştir. Kripto para birimleri bu konsepti genişleterek kullanıcıların dijital varlıkları cüzdanlarda güvenli bir şekilde saklamasına ve yönetmesine olanak tanımıştır.

Kripto para birimleri, aracıları ve işlem ücretlerini azaltarak sınır ötesi havalesi basitleştirebilir. Fintech platformları, daha uygun maliyetli havale hizmetleri sağlamak için kripto para birimlerinden yararlanabilir.

Çoğu kripto para biriminin temelindeki teknoloji olan blok zincirinin Fintech'te geniş uygulamaları vardır. Kimlik doğrulama, tedarik zinciri yönetimi ve varlık tokenizasyonu gibi alanlarda şeffaflığı, güvenliği ve verimliliği artırabilmektedir.

Kripto para birimleri ile Fintech'in kesişimi, düzenleyici karmaşıklıkları da beraberinde getirir. Kripto para birimleriyle çalışan Fintech şirketlerinin uyumluluğu sağlamak için gelişen düzenlemelere uyum sağlaması gerekir.

Her iki alan da hızlı inovasyonla karakterize edilir. Fintech ve kripto para projeleri arasındaki iş birliği, yeni finansal ürün ve hizmetlere yol açabilir.

Kripto para birimleri ve Fintech, finansal hizmetleri yetersiz hizmet alan nüfuslara yayma, onların bankacılık ve ödeme çözümlerine erişmelerini sağlama potansiyeline sahiptir.

Hem Fintech hem de kripto para birimleri hassas finansal veriler içerir. Kripto para birimlerinin entegrasyonu, kullanıcı bilgilerini korumak, dolandırıcılığı ve güvenlik ihlallerini önlemek için sağlam siber güvenlik önlemleri almayı gerektirir.

CBDC'ler, Fintech alt yapısı içerisindeki geleneksel fiat ve kripto para birimlerinin bir birleşimini temsil etmektedir. Fiat para birimi gibi geleneksel varlıkların değerine sabitlenmiş kripto para birimleri olan Stabilcoin'ler, fiyat istikrarı nedeniyle Fintech uygulamalarında popülerlik kazanmıştır. CBDC'ler ve Stabilcoin'ler arasındaki temel farklılıklardan başlıcalarını sıralamak gerekirse şu şekildedir:

- CBDC'ler izinli (özel) blok zincirleri kullanırken, Stabilcoin'ler tescil gerektirmeyen, açık kaynaklı, izinsiz (genel) blok zincirleri kullanır.

- CBDC'ler hala teorik olarak kabul edilirken, Stabilcoin'ler ABD ve Avrupa'da daha yaygın şekilde yasal sınıflandırma görmektedir.

- CBDC'lerin bir merkez bankası tarafından ihraç edilip yönetilmesi gerekirken, Stabilcoin'ler hem banka dışı kuruluşlar hem de denetime bağlı bankalar tarafından ihraç edilip yönetilebilmektedir.

- CBDC'lerin her ne kadar sınır ötesi kullanılsa da daha çok bölgeye özgü olup, öncelikli kullanım alanı yurt içidir. Stabilcoin'ler ise dünyanın her yerinde satın alınıp kullanılabilir.

- CBDC'ler yüksek olasılıkla yetkili araçlar tarafından yönlendirilen özel bir cüzdanda saklanmak durumunda kalırken, Stabilcoin'ler alım satımı yapılan para birimini destekleyen herhangi bir cüzdanda saklanabilmektedir (WEB_84).

Kripto para birimleri, hız ve maliyet verimliliğine, yüksek erişilebilirliğe sahip olması ve döviz dönüştürme ihtiyacını azaltması nedeniyle bireyler, işletmeler ve hatta hükümetler için daha verimli olmakla birlikte Fintech'in attığı adımlardan biri olan sınır ötesi işlemleri önemli ölçüde etkilemektedir. Bazı Fintech şirketleri, daha hızlı ve daha ucuz sınır ötesi ödeme çözümleri sağlamak için kripto para birimlerini entegre etmiştir. Kraken, Gemini, FalconX, Coinbase, Blockchain.com kripto fintech şirketlerinden bazılarıdır (WEB_85).

Kripto para birimleri ve Fintech arasındaki iş birliğinin gelişmeye devam etmesi ve yenilikçi finansal çözümler ve hizmetlere yol açması muhtemeldir. Bununla birlikte bu iş birliğinin tam olarak gelişebilmesi için düzenleyici belirsizlik ve teknolojik entegrasyon gibi zorlukların ele alınması gerekir. Söz konusu bu tip zorluklar aşıldığında ise Fintech girişimleri ve yerleşik kripto para projeleri arasındaki ortaklıklar, değişen tüketici taleplerine ve teknolojik gelişmelere hitap eden en son çözümlerle sonuçlanabilir.

Her iki alan da gelişmeye devam ettikçe bireylerin ve işletmelerin bu gelişmeler hakkında bilgi sahibi olmaları, potansiyel fayda ve riskleri değerlendirmeleri ve finansal operasyonları ve hizmetleri iyileştirmek için bu teknolojilerden nasıl yararlanabileceklerini düşünmeleri önemlidir.

2.8. Kripto Para Piyasası ve Halka Arzı

Kripto para piyasasında, borsada İlk Halka Arz (IPO)'lar gibi geleneksel halka arzlar bulunmamakla birlikte, kripto para birimlerinin fon toplamak ve halkın katılımını sağlamak için alternatif yöntemleri vardır. Bu yöntemleri şu şekilde inceleyebiliriz:

- **İlk Dijital Para Arzı (ICO):** ICO'lar, kripto para piyasasında popüler bir bağış toplama mekanizması olmuştur. Bir ICO sırasında, bir kripto para projesi ya da girişimi, Bitcoin ya da Ethereum gibi yerleşik kripto para birimleri ve hatta itibari para birimleri karşılığında yatırımcılara kendi jetonlarını ya da madeni paralarını sunar. ICO'lar projelerin geliştirme için fon toplamasına olanak tanır ve yatırımcılara jeton satın alarak projenin ekosistemine katılma fırsatı sunar. Bununla birlikte, ICO'ların, yatırımcının korunması ve mevzuata uygunluk konusundaki endişeler nedeniyle bazı yargı bölgelerinde düzenleyici incelemelerle karşı karşıya kaldığını belirtmek önemlidir.

- **Güvenlik Jetonu Arzı (STO):** STO'lar, kripto para piyasasında düzenlemelere tabi ve geçerli yasalara uyulmasını gerektiren bir halka arz şeklidir. ICO'ların aksine, STO'lar gerçek dünya varlıkları tarafından desteklenen ya da bir şirketteki mülkiyeti temsil eden jetonların ihracını içerir. STO'lar menkul kıymet düzenlemelerine uymak ve yatırımcılara daha fazla yasal koruma sağlamak amacıyla tasarlanmıştır. Bu arz tipi genellikle düzenleyici gözetime tabidir ve belirli menkul kıymet yasalarına uyulmasını gerektirir.

- **İlk DEX Arzı (IDO):** IDO'lar, bireysel ve kurumsal yatırımcıların çeşitli kripto para birimi ticareti yapabileceği, projeler ile yatırımcılar arasında aracı olmadan doğrudan jeton satışlarını içeren platformlardır. Geleneksel bir halka arz olmasa da kripto para birimi projeleri, likiditeyi artırmak ve daha geniş bir pazara erişim sağlamak için jetonlarının saygın borsalarda listelenmesini hedeflemektedir. Saygın bir borsada listelenmek, bir kripto para biriminin görünürlüğünü, işlem hacmini ve potansiyel yatırımcı tabanını artırabilir.

- **İlk Borsa Arzları (IEO'lar):** IEO'lar, ICO'lara alternatif olarak popülerlik kazanmıştır. Bir IEO'da, bir kripto para birimi projesi jeton satışını doğrudan bir kripto para birimi borsasında gerçekleştirir. Borsa, proje üzerinde durum tespiti yapar ve jetonları kullanıcı tabanına sunar. IEO'lar, borsanın jeton satışını kolaylaştırması ve yasal gerekliliklere uyum sağlaması nedeniyle yatırımcılara daha fazla güvenlik, güvenilirlik ve katılım kolaylığı sağlamayı amaçlamaktadır.

- **İkincil Piyasa Ticareti:** Kripto para birimleri piyasaya sürüldükten sonra, özellikle kripto para borsalarında olmak üzere ikincil piyasalarda aktif olarak işlem görürler. Bu borsalar, alıcı ve satıcıların arz ve talep dinamikleri, piyasa duyarlılığı ve diğer faktörlere dayalı olarak kripto para ticareti yapmaları için bir platform sağlar. Yatırımcılar, potansiyel olarak fiyat dalgalanmalarından kar elde etmek amacıyla kripto para birimleri satın almak ya da satmak için ikincil piyasaya katılabilir.

2.9. Kripto Para Endeksi

Kripto para endeksi, belirli bir grup ya da kripto para kategorisinin performansını izlemek ve ölçmek için kullanılan bir araçtır. Genel piyasa hareketini izlemenin ve kripto para piyasasının performansını bir bütün olarak değerlendirmenin bir yolunu sağlar.

Yaygın olarak bilinen bazı kripto para endeksleri arasında Bloomberg Galaxy Kripto Endeksi (BGCI), Crypto20 Endeksi, Nasdaq Kripto Endeksi (NCI) ve Bitwise 10 Kripto Endeksi bulunur. Bu endeksler yatırımcılar, analistler ve tüccarlar tarafından kripto para

piyasaının bir bütün olarak ya da belirli sektörlerin performansını ve eğilimlerini ölçmek için kullanılır.

Kripto para endeksleri, belirli kriterleri karşılayan kripto para birimlerinin birleşiminden oluşur. Bileşim, endeks sağlayıcısına ve spesifik endeks metodolojisine bağlı olarak değişebilir. Bazı endeksler çok çeşitli kripto para birimlerini içerebilirken diğerleri büyük ölçekli kripto para birimleri, DeFi jetonları ya da gizlilik odaklı koinler gibi belirli alt kümelere ya da kategorilere odaklanabilir.

Kripto para endeksleri, endekste her bir kripto para biriminin ağırlığını belirlemek için farklı metodolojiler kullanır. Yaygın ağırlıklandırma yöntemleri arasında, daha büyük kripto para birimlerinin endekste daha yüksek bir temsile sahip olduğu piyasa değeri ağırlıklandırması ve her kripto para biriminin, piyasa değerine bakılmaksızın eşit ağırlığa sahip olduğu eşit ağırlıklandırma yer alır.

Kripto para endeksleri, dahil olan kripto para birimlerinin zaman içindeki fiyat hareketlerini takip eder. Tipik olarak, yüzdelik değişimi ya da performansı hesaplamak için endeksin mevcut değerinin karşılaştırıldığı bir temel değere ya da başlangıç noktasına sahiptir. Bu durum, yatırımcıların ve tüccarların genel piyasa eğilimlerini izlemelerine ve kendi portföyleriyle karşılaştırmalar yapmalarına imkân sağlar.

Bir kripto para birimi endeksine yatırım yapmak, yatırımı birden fazla kripto para birimine dağıtarak çeşitlendirme faydaları sağlar. Bu çeşitlendirme, bireysel madeni paralara ya da jetonlara yatırım yapmayla ilişkili riski azaltmaya yardımcı olabilir. Yatırımcılar, bir endeks aracılığıyla çeşitlendirilmiş bir kripto para portföyüne sahip olarak, herhangi bir kripto para biriminin fiyat oynaklığının genel yatırımları üzerindeki etkisini potansiyel olarak azaltabilir.

Kripto para endeksleri, bir bütün olarak kripto para piyasasının performansı için kriter görevi görür. Yatırımcıların ve fon yöneticilerinin kendi portföy performanslarını karşılaştırabilecekleri bir referans noktası sağlar. Bu onların daha geniş bir pazarda daha iyi mi yoksa daha düşük performans mı sergilediklerini ölçmelerine imkan sağlar.

Kripto para endeksleri, çeşitli yatırım ürünleri için temel kriterler olarak kullanılır. Bunlar, endeks fonlarını, borsada işlem gören fonları (ETF'ler), türev ürünleri ve endeksin performansını kopyalamayı amaçlayan diğer finansal araçları içerebilir. Yatırımcılar, kripto para

birimi endekslerine dayalı olan bu tür yatırım ürünleri aracılığıyla çeşitlendirilmiş bir kripto para portföyüyle karşı karşıya kalabilirler.

Birkaç şirket ve kuruluş kripto para birimi endeksleri sağlamaktadır. Popüler kripto para endeks sağlayıcılarına örnek olarak CryptoCompare, Brave New Coin, Bitwise ve CoinGecko verilebilir. Her endeks sağlayıcısının kendi endeksleri için kendi metodolojisi, seçim kriterleri ve hesaplama metodolojisi olabilir.

Kripto para endeksleri genel olarak popüleritesi, fiyatı, ticaret hacmi ve piyasa değerine göre birkaç kripto paranın ağırlıklı ortalamasının alınmasıyla oluşmaktadır. Büyük endeksler çok daha fazla kripto para çeşidini bünyesinde barındırabilmektedir. Bu endekslerden bazıları; CoinMarketCap, CoinCompare, WorldCoinIndex ve Coingecko gibi platformlardır (WEB_86). Bu bilgilere istinaden kripto para endeksleri şu şekilde sınıflandırılabilir:

- Kripto para birimlerinin piyasa değerine göre hesaplanan Piyasa Değeri Ağırlıklı Endeksler,
- Kripto para birimlerinin ticaret hacmine göre hesaplanan Hacim Ağırlıklı Endeksler,
- Kripto para birimlerinin fiyatına göre hesaplanan Fiyat Ağırlıklı Endeksler,
- Kripto para birimlerinin popülerliğine göre hesaplanan Popülerite Ağırlıklı Endeksler,
- Kripto para birimlerinin her birine eşit ağırlık verilmesine göre hesaplanan Eşit Ağırlıklı Endeksler,
- Kripto para birimlerinin piyasa değeri, ticaret hacmi, fiyatı ve popüleritesine göre hesaplanan Hibrit Endeksler (WEB_87).

Kripto para endeksleri yatırımcılar, tüccarlar, analistler ve finansal kurumlar tarafından kripto para piyasasının genel performansı hakkında bilgi edinmek için kullanılır. Yatırım stratejileri hakkında bilgilendirebilir ve kripto para birimi odaklı yatırım ürünlerinin performansını değerlendirmek için bir kıyaslama sağlamaktadır.

2.10. Kripto Paraların Hukuki Boyutu (Regülasyonlar)

Kripto para regülasyonu ülkeler arasında büyük farklılıklar göstermektedir. Bazı ülkeler kripto paraları yasal bir ödeme şekli olarak kabul ederken, diğerleri birtakım kısıtlamalar ve yasaklar getirmiştir.



Şekil 1. Dünya Geneline Kripto Para Regülasyonları (WEB_88)

Dünya genelinde kripto para birimi ile ilgili düzenlemelere bakıldığında; ABD, Kanada, Singapur, Güney Kore, Çin, Hindistan, Birleşik Krallık, Malta, Estonya, Cebelitarık, Lüksemburg gibi ülkelerde kripto paralar yasal ödeme aracı olarak kabul edilmemektedir. Avusturalya ve Japonya gibi ülkelerde ise yasal ödeme aracı ve mülk olarak kabul edilmektedir. İsviçre’de yasal ve bazı durumlarda ödeme aracı olarak kabul edilebilir. Avrupa Birliği’nde yasaldir; fakat AB üyesi devletler yasal düzenlemeler çerçevesinde kendi kripto paralarını tanıtamamaktadır. Latin Amerika’da ise ülkeye göre yasal düzenlemeler değişmektedir.

Kripto para borsalarıyla ilgili dünya çapındaki düzenlemelere bakıldığında ise; ABD’de borsalar yasal olmakla birlikte, düzenlemeler eyalete göre değişmektedir. Kanada’da borsalar yasal ve 1 Haziran 2020’den sonra Kanada Finansal İşlemler ve Raporlar Analiz Merkezi (FinTRAC)’ne, Singapur’da borsalar yasal ve Singapur Para Otoritesi (Monetary Authority of Singapore (MAS))’ne, Avustralya’da borsalar yasal ve Avustralya İşlem Raporları ve Analiz Merkezi (AusTRAC)’a, Japonya’da borsalar yasal ve Finansal Hizmetler Ajansı (FSA)’na, Güney Kore’de borsalar yasal ve Finansal

Denetleme Hizmeti (FSS)'ne, Birleşik Krallık'ta borsalar yasal ve Mali Davranış Otoritesi (FCA)'ne, İsviçre'de borsalar yasal olup İsviçre Federal Vergi İdaresi (SFTA) tarafından denetlenmektedir ve İsviçre Finansal Piyasa Denetleme Otoritesi (FINMA)'ne kayıtlı olmak gerekmektedir. Ek olarak İsviçre'de 2021 yılında Dağıtılmış Defter Teknolojisi (DLT) yasası uygulamaya konulmuş olup, böylelikle bu alandaki yeniliklerden yararlanmak amaçlanmıştır. Çin'de kripto para borsaları yasadışı olarak kabul edilmektedir. Hindistanda düzenlemeler değerlendirilmektedir. AB'de üye olan devlete göre değişen düzenlemeler mevcuttur. Malta'da yasaldir ve Sanal Finansal Varlıklar (VFA) yasasına göre düzenlenmektedir. Estonya'da yasaldir ve Mali İstihbarat Birimi'ne, Cebelitarık'ta yasal ve Cebelitarık Finansal Hizmetler Komisyonu (GFSC)'na, Lüksemburg'da yasal ve Finans Sektörü Denetleme Komisyonu (CCSF)'na kayıtlı olmak gerekmektedir. Latin Amerika'da düzenlemeler nadir olmakla birlikte yasal mevzuat ülkelere göre değişmektedir (WEB_88).

Ülkeler arasında değişen farklı düzenlemeleri takiben birçok düzenleyici çerçeve için ortak olan bazı genel eğilimler ve ilkeler de mevcuttur. Bunlardan bazıları:

- Bazı ülkeler, belirli kripto para türlerine ya da ilk dijital para arzlarına (ICO) doğrudan yasaklar, kripto para madenciliği ya da ticari faaliyetlere ilişkin kısıtlamalar gibi kripto para birimleri konusunda daha katı düzenlemeler uygulamaktadır. Kripto para birimlerinin resmi olarak yasak olduğu ülkelere Cezayir, Bangladeş, Çin, Mısır, Irak, Fas, Nepal, Katar ve Tunus örnek gösterilebilir (WEB_89).

- Hükümetler genellikle kripto para birimi alanında tüketicileri korumak için önlemler uygulamaktadır. Söz konusu önlemler, dolandırıcılığın önlenmesine, risklerin şeffaf bir şekilde açıklanmasına ve adil olmayan uygulamalarının yasaklanmasına ilişkin düzenlemelerden oluşur. Bazı ülkeler, özellikle kripto para birimiyle ilgili faaliyetleri denetlemekle görevli düzenleyici kurumlar kurmuştur.

- Kripto para birimlerinin küresel doğası göz önüne alındığında, uluslararası düzenlemeleri koordine etmek için FATF (Financial Action Task Force) gibi kuruluşlar, kara para aklama ve terörizmin finansmanı ile mücadele için öneri ve yönergeler sunarak bölgesel düzenleyici yaklaşımları etkilemektedir. Örneğin; FATF'ın 2023 Ekim ayında sunduğu yayınına göre Kore Demokratik Cumhuriyeti, İran ve Myanmar yüksek riskli bölgeler arasında yer almaktadır (WEB_90).

- Kripto para birimleri geleneksel bir para birimi yerine, bir varlık olarak ele alınmaktadır. Bu durum, kripto para birimlerinin sermaye kazancı ve madencilik faaliyeti vergilerine, raporlama gereksinimlerine ve diğer yatırım ya da varlık türleri için geçerli olan düzenlemelere bağlı olduğu anlamına gelmektedir. Örneğin, 26/10/2023 tarihinde Investing.com’da yayınlanan habere göre, Türkiye 2024 Cumhurbaşkanlığı Yıllık Programı’nda kripto varlıklara vergilendirme getirileceği yönünde maddelerin yer aldığı bildirilmiştir (WEB_91).

- Kripto para borsalarının ve diğer hizmet sağlayıcıların finansal düzenleyicilere kaydolmasını, belirli kural ve standartlara uymasını gerektirmektedir. Bu kurallar, müşteri tanımlama (KYC) ve kara para aklamayı önleme (AML) prosedürlerine ilişkin gereklilikleri, dolandırıcılığı, terörün finansmanını ve diğer yasadışı faaliyetleri durdurmak için gerekli önlemleri almaya yöneliktir.

Kara para aklama, terörizm finansmanı gibi yasadışı faaliyetlerin önlenmesi için yapılması gereken birtakım çalışmalar:

- Blok zincir işlemlerini analiz etmek ve fonların hareketini izlemek için *özel yazılım araçlarının geliştirilmesi*yle düzenleyici kurumların şüpheli faaliyetleri tespit etme olasılıkları artar.

- Hükümetler, düzenleyici kurumlar, kripto para kuruluşları ve finans kurumları birbirleriyle *bilgi paylaşımını artırarak iş birliği* içerisinde çalışmalıdır.

- Herhangi bir yasa dışı faaliyet durumu anında gerekli önlemlerin alınabilmesi için, geleneksel finansal kurumların bulut yazılıma geçip büyük veri kullanımlarını artırarak tamamen dijital bir ortamda sistemlerini standartlaştırmaları ve diğer kuruluşlarla *tam entegrasyonu* sağlaması gerekir.

- Blok zincir projelerinin şeffaflık ve gizlilik özelliklerini geliştirmekle, gizlilik ve yasadışı faaliyetleri önlemek arasında bir *denge* kurmaları gerekmektedir.

- Kullanıcıların, kripto para birimleriyle yasadışı faaliyetlerde bulunmanın riskleri hakkında bilgilendirilmesi için kamuoyu bilinçlendirme kampanyaları ve *eğitim* çalışmaları yürütülmelidir (WEB_92).

ÜÇÜNCÜ BÖLÜM

YAPAY ZEKÂ VE KRİPTO PARA

3.1. Yapay Zekâ (AI)

Yapay zekâ, görsel algı, konuşma anlama, öğrenme, akıl yürütme ve problem çözme gibi işlevleri yerine getirebilen akıllı makinelerin geliştirilmesine odaklanan bir bilgisayar bilimi alt dalıdır. Tüm bu işlevleri yerine getirirken matematik, fizik, felsefe, mühendislik, bilgisayar bilimleri vb... birçok bilim dalından faydalanmaktadır. Yapay zekâ algoritmaları ise makine öğrenimi, yapay sinir ağları, derin öğrenme, doğal dil işleme ve bilgisayarlı görü gibi yöntemleri kullanarak bireylerin bilişsel süreçlerini taklit etmek ve deneyimlerden öğrenmek için tasarlanmıştır. Dar kapsamlı (zayıf) ve geniş kapsamlı (güçlü) yapay zekâ olmak üzere ikiye ayrılır. Bunlar;

- **Dar Kapsamlı Yapay Zekâ (Zayıf):** Sanal kişisel asistanlar, görüntü tanıma ya da dil çevirisi gibi belirli bir uygulama için tasarlanmış ve eğitilmiş yapay zekâ sistemidir. Iphone'daki "Siri" özelliği, Chrome'daki görsel arama özelliği ve Google'ın çeviri ve çevirirken konuşabilme özelliği bu tür yapay zekâ sistemine örnek gösterilebilir.

- **Geniş Kapsamlı Yapay Zekâ (Güçlü):** İnsan düzeyinde algılayıp anlama, öğrenme ve geçmiş deneyimleriyle karşılaştırıp akıl yürüterek bilgiyi çeşitli durumlarda uygulama yeteneğine sahip olan varsayımsal yapay zekâdır (WEB_93).

3.1.1. Yapay Zekâ Alanları

AI, insan zekâsı gerektiren işlevleri yerine getirebilecek akıllı sistemler oluşturmayı amaçlayan çeşitli yöntemleri barındırır. Bunlar arasında uygulamada en çok rastlanılanlara ilişkin kısaca bilgi vermek gerekirse:

- **Sembolik Yapay Zekâ:** "Klasik AI" olarak da bilinen sembolik yapay zekâ, yapay zekâda bilginin sembolik temsiline dayanan bir yaklaşımı ifade eder. Verilerden istatistiksel öğrenmeye daha çok odaklanan sinir ağları gibi diğer yapay zekâ paradigmatlarıyla çelişir. Sembolik yapay zekâ, bilgiyi temsil etmek için sembollerin kullanılmasıyla, akıl yürütme ve problem çözme için mantık temelli kuralların uygulanmasıyla diğer yapay zekâ türlerinden ayrılır.

- **Sibernetik Yapay Zekâ:** Kontrol teorisi ve geri bildirim mekanizmalarının ilkelerinden ilham alan akıllı sistemler oluşturmaya odaklanan yapay zekâ ve sibernetiğin

kesişimini ifade eder. Sibernetik, sistemlerin düzenlenmesini ve kontrolünü araştıran, genellikle bir sistem ile çevresi arasındaki geri bildirim döngüsünü vurgulayan çok disiplinli bir alandır. Yapay zekâya uygulandığında, sibernetik ilkeler kendi kendini düzenleyen ve uyum sağlayan akıllı sistemlerin geliştirilmesine rehberlik eder.

- **Uzman Sistemler:** Uzman Sistemler, belirli bir alandaki bir uzmanın karar verme yeteneğini taklit eden bilgisayar programlarıdır. Bu sistemler, bireylerin uzmanlığından elde edilen bilgiler ve kurallardan oluşan bir veri tabanından yararlanarak karmaşık sorunları çözmek, tavsiyelerde bulunmak ya da karar vermek üzere tasarlanmıştır. Bu konu, yapay zekâ alanında önemli bir gelişmedir ve uzmanlık bilgisi gerektiren görevler için çeşitli endüstrilerde yaygın olarak kullanılmaktadır (WEB_94).

- **Bulanık Mantık:** Bulanık Mantık, belirsizliğin mevcut olduğu durumlarda akıl yürütme ve karar verme ile ilgilenen matematiksel bir çerçevedir. "Doğru" ya da "yanlış" dünyasında çalışan klasik ikili mantığın aksine bulanık mantıkta, 0 ile 1 arasındaki değerler doğruluk derecelerini temsil eder. Dolayısıyla bulanık mantık belirsiz olan karmaşık sistemlerin modellenmesinde en uygun yapay zekâ yöntemidir.

- **Genetik Algoritmalar (GA):** Genetik Algoritmalar, doğal seçim ve genetik sürecinden ilham alan optimizasyon ve arama algoritmalarıdır. 1960'larda John Holland tarafından geliştirilen ve 1980'lerde David Goldberg tarafından popüler hale getirilen genetik algoritmalar, optimizasyon ve arama problemlerine yaklaşık çözümler bulmak için tasarlanmıştır. Belirli bir probleme yönelik uyum gücünü geliştirmek için çözümleri birbirini izleyen nesiller boyunca geliştirerek, potansiyel çözümlerden oluşan bir popülasyon üzerinde çalışırlar.

- **Genetik Programlama (GP):** Genetik Programlama (GP), biyolojik evrim ve doğal ayırmadan esinlenen evrimsel bir hesaplama tekniğidir. 1990'larda John Koza tarafından tanıtilen genetik programlama, ağaç yapıları olarak temsil edilen çözümleri ya da bilgisayar programlarını geliştirecek şekilde genetik algoritmaların ilkelerini genişletir. Belirli bir görevi gerçekleştirmek ya da belirli bir sorunu çözmek üzere bilgisayar programı popülasyonlarının geliştirildiği otomatik bir programlama şeklidir.

- **Bilgisayarlı Görü:** Bilgisayarlı görü, bilgisayarların dijital görüntülerden üst düzey öğrenme gücü kazanmasını sağlayan çok disiplinli bir alandır. Makinelerin görsel bilgileri yorumlamasına, insan görüşünü taklit etmesine ve görsel verilere dayalı kararlar


vermesine izin veren algoritmaların ve sistemlerin geliştirilmesi bilgisayarlı görünüm kapsamındadır. Bilgisayarlı görü, görüntü ve video analizinden nesne algılama, yüz tanıma ve otonom sistemlere kadar çeşitli uygulamalarda önemli bir rol oynar.

- **Doğal Dil İşleme (NLP):** Yapay zekânın, bilgisayarlar ve insanlar arasındaki doğal dil aracılığıyla etkileşimine odaklanan bir alt alanıdır. NLP'nin amacı bilgisayarların, insan dilini hem anlamlı ve alakalı bir şekilde anlamasını, yorumlamasını ve insan dilinin ürettiklerini üretmesini sağlamaktır. NLP, insanlar ve makineler arasındaki iletişimi kolaylaştıran bir dizi teknik içerir. Sohbet robotları, dil çevirisi ve duygu analizi gibi uygulamalarda kullanılır.

- **Örüntü Tanıma:** Örüntü tanıma, yapay zekâ ve bilgisayar biliminin daha geniş kapsamı içerisinde yer alan ve veri içindeki örüntülerin tanımlanmasını, yorumlanmasını ve sınıflandırılmasını içeren bir alandır. Amaç, verilerdeki kalıpları tanımak ve tanımlanmış bu kalıplara dayanarak bilinçli kararlar vermektir. Örüntü tanıma, bilgisayarlı görü, makine öğrenimi, sinyal işleme ve diğer ilgili alanları kapsayan çok disiplinli bir alandır.

3.2. Yapay Zekâ Tahmin Yöntemleri

Yapay zekâ ile ilgili yapılacak olan herhangi bir tahmin aşamasında yararlanılan alt alanlar; makine öğrenimi, yapay sinir ağları, derin öğrenmedir.



Şekil 2. Yapay Zekâ Alt Alanları

Makine Öğrenmesi (ML): Veriler arasında sınıflandırma yapıp veriler üzerinden tahminlerde bulunan ve zaman içerisinde bu verilerin performanslarını iyileştirmek amacıyla oluşturulan sistemleri içeren bir yapay zekâ alt alanıdır. Makine öğrenmesi, sağlık hizmetleri, finans ve otonom sistemler de dahil olmak üzere çeşitli alanlarda uygulanmaktadır. Makine öğrenimi türleri arasında ise denetimli, denetimsiz, yarı denetimli, kendi kendine denetimli ve pekiştirmeli öğrenme bulunmaktadır.

Denetimli öğrenmede algoritma, her girdinin doğru çıktı ile ilişkilendirildiği belirli bir veri kümesi üzerinde eğitilir. Denetimli öğrenmenin amacı, modelin yeni, bilinmeyen veriler üzerinde tahminler ya da sınıflandırmalar yapmasını sağlayarak girdi özelliklerinden ve bu girdilere karşılık gelen çıktılar arasındaki eşlemeyi öğrenmektir. Denetimli öğrenme için yaygın olarak kullanılan algoritmalar lineer regresyon, karar ağaçları ve destek vektör makineleridir. En yaygın kullanım alanları ise görüntü işleme, konuşma tanıma ve doğal dil işlemedir.

Belirli girdi ve bu girdilere karşılık gelen çıktılardan meydana gelen bir veri kümesi oluşturulur. Veri kümesinin doğru seçimi ve gerçek verilerden toplanması modelin performansı için çok önemlidir. Veriler analizde kullanılmayacak olan gereksiz bilgilerden temizlenerek eksik değerler işlenir. Gerekmesi durumunda değişkenler kategorilerine göre kodlanır. Veri kümesi eğitim ve test serilerine bölünür. Eğitim seti modeli eğitmek için kullanılır ve test seti ise tahmin edilecek veriler üzerindeki performansı değerlendirmek için kullanılır. Sorunun özelliklerine, verilere ve istenen çıktıya uygun bir makine öğrenimi modeli seçilir. Eğitim veri seti seçilen modele uygulanır. Model, tahminleri ile gerçek veriler arasındaki farkı en aza indirmek için eğitim sırasında dahili parametreleri ayarlamaktadır. Doğruluk, hassasiyet ya da geri çağırma gibi değerlendirme metriklerini kullanarak eğitilmiş modelin test setindeki performansı değerlendirilir. Bu adım, modelin yeni verileri ne kadar iyi tahmin ettiğini belirlemeye yardımcı olur. Modelin en iyi performansı sağlaması için model mimarisi ya da diğer parametreler ayarlanır. Bu adım çapraz doğrulama ya da hiper parametre ayarı yapmayı gerektirebilir. Modelin performansını değerlendirdikten sonra sonuçtan memnun kalındığı takdirde yeni tahminlerde bulunmak için kullanılabilir.

Denetimsiz öğrenme, algoritmanın belirlenmemiş veriler üzerinde eğitildiği bir makine öğrenimi türüdür. Amaç, önceden tanımlanmış çıktılar olmadan verilerdeki kalıpları, ilişkileri ya da yapıları ortaya çıkarmaktır. Denetimli öğrenmenin aksine

algoritma, verilerin doğal yapısını kendi başına keşfetmelidir. En yaygın kullanılan denetimsiz öğrenme teknikleri, kümeleme, boyutsallık azaltma, ilişkilendirme, yoğunluk tahmini ve üretken modellemedir.

Veri toplama ve düzenleme aşamasını takiben verilerin dağılımını anlamak, kalıpları belirlemek ve potansiyel yapılar hakkında fikir edinmek için keşifçi veri analizi yapılır. Bu adımda dağılım grafikleri ya da histogramlar gibi görselleştirmelerden faydalanılır. Sorunun doğasına ve verilerin özelliğine bağlı olarak denetimsiz öğrenme tekniklerinden en uygun olanı seçilir. Seçilen denetimsiz öğrenme modeli önceden düzenlenmiş veriler üzerinde eğitilir. Bu aşama, tahmin edilen çıktı üzerinde herhangi bir denetim olmadan, verilerde bulunan kalıpları, ilişkileri ya da yapıları belirlemeye yardımcı olur. Modelin en iyi performansı sağlaması için yapılandırma ayarları ya da diğer parametreler ayarlanır. Modelin performansı değerlendirilerek ilgili sonuçlar yorumlanır. Örneğin, kümelemede, algoritma tarafından oluşturulan gruplar analiz edilerek, boyutsallık azaltmada azaltılmış özellik alanı yorumlanır. Belirlenen kalıp ya da yapıların daha iyi anlaşılabilmesi için sonuçlar görselleştirilebilir. Bu adımda dağılım grafikleri, ısı haritaları ya da dendogramlar (ağacı temsil eden diyagram) gibi görselleştirme araçlarından faydalanılabilir. Gerekirse analiz yinelemeli olarak iyileştirilebilir. Yani, veriler yeniden düzenlenerek, parametreler ayarlanarak ya da farklı bir denetimsiz öğrenme tekniği kullanılarak yeniden analiz yapılır. Son aşamada ise elde edilen çıktı soruna uygulanarak, karar alma, süreçleri iyileştirme ya da daha fazla araştırma için hipotezler oluşturma arasında seçim yapmak gerekir.

Yarı denetimli öğrenme hem denetimli hem de denetimsiz öğrenmenin unsurlarını birleştiren bir makine öğrenmesi paradigmasıdır. Yarı denetimli öğrenmede, eğitim veri kümesi hem belirli çıktıya sahip olan hem de olmayan örnekleri ele alır. Amaç, belirli çıktıları olmayan örnekler de dahil olmak üzere bilinmeyen veriler üzerinde tahmin yapabilen bir model oluşturmak için belirli verilerden yararlanmaktır.

Belirli bir çıktıya (test verisine) sahip olsun ya da olmasın veri toplama işlemi gerçekleştirilir. Veriler gerektiği gibi önceden düzenlenerek eksik değerler giderilir. Veri kümesi test verisine sahip olanlar ve olmayanlar olarak bölümlere ayrılır. Test verisine sahip olan kısım denetimli eğitim için kullanılır ve test verisine sahip olmayan kısım modelin öğrenmesini geliştirmek için kullanılır. Denetimli öğrenme tekniklerini kullanarak test verisine sahip olan kısımlar üzerinde model eğitilir. Bu aşama geleneksel

denetimli öğrenmedeki eğitim sürecine benzer. Modelin temel veri dağılımını anlamasını geliştirmek için test verisine sahip olmayan verilerden yararlanılır. Bu aşamada kendi kendine eğitim, ortak eğitim ya da çoklu görüşlü öğrenme gibi teknikler uygulanır. Yarı denetimli modelin performansı bir doğrulama setinde ya da diğer ilgili metrikler kullanılarak değerlendirilir. Bu aşama, modelin bilinmeyen verileri ne kadar iyi şekilde tahmin edebildiğinin değerlendirilmesine yardımcı olur. Ortaya çıkan sonuca göre modelde ayarlamalar yapılır. Performansı daha da artırmak için yinelemeli iyileştirme uygulanır. Test verisine sahip olmayan örnekler de dahil olmak üzere bilinmeyen veriler hakkında tahminler yapmak için yarı denetimli öğrenme modeli uygundur.

Kendi kendine denetimli öğrenme, bir modelin bireyler tarafından sağlananın dışında test verilerine ihtiyaç duymadan girdi (eğitim) verilerinden kendi test verilerini oluşturmak için eğitildiği bir makine öğrenimi paradigmasıdır. Bir başka deyişle model, verilerde bulunan bilgilerden kendi denetleyici çıkarımlarını oluşturmayı öğrenir.

Test verisine sahip olmayan veriler gerekiyorsa ölçekleme, normalleştirme vb... standart ön düzenleme adımlarından geçirilir. Verilerin niteliğine göre bir neden ya da yardımcı bir fonksiyon tanımlanır. Bu fonksiyon, modeli, yararlı özellikleri ya da örnekleri öğrenmeye teşvik eder. Tanımlanan fonksiyona uygun bir model mimarisi seçilir ya da tasarlanır. Tanımlanmış kendi kendini denetleyen fonksiyonu kullanılarak model test verisine sahip olmayan veriler üzerinde eğitilir. Model, kendi test verilerini oluşturmayı ve seçilen görevde iyi performans göstermek için parametrelerini optimize etmeyi öğrenir. Eğitimli modelden temsiller çıkarılır. Bu öğrenilmiş temsiller genellikle girdi verilerinin anlamlı özelliklerini yakalar aşağı yönlü görevler için kullanılır. Gerekirse fonksiyona ilişkin performansı iyileştirmek için daha küçük test verisine sahip bir veri kümesinde kendi kendine denetimli modele ayarlamalar yapılır. Öğrenilen temsillerin kalitesini değerlendirmek için kendi kendine denetimli modelin aşağı yönlü fonksiyonlar ya da kriterler üzerindeki performansı değerlendirilir.

Pekiştirmeli (takviyeli) öğrenme, bir aracının bir ortamla etkileşime girerek karar vermeyi öğrendiği bir tür makine öğrenimi paradigmasıdır. Öğrenci deneme yanılma yoluyla öğrenir, ödül ya da ceza şeklinde geri bildirim alır. Öğrencinin amacı, zaman içinde kümülatif ödülleri en üst düzeye çıkarmak için çevrenin eylemlerle eşleşmesini sağlayan bir strateji öğrenmektir. Pekiştirmeli öğrenme daha çok oyun oynama ve otonom sistemler gibi uygulamalarda kullanılır. Model tabanlı ve modelsiz pekiştirmeli öğrenme

olarak ikiye ayrılır. Model tabanlı pekiştirmeli öğrenme öğrenilen model ve verilen model olarak ikiye ayrılır. Modelden bağımsız pekiştirmeli öğrenme politika optimizasyonu, Q-öğrenme ve hibrit yöntemler olarak üç yöntemden oluşur (WEB_95).

Öğrencinin stratejisi ile ilgili parametreler başlatılır. Öğrenci çevrenin mevcut durumunu gözlemleyip stratejisine göre bir eylem seçer ve bu eylemi gerçekleştirdiğinde çevre yeni bir duruma geçer. Yapılan eylem ve yeni duruma bağlı olarak bir ödül ya da ceza alır. Gözlenen duruma ya da ödül ve cezaya göre öğrencinin stratejisi güncellenir. Yeni durum gözlemlenerek bir eylem seçilir ve öğrenme süreci tamamlanana kadar kullanılan strateji güncellenip işlem tekrar edilir.

Yapay Sinir Ağları (ANN): Yapay sinir ağları, insan beynindeki biyolojik sinir ağlarının yapısından ve işleyişinden ilham alan bir yapay zekâ tahmin yöntemidir. Bir ya da daha fazla girdi katmanı, bir ya da daha fazla gizli katman ve bir çıktı katmanından oluşur. Her bir katmandaki nöronlar bir sonraki katmanda bulunan nöronlara bağlanır ve her bağlantının ilişkili bir ağırlığı vardır. Nöronlar ağa doğrusal olmama durumunu tanıtabilmek için aktivasyon fonksiyonlarını kullanır. En yaygın aktivasyon fonksiyonları sigmoid, hiperbolik tanjant ve düzeltilmiş doğrusal birim fonksiyonlarıdır (Hasan, 2019: 22-24). Yapay sinir ağları bir eğitim süreci yoluyla verilerden öğrenir. Genellikle tahminler yapmak için ileri besleme, hatayı hesaplama ve ardından hatayı en aza indirmek amacıyla ağırlıkları ayarlamak için geri besleme aşamalarından oluşur. Genel olarak ağ, tahmin yapmak için test verileri üzerinde denetimli öğrenme şeklinde eğitilir. İleri beslemeli sinir ağları (FNN), çok katmanlı algılayıcı (MLP), tekrarlayan sinir ağları (RNN), evrimsel sinir ağları (CNN) ve radyal temelli fonksiyonel sinir ağı (RBFN), Hopfield ve Kohonen özellik haritası gibi birbirinden farklı yapay sinir ağı türleri mevcuttur (WEB_96).

İleri beslemeli sinir ağları (FNN). verinin, girdi katmanından bir ya da daha fazla gizli katmana oradan da çıktı katmanına kadar tek yönde aktığı temel bir yapay sinir ağı türüdür. FNN'ler en basit ve en yaygın sinir ağı mimarisi türüdür. Girdi katmanı, modelin özelliklerini ya da girdi değişkenlerini temsil eden nöronlardan oluşur. Her nöron, girdi verilerinin belirli bir özelliğine karşılık gelir. Gizli katmanlar, girdi ve çıktı katmanları arasındaki ara katmanlardır. Her gizli katman, ağırlıkları ve aktivasyon fonksiyonlarını kullanarak girdi verileri üzerinde hesaplamalar yapan nöronlara sahiptir. Gizli katmanlardaki her nöron tipik olarak girdilerin ağırlıklı toplamına bir aktivasyon

fonksiyonu uygular. Çıktı katmanı, gizli katmanlarda gerçekleştirilen hesaplamalara dayalı olarak tahminleri verir. Çıktı katmanındaki nöronların sayısı görevin niteliğine bağlıdır. İkili sınıflandırma ve regresyon buna örnek gösterilebilir (WEB_97).

Çok katmanlı algılayıcılar (MLP), bir girdi katmanı, bir ya da daha fazla gizli katman ve bir çıktı katmanından oluşan üç ya da daha fazla düğüm katmanına sahip bir tür ileri beslemeli sinir ağıdır. MLP'ler, sınıflandırma ve regresyon da dahil olmak üzere çeşitli makine öğrenimi uygulamalarında yaygın olarak kullanılan bir yapay sinir ağı mimarisidir.

Girdi katmanı, girdi verilerinin özelliklerini temsil eden düğümlerden oluşur. Her düğüm bir özelliğe karşılık gelir ve bu düğümlerin değerleri girdi özellikleridir. Her gizli katman, ağırlıkları ve aktivasyon fonksiyonlarını kullanarak girdi verileri üzerinde hesaplamalar yapan düğümler içerir. Farklı katmanlarda bulunan düğümler arasındaki bağlantıların ilişkili ağırlıkları vardır. Bu ağırlıklar, MLP'nin eğitim süreci sırasında modelin performansını ayarlamak için öğrendiği parametrelerdir. Çıktı katmanı, gizli katmanlarda gerçekleştirilen hesaplamalara dayalı olarak tahminleri üretir.

İleri yayılma sırasında, girdi verileri girdi katmanına iletilir ve hesaplamalar, gizli katmanlar aracılığıyla çıktı katmanına doğru gerçekleştirilir. Nihai çıktı oluşturulur ve kayıp fonksiyonu, modelin tahminleri ile gerçek hedef değerler arasındaki farkı ölçer. Amaç eğitim sırasında bu kaybı en aza indirmektir. Geri yayılım, kaybı azaltmak için ağırlıkların güncellenmesi işlemidir. Düğümler kayba göre hesaplanır ve ağırlıklar, stokastik gradyan inişi gibi optimizasyon algoritmaları kullanılarak ayarlanır (WEB_98). Optimizasyon algoritmaları, ağırlıkları kaybı en aza indirecek yönde ayarlar. Eğitim süreci, model kaybının en aza indirildiği bir duruma yaklaşıncaya kadar tekrarlanır.

MLP'ler sınıflandırma, regresyon ve örüntü tanıma gibi çeşitli uygulamalarda kullanılabilir. Bu durum da onları çeşitli uygulamalar için avantajlı hale getirir. Aktivasyon fonksiyonlarının dahil edilmesi, MLP'lerin verilerdeki doğrusal olmayan ilişkileri modellemesine olanak tanır.

MLP'ler sabit bir mimariye sahiptir ve performansları büyük ölçüde gizli katmanların ve nöronların sayısının seçimine bağlıdır. Bu da bazı uygulamalarda dezavantaj yaratabilir. Düzgün bir şekilde düzenlenmediği takdirde MLP'ler, özellikle küçük veri kümeleriyle çalışırken korelasyon eğilimi gösterebilir.

Üretken rekabetçi ağlar (GAN), Ian Goodfellow ve meslektaşları tarafından 2014 yılında tanıtılmış olup, rekabetçi bir eğitim sürecinde yer alan iki sinir ağı, bir jeneratör ve bir ayırmıcıdan oluşur. GAN'ların amacı, gerçek verilerden öğrenerek görüntü, ses ya da metin gibi gerçekçi yapay veriler oluşturmaktır.

Jeneratör girdi olarak rastgele gürültüyü alır ve yapay veri örnekleri üretir. Gerçek verilerden ayırt edilemeyen veriler oluşturmayı amaçlamaktadır. Ayırmıcı, girdi veri örneklerini değerlendirerek gerçek ve yapay verileri ayırt eder. Girdi verilerinin gerçek ya da oluşturulmuş olmasına olasılıklar atar.

Eğitim sürecinde jeneratör ve ayırmıcı rastgele ağırlıklarla başlatılır. Jeneratör rastgele gürültüden yapay veriler üretir ve ayırmıcı hem gerçek hem de yapay verileri değerlendirir. Ayırmıcı kaybı, ayırmıcının gerçek ve üretilen verileri doğru bir şekilde ayırt etme yeteneğine göre hesaplanır. Jeneratör kaybı ise ayırmıcıyı yapay verilerin gerçek olduğuna inandırma yeteneğine göre hesaplanır. Düğümler hesaplanarak hem jeneratör hem ayırmıcının ağırlıklarını güncellemek için geri yayılma gerçekleştirilir. Stokastik gradyan inişi gibi optimizasyon algoritmaları, ilgili kayıplarını en aza indirmek için ağların ağırlıklarını ayarlamak için kullanılır. Eğitim amacı, jeneratörün gerçek verilerden güvenilir bir şekilde ayırt edemediği gerçekçi veriler ürettiği bir dengenin sağlanmasıdır. GAN'lar denetimsiz bir şekilde çalışır, test verilerine ihtiyaç duymadan verilerdeki kalıpları ve dağılımları öğrenir.

Radyal temel fonksiyon ağları (RBFN), örüntü tanıma, fonksiyon yaklaşımı ve enterpolasyon görevlerinde uygulamalarıyla bilinen bir tür yapay sinir ağıdır. Radyal temel fonksiyon ağları bir girdi katmanı, radyal temel fonksiyonlara sahip gizli bir katman ve bir çıktı katmanı olarak üç katmandan oluşur. Girdi katmanındaki nöronların sayısı, girdi verilerinin boyutluluğuna karşılık gelir. Gizli RBFN katmanı, aktivasyon fonksiyonları olarak radyal temel fonksiyonları kullanır.

Yaygın olarak kullanılan radyal temel fonksiyonlar arasında Gauss, multiquadric ve ters multiquadric fonksiyonları bulunur (WEB_99). Bu fonksiyonlar girdi alanındaki belirli noktalarda toplanır. Gizli katmandaki her nöron, girdi alanındaki bir nokta olan bir merkezle ilişkilidir. Yayılma parametresi, her bir fonksiyonun girdi alanı üzerindeki etkisini belirleyerek radyal temel fonksiyonların genişliğini kontrol eder.

Gizli katman ile çıktı katmanı arasındaki bağlantılar ağırlıklarla ilişkilendirilir. Bu ağırlıklar, ağın performansını optimize etmek için eğitim süreci sırasında ayarlanır. RBFN'ler genellikle iki adımlı bir süreç kullanılarak eğitilir. İlk adımda, genellikle k-means gibi kümeleme algoritmaları kullanılarak radyal temel fonksiyonların merkez konumlarının belirlenmesi sağlanır. İkinci adımda ise, girdi verilerine göre dağılım ve ağırlıkları ayarlanır. Radyal temel fonksiyonların yayılma parametresi bir düzenleme terimi görevi görebilir. Daha küçük yayılmalar daha düzgün işlevlere yol açabilir ve aşırı uyumun önlenmesine yardımcı olur. Bu parametrelerin belirlenmesi zor olabilir.

RBFN'ler hem enterpolasyon (eğitim verileri aralığı içindeki değerleri tahmin etme) hem de ekstrapolasyon (eğitim verileri aralığı dışındaki değerleri tahmin etme) yeteneğine sahiptir, bu da onları çeşitli uygulamalarda faydalı kılar. RBFN'lerin evrensel yaklaşımıcılar olduğu kanıtlanmıştır. Yani yeterli sayıda radyal temel fonksiyonla, herhangi bir sürekli fonksiyonu netliğe yakınlştırabilecekleri anlamına gelir. RBFN'ler küresel öğrenmeyi (ağın genel yapısını belirleme) ve yerel öğrenmeyi (fonksiyona yaklaşmak için ağırlıkları yerel olarak ayarlama) birleştirir. Radyal temel fonksiyonların sayısının ve konumlarının seçimi, RBFN'lerin performansını önemli ölçüde etkileyebilir. Radyal temel fonksiyonların yerel aktivasyonu nedeniyle, RBFN'ler sıklıkla seyrek aktivasyon sergiler. Yani belirli bir girdi için yalnızca bir nöron alt kümesi aktif olur.

RBFN'ler fonksiyon yaklaşımı, zaman serisi tahmini, sınıflandırma ve sistem tanımlama gibi alanlarda uygulanmaktadır. Özellikle verilerdeki doğrusal olmayan ilişkileri içeren belirli problem türleri için doğru ve etkili çözümler sağlayabilir.

Radyal temelli olasılıksal sinir ağları (RBPNN), olasılıksal çıktıları içeren Radyal Temelli Fonksiyon Ağlarının (RBFN) bir uzantısıdır. RBPNN'ler, örüntü tanıma ve sınıflandırma görevleri için tasarlanmış bir tür yapay sinir ağıdır.

RBPNN'ler, bir giriş katmanı, radyal temel fonksiyonlara sahip bir gizli katman ve bir çıkış katmanından oluşan RBFN'lerin mimarisiyle aynıdır. Fark, olasılıksal bir çıktı katmanının tanıtılmasıdır. RBFN'ler gibi RBPNN'ler de gizli katmanda radyal temel fonksiyonları kullanır. Bu fonksiyonlar girdi alanındaki belirli noktalarda toplanır ve girdi kalıpları ile öğrenilen prototipler arasındaki benzerliği yakalar. Çıktı katmanı, deterministik çıktılar sağlamak yerine olası sınıflar üzerinde olasılık dağılımları üretir. Softmax aktivasyon fonksiyonu, ağın ham çıktı değerlerini olasılıklara dönüştürmek için

çıktı katmanında yaygın olarak kullanılır (Wu vd., 2020: 108505). Olasılıklar, girdi verilen her sınıfın olasılığını gösterir. RBPNN'ler sınıflandırma sürecindeki belirsizliği modellemeyi amaçlar. Olasılık dağılımları, modelin belirli bir girdiyi belirli bir sınıfa atamasındaki güveni ya da belirsizliği hakkında bilgi sağlar.

Eğitim sırasında ağ, eğitim verilerindeki gerçek sınıf dağılımlarıyla eşleşen olasılık dağılımları üretmek için eğitilir. Bu, gerçek sınıf test verilerinin negatif log olasılığının en aza indirilmesini kolaylaştırır. Sınıflandırma görevlerinde, çıktı katmanında en yüksek olasılığa sahip olan sınıf genellikle tahmin edilen sınıf olarak seçilir. Bununla birlikte olasılık dağılımları, belirsizliği göz önünde bulundurarak daha hassas kararlar vermek için de kullanılabilir. RBFN'lere benzer şekilde RBPNN'lerin performansı, radyal temel fonksiyonların sayısı ve konumları ile yayılma parametreleri gibi parametrelerin doğru şekilde ayarlanmasına bağlıdır. Modelin tahminlerindeki güveni ve belirsizliği hakkında daha fazla bilgi sunabilen olasılıksal bir çerçeve sağlar. Bu, belirsizliği anlamının çok önemli olduğu karar verme senaryolarında değerli olabilir. Olasılıksal unsurların tanıtılması, eğitim sürecine karmaşıklık katar ve model değerlendirmesi ve yorumlanması açısından ek hususlar gerektirebilir.

RBPNN'ler örüntü tanıma, görüntü sınıflandırma ve tıbbi teşhisler gibi tahminlerdeki belirsizliğin çok önemli olduğu durumlar dahil olmak üzere çeşitli konularda uygulama alanı bulur.

Tekrarlayan sinir ağları (RNN), sıralı verileri işlemek için tasarlanmış bir tür yapay sinir ağıdır. İleri beslemeli sinir ağlarının aksine, RNN'ler, geçmiş girdilerin belleklerini korumalarına olanak tanıyan yönlendirilmiş döngüler oluşturan bağlantılara sahiptir. Bu bellek, RNN'lerin sıralı verilerdeki zamansal bağımlılıkları ve ilişkileri yakalamasını sağlar.

RNN'ler, bilginin zaman içinde kalıcı olmasına izin veren tekrarlayan bağlantılara sahiptir. Ağdaki her nöron, yalnızca geçerli zaman adımından değil aynı zamanda önceki zaman adımından da girdi alarak bir bellek biçimi oluşturur. Zaman içinde açılma kavramı genellikle dizilerin bir RNN tarafından işlenmesini görselleştirmek için kullanılır. Her zaman adımı, açılmış ağda farklı bir katman olarak temsil edilir. RNN'ler, geri yayılım algoritmasının bir uzantısı olan zaman içinde geri yayılım (BPTT) kullanılarak eğitilir. BPTT, ağın dizileri zaman içinde açarak öğrenmesine olanak tanır.

RNN'ler çevrimiçi bir şekilde, dizileri geldikçe işleyerek ya da tüm dizinin başlangıçtan itibaren mevcut olduğu çevrimdışı bir şekilde eğitilebilir (WEB_100). RNN'ler, doğal dil işleme (NLP), makine çevirisi, konuşma tanıma, video analizi, duygu analizi ve zaman serisi tahmini dahil olmak üzere çeşitli uygulamalarda kullanılır.

Bir RNN'nin gizli durumu, ağı belleğini temsil eder. Ağ, dizideki her bir öğeyi işledikçe gelişir. RNN'ler, zaman içerisinde geri yayılım sırasında düğümlerin son derece küçük hale geldiği kaybolan düğüm sorunundan muzdarip olabilir. Bu, ağı uzun vadeli bağımlılıkları öğrenmesini zorlaştırabilir. Kaybolan düğüm sorununu ele almak için Uzun Kısa Süreli Bellek ağları (LSTM'ler) gibi daha karmaşık olan RNN mimarileri geliştirilmiştir. LSTM'ler, uzun vadeli bağımlılıkları daha etkili bir şekilde yakalamalarına izin veren bellek hücrelerine ve geçiş mekanizmalarına sahiptir. Geçitli Tekrarlayan Birimler (GRU), LSTM'lere benzer; fakat basitleştirilmiş yapıya sahip başka bir RNN mimarisi türüdür. Ayrıca bilgi akışını kontrol etmek için geçit mekanizmaları da içerir. RNN'ler uzun vadeli bağımlılıkları yakalamakta zorlanabilir ve patlayan düğümler gibi sorunlardan muzdarip olabilir. LSTM'ler ve GRU'ler gibi mimari değişimler bu zorlukları azaltmak için tasarlanmıştır. Çift yönlü RNN'ler, girdi dizilerini hem ileri hem de geri yönde işleyerek geçmiş ve gelecek zaman adımlarından bilgi yakalamalarını sağlar.

Uzun kısa süreli bellek ağları (LSTM), kaybolan düğüm sorununu çözmek ve sıralı verilerdeki uzun vadeli bağımlılıkları yakalamak için tasarlanmış bir tür tekrarlayan sinir ağı (RNN) mimarisidir. LSTM'ler 1995 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından tanıtılmıştır (WEB_101).

Bir LSTM birimi tipik olarak bir hücre durumu, bir girdi kapısı, bir unutma kapısı, bir çıktı kapısı ve bir gizli durumdan oluşur. Bellek hücrelerine giren ve çıkan bilgi akışını kontrol etmek için geçit mekanizmalarını kullanır. Bu mekanizmalar girdi kapısı, unutma kapısı ve çıktı kapısından oluşur. Girdi Kapısı, yeni bilginin ne kadarının bellek hücresinde saklanması gerektiğini belirler. Unutma kapısı, bellek hücresinin mevcut içeriğinin ne ölçüde atılması gerektiğini kontrol eder. Çıktı Kapısı, bellek hücresi içeriğinin ne kadarının LSTM'nin çıktısı olarak açığa çıkması gerektiğini belirler.

Modelin sıralı verilerin hiyerarşik temsillerini öğrenmesine izin veren derin mimariler oluşturmak için çoklu LSTM katmanları kullanılabilir. Çift yönlü LSTM'ler

dizileri hem ileri hem de geri yönde işler. Bu, modelin geçmiş ve gelecekteki zaman adımlarından bilgi yakalamasını sağlar.

LSTM'ler, tekrarlayan sinir ağları için tasarlanmış geri yayılım algoritmasının bir çeşidi olan zaman içinde geri yayılım (BPTT) kullanılarak eğitilir (WEB_102). Bir düzenleme tekniği olan Dropout, aşırı uyumu önlemek için LSTM'lere uygulanabilir. Eğitim sırasında sonraki katmana olan girdi birimlerinin bir kısmının rastgele alıkonulması anlamına gelir (WEB_103). Geleneksel RNN'lere benzer şekilde, LSTM'ler, dizileri geldikçe işleyerek çevrimiçi olarak eğitilebilir ya da tüm dizinin başlangıçtan itibaren mevcut olduğu çevrimdışı olarak eğitilebilir.

LSTM'ler kısa süreli ve uzun süreli belleği birbirinden ayırır. Bilgileri uzun süre saklayabilen özel birimler olan bellek hücreleri kavramını ortaya koymaktadır. Bellek hücreleri okunabilen, yazılabilen ve silinebilen dahili bir duruma sahiptir. Bu hücreler, bilgileri uzun bir süre saklayabilir ve sıralı verilerdeki uzun vadeli bağımlılıkların yakalanmasını sağlar. Etkinliklerine rağmen, LSTM'ler hiper parametrelere duyarlılık, eğitim süresi ve öğrenilen temsilleri yorumlama gibi zorluklarla karşılaşabilir.

LSTM'ler, dil modelleme, makine çevirisi ve duygu analizi gibi doğal dil işleme görevlerinde yaygın olarak kullanılmaktadır. Ayrıca zaman serisi analizi, konuşma tanıma ve diğer çeşitli sıralı veri uygulamalarında da kullanılmaktadır.

Geçitli tekrarlayan birimler (GRU), Geçitli tekrarlayan birimler, LSTM'ler gibi, kaybolan düğüm sorununu çözmek ve sıralı verilerdeki uzun vadeli bağımlılıkların öğrenilmesini kolaylaştırmak için tasarlanmış bir tür tekrarlayan sinir ağı (RNN) mimarisidir. GRU'lar, 2014 yılında Kyunghyun Cho ve diğerleri tarafından tanıtılmıştır (Cho vd., 2014: 1-15). LSTM'lere göre daha basit bir yapıya sahiptir. Bellek hücrelerini ve gizli durumu tek bir durum vektöründe birleştirerek mimariyi daha akıcı hale getirirler.

GRU'lar bilgi akışını kontrol etmek için LSTM'lere benzer geçit mekanizmaları kullanır. Her biri bilgi akışında farklı bir amaca hizmet eden bir sıfırlama geçidi ve bir güncelleme geçidi vardır. Sıfırlama geçidi, geçmiş bilgilerin ne kadarının unutulacağını belirler. Güncelleme geçidi, yeni bilgilerin ne kadarının mevcut duruma dahil edileceğine karar verir. Gizli durum, sıfırlama ve güncelleme geçitleri kullanılarak tek bir adımda güncellenir. Bu durum da daha uzun diziler üzerindeki bağımlılıkları daha verimli bir şekilde yakalamaya yardımcı olur. LSTM'lere benzer şekilde, GRU'lar çift yönlü olabilir;

geçmiş ve gelecekteki zaman adımlarından bilgi yakalamak için hem ileri hem de geri yönlerde dizileri işleyebilir. Genellikle basitlikleri ve LSTM'lerle karşılaştırılabilir performansları nedeniyle tercih edilirler.

GRU'lar, LSTM'ler gibi, sıralı verilere dayalı olarak ağırlıklarını ayarlamak için zaman içinde geri yayılım (BPTT) kullanılarak eğitilir. LSTM'lere kıyasla daha az parametreye sahip olma eğilimindedir, bu da onları hesaplama açısından daha verimli ve bazen daha hızlı eğitilir hale getirir. GRU'lar, geleneksel RNN'lere kıyasla daha uzun bağımlılıkları yakalamada etkili olsa da, uzun vadeli bağımlılıkları LSTM'ler kadar açık bir şekilde yakalayamayabilirler. GRU'lar, dizileri geldikleri anda işleyerek çevrimiçi olarak eğitilebilir ya da tüm dizinin başlangıçtan itibaren mevcut olduğu çevrimdışı olarak eğitilebilir. LSTM'lere benzer şekilde, aşırı uyumu önlemek için GRU'lara bir düzenleme tekniği olarak dropout uygulanabilir. Modelin hiyerarşik temsilleri öğrenmesine izin veren derin mimariler oluşturmak için çoklu GRU katmanları kullanılabilir. GRU'lar belirgin uzun süreli bellek gerektiren uygulamalarda kullanılabilir ve GRU'lar ile LSTM'ler arasındaki seçim genellikle görevin spesifik özelliklerine bağlıdır. GRU'lar daha basit olsa da azaltılmış parametre sayısı nedeniyle LSTM'lerden daha yorumlanabilir olabilirler.

GRU'lar, doğal dil işleme, konuşma tanıma ve zaman serisi analizi dahil olmak üzere çeşitli uygulamalarda kullanılır.

Evrişimli sinir ağları (CNN), görüntüler ve videolar gibi yapılandırılmış ızgara verilerini işlemek için tasarlanmış bir derin sinir ağları sınıfıdır. CNN'nin görüntü sınıflandırma, nesne algılama, görüntü segmentasyonu ve diğer görsel tanıma görevlerinde güçlü performans sergileyerek bilgisayarlı görü görevlerinde oldukça etkili olduğu kanıtlanmıştır.

CNN'ler, girdi görüntülerinden özelliklerin mekansal hiyerarşilerini otomatik ve uyarlanabilir bir şekilde öğrenmek için evrişimli katmanları kullanır. Evrişimsel işlemler, yerel kalıpları çıkarmak için küçük filtrelerin (çekirdeklerin) girdi verileri üzerinde kaydırılmasını içerir. Havuz katmanları genellikle evrişimli katmanlar tarafından üretilen özellik haritalarının uzamsal boyutlarını azaltmak için kullanılır. Maksimum havuzlama ve ortalama havuzlama, önemli özellikleri azaltmak ve korumak için yaygın tekniklerdir. Evrişimli katmanlar, ağ daha derin katmanları işlerken üst düzey özellikleri temsil eden

özellik haritaları oluşturur. Bu özellikler, giriş verilerindeki hiyerarşik kalıpları yakalar. Düzeltilmiş doğrusal birim (ReLU) gibi doğrusal olmayan aktivasyon fonksiyonları, doğrusallığı tanıtmak ve ağı karmaşık ilişkileri öğrenmesine olanak sağlamak için CNN’lerde yaygın olarak kullanılır. CNN’ler, son tahminler için üst düzey özellikleri birleştirmek amacıyla genellikle mimarinin sonunda bir ya da daha fazla tam bağlantılı katman içerir.

CNN’lerde, büyük veri kümeleri (örn. ImageNet) üzerindeki önceden eğitilmiş modellerin belirli görevler için ince ayarının yapıldığı, hesaplama kaynaklarından tasarruf edildiği ve performansın iyileştirildiği transfer öğrenmesi yaygındır. Rotasyon, çevirme ve ölçeklendirme gibi veri artırma teknikleri, eğitim veri kümesinin çeşitliliğini artırmak ve CNN’lerin genellemesini iyileştirmek için yaygın olarak uygulanır. Aşırı uyumu önlemek için CNN’lere uygulanan bir düzenleme tekniği olan Dropout, eğitim sırasında girdi birimlerinin bir kısmının rastgele alıkonulmasını sağlar. CNN’ler, yalnızca nesneleri sınıflandırmakla kalmayıp aynı zamanda bir görüntü içindeki konumlarını da tanımladıkları nesne yerelleştirme ve algılama görevleri için kullanılabilir. CNN’ler, filtre boyutu, aşama ve katman sayısı gibi hiper parametrelerin ayarlanmasını gerektirir. VGG, ResNet ve Inception gibi çeşitli mimariler farklı işlevler sunar. CNN’ler hiyerarşik özellikleri öğrenir ve alt katmanlar genellikle basit hatları yakalarken daha derin katmanlar karmaşık yapıları ve nesne parçalarını betimler. Video işleme için, 3D CNN’ler evrimsel işlemleri zamansal boyuta genişleterek hem zaman hem mekanla ilgili özellikleri yakalar.

Kohonen özellik haritası (Kendi kendini düzenleyen haritalar (SOM)), yüksek boyutlu verileri kümelemek ve görselleştirmek için kullanılan bir tür denetimsiz sinir ağıdır. SOM’lar 1984’te Teuvo Kohonen tarafından tanıtılmıştır. Özellikle karmaşık veri kümelerinin yapısını keşfetmek ve anlamak açısından fayda sağlarlar (WEB_104).

SOM’lar denetimsiz bir şekilde eğitilir, yani test verisine sahip eğitim verilerine ihtiyaç duymazlar. Ağ, girdi verilerini yalnızca girdi modellerine dayalı olarak organize etmeyi ve temsil etmeyi öğrenir. SOM’ların temel özelliklerinden biri, çıktı haritasındaki girdi alanının yüzeysel özelliklerini koruma yetenekleridir. SOM’da birbirine yakın nöronlar, benzer özelliklere sahip girdi modellerini temsil eder. SOM, her bir nöronun çıktı haritasındaki bir düğüme karşılık geldiği bir nöron ızgarası olarak düzenlenir. Nöronların düzeni girdi alanının organizasyonunu yansıtır. SOM’daki her nöronun,

eğitim sırasında güncellenen ilişkili bir ağırlık vektörü vardır. Ağırlık vektörleri, temsil ettikleri girdi modellerine benzeyecek şekilde ayarlanır. Eğitim sırasında, girdi kalıpları SOM'da temsil edilmek için rekabet eder. Girdi modeline en yakın ağırlık vektörüne sahip olan nöron kazanır ve ağırlıkları girdiye daha iyi uyum sağlayacak şekilde ayarlanır. SOM'lar, eğitim sırasındaki ağırlık ayarlamalarının kapsamını kontrol eden bir öğrenme oranı içerir. Öğrenme oranı zamanla azalarak ağırlık kararlı bir duruma yaklaşmasına olanak tanır. Kazanan nöronların komşu nöronlar üzerindeki etkisini tanımlamak için Gauss komşuluk fonksiyonu kullanılır. Kazanana yakın olan nöronlar ağırlık güncellemeleri sırasında daha güçlü bir şekilde etkilenir. Eğitim süresince komşuluk boyutu (Gauss komşuluk fonksiyonundan etkilenir) kademeli olarak azalır, bu da daha ince ayarlamalara ve daha fazla hassasiyete yol açar.

SOM'lar doğal olarak benzer girdi modellerini çıktı haritasında bir araya getirir. Bu onları veri kümeleme ve görselleştirme gibi uygulamalarda etkili kılar. SOM'lar, yapısını korurken girdi alanının düşük boyutlu bir temsilini sağlayarak boyutsallığı azaltmak için kullanılabilir. Genellikle 2D ya da 3D haritada yüksek boyutlu verileri görselleştirmek için kullanılır ve kullanıcıların veri noktaları arasındaki ilişkileri keşfetmesine ve anlamasına olanak tanır.

SOM'lar veri madenciliği, görüntü işleme, örüntü tanıma ve keşfedici veri analizi dahil olmak üzere çeşitli alanlarda uygulanır.

Hopfield ağları, 1982 yılında John Joseph Hopfield tarafından geliştirilmiş olmakla birlikte, çağrışımsal bir bellek sistemi olarak hizmet veren bir tür tekrarlayan yapay sinir ağıdır. Bu ağlar, örüntüleri saklama ve geri çağırma yetenekleriyle karakterize edilir. Bu durum da onları örüntü tanıma ve içerik adreslemeli bellek alma gibi uygulamalar için faydalı kılar.

Hopfield Ağları, kısmi ya da gürültülü girdiye dayalı örüntüleri hatırlamalarına olanak tanıyan, ilişkisel bellekler olarak işlev görecektir şekilde tasarlanmıştır. Her bir nöronun ağıdaki diğer tüm nöronlara bağlı olduğu tamamen bağlantılı, tekrarlayan bir mimariye sahiptir. Bağlantılar simetrik ve ağırlıklı bir bitişiklik matrisi oluşturur. Bir hopfield ağındaki nöronlar tipik olarak +1 veya -1 değerlerini alan ikili aktivasyon durumlarını kullanır. Bu durum, modeli basitleştirir ve ikili modellerle çalışmasına izin verir. Hopfield Ağları, ağ durumlarının kararlılığını temsil etmek için bir enerji

fonksiyonu kullanır. Amaç, depolanan örüntülere karşılık gelen kararlı durumları (minimum enerji) bulmaktır.

Hopfield Ağları, bağlantı ağırlıklarının nöronların ortak aktivasyonuna göre ayarlandığı Hebbian öğrenme kullanılarak eğitilir. İki nöron arasındaki bağlantı ağırlığı, aynı aktivasyon durumuna sahiplerse güçlenir, zıt durumlara sahiplerse gücünü kaybeder. Geri çağırma sırasında Hopfield Ağları, sağlanan girdiye en yakın kararlı bir duruma yaklaşarak ağın enerjisini en aza indirmeyi amaçlar. Modeller, bağlantı ağırlıkları eğitim setine göre ayarlanarak ağda saklanır. Ağ, geri çağırma sırasında bu depolanan modellere yakınsamayı öğrenir. Hopfield ağları, geri çağırma sırasında ağın yakınsadığı kararlı durumlar olan çekici durumlara sahiptir. Bu çekiciler depolanan modellere karşılık gelir. Hopfield ağları, kısmi ya da gürültülü bir girdiye dayalı olarak depolanmış bir modeli geri çağırmalarına izin veren içerik adreslenebilir bellek sergiler. Ağ en yakın belleğe alınmış modele yakınsayabilir. Bir hopfield ağındaki nöronlar aynı anda değil sırayla güncellenir. Güncelleme sırası yakınsama dinamiklerini etkileyebilir. Hopfield ağlarının depolama kapasitesi açısından sınırlamaları vardır. Güvenilir bir şekilde saklanabilen ve geri çağırılabilen modellerin sayısı ağın kapasitesiyle sınırlıdır. Hopfield ağları çift yönlü ilişkilendirilebilirlik sergiler. Yani bir modelin, kısmi bir girdiden geri çağırılmasının diğer ilişkili modellerin de çağırılmasını tetikleyebileceği anlamına gelir. Hopfield Ağları, geri çağırma sırasında kısmen bozuk modelleri tamamlayarak gürültüye karşı dayanıklılıklarını gösterebilir. Hopfield Ağları, örüntü tanıma, optimizasyon sorunları ve içerik adreslenebilir bellek dahil olmak üzere çeşitli uygulamalara dahil olmuştur.

Basit tekrarlayan ağlar (SRN) olarak da bilinen Elman ağları, 1990 yılında Jeffrey Elman tarafından tanıtilen bir tür tekrarlayan sinir ağı (RNN) mimarisidir Elman Ağları, önceki zaman adımından bağlam bilgilerini temsil eden gizli bir durumu koruyarak sıralı verileri işlemek üzere tasarlanmıştır (Elman, 1990: 184).

Elman ağları bir geri bildirim döngüsü oluşturan tekrarlayan bağlantılara sahiptir. Gizli katmanın çıktısı, bir sonraki zaman adımında aynı katmana girdi olarak geri beslenir ve ağın bellek biçimini korumasına izin verir. Bir Elman ağında gizli katman bağlam katmanı görevi görür. Girdilerin yakın geçmişine ilişkin bilgileri saklar ve mevcut girdinin işlenmesine katkıda bulunur. Elman Ağları, zaman serileri ya da doğal dil gibi sıralı verileri işlemek için özel olarak tasarlanmıştır. Tekrarlayan bağlantılar ağına girdi

sırasındaki zamansal bağımlılıkları yakalamasını sağlar. Her zaman adımında gizli katmanın aktivasyonu, o zaman adımındaki girdiye ve bir önceki zaman adımındaki gizli katmanın aktivasyonuna bağlıdır. Bu aşama, verilerin sıralı doğasını yakalar.

Elman Ağları genellikle ağın zaman içerisindeki gelişimini dikkate alan geri yayılım algoritmasının bir uzantısı olan zaman içinde geri yayılım (BPTT) kullanılarak eğitilir. Diğer tekrarlayan mimarilere benzer şekilde Elman Ağları, özellikle birçok zaman adımı boyunca geri yayılım sırasında kaybolan düğüm probleminden muzdarip olabilir. Bu, ağın uzun vadeli bağımlılıkları öğrenmesini zorlaştırır. Çift yönlü Elman ağları giriş dizilerini hem ileri hem de geri yönde işler. Bu onların geçmiş ve gelecek zaman adımlarından bilgi toplamasına olanak tanıyarak bağımlılıkları modelleme yeteneklerini geliştirir. Birden fazla gizli katmana sahip ağlar, geçitli tekrarlayan birimler (GRU) ve kaybolan düğümlerin bazı zorluklarını ele alan uzun kısa süreli bellek (LSTM) ağları da dahil olmak üzere Elman ağı mimarisinin farklı uzantıları ve çeşitlendirmeleri mevcuttur. Elman Ağları, diğer RNN'ler gibi, uzun vadeli bağımlılıkları yakalamakta zorlanabilir ve performansları hiper parametrelerin seçimine duyarlı olabilir. Elman Ağları bazen zamana bağlı dizileri işleme yeteneklerini vurgulayan Zaman Gecikmeli Sinir Ağları olarak adlandırılır.

Elman Ağları, zaman serisi tahmini, doğal dil işleme ve konuşma tanıma gibi sıralı verileri içeren uygulamalarda kullanılır.

Jordan tekrarlayan ağları olarak da bilinen Jordan ağları, Elman ağı gibi sıralı verileri işlemek için tasarlanmış bir tür tekrarlayan sinir ağı (RNN) mimarisidir. Jordan Ağı, 1986 yılında Michael Jordan tarafından tanıtılmıştır (Su ve Ling, 2020: 2).

Jordan ağları, ağın çıktısını bir sonraki zaman adımında girdi olarak geri besleyen tekrarlayan bağlantılara sahip olmasıyla nitelendirilir. Bu geri besleme döngüsü, ağın mevcut tahmin için bağlam bilgisi olarak kendi çıktısını değerlendirmesine olanak tanır. Gizli katmanın bağlam katmanı görevi gördüğü Elman ağlarının aksine, Jordan ağlarında çıkış katmanının kendisi bir sonraki zaman adımı için bağlam katmanı görevi görür. Elman ağlarına benzer şekilde, Jordan ağları sıralı verileri işlemek için tasarlanmıştır ve tekrarlayan bağlantıları, girdi dizisindeki zamansal bağımlılıkları yakalamalarına izin verir. Jordan ağları da tıpkı Elman ağları gibi, genellikle ağın zaman içindeki gelişimini dikkate alan geri yayılım algoritmasının bir uzantısı olan zaman içinde geri yayılım

(BPTT) kullanılarak eğitilir. Bir sonraki zaman adımında ağı kendi çıktısının girdi olarak kullanılması, bağlama bağlı işlemeyi mümkün kılar. Ağ, sonraki tahminleri yaparken kendi son tahminlerini dikkate alabilir. Elman ağlarındaki gibi girdi dizilerini hem ileri hem geri yönde işleyerek çift yönlü mimarilere genişletilebilir. Diğer RNN'ler gibi Jordan Ağları da, verilerdeki uzun vadeli bağımlılıkları yakalama yeteneklerini etkileyebilecek yok olma düğümü sorunu gibi zorluklarla karşılaşabilir.

Jordan ağlarının farklı uzantıları ve çeşitleri mevcuttur. Bununla birlikte Jordan ağlarının mimarisi, uzun kısa süreli bellek (LSTM) ve geçitli tekrarlayan birimler (GRU) gibi gelişmiş yeteneklere sahip daha gelişmiş tekrarlayan modellerin geliştirilmesine ilham vermiştir.

Jordan ağları, gene Elman ağlarına benzer şekilde zaman serisi tahmini, doğal dil işleme ve konuşma tanıma gibi sıralı verileri içeren görevlerde kullanılır.

Uyarlanabilir Doğrusal Nöron (Adaline), ikili sınıflandırma uygulamaları için tek katmanlı bir sinir ağı görevi gören bir tür yapay sinir ağıdır. 1960 yılında Bernard Widrow ve öğrencisi Ted Hoff tarafından tanıtılmıştır. Adaline genellikle daha yaygın olarak bilinen Perceptron (algılayıcının)'un öncülüğünde geliştirilmiştir ve onunla bazı benzerlikler taşır (WEB_105).

Adaline tahminlerde bulunmak için doğrusal bir aktivasyon fonksiyonu kullanır. Çıktı, girdi özelliklerinin ağırlıklı toplamıdır ve çıktıyı ikili değere dönüştüren herhangi bir eşik ya da aktivasyon fonksiyonu yoktur. Adaline, Widrow-Hoff veya LMS (En Küçük Ortalama Kareler) öğrenme kuralı kullanılarak eğitilir. Eğitim sırasındaki amaç, tahmin edilen çıktı ile gerçek hedef değer arasındaki farkı en aza indirmektir. Perceptron'dan farklı olarak Adaline, ikili çıktı yerine sürekli bir çıktı sağlar. Sürekli çıktı, tahmin edilen değerlerin daha detaylı bir şekilde ifade edilmesine olanak tanır. Adaline'daki ağırlık ayarı, tahmin edilen çıktı ile gerçek hedef değer arasındaki hataya dayanmaktadır. Ağırlıklar hatayı azaltacak yönde güncellenir ve bu da onu bir tür gradyan iniş haline getirir. Eğitim süreci, genellikle tahmin edilen çıktı ile gerçek hedef değerler arasındaki ortalama kare hata olan bir maliyet fonksiyonunun en aza indirgenmesini kapsar. Adaline'daki karar sınırı, girdi alanını farklı sınıflara karşılık gelen bölgelere ayıran bir hiper düzlemdir. Girdi özelliklerine atanan ağırlıklara göre belirlenir. Adaline öncelikle amacın girdi modellerini iki sınıftan birine atamak olduğu ikili sınıflandırma

görevlerinde kullanılır. Adaline tarihsel bir öneme sahiptir ve sinir ağlarının örüntü tanıma ve sinyal işleme gibi ilk uygulamalarında kullanılmıştır. Adaline, verilerdeki aykırı değerlere karşı duyarlıdır ve performansı, girdi özelliklerinin ölçeğinden etkilenebilir. Ek olarak, doğrusal olmayan ayrılabilir verilerle çatışabilir. Adaline, gizli katmanları olmayan tek katmanlı bir mimariye sahiptir. Girdi özelliklerini doğrudan çıktı tahminleriyle eşleştirir. Adaline doğrusal bir aktivasyon fonksiyonu kullanırken, benzeri olan perceptron, ikili çıktı için adım fonksiyonunu tanıtmıştır.

Vektör nicemleme öğrenmesi (LVQ), örüntü sınıflandırması ve vektör nicemlemesi için kullanılan bir tür denetimli ve denetimsiz makine öğrenme algoritmasıdır. Rekabetçi öğrenme algoritmasının bir uzantısı olarak geliştirilmiş ve Teuvo Kohonen tarafından tanıtılmıştır (Kohonen, 1995: 175). LVQ, denetimli ve denetimsiz öğrenmenin unsurlarını birleştirerek onu kümeleme ve sınıflandırma uygulamaları için yararlı hale getirir. Örüntü tanıma, görüntü sıkıştırma ve konuşma işleme dahil olmak üzere çeşitli alanlarda uygulanmaktadır.

Derin Öğrenme (DL): Derin öğrenme, karmaşık problemleri modellemek ve çözmek için yapay sinir ağlarının kullanan bir makine öğrenimi alt alanıdır. "Derin" terimi, girdi ve çıktı katmanları arasında birden fazla katmana (derin mimariler olarak da bilinir) sahip olan derin sinir ağlarının kullanımını ifade eder. Bu derin mimariler, karmaşık örüntülerin öğrenilmesini ve verilerin gösterimini sağlar. Derin öğrenmenin temel bileşenleri şunlardır:

1. Sinir Ağları: Derin öğrenme, insan beyninin yapısından ve işleyişinden ilham alan hesaplamalı modeller olan yapay sinir ağlarına dayanır. Bu ağlar, bir çıktı üretmek için girdi verilerini işleyen ve dönüştüren birbirine bağlı düğümlerden (nöronlar) oluşan katmanlardan oluşur.

2. Derin Sinir Ağları: Bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı dahil olmak üzere çok katmanlı sinir ağlarıdır. Her katman bir dizi düğüm içerir ve düğümler arasındaki bağlantıların, eğitim süreci sırasında ayarlanan ilişkili ağırlıkları vardır.

3. Eğitim: Derin öğrenme modelleri, optimizasyon algoritmaları kullanılarak büyük veri kümeleri üzerinde eğitilir. Eğitim sırasında model, tahmin edilen ve gerçek çıktılar arasındaki farkı en aza indirmek için dahili parametrelerini (ağırlıklar ve

sapmalar) ayarlar. Bu işlem, modelin parametrelerini güncellemek için sapmanın ağ üzerinden geriye doğru yayıldığı geri yayılımı içerir.

4. Özellik Öğrenme: Derin öğrenme, ham verilerden hiyerarşik gösterimleri ve özellikleri otomatik olarak öğrenme konusunda mükemmeldir. Ağın alt katmanları basit özellikleri yakalama eğilimindeyken, üst katmanlar daha karmaşık ve soyut gösterimleri öğrenir.

5. Uygulamalar: Derin öğrenme, görüntü, konuşma tanıma, doğal dil işleme, bilgisayarlı görme, otonom araçlar, sağlık hizmetleri teşhisleri ve diğer birçok alan dahil olmak üzere çeşitli uygulamalarda başarılı olmuştur.

Derin öğrenmede kullanımı en yaygın olan CNN, FNN, RNN, LSTM, GAN gibi mimariler ile ilgili ayrıntılara yapay sinir ağları dahilinde bir önceki bölümde yer verilmiştir. Dolayısıyla derin öğrenmede zaman serisi analizinde kullanılan mimarileri Kapsül Ağları (CapsNets), Derin Pekiştirmeli Öğrenme (DRL), Sinirsel Turing Makinesi (NTM), Kuantum Sinir Ağları (QNN), Derin Otomatik Kodlayıcılar (DAE), Transfer öğrenmesi ve Derin Artık Ağlar (ResNets (DRN)) olarak sıralamak mümkündür.

Kapsül ağları (CapsNets). özellikle hiyerarşik ilişkilerin ve nesne çeşitliliklerinin ele alınmasında, geleneksel evrişimli sinir ağlarının (CNN) bazı sınırlamalarını ele almak için tasarlanmış bir tür sinir ağı mimarisidir. Kapsül Ağları, Geoffrey Hinton ve ekibi tarafından 2017'de "Kapsüller Arasında Dinamik Yönlendirme" başlıklı bir makaleyle tanıtılmıştır. Kapsül Ağlarındaki temel yapı taşı, bir nesnenin belirli bir bölümünü temsil eden bir grup nöron olan "kapsül" dür. Kapsüller, parçalar ve nesneler arasındaki hiyerarşik ilişkileri ve mekansal hiyerarşileri yakalamak için tasarlanmıştır. Kapsül Ağları, temel özellikleri tespit etmekten sorumlu birincil kapsüller ve hiyerarşiyi oluşturan ve parçalar arasında ilişkiler kuran yönlendirme kapsülleri olarak iki ana kapsül türünden oluşur (WEB_106).

Kapsül Ağları, kapsüller arasında bağlantı kurmak için dinamik yönlendirme mekanizmaları kullanır. Dinamik yönlendirme algoritması, daha düşük seviyeli kapsüllerin üst düzey kapsüllerle iletişim kurduğu ve bağlantı ağırlıklarını anlaşılmaya göre ayarladığı yinelemeli süreçleri içerir. Bu, ağın tutarlı bir temsilde birleşmesini sağlar. Kapsüller, temsil edilen parçanın ya da nesnenin konumu (yönelimi ve ölçeği) hakkında

bilgi taşır. Bu, nesne konumundaki farklılıklarla mücadele eden geleneksel ağların sınırlamalarını ele almak için çok önemlidir.

Eğitim sürecinde, kapsüller anlaşılmaya göre yönlendirme yapar. Bir katmandaki kapsüller, tahminlerinin daha yüksek seviyeli kapsüllerin tahminleriyle ne kadar uyumlu olduğuna bağlı olarak, daha yüksek seviyeli kapsüllere bilgi gönderir. Bu işleyiş, nesnelerin varlığı ve özellikleri hakkında fikir birliğine varılmasına yardımcı olur. Kapsüllerin çıktısı doğrusal olmayan bir "ezme" fonksiyonu kullanılarak işlenir. Ezme fonksiyonu, kapsülün çıktı vektörünün uzunluğunu 0 ile 1 arasında olacak şekilde normalleştirir (WEB_107).

Kapsül Ağları, bir nesnenin parçaları arasındaki hiyerarşik mekansal ilişkileri yakalayarak bakış açısı değişmezliğini elde etmeyi amaçlar. Bu durum nesneleri farklı bakış açılarından tanımak için faydalıdır. Kapsül Ağları, rotasyon, çevirme ya da ölçekleme gibi afin dönüşümlere karşı daha dayanıklı olacak şekilde tasarlanmıştır. Bu da onları çeşitli yönlerdeki nesneleri tanımanın önemli olduğu uygulamalara uyumlu hale getirir.

Kapsül Ağları görüntü tanıma, nesne algılama ve sahne anlama gibi uygulamalarda kullanılır.

Derin pekiştirmeli öğrenme (DRL), araçların karmaşık davranışları ve karar verme süreçlerini öğrenmesini sağlamak için pekiştirmeli öğrenmeyi (RL) derin öğrenme teknikleriyle, özellikle derin sinir ağlarıyla birleştiren bir makine öğrenimi alt alanıdır. Pekiştirmeli öğrenme, araçların kümülatif bir ödül sinyalini en üst düzeye çıkarmak için bir ortamla etkileşime girerek bir dizi karar almayı öğrendiği bir paradigmadır. Derin öğrenme, ham duyuşal verilerden doğal dil işleme, görüntü tanıma gibi temsillerin öğrenilmesine olanak sağlayan yüksek boyutlu girdi alanlarını işlemek için tanıtılmıştır (WEB_108).

RL'de, bir aracı bir ortamla etkileşime girer, harekete geçer, ödül ya da ceza şeklinde geri bildirim alır ve kümülatif ödülü en üst düzeye çıkarmak için zaman içerisinde daha iyi kararlar almayı öğrenir. DRL, durum gözlemlerinden eylemlere kadar karmaşık eşlemeleri yaklaşık olarak tahmin etmek için derin sinir ağlarından, derin Q ağlarından (DQN), evrişimli sinir ağlarından (CNN) ya da tekrarlayan sinir ağları (RNN) gibi daha gelişmiş mimarilerden yararlanır. Q-öğrenme, DRL'de kullanılan yaygın bir

RL tekniğidir. Derin Q ağları (DQN), belirli bir durumda belirli bir eylemi gerçekleştirmek için beklenen kümülatif gelecekteki ödülleri temsil eden Q değerlerine yaklaşmayı (değere dayalı optimizasyon) öğrenir. Bazı DRL yaklaşımları, Q değerlerini tahmin etmek yerine, durumlardan eylemlere dönüştüren politikaları (politikaya dayalı optimizasyon) doğrudan öğrenir (WEB_109). Politika gradyanı yöntemleri (deterministik ve stokastik), iyi eylemlerin olasılığını artırmak için politika ağının parametrelerini optimize eder. Aracının geçmiş etkileşimlerindeki deneyimleri depolamak ve rastgele örneklemek için kullanılan bir teknik olan deneyim tekrarı, verilerdeki zamansal korelasyonların kırılmasına yardımcı olarak daha istikrarlı öğrenmeye yol açar. Eğitimi istikrara kavuşturmak için DRL genellikle hedef ağları kullanır. Bunlar, mevcut parametrelerle periyodik olarak güncellenen, yavaş hareket eden parametrelere sahip ayrı ağlardır. Bu süreç, hareketli hedeflere ilişkin eğitim sorununu azaltır. DRL, bir görevi çözerek elde edilen bilginin ilgili görevde öğrenmeyi hızlandırmak için kullanılabileceği transfer öğrenimini destekler. Bu özellikle sıfırdan eğitimin pratik olmadığı alanlarda kullanışlıdır (Dong vd., 2020: 98, 266).

DRL, oyun, robotik kontrol, otonom araçlar, doğal dil işleme ve çok daha fazlası dahil olmak üzere çeşitli uygulamalarda kullanılmaktadır.

Sinirsel turing makinesi (NTM), Alex Graves, Greg Wayne ve Ivo Danihelka tarafından 2014 yılında "Neural Turing Machines" başlıklı bir makalede tanıtılmıştır. Geleneksel sinir ağlarının yeteneklerini donanımsal, harici bir bellek ile genişleten bir tür yapay sinir ağı mimarisidir. Von Nuemann (1945)'ın tespitine göre bu bellek, ağın hesaplamaları sırasında okuyabileceği ve yazabileceği bilgileri depolamak için tasarlanmıştır (Graves vd., 2014: 1).

NTM, denetimli öğrenme ve pekiştirmeli öğrenmenin bir kombinasyonu kullanılarak eğitilebilir. Bu durum onun hem test verisine sahip verilerden, hem de ödül almak için bir ortamla etkileşime girerek öğrenmesine olanak tanır. Bununla birlikte, NTM'de bulunan okuma yazma kafaları geleneksel Turing Makinesindeki okuma yazma kafalarına benzerdir. Bu kafalar harici belleğin içeriğine erişmek ve bunları değiştirmekten sorumludur. NTM'de adresleme içerik tabanlıdır; yani okuma ve yazma kafaları, belleğin içeriği ile içerik tabanlı bir anahtar arasındaki benzerliğe dayalı olarak bellekteki belirli konumları algılayabilir. Harici bellekteki okuma ve yazma işlemleri farklılaştırılabilir, bu da NTM'nin eğitim sırasında bellekle nasıl etkileşime gireceğini ve

belleği nasıl kullanacağını öğrenmesini sağlar. Bu, ağıın uzun vadeli karmaşık işlemleri gerçekleştirmesini sağlar. Tüm NTM mimarisi farklılaştırılabilir, bu da zaman içinde geri yayılma (BPTT) gibi gradyan tabanlı optimizasyon algoritmalarını kullanarak uçtan uca eğitimi kolaylaştırır. Harici bellek NTM'ye, algoritmaları öğrenmesine ve bilgilerin zaman içinde depolanmasını ve alınmasını gerektiren hesaplamaları gerçekleştirmesine olanak tanıyan bir tür programlanabilirlik sağlar. NTM, uygulamanın kapsamına bağlı olarak hafıza etkileşimlerini kontrol etmeyi öğrenebilir. Gelecekteki hesaplamalar için bilgileri saklayarak okumayı ve yazmayı öğrenebilir.

Sinirsel turing makineleri, sıralı veri işleme, algoritmik görevler ve harici bellekten okuma ve yazma yeteneğinden yararlanan diğer problemleri içeren uygulamalarda kullanılmaktadır.

Kuantum sinir ağları (QNN). hesaplamaları gerçekleştirmek için kuantum hesaplama ve yapay sinir ağı modellerinden yararlanan yeni bir model olarak ortaya çıkmıştır. QNN'lerin klasik iki nöronlar (bitler) yerine kuantum bitleri (kübitleri) kullanan ileri beslemeli bir ağ yapısı vardır. Bununla birlikte QNN'ler hesaplama yeteneklerini potansiyel olarak geliştirmek için kuantum süper pozisyonundan ve dolanıklığından yararlanarak kübitlerden maksimum fayda sağlar. Kübitler kuantum parçacığı olgusundan ilham alınarak ortaya çıkarılmıştır. Bir kübitin aynı anda iki farklı duruma sahip olması süper pozisyon olarak adlandırılmaktadır (WEB_110). Bir başka deyişle, kuantum mekaniğinde iki dolanık parçacığa yani kübite süper pozisyon (kuantum dolanıklığı) denir (WEB_111). Söz konusu bu iki dolanık parçacığın eş zamanlı olarak işletilmesine de paralel hesaplama adı verilmektedir (WEB_112).

Yalnızca 0 veya 1 durumlarında bulunabilen klasik bitlerin aksine, kübitler aynı anda paralel hesaplama da izin verir. Bu durum, klasik muadillerine kıyasla belirli hesaplamalar için potansiyel olarak üstel bir hız sağlayabilir.

Dolanıklık, fiziksel olarak ayrılmış olsalar bile bir kübitin durumunun diğerinin durumuyla ilişkili hale geldiği bir kuantum olgusudur. Dolayısıyla dolanıklık, QNN'lerin hesaplama gücünü artırmak için kullanılabilir.

Kuantum mekaniği, QNN'lerin örüntü tanıma için makine öğreniminde kullanılan algoritmaların verimliliğini artırmak amacıyla ilkelerinden yararlandığı alandır. Dolayısıyla QNN'in ana arterlerinden biridir.

Paralellik, girişim ve dolanıklık gibi kuantum özelliklerinin büyük veri uygulamalarında eğitimi geliştirebilmesi QNN'in en büyük avantajlarındanır.

QNN'lerde kuantum kapıları klasik mantıksal kapılara eşdeğerdir. Kuantum kapıları, klasik işlemlerin kuantum analogları olan işlemleri gerçekleştirerek kubitlerin durumlarını yönetir. QNN'ler genellikle kubitlerin başlangıç durumunu son çıkış durumuna dönüştüren kuantum kapı dizileri olan kuantum devreleri olarak ifade edilir. Bu devreler, belirli bir görev için kuantum ağının performansını optimize etmek amacıyla eğitim sırasında ayarlanabilen eğitilebilir parametrelere sahiptir ve kuantum algoritmaları kullanılarak eğitilebilir.

Kuantum sinir ağları ile yapılan araştırmalar, kuantum verilere sahip olan kuantum bilgisayarlar, kuantum verilere sahip olan klasik bilgisayarlar ve klasik verilere sahip olan kuantum bilgisayarlar olmak üzere üç farklı kategori altında incelenir (WEB_113). Kuantum ve klasik sinir ağları hibrit modelinde, kuantum donanımı dahilinde kubitler ne kadar küçük, kapı sayısı ne kadar az olursa modelin o kadar çok daha iyi performans gösterdiği görülmüştür (Arthur and Date, 2022: 49).

Klasik sinir ağları, belirli görevleri yerine getirmek için kuantum alt ağlarıyla birlikte kullanılabilir. QNN'ler, kriptografi, optimizasyon, örüntü tanıma, sınıflandırma gibi çeşitli makine öğrenimi görevlerini geliştirmek için kuantum hesaplama tekniklerinin kullanımını araştıran daha geniş kuantum makine öğrenimi alanının bir parçasıdır. Mevcut QNN yaklaşımlarının çoğu, kuantum ve klasik bileşenleri bir araya getiren hibrit modelleri kapsar.

Kuantum bilgisayarlar çevresel faktörlere karşı duyarlılıklarından dolayı gürültüye ve hatalara karşı hassastır. Etkili hata düzeltme yöntemleri geliştirmek, QNN'lerin pratik uygulamasında önemli bir zorluktur. Ölçeklenebilir ve güvenilir kuantum donanımının geliştirilmesi, QNN'lerin tam potansiyelini gerçekleştirmenin önemli bir unsurudur.

Derin otomatik kodlayıcılar (DAE), otomatik kodlayıcılar ailesine ait bir tür yapay sinir ağı mimarisidir. Otomatik kodlayıcılar, boyutsallık azaltma, özellik öğrenme ve veri yeniden yapılandırma için tasarlanmış denetimsiz öğrenme modelleridir (WEB_114). Derin otomatik kodlayıcılar, genellikle derin sinir ağı mimarilerini içeren birden fazla katmanı birleştirerek geleneksel otomatik kodlayıcılar konseptini genişletir.

Bir otomatik kodlayıcı, bir kodlayıcı ve bir kod çözücünden oluşur. Kodlayıcı, girdi verilerini daha düşük boyutlu bir gösterime eşler ve kod çözücü bu gösterimden girdi verilerini yeniden yapılandırır. Derin otomatik kodlayıcılar, hem kodlayıcı hem de kod çözücü parçalarında birden fazla gizli katmana sahiptir, bu da onları "derin" yapar. Derinliğin eklenmesi, ağın girdi verilerinin daha karmaşık ve hiyerarşik gösterimlerini öğrenmesine olanak tanır. Kodlayıcı ağı, girdi verilerinin boyutsallığını aşamalı olarak azaltan birden fazla katmandan oluşur (WEB_115). Her katman bir öncekine göre daha fazla soyut özellik çıkararak hiyerarşik temsilleri yakalar. Gizli alan veya kodlama katmanı olarak da bilinen darboğaz katmanı, girdi verilerinin sıkıştırılmış ve daha düşük boyutlu temsilini ifade eder. Temel özellikleri yakalamak için kritik bir bileşendir. Kod çözücü ağı, kodlayıcıyı ters yönde yansıtır. Kodlanmış gösterimi darboğaz katmanından alır ve boyutsallığı kademeli olarak artırarak girdi verilerini yeniden yapılandırır. Düzeltilmiş doğrusal birimler (ReLU) ya da hiperbolik tanjant (tanh) gibi doğrusal olmayan aktivasyon fonksiyonları, doğrusal olmayışı tanıtmak ve modelin karmaşık ilişkileri öğrenmesini sağlamak için genellikle hem kodlayıcının hem de kod çözücünün gizli katmanlarında kullanılır.

Derin otomatik kodlayıcıların eğitimi için amaç fonksiyonu, genellikle girdi verileri ile yeniden oluşturulan çıktı arasındaki farkı ölçen yeniden yapılandırma kaybıdır. Ortak kayıp fonksiyonları, sürekli veriler için ortalama karesel hatayı (MSE) ya da ikili veriler için ikili çapraz entropiyi içerir (WEB_116). Derin otomatik kodlayıcılar, geri yayılım ve gradyan iniş optimizasyonu kullanılarak eğitilir. Model, sinir ağının ağırlıklarını ve sapmalarını ayarlayarak yeniden yapılandırma kaybını en aza indirmeyi amaçlamaktadır. Derin otomatik kodlayıcılar, aşırı uyumu önlemek ve genelleme performansını iyileştirmek için bırakma veya seyreklik kısıtlamaları gibi düzenleme tekniklerini içerebilir. Varyasyonel otomatik kodlayıcılar, olasılıksal modellemeyi içeren, öğrenilen gizli alandan örnekleme yoluyla yeni örnekler oluşturmalarına olanak tanıyan özel bir derin otomatik kodlayıcı türüdür (WEB_117). Gürültü giderici otomatik kodlayıcılar, gürültülü sürümlerden temiz giriş verilerini yeniden oluşturmak üzere eğitilir. Bu da onları girdi değişikliklerine karşı dayanıklı ve gürültü giderme işlemleri için kullanışlı hale getirir.

Derin otomatik kodlayıcıların, görüntü sıkıştırma, özellik öğrenme, gürültü giderme, anormallik tespiti ve gerçekçi veri örnekleri oluşturma dahil olmak üzere çeşitli kullanım alanları vardır.

Transfer öğrenimi, bir görev üzerinde eğitilmiş bir modelin, ilgili ikinci bir görevi gerçekleştirmek üzere uyarlandığı bir makine öğrenme tekniğidir. Buradaki fikir, bir kaynak görevi çözerek elde edilen bilgiden yararlanmak ve bunu daha az veriye ya da biraz farklı özelliklere sahip olabilecek bir hedef göreve uygulamaktır.

Transfer öğrenimi genellikle kaynak görev için büyük veri kümeleri üzerinde önceden eğitilmiş modellerin kullanılmasını içerir. Bu modeller, diğer görevler için yararlı olabilecek genel özellikleri ve kalıpları öğrenmiştir. Transfer öğreniminde, önceden eğitilmiş modelin mimarisi, hedef görevin gereksinimlerine uyacak şekilde uyarlanabilir. Bu aşama, son birkaç katmanın değiştirilmesini ya da göreve özel katmanların eklenmesini içerebilir. İnce ayar süreci, hedef görevin veri kümesindeki önceden eğitilmiş modelin ağırlıklarının güncellenmesini içerir (WEB_118). Bu süreç, modelin kaynak görevden edinilen genel bilgiyi kaybetmeden göreve özgü nüansları öğrenmesini sağlar. Transfer öğrenimi, farklı alanlarda olsalar bile, kaynak ve hedef görevler birbiriyle ilişkili olduğunda özellikle etkilidir. Örneğin, görüntü sınıflandırması için büyük bir veri kümesi üzerinde eğitilen bir model, farklı bir alandaki belirli bir görüntü tanıma görevi için ince ayar yapılabilir. Alan uyarlaması, kaynak ve hedef alanların bazı farklılıklara sahip olabileceği özel bir transfer öğrenme durumudur. Model, etki alanı boşluğunu azaltarak hedef alanda iyi performans gösterecek şekilde uyarlanmıştır.

Transfer öğrenimi, özellikle hedef görevin sınırlı test verisine sahip olduğu durumlarda daha hızlı yakınsamaya ve daha iyi performansa yol açabilir. Aynı zamanda VGG, ResNet, AlexNet, Inception, BERT ve diğerleri gibi, kıyaslama veri kümelerinde en son teknolojiye sahip performansa ulaşan önceden eğitilmiş modeller tarafından popüler hale getirilmiştir (WEB_119).

Transfer öğrenimi, bilgisayarlı görü, görüntü sınıflandırma, nesne algılama, duygu analizi, doğal dil işleme, dil çevirisi ve daha fazlası gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır.

Derin artık ağlar (ResNet) (DRN), çok derin ağların eğitim zorluğunu gidermek için oluşturulan bir tür derin sinir ağı mimarisidir. Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından 2016'da "Görüntü Tanıma için Derin Kalıntı Öğrenme" başlıklı makalede önerilmiştir (He vd., 2016, 1-15).

Artık sinir ağı, haritalamayı doğrudan öğrenmek yerine, girdi ile istenen çıktı arasındaki artığı (farkı) öğrenir. ResNet'lerde standart olarak kullanılan blok kimlik bloğudur. Kısaca değinmek gerekirse; girdi ve çıktı boyutları eşleşmezse eğer evrişimli katman kısayol bağlantısına eklenir ve buna da evrişim bloğu denir. Kimlik bloğu ana yol ve kısayol bağlantısı olmak üzere iki yoldan oluşur. Ana yol, düğümün doğrudan blok içinden akmasını sağlar. Kısayol bağlantılarını atlama, düğümün hem ileri hem de geri geçişler sırasında bir ya da daha fazla katmanı atlamasına izin verir. Bu, kaybolan düğüm sorununun azaltılmasına yardımcı olur ve çok derin ağların eğitilmesini sağlar (WEB_120). ResNet'ler çok derin artık blok yığınlarıyla tasarlanabilir. Daha fazla katman eklemenin performansta düşüşe yol açabileceği geleneksel mimarilerin aksine, ResNet'ler derinlik arttıkça daha iyi performans gösterir. ResNet'ler genellikle ağın son katmanlarındaki tamamen bağlı katmanlara alternatif olarak küresel ortalama havuzlamayı kullanır (WEB_121). Bu aşama, parametre sayısını azaltır ve girdi boyutundan bağımsız olarak sabit boyutlu bir gösterim elde edilmesine yardımcı olur. Toplu normalleştirme, ResNet'lerde bir katman içindeki aktivasyonları normalleştirmek için sıklıkla kullanılır. Bu da eğitim sürecini stabilize etmeye ve hızlandırmaya yardımcı olur.

ResNet-50, ResNet-101 ve ResNet-152 gibi önceden eğitilmiş ResNet modelleri, kıyaslama veri kümelerindeki güçlü performansları nedeniyle genellikle çeşitli bilgisayarlı görü uygulamaları için başlangıç noktaları olarak kullanılır. ResNet'ler transfer öğrenimi için çok uygundur. ImageNet gibi büyük veri kümeleri üzerinde önceden eğitilmiş modellere, belirli görevler için daha küçük veri kümeleri üzerinde ince ayar yapılabilir. ResNeXt, temsil gücünü artırmak için bir kardinalite (önem) parametresi getiren bir ResNets çeşididir. Ağın kanallarını genişleten geniş ResNet'ler gibi başka değişkenler de vardır (WEB_123).

ResNet'ler görüntü sınıflandırma görevlerinde oldukça başarılı olmuş ve birçok yarışma kazanmıştır. Ayrıca nesne algılama ve segmentasyon gibi diğer bilgisayarlı görü görevlerine de uygulanmıştır.

3.3. Kripto Para ile Yapay Zekâ İlişkisi

Kripto para birimi ile yapay zekâ arasındaki ilişki karmaşık ve çok yönlüdür. Çünkü kripto para birimi ve yapay zekâ (AI) iki farklı alandır; fakat bazı potansiyel örtüşme ve etkileşim alanlarına sahiptir.

Olası bir etkileşim alanı, kripto para birimi ticareti ve analizi için yapay zekânın kullanılmasıdır. Kripto para piyasaları son derece değişken ve karmaşıktır ve AI algoritmaları, büyük miktarda veriyi analiz etmek ve yatırımcıların tanımlamasının zor olabileceği kalıpları ve eğilimleri belirlemek için kullanılabilir. Bu potansiyel olarak piyasa eğilimlerinin daha doğru tahmin edilmesine ve daha karlı ticaret stratejilerine yol açar.

Bir başka potansiyel etkileşim alanı da yapay zekâ destekli kripto para birimi cüzdanlarının ve platformlarının geliştirilmesidir. Bu platformlar, kişiselleştirilmiş yatırım tavsiyesi ve rehberliği sağlamak, işlemleri otomatikleştirmek ve bireysel kullanıcılar için portföy yönetimini optimize etmek için yapay zekâ algoritmalarını kullanabilir.

Bununla birlikte, özellikle piyasa manipölasyonu bağlamında, kripto para birimi ticaretinde yapay zekânın kullanımına ilişkin riskler mevcuttur. Yapay zekâ destekli ticaret botlarının ve algoritmalarının kullanımı, potansiyel olarak fiyatları manipüle etmek ya da diğer etik olmayan uygulamalara girişmek için kullanılabilir.

Ek olarak, kripto para birimi yatırımlarını yönetmek için yapay zekâ destekli platformları kullanmanın potansiyel riskleri konusunda da riskler mevcuttur. Yapay zekâ destekli bir platformun saldırıya uğraması ya da başka bir şekilde tehlikeye atılması, kullanıcılar için önemli finansal kayıplara yol açabilir.

Bir yandan yapay zekâ, kripto para birimi işlemlerinin güvenliğini artırmak, dolandırıcılık faaliyetlerini tespit etmek ve kripto para birimlerinin değerini tahmin etmek için kullanılabilir. Öte yandan, kripto para piyasasında yapay zekânın kullanılması, kripto para birimi ağlarına yapay zekâ destekli saldırı olasılığı veya kripto para birimi fiyatlarını manipüle etmek için yapay zekâ tarafından oluşturulan sahte haberlerin oluşturulması gibi potansiyel riskleri de beraberinde getirebilir.

Ayrıca yapay zekâ, kripto para madenciliğinin verimliliğini artırmak, yeni kripto para türleri oluşturmak ve kripto para platformlarının kullanıcı deneyimini geliştirmek için de kullanılabilir. Bununla birlikte, yapay zekânın kripto para piyasasında kullanılmasının, yapay zekâ destekli ayrımcılık potansiyeli ya da yapay zekânın piyasadaki mevcut güç dengesizliklerini sürdürmek için kullanılması gibi etik sonuçları da dikkate alınmalıdır.

Genel olarak, kripto para birimleri ile yapay zekâ arasındaki ilişki, hem potansiyel faydaları hem de riskleri olan, gelişen ve karmaşık bir ilişkidir. Bu ilişki, sektörün geleceği için hem fırsatlar hem de zorluklarla birlikte sürekli gelişmektedir. Yeni ortaya çıkan herhangi bir teknolojide olduğu gibi, yapay zekâ destekli kripto para birimi platformlarına ya da ticaret stratejilerine yatırım yapmadan ya da bunları kullanmadan önce potansiyel riskleri ve faydaları dikkatli bir şekilde değerlendirmek önemlidir.

3.4. Kripto Para Tahmininde Yapay Zekânın Yeri

Yapay zekâ, geleneksel ticaret yöntemlerine göre çeşitli avantajlar sunduğu için kripto para birimi tahmini ve ticaretinde giderek daha fazla kullanılmaktadır. Söz konusu bu temel avantajlarından biri, büyük miktarda veriyi işleyebilmesi ve yatırımcıların tespit etmesi zor ya da imkânsız olabilecek kalıpları belirleyebilmesidir. Bu, piyasa eğilimlerinin daha doğru tahmin edilmesine ve daha karlı ticaret stratejilerine yol açabilir.

Yapay zekâ algoritmaları aynı zamanda değişen piyasa koşullarını öğrenip bunlara uyum sağlayarak, tahminlerini ve ticaret stratejilerini zaman içerisinde sürekli olarak geliştirmelerine olanak tanır. Yapay zekânın kripto para birimi tahmini için kullanılabileceği çeşitli şekiller vardır:

1. Duygu analizi: Yapay zekâ algoritmaları, kripto para birimi fiyatlarını etkileyebilecek duygu kalıplarını belirlemek için sosyal medya gönderilerini, haber makalelerini ve diğer çevrimiçi içerikleri analiz edebilir.

2. Teknik analiz: Yapay zekâ algoritmaları, kripto para birimi fiyat grafiklerini analiz edebilir ve gelecekteki fiyat hareketlerini gösterebilecek kalıpları ve eğilimleri belirleyebilir.

3. Makine öğrenimi: Yapay zekâ algoritmaları, gelecekteki fiyat hareketlerini tahmin etmek için kullanılabilecek tahmine dayalı modeller geliştirmek için geçmiş kripto para birimi fiyat veri ve grafiklerinden öğrenebilir.

4. Doğal dil işleme: Yapay zekâ algoritmaları, kripto para birimi fiyatlarını etkileyebilecek anahtar kelimeleri ve diğer faktörleri belirlemek için haber makalelerini ve diğer metin tabanlı içerikleri analiz edebilir.

3.5. Kripto Paraların Yapay Zekâ ile Tahminine Dayalı Literatür Araştırması

Kripto para birimleri ve yapay zekâ ilişkisine dayalı olarak literatürde oldukça çok sayıda çalışma bulunmaktadır. Literatürde genel olarak günümüze kadar; kripto paraların finans sektöründeki yerine ve kripto paraların değer tahminine yönelik çalışmalar üzerinde durulmuştur. Konunun daha anlaşılabilir olması bakımından bu şekilde iki farklı başlık altında incelenmiştir.

3.5.1. Kripto Paraların Finans Sektöründeki Yerine Yönelik Çalışmalar

Çetinkaya (2018), kripto paraların para piyasalarındaki yerinin analizini yapmıştır. Yasal altyapısının tam olarak oturmuş olmamasının bir tehdit unsuru oluşturduğu, dolayısıyla devletlerin kripto paraların yasallaşma süreciyle ilgili gerekli altyapıyı sağlamaları gerektiği sonucuna ulaşmıştır.

Ceylan (2019), Bitcoin'in finans sektörü içerisindeki yerinin analizlerini yapmıştır. Sonuç olarak, kripto para Bitcoin'in yasal boşlukları ve bilinmeyen noktalarını birer tehdit olarak görmüş olsa da kullanımının uluslararası ticarete istikrarı sağlamanın bir yolu olduğu kanısına ulaşmıştır.

Yiying ve Yeze (2019)	2015:M8-2018:M6	Kripto para fiyat dinamikleri ve fiyat öngörülebilirliği	Bitcoin, Ethereum, Ripple fiyatları (açılış, kapanış, min, max)	R	YSA, LSTM	Kısa vadede LSTM, Uzun vadede YSA ✓
Veri Kaynağı: https://www.blockchain.com/markets						
Valencia ve diğ. (2019)	2018:M2-2018:M4	Bitcoin, Ethereum, Ripple ve Litecoin fiyat hareketleri	Bitcoin, Ethereum, Ripple ve Litecoin	S, R	SA, NN, MLP, SVM, RF	SA ve NN ✓
Veri Kaynağı: https://www.cryptocompare.com/						
Souza ve diğ. (2019)	2012:M4-2017:M4	Kripto para fiyatı	Btc, altın, gümüş günlük fiyatlar (açılış, kapanış, min, max)	S, R	SVM ve YSA	✓
Veri Kaynağı: https://www.bloomberg.com/professional/solution/bloomberg-terminal/						
Smuts (2019)	2017:M12-2018:M6	Bitcoin ve Ethereum fiyat hareketleri	Google Trends ve Telegram üzerinden Saatlik BTC ve ETH verileri	S	SA, CA	Google Trends 1 haftalık dönemde ETH için, Telegram verileri BTC için en yüksek tahmin gücüne sahiptir.
Veri Kaynağı: https://trends.google.com/trends , https://telegram.org						
Senthuran ve Halgamug e (2019)	2009-2018	Kripto para fiyatları	Bitcoin ve Ethereum Kripto para ve Blokzincir verileri	R	LSTM	✓
Veri Kaynağı: https://www.blockchain.com/explorer , https://bitinfocharts.com/ethereum/						
Miura ve diğ. (2019)	2012:M1-2018:M11	Btc oynaklığı	Btc günlük kapanış fiyatı	S, R	MLP, GRU, LSTM, CNN, SVM, HARRV, RR	RR ✓
Veri Kaynağı: https://www.bitstamp.net/market/tradeview/						
Mallqui ve Fernandes (2019)	2013:M4-2017:M4	BTC günlük max, min ve kanış fiyat yönü	Günlük dahili ve harici BTC veriler	S, R	ANN, SVM ve RNN, TC, k-means	En iyi regresyon modeli SVM, En iyi sınıflandırma modeli RNN ve TC
Veri Kaynağı: http://bitcoincharts.com , http://quandl.com , http://investing.com						
Liew ve diğ. (2019)	2015:M1-2018:M2	Kripto para getiri tahmini	En büyük 100 kripto kapanış fiyatı, işlem hacmi, piyasa değeri (günlük)	S, R	PCA, BTA, LASSO, EN, SGD, BR, DT, ETRF, AdaBoost, GTB, kNN, SVM, MLP	LASSO ✓
Veri Kaynağı: https://coinmarketcap.com/api/						

Atsalakis ve diğ. (2019)	2011:M9-2017:M10	Kripto para getirisi	Bitcoin, Ethereum, Litecoin ve Ripple getirileri (Günlük)	R	PATSOG-Hibrit bir nöro-bulanık model	√
Veri Kaynağı: https://bitcoincharts.com						
Ashayer (2019) (YL TEZİ)	2008-2018	Kripto para kapanış fiyatları	Btc, Eth, Btc Cash, Dash, Ltc, Xmr günlük kapanış fiyatları	S, R	Otoregresyon, ARIMA, Üstel yumuşatma, FNN, LSTM	Fiyat tahmini için ARIMA √, Fiyat hareket yönü tahmini için LSTM √
Veri Kaynağı: https://coinmetrics.io/						
Adcock ve Gradojevic (2019)	2010:M7-2018:M3	BTC getirilerini n nokta ve yoğunluğu	Günlük BTC fiyatları	R	İleri beslemeli geri yayımlı yapay sinir ağı	ANN nokta ve yoğunluk tahminini iyileştirebilir.
Veri Kaynağı: https://www.bloomberg.com/professional/solution/bloomberg-terminal/						
Wu ve diğ. (2018)	2018:M1-2018:M7	BTC tahmini	BTC günlük fiyat ve işlem hacimleri	R	Geleneksel LSTM ve AR(2) modeli ile LSTM	AR(2) Modeli ile LSTM √
Veri Kaynağı: https://www.investing.com/crypto/bitcoin/historical-data						
Velankar ve diğ. (2018)	2013-2018	BTC fiyatı	Günlük Btc fiyatları (Açılış, kapanış, en düşük, en yüksek fiyatlar, işlem hacmi, ağırlıklı fiyat)	S, R	1. Logaritmik, Standart sapma, Z skor ve Box-Cox normalizasyonu 2. BR, GLM / RF	Tahmin için yapılacak olan makale çalışması devam etmektedir.
Veri Kaynağı: https://www.quandl.com/collections/markets/bitcoin-data , https://coinmarketcap.com/						
Vo ve Yost-Bremm (2018)	2012:M1-2017:M10	BTC fiyatı	Dakikalık BTC Fiyatları (usd,cny,jpy,e ur para biriminde açılış,kapanış, en yüksek, en düşük fiyat, ticaret hacmi)	R	RF, DSR	RF √
Veri Kaynağı: https://www.bitstamp.net/markets/btc/usd/ , https://btc-e.com/ , https://www.btcn.com/ , https://www.coinbase.com/price/bitcoin , https://coincheck.com/exchange/tradeview , https://www.kraken.com/prices/bitcoin						
Tupinambás ve diğ. (2018)	2017:M8-2017:M12	Kripto para fiyat değişimi	15 kripto paranın dakika başına ort. fiyatı	S	Genetik Mamdani yorumlanabilir bulanık çıkarım (%70 eğitim, %30 test)	En yüksek doğrulama performansına sahip kripto para kazanç katsayısı normal para birimine kıyasla çok daha fazladır.
Veri Kaynağı: https://www.kraken.com/prices						
Taher ve Subhi (2018)	2011:M9-2018:M1	BTC fiyatı	Btc fiyatları (açılış, kapanış, en düşük, en yüksek)	R	SVM, k-means kümeleme ve Mahalanobis mesafesi, ANN	Sınıflandırılmış ANN √
Veri Kaynağı: https://www.quandl.com/api						

DÖRDÜNCÜ BÖLÜM

YÖNTEM VE UYGULAMA

4.1. Araştırmanın Amacı ve Önemi


Dünya ekonomik sistemi açısından bakıldığında, tıpkı diğer alanlarda olduğu gibi ekonomi alanında da teknolojiye olan gereksinim (talep) arttığından, günümüzde katma değeri yüksek ürünlerin üretiminin yapılabiliyor olması o ülkenin ekonomik, dolayısıyla toplumsal refahının artacağına sinyallerini vermektedir. Hızlı gelişen ülkelerin kısa geçmişine bakıldığında katma değeri yüksek teknoloji ürünlerinin üretimine yaptıkları yatırımın yüksek olduğu bilinmektedir. Kripto paraların da diğer yüksek teknolojik ürünler gibi insan hayatına girmesi ve zaman içerisinde kendi alanını genişletmesi, dijitalleşmenin dünya ekonomik sistemi üzerine yansımalarının en temel örneğidir.

Dijital dönüşüm çağına ayak uydurabilmek adına teknolojik bilgilerin entegre edilmesi işlevsellik açısından büyük kolaylıklar sağlayabilmektedir. Bu bağlamda bu çalışmanın amacı kripto paralara ilişkin ulaşılmak istenen gelecekteki gerekli verilerin yapay zekâ teknikleri yardımıyla öngörümlemesinin sağlanmasıdır. Kripto para fiyatlarının ve kripto paraların para piyasalarındaki yerinin tahmini vb.. gibi alt konular bu öngörümlemeye dahil edilebilmektedir.

4.2. Veri Seti

Bu çalışmada ilk kripto para birimlerinden olan Tether (Usdt) stabilcoin olması sebebiyle analize tabi tutulmamıştır. Bununla birlikte söz konusu çalışmada diğer ilk 11 kripto para birimi olan Bitcoin (Btc), Bitcoin Cash (Bch), Ethereum (Eth), Ethereum Classic (Etc), Litecoin (Ltc), Dashcoin (Dash), Dogecoin (Doge), Ripple (Xrp), Stellar (Xlm), Monero (Xmr) ve ZCash (Zec)'in Yahoo Finans'ta ilk listelenmeye başladığı tarih itibarıyla günlük verileri kullanılarak gerekli incelemeler yapılmıştır. Tüm kripto paralar için yaklaşık 10 yıllık günlük veriler finance.yahoo.com ve [CoinMarketCap](https://coinmarketcap.com)'ten çekilmiş olup bu veriler açılış-kapanış fiyatları, en düşük-en yüksek fiyatlar, işlem hacimlerini kapsamaktadır. Aşağıda bu çalışmada analize tabi tutulan kripto para birimlerinin kapanış fiyat grafikleri verilmiştir.

Btc Fiyat Grafiği



Bch Fiyat Grafiği




Eth Fiyat Grafiği



Etc Fiyat Grafiği




Dash Fiyat Grafiği



Doge Fiyat Grafiği





Şekil 3. Kripto Para Kapanış Fiyat Grafikleri

Grafiklere bakıldığında ele alınan tüm kripto para birimleri için her dört yılda parabolik bir döngüye sahip oldukları görülmektedir. Söz konusu bu parabolik eğrinin oluşumunda her dört yılda bir gerçekleşen Bitcoin yarılanmasının yanı sıra çeşitli mecralarda ortaya çıkan spekülasyon haberleri, savaşlar, salgın hastalıklar, ekonomik krizler gibi pek çok faktörün de payı bulunmaktadır. Geçmiş kaynaklardan elde edilen bilgilere göre, Amerika Birleşik Devletleri'nin

Merkez Bankası olarak bilinen Federal Rezerv Sistemi (FED) faiz kararlarına bakıldığında 2017 ve 2021 yıllarında faizi sabit bıraktığı görülmektedir. Dolayısıyla faiz artırımının yapılmadığı dönemlerin de kripto para fiyatlarındaki artışlara etkisi açık bir şekilde görülebilmektedir.

Durağan zaman serileri, istatistiksel analizlerde daha kolay modelleme ve tahmin yapmayı mümkün kılmaktadır. Analizlerde bu tür zaman serileriyle çalışmak, tahmin yöntemlerinin daha güvenilir sonuçlar üretmesini sağlamaktadır. Bu bağlamda finansal ve ekonomik zaman serileri verilerinde durağanlık görmek pek mümkün olmadığından, bu tür zaman serilerinin durağanlık özelliklerini değerlendirmek ve en uygun modeli kullanmak amacıyla durağanlaştırılmış serilerin yanısıra durağanlaştırılmamış seriler de analize tabi tutulmuştur.

Şekil 4 Btc, Bch, Eth, Etc, Dash, Doge, Ltc, Xlm, Xmr, Xrp ve Zec'in temel anahtar ölçümlerinden bazılarının logaritmik verilerini göstermektedir.

Bir finansal zaman serisinde riski anlamak için önemli bir ölçü olan standart sapma (std) zaman serisindeki volatilitiyi gösterir. Şekil 4'teki standart sapmaların karşılaştırılması sonucu gözlenen dönemde Btc, Bch, Eth, Etc, Dash, Ltc ve Zec'in analize tabi diğer kripto paralardan daha değişken davrandığı görülmektedir.

	Btc_Close	Btc_Close_log
Count	3759.00	3759.00
Median	19585.86	8.63
Std	22126.52	2.14
Min	178.10	0.00
Max	106140.60	11.57
Skewness	1.28	-0.80
Kurtosis	0.93	-0.52

	Bch_Close	Bch_Close_log
Count	2610.00	2610.00
Median	425.23	5.38
Std	395.12	1.01
Min	77.37	0.00
Max	3923.07	8.25
Skewness	3.24	-0.28
Kurtosis	14.53	0.16

	Eth_Close	Eth_Close_log
Count	2610.00	2610.00
Median	1491.48	6.55
Std	1226.56	1.46
Min	84.31	0.00
Max	4812.09	8.46
Skewness	0.55	-0.71
Kurtosis	-0.85	-0.49

	Etc_Close	Etc_Close_log
Count	2610.00	2610.00
Median	20.40	2.47
Std	15.61	1.00
Min	3.47	-0.00
Max	134.10	4.88
Skewness	1.78	-0.41
Kurtosis	5.34	-0.81

	Dash_Close	Dash_Close_log
Count	2610.00	2610.00
Median	134.88	3.95
Std	175.00	1.33
Min	21.45	0.00
Max	1550.85	7.33
Skewness	3.62	-0.20
Kurtosis	16.08	-0.29

	Doge_Close	Doge_Close_log
Count	2610.00	2610.00
Median	0.08	0.07
Std	0.10	0.08
Min	0.00	0.00
Max	0.68	0.52
Skewness	1.90	1.59
Kurtosis	4.43	2.73

	Ltc_Close	Ltc_Close_log
Count	3759.00	3759.00
Median	69.48	3.56
Std	61.09	1.49
Min	1.16	0.00
Max	386.45	5.96
Skewness	1.33	-0.88
Kurtosis	2.39	-0.66

	Xlm_Close	Xlm_Close_log
Count	2610.00	2610.00
Median	0.17	0.13
Std	0.13	0.10
Min	0.03	-0.00
Max	0.90	0.62
Skewness	1.63	1.38
Kurtosis	2.53	1.37

	Xmr_Close	Xmr_Close_log
Count	2610.00	2610.00
Median	151.12	4.53
Std	74.70	0.79
Min	33.01	0.00
Max	483.58	6.11
Skewness	1.05	-0.99
Kurtosis	1.70	1.02

	Xrp_Close	Xrp_Close_log
Count	2610.00	2610.00
Median	0.55	0.32
Std	0.37	0.22
Min	0.14	0.00
Max	3.38	1.44
Skewness	2.79	1.57
Kurtosis	11.14	3.50

	Zec_Close	Zec_Close_log
Count	2610.00	2610.00
Median	98.42	3.79
Std	101.36	1.13
Min	18.29	0.00
Max	880.76	6.76
Skewness	2.79	-0.02
Kurtosis	10.04	-0.46

Şekil 4. Kripto Para Temel Ölçüm Logaritmik Veriler

4.3. Araştırmanın Yöntemi

Üretken çekişmeli ağlar (GANs), gerçeğe çok yakın yeni veri örnekleri oluşturmak ve veri sentezi için kullanılırlar. GAN'lar, bu işlevi yerine getirmek için gerçekçi veriler üreten jeneratör (generator) ve üretilen bu verileri gerçeğinden ayırt etme görevini üstlenen ayırt edici (discriminator) olmak üzere iki temel bileşenden oluşur. Jeneratör, rastgele gürültüyü (random noise) alarak yeni veri örnekleri üretir. Ayırt edici ise jeneratör tarafından üretilen örneklerle gerçek veriler arasında karşılaştırma yaparak sahte verileri algıladığında jeneratöre geri yayılım gönderir ve jeneratör bunun üzerine gerçeğine daha yakın yeni veriler üretmeye başlar. Söz konusu bu döngüye ise ağların eğitimi (training) adı verilir. Jeneratör, ayırt edici üretilen bu verileri gerçeğinden ayırt edemeyinceye kadar yeni veriler üretmeye devam eder.

GAN'ların diğer derin öğrenme yöntemlerinden önemli ölçüde farklılık gösteren birkaç belirgin özelliği aşağıda maddeler halinde gösterilmiştir:

- Diğer derin öğrenme modelleri genel olarak sınıflandırma ya da regresyon gibi belirli bir görev için eğitilirken, GAN'lar gerçeğinden ayırt edilemeyecek düzeyde yeni veri örnekleri oluşturmak için eğitilir.
- Yukarıda da değinildiği üzere GAN'lar çekişmeli öğrenme yaklaşımı altında çalışır. Yani jeneratörün ürettiği verilerin gerçek verilerle karşılaştırılabilirliğini artırmak için sürekli olarak geliştirilmesini sağlar.
- GAN'lar daha gerçekçi ve yüksek kalitede sonuçlar üretme yeteneğine sahiptir.
- GAN'lar veri artırmanın yanı sıra görüntü ve ses sentezi, metinden görüntü sentezi gibi birçok alanda başarıyla uygulanabilir. Dolayısıyla bu tip özellikler, çeşitli alanlarda kullanımında GAN'ları önemli bir araç haline getirir.

Üretken çekişmeli ağlarda üretici ve ayırt ediciye yönelik temel fonksiyonlar şu şekilde gösterilir ve formülize edilir (Goodfellow vd., 2014: 4):

Gerçek görüntülerin alımı

$$\{D(x^{(1)}), \dots, D(x^{(m)})\} \quad (1)$$

Ayırt edicinin eğitimi

$$\nabla_{\theta_d} = \frac{1}{m} \sum_{i=1}^m [\log D(x^i) + \log (1 - D(G(z^i)))] \quad (2)$$

Üreticinin eğitimi

$$\nabla_{\theta_g} = \frac{1}{m} \sum_{i=1}^m \log (1 - D(G(z^i))) \quad (3)$$

Sahte görüntüler üretimi

$$\{G(z^{(1)}), \dots, G(z^{(m)})\} \quad (4)$$

m = Toplam veri noktaları sayısı

G = Jeneratör çok katmanlı algılayıcısı

G(z) = Veri alanına eşleme

D = Tek bir skaler çıktı veren ayırt edici çok katmanlı algılayıcısı

D(x) = Verilerden gelen x 'in olasılığı

Varyasyonel otomatik kodlayıcı (VAE), girdi verisinin gerçek dağılımını öğrenmek için değişken öğrenme kurallarını kullanırken, aynı zamanda veri girdisini gizli bir uzayda dağılım parametrelerine (gizli değişkenlere) dönüştürerek veri setinin yapısını öğrenir. Böylelikle değişkenlerin kodlanmış uzayını öğrenmenin yanısıra girdi verisinin yeniden oluşturulması ve örneklenmesini de sağlayan bir model oluşturur. VAE'ye ilişkin temel fonksiyon aşağıdaki şekilde gösterilir:

Varyasyonel otomatik kodlayıcının eğitimi

$$\mathcal{L} = - \sum_{i=1}^m \frac{1}{2} [1 + \log(\sigma_i^2) - \sigma_i^2 - \mu_i^2] - \frac{1}{L} \sum_l E_{\sim q_{\theta}(z|x^i)} [\log_p(x^i \setminus z^{(i,l)})] \quad (5)$$

μ, σ = Gürültü dağılımından rastgele örnekler $p(\epsilon)$

q = Parametreleyen gerçek değerler kümesi

χ^i = Gerçek verilerden bir grup

Z^i = Üretilen verilerden bir grup

VAE, veri setlerinin üretken modellemesi ve yeni verilerin üretilmesi için kullanılırken, GAN'lar gerçekçi veriler üretmek için kullanılmaktadır. Söz konusu bu iki yaklaşım, üretken modelleme alanında birbirlerini tamamlayan özelliklere sahiptir. Dengeli bir eğitimle, dikkatli bir şekilde gerekli yapılandırmalar ve ayarlamaların yapılmasıyla oldukça iyi bir performans göstermektedir. Gerçek veriye ulaşmada gösterdiği performansla istinaden birlikte kullanılması için bazı nedenler şu şekilde sıralanabilir:

- VAE, veri dağılımını daha iyi modellemek ve veriyi daha doğru bir şekilde yeniden oluşturmak için kullanılabilirken, GAN'lar daha gerçekçi veriler üretebilmektedir.

- VAE, verinin gizli uzayını modelleyerek daha iyi özelliklerin çıkarılmasına ışık tutarken, GAN'lar gerçekçi veriler üreterek daha iyi özelliklerin elde edilmesini sağlamaktadır.

- VAE ve GAN'ların bir arada kullanımı, eğitim sürecinde daha istikrarlı bir ilerleme sağlayabilir. VAE, başlangıçta daha istikrarlı bir eğitim sağlayabilirken, GAN'lar eğitim sürecinde daha gerçekçi veriler üreterek daha iyi sonuçlar elde edebilmektedir. Dolayısıyla bu kombinasyon daha iyi bir üretken model oluşturabilmektedir. VAE-GAN modeli kayıp fonksiyonu denklemi aşağıdaki şekilde uyarlanmıştır:

$$\mathcal{L}_{VAE-GAN} = -\frac{1}{n} \sum_{i=1}^n \mathbb{E}_{q(z|x^i)} [\log p(x^i|z)] + \frac{1}{n} \sum_{i=1}^n KL(q(z|x^i) || p(z)) + \frac{1}{m} \sum_{i=1}^m [\log D(x^i) + \mathbb{E}_{z \sim q(z|x^i)} [\log(1 - D(G(z)))]] \quad (6)$$

x^i = Gerçek veri noktası x 'in i numaralı örneği

z = Gizli (latent) değişken

$q(z|x^i)$ = Verilen bir x^i verisine göre z değişkeninin (varyasyonel) dağılımı

$p(x^i|z)$ = Gizli değişken z 'den üretilen x^i veri noktasının (yeniden inşa) olasılığı

$p(z)$ = Standart normal (öncel) dağılım

$\mathbb{E}_{q(z|x^i)} [\log p(x^i|z)]$ = x^i 'nin z ile yeniden inşa edilmesi olasılığının beklenen değeri


$KL(q(z|x^i) || p(z))$ = Kullback-Leiber (KL) ayrımı, $q(z|x^i)$ varyasyonel dağılımı ile $p(z)$ standart normal dağılımı arasındaki farklılığı ölçer

$D(x^i)$ = Ayırt edicinin x^i 'nin gerçek veri olup olmadığına yönelik verdiği olasılık

$G(z)$ = Jeneratörün gizli değişken z 'den ürettiği sahte veri

$\mathbb{E}_{z \sim q(z|x^i)} [\log(1 - D(G(z)))]$ = $G(z)$ 'nin ayırt edici tarafından yanlış sınıflandırılma olasılığı

VAE-GAN modeline ilişkin mimari Şekil 4'te gösterilmiştir.



Şekil 5. VAE-GAN Mimarisi

Bu çalışmada VAE (Variational Autoencoder) ve GANs (Generative Adversarial networks)'ın birlikte kullanılmasıyla gerçeğe en yakın sonuca ulaşılmıştır. VAE-GAN, varyasyonel otokodlayıcının değişken öğrenme modellemesi ile üretken çekişmeli ağların üretken modelleme yeteneklerini birleştirmektedir. Bu kombinasyon, daha iyi bir üretken modelleme performansı ve daha gerçekçi veri üretme yeteneği sağlamaktadır.

4.3.1. Veri Analizinde Kullanılan Teknik İndikatörler ve Veri Ön İşleme

Bu çalışmada fiyat hareketlerini analiz etmek, trendleri tanımlamak, aşırı alım-satım koşullarını belirlemek ve volatilitiyi ölçmek amacıyla SMA (Basit hareketli ortalama) ya da MA (Hareketli ortalama), Bollinger bantları, EMA (Üstel hareketli ortalama), MACD (Hareketli ortalama yakınsama diverjansı), RSI (Göreceli güç endeksi), ATR (Ortalama gerçek aralık) ve RSV (Göreceli güç değeri) kullanılmıştır. Kısaca özetlemek gerekirse;

SMA ya da MA, fiyatın belirli bir zaman dilimindeki (genel olarak günlük) ortalamasını hesaplayarak trendleri tanımlamak amacıyla kullanılır. Fiyat hareketlerini yumuşatarak piyasadaki genel eğilimi belirlemeye yardımcı olur. Kısa vadeli (20 günlük), orta vadeli (50 günlük) ve uzun vadeli (200 günlük) hareketli ortalamalar gibi farklı periyotlarda kullanılabilir.

Bollinger bantları, fiyatın ortalamadan sapmasını ölçen bir göstergedir. 20 günlük MA etrafında üst (upper) ve alt (lower) bantlar oluşturur. Üst bant, MA ile standart sapmanın iki katının toplamı kadar yukarıya yerleştirilirken ($upper = sma + 2 * std$), alt bant MA ile standart sapmanın iki katının arasındaki fark kadar aşağıya yerleştirilir ($lower = sma - 2 * std$). Bollinger bantları, fiyatın aşırı alım-satım durumlarını belirlemek için kullanılır. Bantların daralması düşük

volatilitiyi, genişlemesi ise yüksek volatilitiyi göstermektedir. Bantlar arasındaki sıkışma genellikle bir fiyat hareketi öncesi bir boğa ya da ayı piyasasının başlangıcını işaret etmektedir.

EMA, SMA'ya benzer şekilde fiyatın belirli bir zaman dilimindeki ortalamasını hesaplar, ancak son fiyat hareketlerine daha fazla ağırlık verir. Daha hızlı tepki verir ve trend değişikliklerini daha hızlı yakalayabilir.

MACD, farklı iki EMA'nın birbirinden çıkarılmasıyla oluşur. MACD çizgisi ve sinyal çizgisi arasındaki kesişmeler, alım ve satım sinyalleri üretir. Histogram, MACD çizgisi ile sinyal çizgisi arasındaki farkı gösterir ve momentumu görselleştirir.

RSI, fiyat hareketlerinin aşırı alım-satım koşullarını belirlemek için kullanılır. Genellikle 0 ile 100 arasında bir ölçekle ifade edilir. 70'in üzerinde bir RSI değeri aşırı alımı, 30'un altında bir RSI değeri ise aşırı satımı göstermektedir.

ATR, volatilitiyi ölçmek ve fiyat hareketlerinin beklenen aralığını tahmin etmek için kullanılır. Belirli bir zaman aralığındaki en yüksek ve en düşük fiyatlar arasındaki farkların ortalamasını hesaplar.

RSV, RSI hesaplamak için kullanılan bir indikatördür. Mevcut kapanış fiyatının, belirli bir zaman aralığındaki en yüksek ve en düşük fiyatlar arasında nerede olduğunu ölçer.

Fourier dönüşümü (FT), zaman alanında tanımlanan bir sinyalin frekans alanına dönüştürülmesini sağlayan matematiksel bir işlemdir. Bu sinyalin zamanla nasıl değiştiğini anlamak ve sinyalin frekans bileşenlerini analiz etmek için yaygın olarak kullanılır. Veri setlerinden çeşitli özelliklerin çıkarılması için kullanılabilir. Dolayısıyla VAE-GAN modelinde de girdi verilerinin özelliklerini analiz etmek ve modellemek için kullanılmıştır.

Fourier dönüşümünün formülü, karmaşık analiz ve integral hesabına dayanmaktadır. $f(t)$ sinyalinin dönüşümü genellikle şu şekilde ifade edilir:

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt \quad (7)$$

ω = frekans

t = zaman

$e^{-i\omega t}$ = kompleks düzlemdeki dönüşüm

MinmaxScaler, veri özelliklerinin aralıklarını sınırlamak ve modellerin daha iyi performans göstermesini sağlamak amacıyla kullanılan etkili bir ön işleme tekniğidir. Her bir özellik için min-max değerleri kullanarak veriyi belirli bir aralığa dönüştürür. Genellikle [0,1] aralığı tercih edilmekle birlikte bir başka aralık da seçilebilir. Dolayısıyla veri normalizasyonu için kullanılan bir yöntemdir. Veri özelliklerinin farklı aralıklarda olması durumunda ortaya çıkan dengesizliği giderir. Bu, farklı özelliklerin model tarafından eşit önemde değerlendirilmesini sağlamaktadır. Veri setindeki aykırı değerlerin etkisini azaltmaz. Aykırı değerler, min-max değerler arasında kaldığı sürece dönüşüm sırasında dikkate alınır. Min-Max scaler formülü şu şekildedir:

$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (8)$$

X = ölçeklenecek veri seti

X_{min} = veri setindeki en küçük değer

X_{max} = veri setindeki en büyük değer

Durağanlaştırma işlemi, zaman serisi analizinde modelleme sürecinin temel gerekliliklerinden biri olup, tahmin doğruluğunu ve istatistiksel geçerliliği doğrudan etkilemektedir. Birim kök içeren seriler, değişen ortalama ve varyans yapıları nedeniyle analiz sonuçlarında taraflılık ve tutarsızlık ortaya çıkarma potansiyeline sahiptir. Dolayısıyla, serinin durağan olup olmadığının tespit edilmesi ve birim kök içeren serinin durağanlaştırılması, sağlıklı bir analiz süreci için kritik öneme sahiptir. Bu çalışmada, serinin durağanlık özellikleri Genişletilmiş Dickey Fuller (ADF), Phillips Perron (PP) ve Kwiatkowski Phillips Schmidt Shin (KPSS) testleri aracılığıyla değerlendirilerek, serinin hem durağanlaştırılmış hem de durağanlaştırılmamış hâliyle VAE-GAN modeline giriş yapıp durağanlaştırma işleminin model performansı üzerindeki etkisi karşılaştırılmıştır.

Dickey & Fuller (1979) tarafından ilk olarak ortaya atılan Dickey & Fuller (DF) birimkök testine ilişkin denklem aşağıdaki gibidir:

$$\Delta Y_t = \alpha Y_{t-1} + Z_t' \gamma + \varepsilon_t \quad (9)$$

Eşitlik 9'daki denklemde ΔY_t , Y bağımlı değişkeninin birinci farkını ifade ederken, Y_{t-1} bağımlı değişkenin bir önceki döneme ait gecikmesini ifade etmektedir.

Z'_t , deterministik öğeleri içinde barındıran bir matristir ve ε_t ise hata terimini ifade etmektedir (Aldı vd., 2025: 35).

4.3.1.1. Genişletilmiş Dickey & Fuller (ADF) Birimkök Testi

DF denklemleri, bağımsız değişkenlerin bulunduğu tarafa bağımlı değişkenin gecikmeleri eklenerek geliştirilmiştir. Gecikmelerin eklenmesinin nedeni, zaman serilerinin genellikle dinamik yapıya sahip olması, geçmiş dönem değerlerinin gelecek dönem değerlerini etkileyebilmesi ve otokorelasyon kaynaklı hataların giderilmeye çalışılmasıdır. Böylece Genişletilmiş Dickey & Fuller (ADF) testi olarak literatürde yerini almıştır. İlk olarak ADF testi yapılmış olup gerekli denklem Eşitlik 4.1'deki gibidir:

$$\Delta Y_t = \alpha Y_{t-1} + \gamma' Z_t + \rho_1 \Delta Y_{t-1} + \rho_2 \Delta Y_{t-2} + \dots + \rho_q \Delta Y_{t-q} + \varepsilon_t \quad (10)$$

Burada ΔY_t bağımlı değişken Y 'nin birinci farkını, Y_{t-1} Y 'nin bir dönem önceki gecikmesini, Z_t deterministik öğeleri içeren matristir.

4.3.1.2. Phillips & Perron (PP) Birimkök Testi

Phillips & Perron (1989) yaptığı çalışmasında DF birimkök testinden yola çıkarak doğru otokorelasyonu yakalamak için gecikmeleri artırmaktansa parametrik olmayan bir yaklaşımı ele alarak, PP birimkök testini çıkarmıştır. Bu yaklaşımı içeren ekonometrik denklemler Eşitlik 11, 12 ve 13'teki gibidir:

$$Z_{\hat{\alpha}} = T_{\hat{\alpha}} - (\hat{\omega}^2 - \hat{\sigma}_{\varepsilon}^2) + (2T^{-2} \sum_{t=1}^T \hat{\varepsilon}_t^2)^{-1} \quad (11)$$

$$Z_{\hat{\varepsilon}} = t_{\hat{\alpha}} \left(\frac{\hat{\sigma}_{\varepsilon}^2}{\hat{\omega}^2} \right)^{\frac{1}{2}} - \frac{1}{2} (\hat{\omega}^2 - \hat{\sigma}_{\varepsilon}^2) (\hat{\omega}^2 T^{-2} \sum_{t=1}^T \hat{\varepsilon}_t^2)^{-\frac{1}{2}} \quad (12)$$

$$\hat{\sigma}_{\varepsilon}^2 = \frac{\sum_{t=1}^T \hat{\varepsilon}_t^2}{T-k} \quad (13)$$

Eşitlik 11 ve 12'de yer alan $\hat{\omega}^2$, tutarlı uzun dönem hata varyansını göstermektedir. Bunun nedeni PP testinin, DF ve ADF testi varsayımlarından farklı olarak Newey West hata düzeltme mekanizmasıyla birlikte Kernel tahminicisini kullanıyor olmasıdır. Böylelikle ardışık bağımlılığı ortadan kaldırıp, eş-varyans varsayımını tamamlamış olmaktadır. Birim kök testlerinde, $H_0: \alpha=0$ olması serinin birim kök içerdiği, $H_1: \alpha<0$ olması o serinin durağan olduğu anlamını ifade etmektedir.

4.3.1.3. Kwiatkowski-Phillips-Schmidt-Shin (KPSS) Durağanlık Testi

KPSS testi Kwiatkowski vd. (1992) tarafından oluşturulmuş olup, ADF ve PP birimkök testlerinin aksine serinin durağan olup olmadığını test etmek yerine serinin durağan olmadığına dair bir kanıt arar. Burada sıfır hipotezi, zaman serisinin durağan olduğu yönündedir. KPSS testi için gerekli olan ekonometrik denklem Eşitlik 14 ve 15'teki gibidir:

$$Y_t = Z_t' \gamma + r_t + \varepsilon_t \quad (14)$$

$$r_t = r_{t-1} + u_t \quad (15)$$

Burada r_t , zaman serisinin t anındaki değerini, r_{t-1} bir önceki dönemdeki değerini, u_t ise her dönemde ortaya çıkan rastgele şoku, bir diğer ifadeyle hata terimini göstermektedir. KPSS durağanlık testinde, $H_0: \alpha=0$ olması serinin durağan olduğunu, $H_1: \alpha<0$ olması da o serinin birim kök içerdiği anlamını ifade etmektedir.

4.3.2. Aktivasyon Fonksiyonları

Derin öğrenme ve yapay sinir ağlarında yaygın olarak kullanılan aktivasyon fonksiyonlarından ikisi ReLu ve Hiperbolik Tanjant (tanh) fonksiyonlarıdır. Temel özellikleri şu şekildedir:

-ReLu, giriş değeri negatif ise sıfır, pozitif ise aynı değeri döndüren basit bir aktivasyon fonksiyonudur. $f(x) = \max(0, x)$ şeklinde formülize edilmiştir. En önemli özelliği, sıfır olmayan bir gradyanı olduğu için eğitimi hızlandırması ve daha hızlı öğrenme sağlamasıdır. Özellikle derin sinir ağlarında tercih edilir ve genellikle gizli katmanlarda kullanılmaktadır.

-Tanh, giriş değerini -1 ile 1 arasında olan bir değere dönüştüren bir aktivasyon fonksiyonudur. $f(x) = \tanh(x) = [(e^x - e^{-x}) / (e^x + e^{-x})]$ şeklinde formülize edilmiştir. Sıfır merkezli olması nedeniyle simetrik bir çıktı aralığı sağlar (-1 ile 1 arasında). Bundan dolayı da genellikle çıktı katmanlarında kullanılır.

4.3.3. Optimizasyon

Gradyan inişi, stokastik gradyan inişi, evrim algoritmaları, parçacık sürü optimizasyonu, yapay arı kolonisi, genetik algoritmalar ve benzetimli tavlama bir hedef fonksiyonun belirli kriterlere göre optimize edilmesini sağlamak için kullanılan yaygın optimizasyon algoritmalarıdır.

Adam (Adaptive momentum) optimizasyon algoritması, sinir ağını daha verimli bir şekilde eğiterek kayıp fonksiyonunu en aza indirmek için yaygın olarak kullanılan bir optimizasyon algoritmasıdır. 2014 yılında Diederik P. Kingma ve Jimmy Ba tarafından geliştirilmiştir. Adam optimizasyonu, mometumlu stokastik gradyan inişin ve kök ortalama kare yayılımının (RMSProp) bir kombinasyonu olarak düşünülebilir.

Momentumlu stokastik gradyan iniş (MSGD): Her adımda eğitim veri setinin rastgele bir alt kümesi (mini-batch) kullanarak gradyan hesaplar ve model parametrelerini günceller. Böylelikle güncellemeler daha hızlı şekilde yapılabilmektedir. Dolayısıyla büyük veri kümelerinde çok daha etkilidir. Ancak bu optimizasyon yöntemi, gürültülü gradyan tahminleri nedeniyle dalgalanma ya da yön değişimleriyle karşılaşabilir. Dolayısıyla momentum, bu tür dalgalanmaları ya da yön değişimlerini düzelter ve gradyan inişlerinin hızlanmasını sağlayan bir mekanizma olduğu için Adam optimizasyonunda Stokastik gradyan inişin momentumlu kombinasyonu kullanılmaktadır. Böylelikle gradyan değişimlerinin yönleri de hesaplanarak stabil bir gradyan iniş ve hızlı bir yakınlaştırma (konverjans) da sağlanmış olmaktadır. Momentumlu stokastik gradyan iniş matematiksel olarak şu şekilde formüle edilmiştir:

$$v_t = \beta v_{t-1} + (1 - \beta) g_t \quad (9)$$

$$\theta_{t+1} = \theta_t + \eta v_t \quad (10)$$

m_t = t anındaki momentum terimi

β = Momentum katsayısı

g_t = t anındaki gradyanlar

η = Öğrenme oranı

θ_t = t anındaki model parametreleri

Burada, her adımda momentum terimi, önceki adımların momentumları ve mevcut adımın gradyanının birleşimidir. Sonraki adımda ise bu momentum terimi stokastik gradyan inişe eklenir ve model parametreleri güncellenerek bu şekilde devam eder. Böylelikle hem gradyan inişin hızı artarken hem de dalgalanmalar azaltılmış ve daha istikrarlı bir optimizasyon süreci sağlanmış olur.

RMSProp: Kök ortalama kare yayılımı, öğrenme oranının her parametre için ayrı ayrı adapte edilmesini sağlar. Bunun için gradyanların karelerinin hareketli ortalamasını alır ve bu değerlerle öğrenme oranını düzenler. Söz konusu durum, büyük gradyanlar için öğrenme oranını düşürürken, küçük gradyanlar için artırır ve böylece daha dengeli bir öğrenme süreci sağlanmış olur. RMSProp matematiksel olarak aşağıdaki gibi ifade edilmektedir:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_t + \epsilon}} * g_t \quad (11)$$

θ_t = t anındaki model parametreleri

η = Öğrenme oranı

v_t = t anındaki gradyan karelerinin hareketli ortalaması

ϵ = sıfıra bölme hatasını önlemek için düzeltme terimi

g_t = t anındaki gradyanlar

Adam algoritması, bu iki bileşeni birleştirir ve her birinin etkisini dengeleyerek gradyan inişin performansını artırır. Her adımda, hem momentumlu stokastik gradyan iniş bileşenini hem de öğrenme oranını adapte eden RMSProp bileşenini kullanır.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} * \hat{m}_t \quad (12)$$

$\hat{v}_t$ = bias koreksiyonu yapılmış hareketli ortalama kare

$\hat{m}_t$ = bias koreksiyonu yapılmış momentum

Adam optimizasyonu, özellikle büyük veri seti ve karmaşık modellerde, eğitim süresini kısaltmak ve daha iyi sonuçlar elde etmek için yaygın olarak kullanılmaktadır. Dolayısıyla VAE-GAN eğitimi sırasında modelin daha istikrarlı ve verimli şekilde öğrenmesine yardımcı olabilmesi ve aşırı uydurmayı önleyebilmesi açısından modelimizde en uygun düzenleme tekniği olarak ADAM optimizasyon algoritması kullanılmıştır.

4.3.4. Kayıp Fonksiyonları

İkili çapraz entropi (BCE) ve ortalama kare hatası, derin öğrenme modellerinin eğitimi sırasında sıkça kullanılan iki farklı kayıp fonksiyonudur. İkisi de modelin tahminlerinin gerçek verilerle ne kadar uyumlu olduğunu ölçmek amacıyla kullanılmaktadır.

İkili çapraz entropi, iki sınıflı sınıflandırma problemlerinde kullanılmaktadır. Üretilmiş veriler ve gerçek veriler arasındaki farkı ölçmek ve en aza indirmek için ikili çapraz entropi kaybı kullanılır. Bununla birlikte her bir sınıfın bağımsız olarak ele alındığı durumlarda kullanılmaktadır.

Dolayısıyla bu çalışmada da modelin eğitimi aşamasında tahmin edilen verilerin gerçek verilerden ne kadar uzak olduğunu hesaplayabilmek için ikili çapraz entropi kullanılmıştır. İkili çapraz entropi kayıp fonksiyonu şu şekilde gösterilmektedir:

$$-\frac{1}{m} \sum_{i=1}^m [D(y^i) * \log(G(x^i)) + (1 - D(y^i)) * \log(1 - G(x^i))] \quad (13)$$

$D(y^i)$ = Ayırt edicinin tuttuğu gerçek veri

$G(x^i)$ = Jeneratörün ürettiği veri

Ortalama kare hatası (MSE), regresyon problemlerinde kullanılmaktadır. Üretilmiş veriler ve gerçek veriler arasındaki farkın karesinin ortalamasını yansıtmaktadır. Bu çalışmada ikili çapraz entropi ile kullanılmış olup modelimize uygun olarak yeniden düzenlenen formülü şu şekildedir:

$$MSE(D(y^i), G(x^i)) = \frac{1}{m} \sum_{i=1}^m (D(y^i) - G(x^i))^2 \quad (14)$$

4.3.5. Performans Değerlendirmesi


Derin öğrenmede performans değerlendirme kriterleri olarak en yaygın kullanılanları; doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall), F1 puanı, AUC-Roc, kayıp (loss) fonksiyonları ve karmaşıklık matrisleri (confusion matrix)'tir.

Bu çalışmada yalnızca kayıp fonksiyonlarına bağlı kalınmamış olup modelin performansını daha iyi bir şekilde anlayıp doğruluğunu değerlendirmek adına aynı zamanda doğruluk kriterinden de yararlanılmıştır.

Doğruluk, bir modelin doğru tahmin ettiği örneklerin oranını ifade eden bir performans değerlendirme metriğidir. Doğru tahmin edilen verilerin toplam veri sayısına oranını göstermekte ve genellikle yüzde olarak ifade edilmektedir. Bu nedenle anlaşılması ve yorumlanması oldukça kolaydır. Literatürde sıkça karşılaşılır ve geniş bir araştırmacı kitlesi tarafından benimsenmiştir. En basit şekliye aşağıdaki gibi gösterilmektedir:

$$\text{Doğruluk} = \frac{\text{Doğru tahminler}}{\text{Toplam örnek sayısı}} * \%100 \quad (15)$$

Kripto para birimi fiyat tahmini için Varyasyonel Otokodlayıcı ve Üretken Çekişmeli Ağların (GAN'lar) kullanılması, geçmiş verilere dayalı olarak kripto para birimleri için gerçekçi veriler üreten bir modelin eğitilmesini ve ardından gerçek verilerin ve üreticiden gelen verilerin ayırt edici ve kodlayıcıya iletilmesini, bu oluşturulan verilerin gerçekliğini değerlendirmek için bir ayırıcının ve şifre çözücünün kullanılmasını içermektedir. VAE-GAN çalışmasında kullanılan özellik ve filtreler Şekil 5'te görülmektedir.



Şekil 6. VAE-GAN İşleyiş Şeması

4.4. Uygulama

Analizde örneklem olarak ilk 11 kripto paranın ele alınmasının nedeni kripto paraların tarihsel geçmişi ne kadar uzun ve veri kümesi de ne kadar büyük olursa söz konusu kripto paralar üzerindeki tahmin gücünün de o derece yüksek olmasıdır. Dolayısıyla uzun yıllardır süregelen ve kullanımda olan kripto paraların genetik mimarisi yaklaşık olarak belirlidir ve piyasaya yeni sürülen bir kripto paranın genetik mimarisini çözümlmek bu anlamda zor olacaktır. Daha doğrusu analizde çıkan sonuçların gerçeklerle tutarlı olmama riski maksimum düzeyde olacaktır.

Bu çalışmada VAE-GAN değerlendirme yöntemi kullanılarak öncelikle jeneratör ve ayırt edicinin kodlayıcı ve şifre çözücüyle birlikte gelişimini değerlendirmek amacıyla birtakım deneyler yapılmıştır. Bunu takiben en iyi sonucu elde edebilmek amacıyla parametre ve metriklerde gerekli ayarlamalar yapılmıştır.

1. Adım: Uygun Kütüphanelerin Seçimi


İlk olarak aşağıda da görüldüğü üzere analize ve analize giden yolda tamamlanması gereken her aşamada gerekli görüldüğü üzere Pandas, Numpy, Pytorch, Mathplotlib, Scikit-Learn, Tensorflow ve Keras kütüphanelerinin kurulumu gerçekleştirilmiştir.

2. Adım: Verilerin Python'a Aktarılması

Yahoo Finance websitesi üzerinden alınan tüm veriler - her bir kripto para için ayrı ayrı olmak koşuluyla – çalışma kağıdının bulunduğu .ipynb dosyasına çekilmiştir. Veriler üzerinde şekil standartları sağlanması ve analizde hata vermemesi adına gerekli ön işlemler yapılmıştır.

3. Adım: Veri Analizi

Fiyat hareketlerinin pürüzsüzleştirilmesi, trendin belirlenmesi, göreceli oynaklığının ölçülebilmesi için kullanılan göstergeler “Veri ön işleme ve analizinde kullanılan teknik indikatörler” başlığı altında belirtilmiştir. Bu çalışmadaki belirli bir zaman diliminde tekrar eden zaman serisi verilerindeki döngüyü, mevsimsel (sezonluk) etkileri, verilerdeki belirli frekanslardaki değişimleri, volatilité düzeyini belirleyip, verilerdeki gürültüyü azaltmaya olanak tanıyan, aynı zamanda gelecekteki fiyat hareketlerinin tahmininde önemli bir araç olan fourier dönüşümü grafiklerine Şekil 7’de yer verilmiştir.



Şekil 7. Kripto Para Fourier Dönüşüm Grafikleri

Şekil 7’de görüldüğü üzere kripto paralara ait çok bileşenli fourier dönüşüm grafiklerine bakıldığında her kripto paranın 100 bileşenli fourier dönüşümü eğrisinin gerçeğe çok daha yakın olduğu görülmektedir. Bu durum frekans bileşeninin artmasıyla sinyalin frekans dağılımının hassasiyetinin daha yüksek ve daha ayrıntılı bir şekilde temsil edilmesinden kaynaklanmaktadır. Bu da sinyalin frekans özelliklerini gerçeğe daha yakınsatarak incelemek anlamına gelmektedir. Daha fazla bileşen kullanılarak, sinyalin içerdiği daha küçük ölçekli frekans değişimleri ve desenler daha iyi yakalanabilmektedir. Daha az bileşenli bir fourier dönüşümü genel bir bakış sağlarken, daha fazla bileşenli bir dönüşüm daha detaylı bir analiz sağlamaktadır. Analiz sonucunda gerçeğe en yakın değeri elde edebilmek amacıyla 100 bileşenli fourier dönüşümü kullanılmıştır.

VAE-GAN modelinde daha güvenilir ve tutarlı sonuçlar elde edebilmek amacıyla, zaman serileri hem durağanlaştırılmış hem de ham hâliyle modele dahil edilmiştir. Bu doğrultuda gerçekleştirilen birim kök test sonuçlarına Tablo 3’te yer verilmiştir.

Tablo 3. ADF ve PP Birim Kök Testleri ile KPSS Durağanlık Testi Sonuçları

	ADF		PP		KPSS	
	Seviye	Birinci Fark	Seviye	Birinci Fark	Seviye	Birinci Fark
BTC	-1.83	-12.84***	0.54	-42.77***	0.53***	0.02
BCH	-3.66**	-24.20***	-3.86***	-39.22***	0.59***	0.03
ETH	-2.34	-23.56***	-2.41	-36.84***	0.44***	0.03
ETC	-3.34*	-31.83***	-3.46***	-32.31***	0.52***	0.07
DASH	-4.31***	-13.89***	-3.42**	-35.56***	0.54***	0.08
DOGE	-3.76**	-14.75***	-3.32**	-44.06***	0.37***	0.08
LTC	-3.31*	-9.54***	-3.47***	-47.90***	0.64***	0.02
XLM	-3.15*	-15.65***	-3.55***	-47.51***	0.39***	0.04
XRP	-3.86**	-14.61***	-3.68***	-35.98***	0.30***	0.01
XMR	-3.21*	-15.73***	-3.27**	-43.62***	0.54***	0.04
ZEC	-3.28*	-35.48***	-3.30**	-36.92***	0.57***	0.06

- Birimkök testlerinde trend & intercept’i dikkate alınmıştır.

-ADF testinde max lag-günlük veriler olduğu için 7 alınmıştır.

***%1, **%5 ve * istatistiksel olarak %10 anlamlılık düzeyini ifade etmektedir.

-ADF için %1 (-3.96), %5 (-3.41), %10 (-3.12); PP için %1 (-3.43), %5 (-2.86), %10 (-2.57); KPSS için %1 (0.21), %5 (0.14), %10 (0.11), kritik değerleri baz alınmıştır.

Tablo 3 incelendiğinde, ADF ve PP testleri sonuçlarına göre, seviye düzeyinde BTC ve ETH için test istatistikleri kritik eşik değerini aşamamış olup, bu serilerin birim kök içerdiği tespit edilmiştir. Ancak diğer seriler için test istatistikleri farklı anlamlılık düzeylerinde birim kök hipotezinin reddedildiğini göstermektedir. KPSS test istatistikleri ise tüm seriler için seviye düzeyinde kritik eşik aşımış olduğunu, dolayısıyla incelenen tüm serilerin durağan olmadığını ortaya koymaktadır.

Tüm seriler için birinci farklar alındığında ise ADF ve PP test sonuçlarına göre birim kök hipotezinin reddedildiği, KPSS testine göre ise durağanlığın sağlandığı sonucuna ulaşılmaktadır.

4. Adım: Veri Seti Bölümleme

Bu çalışmada eğitim ve test verileri sırasıyla %80 ve %20 olarak bölümlenmiştir. Btc ve Ltc için toplamda 3759 günlük bir gözlem sayısına sahip olmaları nedeniyle bu verilerin 3007 günü eğitim, 752 günü test verilerine ayrılmıştır. Bch, Eth, Etc, Dash, Doge, Xlm, Xmr, Xrp ve Zec ise toplamda 2610 günlük veriye sahip olmalarından dolayı bu verilerin 2088 günü eğitime ve kalan 522 günü ise test verilerine ayrılmıştır.

5. Adım: Ağ Mimarilerinin Oluşturulması

Kodlayıcı (encoder), gizli uzay (latent space), yeniden parametrelendirme hilesi (reparametrization trick), şifre çözücü (decoder), rastgele gürültü (random noise) boyutu [400], jeneratör (generator), ayırt edici (discriminator), ReLu – Sigmoid - Tanh aktivasyon fonksiyonları, çekişmeli kayıp (adversarial loss) fonksiyonu (ikili çapraz entropi, ortalama kare hatası) eklenip eğitim prosedürü ile ilgili kodlar yazılarak VAE-GAN mimarisi oluşturulmuştur. Ek olarak mimariye [400] boyutlarında 3 gizli katman ve bir gizli uzay eklenmiştir.

6. Adım: Parametrik ayarlamaların yapılması

Yığın boyutları (batch size) [128], Adam optimizasyon algoritması, doğruluk metriği eklenerek dönem sayısının (epoch) da [300] olarak girilmesinin ardından eğitime başlanmıştır.

7. Adım: Eğitim ve Test

Eğitilen verilerin doğruluğu test verileriyle karşılaştırılarak en doğru sonucu verene kadar eğitime devam edilir. En doğru sonucu veren model tahminde kullanılmak üzere seçilmiştir.

8. Adım: Tahmin

Kapanış fiyatlarının oluşturulacağı, yani kaç günlük tahmin yapılacağına ilişkin gün sayısı belirlenmiş olup, piyasa hareketliliği ve değişkenliği de göz önünde bulundurulduğunda 7 günlük tahmin yapılmasının daha uzun vadeli tahmine göre daha net sonuçlara ulaştıracağı öngörülmüştür. Min-Max ölçeklendirme işlemi tersine çevrilip gerekli ölçeklendirme ayarları yapıldıktan sonra fiyatlar [0,1] aralığından orijinal aralığa geri getirilerek Pandas Dataframe'e dönüştürülmüştür. Analizde ele alınan 11 kripto paraya ilişkin zaman serilerinin, trend ile mevsimsellikten arındırılıp durağanlaştırılarak (ΔY_t)ve durağanlaştırmadan (Y_t) analize tabi edilmesiyle birlikte 01.01.2025-07.01.2025 tarihleri arası 7 günlük fiyat çıktıları ve gerçek fiyatlar aşağıdaki gibidir:

Tablo 4. Çıktı Raporları ve Gerçekleşen Fiyat Tablosu (ABD Doları)(USD)

	\$	1	2	3	4	5	6	7	Max Doğr.
Btc	ΔY_t	102430,61	105727,97	105978,31	108705,84	103782,81	104602,94	104020,19	0,02299464
	Y_t	98367,01	98367,01	98367,01	98367,01	98367,02	98367,02	98367,02	0,99999976
	C_t	94419,76	96886,88	98107,43	98236,23	98314,96	102078,09	96922,71	-
Bch	ΔY_t	475,898	475,897	475,897	475,898	475,898	475,895	475,897	0,99999976
	Y_t	464,046	464,162	464,162	464,063	464,195	463,766	464,195	0,99999890
	C_t	449,360	461,369	473,068	478,978	470,911	482,686	437,475	-
Eth	ΔY_t	3294,22	3293,562	3293,753	3292,708	3291,581	3293,055	3292,755	0,0067643
	Y_t	3634,756	3640,015	3640,015	3637,911	3642,118	3642,118	3639,489	0,99999917
	C_t	3353,504	3451,393	3605,010	3657,707	3634,104	3688,611	3381,577	-
Etc	ΔY_t	25,907	25,907	25,907	25,907	25,907	25,907	25,907	0,99999696
	Y_t	32,071	32,161	32,123	32,100	32,178	32,199	32,102	0,01190571
	C_t	25,758	26,877	28,427	28,387	28,118	28,657	25,941	-
Dash	ΔY_t	40,117	40,121	40,121	40,121	40,119	40,120	40,119	0,99999976
	Y_t	64,097	114,899	64,090	64,089	64,066	64,096	64,321	0,6047751
	C_t	39,347	40,250	43,059	42,690	43,693	43,726	38,724	-
Doge	ΔY_t	0,3632	0,363	0,333	0,363	0,347	0,305	0,346	0,999999
	Y_t	0,341	0,341	0,341	0,341	0,341	0,341	0,341	0,99999976
	C_t	0,324	0,339	0,379	0,395	0,383	0,388	0,348	-
Ltc	ΔY_t	105,579	105,579	105,579	105,579	105,579	105,579	105,579	0,99999523
	Y_t	113,547	113,547	113,547	113,547	113,547	113,547	113,547	0,99999976
	C_t	104,812	105,090	112,687	111,168	115,466	114,011	102,838	-
Xlm	ΔY_t	0,538	0,517	0,520	0,508	0,513	0,521	0,509	0,0149714
	Y_t	0,427	0,427	0,427	0,427	0,427	0,427	0,427	0,99999976
	C_t	0,424	0,433	0,448	0,451	0,441	0,446	0,418	-
Xrp	ΔY_t	2,443	2,443	2,443	2,444	2,443	2,443	2,443	0,99965084
	Y_t	2,390	2,390	2,390	2,390	2,391	2,391	2,390	0,99999964
	C_t	2,322	2,403	2,453	2,420	2,400	2,419	2,272	-
Xmr	ΔY_t	196,164	196,164	196,164	196,164	196,164	196,164	196,164	0,99999875
	Y_t	127,468	127,120	126,190	126,445	127,135	127,044	118,435	0,01327684
	C_t	195,404	197,066	200,872	194,448	196,710	203,778	194,043	-
Zec	ΔY_t	58,733	58,733	58,733	58,733	58,733	58,734	58,792	0,99999976
	Y_t	58,959	58,959	58,959	58,959	58,959	58,959	58,959	0,99999976
	C_t	58,113	59,397	60,918	59,188	58,536	60,163	52,334	-

- ΔY_t durağanlaştırılmış serilerden elde edilen çıktıları, Y_t durağanlaştırılmamış serilerden elde edilen çıktıları, C_t ise gerçek kapanış fiyatlarını ifade etmektedir.

Bu çalışmada, durağanlaştırılmış ve durağanlaştırılmamış kripto para zaman serilerinin VAE-GAN modeli çerçevesinde analiz edilerek modelin tahmin performansı değerlendirilmiştir. Analiz kapsamında, her bir kripto para serisi için durağanlaştırılmış (ΔY_t) ve durağanlaştırılmamış (Y_t) veriler kullanılarak modelin tahmin doğruluğu incelenmiş; doğruluk oranı ise Max Doğruluk metriği ile ifade edilmiştir.

Elde edilen bulgular BCH, DOGE, LTC, XRP ve ZEC serileri için durağanlaştırma işleminin modelin tahmin başarısı üzerinde belirgin bir etkisi olmadığını göstermiştir. Bu varlıklar için durağanlaştırılmış ve durağanlaştırılmamış serilerde Max Doğruluk değerinin yaklaşık olarak 0.99 seviyesinde gerçekleştiği tespit edilmiştir. Diğer bir deyişle, bu varlıkların zaman serileri model tarafından hem durağan hem de durağan olmayan halleriyle yüksek doğruluk oranlarıyla tahmin edilebilmiştir.

Öte yandan, Etc ve Xmr için durağanlaştırma işlemi modelin tahmin performansında önemli bir iyileşmeye yol açmıştır. Bu varlıkların durağanlaştırılmamış serileriyle yapılan analizlerde modelin Max Doğruluk oranları sırasıyla 0.0119 ve 0.0132 olarak gerçekleşmiş olup, durağanlaştırılmış seriler kullanıldığında doğruluk oranlarının belirgin şekilde arttığı gözlemlenmiştir. Bu durum, söz konusu varlıklar için zaman serilerinin durağan hale getirilmesinin modelin tahmin başarısını artıran kritik bir unsur olduğunu göstermektedir.

Buna karşın Btc, Eth ve Xlm gibi varlıklar için durağanlaştırılmamış serilerin Max doğruluk oranları 0.9999 civarında iken durağanlaştırma işlemi modelin tahmin performansını belirgin şekilde azaltmaktadır. Bu durum da durağanlaştırma işleminin yalnızca belirli zaman serilerinde daha etkili olduğunu vurgulamaktadır.

VAE-GAN modeli, kripto para piyasasının yüksek volatiliteye sahip karmaşık dinamiklerini durağanlaştırma işlemi uygulanmaksızın analiz edebilme yetisini sergileyerek Btc, Bch, Eth, Doge, Ltc, Xlm, Xrp ve Zec kripto varlıkları için 0.9999 doğruluk oranına ulaşmıştır. Dash için ise model, 0.6047 gibi bir doğruluk oranına ulaşarak genel olarak ortalamanın üzerinde bir tahmin başarısı göstermiştir. Bununla birlikte, ETC ve XMR serileri için modelin doğruluk oranının 0.01 seviyesinde kaldığı gözlemlenmiştir. Elde edilen genel bulgular, VAE-GAN mimarisinin kısa ve uzun vadeli tahminleme süreçlerinde oldukça yüksek performans sergilediğini ve finansal zaman

serilerindeki karmaşık yapıları başarılı bir şekilde öğrenerek gelecekteki fiyat hareketlerini isabetli bir şekilde öngörebildiğini ortaya koymaktadır.

Varyasyonel otomatik kodlayıcılar veri dağılımını öğrenirken, üretken rakip ağlar gerçekçi veri örnekleri oluşturarak modelin genelleme yeteneğini artırmaktadır. Bundan dolayıdır ki farklı zaman dilimlerinde ve piyasa koşullarında test edilen model genelleme yeteneğini koruyarak tutarlı sonuçlar vermiştir. Bununla birlikte piyasa volatilitatesini başarılı bir şekilde yakalayan model, ani fiyat değişimlerini öngörmeye etkili olmuştur. VAE-GAN modeli, geleneksel derin öğrenme modelleri ile kıyaslandığında, belirgin bir üstünlük göstermiş olup, gürültülü ve karmaşık piyasa verilerini daha iyi anlamada etkili olmuştur.

Çalışmadan elde edilen bulgular, VAE-GAN modelinin kripto para tahminlerinde kullanılabilirliğini ve etkinliğini desteklemektedir.

TARTIŞMA

Modelin bazı varlıklar için durağanlaştırma olmaksızın da yüksek doğruluk oranlarıyla tahmin yapabildiğini, ancak bazı varlıklar için durağanlaştırma işleminin tahmin performansını önemli ölçüde artırdığını göstermektedir. Bu farklılığın temelinde, ilgili varlıkların fiyat serilerinin istatistiksel özellikleri yatmaktadır. Btc, Bch, Eth, Ltc, Doge, Xlm, Xrp ve Zec gibi piyasa lideri kripto varlıklar daha olgun ve yüksek likiditeye sahip piyasalarda işlem gördüğünden, fiyat hareketleri daha tahmin edilebilir olup model tarafından durağanlaştırmaya ihtiyaç duyulmadan doğru şekilde öngörülebilmektedir. Buna karşılık, Etc ve XMR gibi varlıkların daha yüksek volatilitelere sahip olması, modelin bu varlıkları doğru tahmin edebilmesi için zaman serilerinin durağan hale getirilmesini gerektirmektedir. Öte yandan, Dash'ın orta seviyede bir etkilenme göstermesi, bu varlığın fiyat dinamiklerinin hem durağan hem de durağan olmayan bileşenler içerdiğine işaret etmektedir.

Modelin karmaşık finansal verileri anlamada ve tahmin aşamasında yüksek doğruluk oranına ulaşmasındaki başarısına rağmen bazı sınırlamalar ve dikkat edilmesi gereken hususlar bulunmaktadır. Bunlar arasında üzerinde durulması önem arz edecek olanlar maddeler halinde sıralanacak olunursa:

- Modelin eğitimi için kullanılan veri setlerinin doğru seçimi ve çeşitliliği, elde edilen sonuçların doğruluğunu direkt olarak etkilemektedir. Yalnızca belirli kripto para birimlerine odaklanmak, modelin genelleme yeteneğini sınırlayabilmektedir. Bu nedenle, daha geniş yelpazedeki kripto para birimlerinin ve piyasa göstergelerinin kullanılması önem taşımaktadır.

- Kripto para piyasaları son derece dinamik ve volatilitesi yüksek ortamlar olduğundan, modelin güncel verilerle eğitilip test edilmesi, performansının sürdürülebilirliği açısından kritik bir noktadır.

- VAE-GAN modelinin farklı piyasa koşullarında (örneğin, boğa ve ayı piyasaları, savaş ve pandemiler vb... gibi) nasıl performans gösterdiği, uzun vadeli kullanım potansiyeli açısından önemli bir araştırma alanıdır. Modelin bu koşullara adaptasyon yeteneği incelenmelidir.

- Yüksek doğruluk oranına ulaşmak, modelin eğitim verilerine aşırı uyum sağlama (overfitting) riskini beraberinde getirebilir. Bu nedenle, modelin test verileri üzerindeki performansı dikkatlice izlenmelidir.

- VAE-GAN modelinin ürettiği tahminlerin, etkili risk yönetim teknikleri uygulanarak yatırım stratejilerinde nasıl kullanılabileceği ve bu stratejilerin potansiyel getirileri incelenmelidir. Bu bakış açısı, modelin pratikteki değerini ve yatırımcılara sağlayabileceği faydaları ortaya koymaktadır.

- VAE-GAN'ın diğer derin öğrenme ve makine öğrenme teknikleri ile entegrasyonu, daha karmaşık ve hassas tahmin modellerinin geliştirilmesine olanak tanır. Bu tür hibrit modeller, piyasa dinamiklerini daha iyi anlamaya yardımcı olabilmektedir.

- Modelin performansını artırmak ve yeni piyasa koşullarına uyum sağlamak için sürekli olarak güncellenmesi ve en uygun hale getirilmesi gerekmektedir. Bu durum, araştırmacı-endüstri iş birliği ile mümkün olabilir.

Kısaca özetlemek gerekirse, VAE-GAN modelinin kripto para tahminlerinde sağladığı doğruluk oranı, modelin potansiyelini ortaya koymaktadır. Ancak, modelin çeşitli piyasa koşullarında ve daha geniş veri setleri ile test edilmesi, uzun vadeli sürdürülebilirliğinin ve genelleme yeteneğinin değerlendirilmesi açısından önem taşımaktadır. Gelecekteki çalışmalar, bu alanlarda derinlemesine araştırmalar yaparak modelin pratik uygulamalarda nasıl daha etkili kullanılabileceğini ortaya koyabilir.

SONUÇ

Kripto para piyasaları, volatilitesi yüksek ve karmaşık yapısıyla öne çıkan dinamik bir finansal piyasadır. Bu piyasalarda fiyatların doğru bir şekilde tahmin edilmesi, yatırımcılar ve diğer kullanıcılar için karar alma süreçlerini yönlendirebilmekte ve riskleri azaltabilmektedir. VAE-GAN modeli:

- Kripto para fiyatlarının yüksek değişkenliğe sahip olması ve çalışmada kullanılan modelin de veriler arasındaki karmaşık ve doğrusal olmayan ilişkileri öğrenme kapasitesine sahip olması nedeniyle,
- Zaman içerisinde değişen piyasa koşullarına hızlı bir şekilde uyum sağlama (adaptif öğrenme) yeteneğine sahip olması nedeniyle,
- Kripto para fiyatları üzerinde etkin tahminler yapabilmek adına birden fazla faktör ve değişken göz önünde bulundurulmalıdır. Dolayısıyla, çok boyutlu veri setlerini işlemek ve bu karmaşıklığı ele almak için uygun bir çözüm sunması nedeniyle diğer geleneksel tahmin yöntemlerinden ayrılmakta ve kripto para fiyatlarının doğru bir şekilde tahmin edilmesinde potansiyel olarak etkili bir araç haline gelmektedir.

Bu çalışma, VAE-GAN modelinin kripto para piyasasındaki tahmin performansı ile zaman serilerinin durağanlık durumu arasındaki ilişkiyi ortaya koymuştur. Bulgular, durağanlaştırma işleminin varlık bazında farklı etkiler yarattığını ve bazı varlıklar için modelin tahmin doğruluğunu artırırken, bazıları için ise anlamlı bir katkı sağlamadığını göstermektedir. Modelin, karmaşık fiyat dinamiklerini başarılı bir şekilde simüle ederek yüksek doğruluk oranlarını sürdürebilmesi, özellikle likiditesi yüksek ve olgun piyasalarda işlem gören varlıklar için güçlü bir tahminleme kapasitesine sahip olduğunu göstermektedir. Özetle, temel bulgular piyasa yatırımcıları açısından önemli çıkarımlar sunmaktadır. Çalışma sonuçları, durağanlaştırma tekniklerinin yapay zekâ modellerinin öngörü performansını özellikle volatil piyasa koşullarında artırabileceğini göstermektedir. Bu durum, yapay zekâ tabanlı tahmin araçlarını kullanan yatırımcıların, piyasa dalgalanmalarının yüksek olduğu dönemlerde daha sağlam ve uyarlanabilir stratejiler geliştirebileceğini düşündürmektedir.

Ayrıca, durağanlaştırılmamış verilerle yapılan analizlerde, yüksek piyasa değeri ve likiditeye sahip varlıklar için tahmin doğruluğunun daha yüksek olması, geleneksel

tahmin yaklaşımlarının daha istikrarlı kripto varlıklar için hâlâ etkili olabileceğini göstermektedir. Bu farklılık, tahmin modellerinin varlıkların özelliklerine göre uyarlanması önemi vurgulayarak, yatırımcıların piyasa dinamiklerine göre karar alma süreçlerini optimize etmelerine olanak tanımaktadır.

Genel olarak, çalışma, yapay zekâ tabanlı modellemenin kripto para piyasalarında fiyat tahminlerini iyileştirme potansiyeline sahip olduğunu ortaya koymakta ve yatırımcılara daha bilinçli işlem stratejileri geliştirmeleri için veri odaklı içgörüler sunmaktadır.

Sonuç olarak, öncelikle gelecekteki araştırmalar, modelin genelleştirilebilirliğini daha kapsamlı bir şekilde değerlendirmek amacıyla, farklı volatilité seviyelerine sahip daha geniş bir varlık yelpazesi ve daha uzun zaman dilimlerini içerecek şekilde tasarlanabilir. Ayrıca, durağanlaştırma işleminin etkisinin piyasa koşulları, makroekonomik değişkenler ve diğer finansal faktörler ile birlikte ele alınarak daha derinlemesine incelenmesi, modelin farklı ekonomik ortamlar ve piyasa rejimleri altında nasıl optimize edilebileceğine yönelik daha kapsamlı bir analitik çerçeve sunabilir.

Son olarak, modelin genel olarak ortaya çıkan yüksek doğruluk oranı, yatırımcılar ve finansal analiz uzmanları için güvenilir bir araç olma potansiyeli taşımaktadır. Önerilen VAE-GAN modelinin, kripto para piyasalarındaki riskleri azaltmaya ve karlı ticaret stratejileri geliştirmeye yardımcı olabileceği düşünülmektedir. Daha önceden de bahsedildiği üzere modele girilen değişken sayılarının artırılması (daha geniş veri seti), modelin farklı parametre ayarlarının yapılması, farklı hiperparametrelerin performansa etkisinin ölçülmesi, farklı kripto para birimleri üzerindeki performanslarının karşılaştırılması, farklı dönemlerdeki piyasa koşullarına uyumu ve dayanıklılığı üzerine analizlerin artırılması, modele farklı veri ön işleme tekniklerinin ve özellik mühendisliği stratejilerinin uygulanmasıyla bu çalışma modeli geliştirilip ileriye yönelik araştırma ve farklı uygulamalara olanak sağlayabilmesiyle gelecekteki araştırmalar için önem arz etmektedir.

KAYNAKLAR

- Al-Rayhi, N. Cryptocurrency Exchange Market Prediction and Analysis Using Data Mining and Artificial Intelligence. Master Thesis, The British University, Dubai, United Arab Emirates, 2020.
- Aldı, F., Küçükkaplan, İ., Şahin, E. E. (2025). Kripto paralar ve Batı Teksas ham petrol getirisi ilişkisi: Granger ve Toda Yamamoto nedensellik analizleri ile incelenmesi. Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 27(1), 30-43.
- Arıkan, N. İ. Para Kuramı Açısından Kripto Paraların Ekosistemi. Doktora Tezi. İnönü Üniversitesi, Malatya, Türkiye, 2020.
- Arthur, D., Date, P. (2022). "Hybrid Quantum-Classical Neural Networks" [Bildiri], IEEE International Conference on Quantum Computing and Engineering (QCE), 18-23 Eylül 2022, Broomfield.
- Aziz, A. (2019). Cryptocurrency: Evolution & Legal Dimension, International Journal of Business, Economics and Law, Vol. 18 (4), 31-33.
- Buonaiuto, G., Gargiulo, F., De Pietro, G., Esposito, M., Pota, M. (2023). Best practices for portfolio optimization by quantum computing, experimented on real quantum devices, Scientific Reports, 13: 19434, 1-14.
- Blockchain Türkiye, (2022). "Yeni Ticaret Biçimleri: Merkez Bankası Dijital Parası (CBDC) Üzerine Değerlendirme Raporu", Türkiye Bilişim Vakfı, İstanbul, 18-22.
- Ceylan, M.E. Bitcoin Ekonomisi: Kripto Para Bitcoin'in Finans Sektörü İçindeki Yeri. Yüksek Lisans Tezi, Batman Üniversitesi, Batman, Türkiye, 2019.
- Cho, K., Merrienboer, B.V., Gülçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation, Cornell University, Arxiv: 1406.1078, 1-15.
- Çelik, G., Talu, M.F. (2020). Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi. BAUN Fen Bil. Enst. Dergisi, 22 (1), 181-192.
- Çetinkaya, Ş. (2018). Kripto Paraların Gelişimi Ve Para Piyasalarındaki Yerin Swot Analizi ile İncelenmesi. Uluslararası Ekonomi ve Siyaset Bilimleri Akademik Araştırmalar Dergisi, 2:5, 11-21.
- Dağtekin, O.C. Makroekonomide Güven Kavramı ve Bu Kavrama Davranışsal İktisat Çerçevesinde Yaklaşım: Kripto Para Örneği. Doktora Tezi, Gazi Üniversitesi, Ankara, Türkiye, 2019.
- Davies, G. (2002). A History of Money From Ancient Times to the Present Day, University of Wales Press, Cardiff.

- Deng, N., Tian, Y., Zhang, C. (2012). Support Vector Machines: Optimization Based Theory, Algorithms, and Extensions. Chapman and Hall/CRC, Boca Raton.
- Dickey, D.A., Fuller, W.A. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal of the American Statistical Association*, Volume 74, Issue 366, 427-431
- Dong, H., Ding, Z., Zhang, S. (2020). Deep Reinforcement Learning: Fundamentals, Research and Application, Springer, Singapur.
- Dunmore, A., Jang Jaccard, J., Sabrina, F., Kwak, J. (2023). A Comprehensive Survey of Generative Adversarial Networks (GANs) in Cybersecurity Intrusion Detection. *IEE Access*, Vol. 11, 76071-76094.
- Eldele, E., Ragab, M., Chen, Z., Wu, M., Kwok C.K., Li, X., Guan, C. (2023). Self-Supervised Contrastive Representation Learning for Semi-Supervised Time-Series Classification, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 45 (12), 15604-15618.
- Elman, J.L. (1990). Finding Structure in Time, *Cognitive Science* 14, 179-211.
- Fawaz, H. İ., Forestier, G., Weber, J., Idoumghar, L., Muller, P. A. (2019). Deep learning for time series classification: a review. *Data Min. Knowl. Discov.* 33(4), 917–963.
- Fettahoglu, S., Kildize, D. (2019). Dijital Finansal Okuryazarlık ve Bireylerin Finansal Teknoloji Kullanma Konusundaki Tutumları. *International Journal of Society Researches*, 12:18, 867 - 889.
- Goodfellow, I.J., Abadie, J.P., Mirza, M., Xu, B., Farley, D.W., Ozair, S., Courville, A., Yoshua, B. (2014). Generative Adversarial Nets. Cornell University, Arxiv: 1406.2661, 1-9.
- Granger, C.W.J. (1969). Investigating Causal Relations by Econometric Models and Cross-spectral Methods. *Econometrica*, 37:3, 424-438.
- Graves, A. (2012). Long short-term memory. In: Graves, A. (ed.) *Supervised Sequence Labelling with Recurrent Neural Networks*, Springer, Heidelberg (SCI), 385, 37–45.
- Graves, A., Wayne, G., Danihelka, I. (2014). Neural Turing Machines, Cornell University, Arxiv: 1410.5401, 1-26.
- Gupta, S., Zia, R.K.P. (2001). Quantum Neural Network, *Journal of Computer and System Sciences*, 63, 355-383.
- Gurgul, V., Lessmann, S., Hardle, W.K. (2023). Forecasting Cryptocurrencies Prices Using Deep Learning: Integrating Financial, Blockchain, and Text Data, Cornell University, Arxiv: 2311.14759, 1-35.

- Güler, K. Uluslararası Ticaretin Dijitalleşmesi ve Sanayi Akımlarının Etkisi: Endüstri 4.0 Devrimi Üzerine Bir Araştırma. Doktora Tezi, İstanbul Ticaret Üniversitesi, İstanbul, Türkiye, 2019.
- Hasan, S.N. (2019). Derin Öğrenme Yöntemleri ile Cilt Lezyon Bölütlemesi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü Enformatik Anabilim Dalı Enformatik Programı, Yüksek Lisans Tezi, İstanbul.
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Identity Mappings in Deep Residual Networks, Cornell University, Arxiv: 1603.05027, 1-15.
- Huang, J.Z., Huang, W., N., J. (2018). Predicting Bitcoin returns using high-dimensional technical indicators. *The Journal of Finance and Data Science*, **5**(3), 140–155.
- Ji, S., Kim, J., Im, H. (2019). A comparative study of Bitcoin price prediction using deep learning. *Mathematics*, **7**, 898.
- Kingma, D.P., Welling, M. (2022). Auto-Encoding Variational Bayes. Cornell University, Arxiv: 1312.6114v11, 1-14.
- Kohonen, T. (1995). Learning Vector Quantization, *SSINF*, **30**, 175-189.
- Kwiatkowski, D., Phillips, P.C.B., Schmidt, P., Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal of Econometrics*, **54**, 159-178.
- Lahmiri, S., Bekiros, S. (2020). Intelligent forecasting with machine learning trading systems in chaotic intraday Bitcoin market. *Chaos, Solitons and Fractals*, **133**, 109641.
- Lara-Benitez, P., Carranza-Garcia, M., Riquelme, J.C. (2021). An Experimental Review on Deep Learning Architectures for Time Series Forecasting, *International Journal of Neural Systems*, Vol. 31, No. 3, 1-25.
- Maghyereh, A., Abdoh, H. (2020). Tail dependence between Bitcoin and financial assets: Evidence from a quantile cross-spectral approach. *International Review of Financial Analysis*, **71**, 101545.
- Mazzia V., Salvetti, F., Chiaberge, M. (2021). Efficient-CapsNet: Capsule Network with Self-Attention Routing, *Springer Nature*, 11:14634, 1-13.
- Montgomery, D.C., Jennings, C.L., Kulahci, M. (2015). *Introduction to Time Series Analysis and Forecasting*. Wiley, Hoboken, NJ: John Wiley & Sons, 2, 1-24.
- Moritz, P., Nico, B., Rikli, S., Osterrieder, J. (2021). Wasserstein Gan: Deep Generation Applied on Financial time Series. *Social Sciences Research Network*, Preprint, Arxiv: 2107.06008v1, 1-32.
- Nakamoto S. (2008). Bitcoin: a peer-to-peer electronic cash system. *Decentralized Business Review*, Seoul.

- Narayanan, A., Bonneau, J., Felten, E., Miller, A., Goldfeder, S. (2016). Bitcoin and Cryptocurrency Technologies: A Comprehensive Introduction. Princeton University Press, New Jersey.
- Nazlıoğlu, Ş. (2020). Ekonometri [Ders Notları].
- Olvera-Juarez, D., Huerta-Manzanilla, E. (2019). Forecasting Bitcoin pricing with hybrid models: a review of the literature. *International Journal of Advanced Engineering Research Science*, 6(9), 161–164.
- Pintelas, E., Livieris, I.E., Stavroyiannis, S., Kotsilieris, T., Pintelas, P. (2020). "Fundamental research questions and proposals on predicting cryptocurrency prices using DNNs". Technical report, TR20-01, University of Patras, 1-20.
- Ravula, S., Jain, S. (2021). "Deep Autoencoder-based Massive MIMO CSI Feedback with Quantization and Entropy Coding" [Bildiri], IEEE Global Communications Conference, 07-11 Aralık 2022, Madrid.
- Schuster, M., Paliwal, K.K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673–2681.
- Schwartz, D., Youngs, N., Britto, A. (2018). The Ripple Protocol Consensus Algorithm, RippleNet, RPCA Report, 7.
- Shintate, T., Pichl, L. (2019). Trend prediction classification for high frequency Bitcoin time series with deep learning. *Journal of Risk and Financial Management*, 12: 17, 1-15.
- Siami-Namini, S., Tavakoli, N., Namin, A.S. (2018). "A comparison of ARIMA and LSTM in forecasting time series" [Bildiri], IEEE International Conference on Machine Learning and Applications (ICMLA), 17-20 Aralık 2018, Orlando.
- Stavroyiannis, S., Babalos, V., Bekiros, S., Lahmiri, S., Uddin, G.S. (2019). The high frequency multifractal properties of Bitcoin. *Physica A: Statistical Mechanics and its Applications*, 520, 62–71.
- Su, L., Ling, X. (2020). Estimated Weak Pulse Signal in Chaotic Background with Jordan Neural Network, Wiley, Art. Id: 3284587, 1-14.
- Toda, H.Y., Yamamoto, T. (1995). Statistical inference in vector autoregressions with possibly integrated processes. *Journal of Econometrics*, 66, 225-250.
- Tzirakis, P., Zafeiriou, S., Schuller, B. (2019). Real-world automatic continuous affect recognition from audiovisual signals, *Multimodal Behavior Analysis in the Wild*, 387-406.
- Ulucan Özkul, F. (2020). Dijital Çağın Teknolojisi Blokzincir ve Kripto Paralar: Ulusal Mevzuat ve Uluslararası Standartlar Çerçevesinde Mali Yönden Değerlendirme. *Muhasebe ve Denetime Bakış*, 60, 57-74.

- Urom, C., Abid, I., Guesmi, K., Chevallier, J. (2020). Quantile spillovers and dependence between Bitcoin, equities and strategic commodities. *Economic Modelling*, 93, 230–258.
- Urquhart A. (2016). The inefficiency of Bitcoin. *Economics Letters*, 148, 80–82.
- Von Neumann, J. (1945). First Draft of a Report on the EDVAC.
- Wu, L., Wang, Y., Xu, S., Liu, K., Li, X. (2020). A CNN-RBPNN Model With Feature Knowledge Embedding and Its Application to Time-Varying Signal Classification, *IEEE*, 8, 108503-108513.
- Wu, Y., Wang, H., Zhang, B., Du, K.L. (2011). Using Radial Basis Function Networks for Function Approximation and Classification, *Journal of Applied Mathematics*, Vol. 2012, Article ID. 324194, 1-34.
- Yılmaz, C. (2022). Yapay Sinir Ağları ile Denizli İli Doğal Gaz Tüketim Analizi ve Tahmini. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Enerji Yönetimi ve Teknolojileri Anabilim Dalı, Yüksek Lisans Tezi, Denizli.
- Zhang, J., Cai, K., Wen, J. (2023). A Survey of Deep Learning Applications in Cryptocurrency, *Iscience*, 27: 108509, 1-40.
- Zhang, C., Sjarif, N.N.A., Ibrahim, R. (2023). 1D-CapsNet-LSTM: A Deep Learning-Based mODEL for Multi-Step Stock Index Forecasting, Cornell University, Arxiv: 2310.02090, 1-32.
- WEB_1. (2021). *Ekonomist Dergisi*.
<https://www.ekonomist.com.tr/encyclopedia/kripto-para-nedir-ne-anlama-gelir-nasil-uretilir-nasil-alinir> (04.02.2022)
- WEB_2. (2022). *TradingView*.
<https://tr.tradingview.com/markets/cryptocurrencies/news> (04.02.2022)
- WEB_3. (2022). *Dünya Gazetesi*.
<https://www.dunya.com/finans/kripto-para/gelecek-kripto-paralarin-hazirlanin-haberi-631550> (04.02.2022)
- WEB_4. (2020). *CoinTelegraph*.
<https://tr.cointelegraph.com/news/what-is-hash-whats-the-meaning-of-bitcoin-sha-256-algorithm> (05.02.2022)
- WEB_5. (2022). *CoinMarketCap*.
<https://coinmarketcap.com/tr/currencies/> (05.02.2022)
- WEB_6. (2021). *Uzmancoin*.
<https://uzmancoin.com/sozluk/token-nedir/> (05.02.2022)
- WEB_7. (2021). *Coinbase*.
<https://www.coinbase.com/tr/learn/crypto-basics/what-is-a-token> (05.02.2022)

- WEB_8. (2022). Bitlo.
<https://www.bitlo.com/rehber/kripto-para-nedir> (05.02.2022)
- WEB_9. (2021). Ekonomist Dergisi.
<https://www.ekonomist.com.tr/encyclopedia/kripto-para-madenciligi-mining-nedir-nasil-yapilir> (05.02.2022)
- WEB_10. (2021). Ekonomist Dergisi.
<https://www.ekonomist.com.tr/encyclopedia/hash-rate-nedir-mining-hash-rate-ne-anlama-geliyor> (05.02.2022)
- WEB_11. (2014). StackExchange.
<https://bitcoin.stackexchange.com/questions/9219/what-is-the-difference-between-kh-s-mh-s-and-gh-s> (05.02.2022)
- WEB_12. (2021). CoinTelegraph.
<https://tr.cointelegraph.com/news/what-is-a-bitcoin-fork-for-beginners> (06.02.2022)
- WEB_13. (2022). Blockchain.
<https://www.blockchain.com/research> (06.02.2022)
- WEB_14. (2022). CoinMarketCap.
<https://support.coinmarketcap.com/hc/en-us/sections/360008888252-Metric-Methodologies> (06.02.2022)
- WEB_15. (2019). Genesis Mining.
<https://www.genesis-mining.com/about-us> (06.02.2022)
- WEB_16. (2022). Crypto.com.
<https://crypto.com/research> (06.02.2022)
- WEB_17. (2008). Decentralized Business Review.
<https://www.debr.io/articles> (06.02.2022)
- WEB_18. (2022). CoinGecko.
<https://www.coingecko.com/> (06.02.2022)
- WEB_19. (2021). Bilim Genç Tubitak.
<https://bilimgenc.tubitak.gov.tr/paranin-icadi> (18.01.2023)
- WEB_20. (2023). Wikipedia.
<https://tr.wikipedia.org/wiki/Para> (22.01.2023)
- WEB_21. (2023). Ekonomist.
<https://www.economist.com/special-report/2023/05/15/central-bank-digital-currencies-are-talked-about-more-than-coming-to-fruit> (20.01.2023)
- WEB_22. (2022). WorldBank.
<https://www.worldbank.org/en/publication/globalindex> (27.01.2023)

- WEB_23. (2022). FED.
<https://www.federalreserve.gov/newsevents/pressreleases/other20220627a.htm>
 (02.02.2023)
- WEB_24. (2023). Yapay Zeka ve Teknoloji Derneği.
<https://yztd.org.tr/blog/kuantum-bilgisayarlarinin-finans-piyasalarinda-kullanim- alanlari-2> (07.04.2023)
- WEB_25. (2023). Nasdaq.
<https://www.nasdaq.com/articles/honda-races-to-grab-consumers-with-crypto- payment-expansion> (11.10.2023)
- WEB_26. (2023). Binance.
<https://www.binance.com/en/feed/post/1247435> (11.10.2023)
- WEB_27. (2023). The Crypto Basic.
<https://thecryptobasic.com/2023/10/14/ferrari-confirms-to-accept-xrp-shiba-inu- for-luxury-cars-in-us/> (15.10.2023)
- WEB_28. (2023). WallStreetMojo.
<https://www.wallstreetmojo.com/money-market/> (04.07.2023)
- WEB_29. (2023). Investopedia.
<https://www.investopedia.com/terms/m/moneymarket.asp> (04.07.2023)
- WEB_30. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Money_market (05.07.2023)
- WEB_31. (2020). Lexpera.
<https://blog.lexpera.com.tr/dijital-merkez-bankasi-paralari-hakkinda-bis- raporunda-yer-alan-temel-tespitler/> (11.07.2023)
- WEB_32. (2021). Ekonomist.
<https://www.ekonomist.com.tr/encyclopedia/kripto-para-madenciligi-mining- nedir-nasil-yapilir> (13.07.2023)
- WEB_33. (2023). CoinMarketCap.
<https://coinmarketcap.com/academy/tr/glossary> (15.07.2023)
- WEB_34. (2023). Inswitch.
<https://www.inswitch.com/blog/binance-partners-with-inswitch-for-fiat-on-off- ramp-in-latam> (15.07.2023)
- WEB_35. (2023). Giesecke+Devrient.
<https://www.gi-de.com/en/ventures/metaco> (18.07.2023)
- WEB_36. (2022). Digital Euro Association.
<https://blog.digital-euro-association.de/en/en/digital-euro-association-partners- with-ripple-0> (18.07.2023)
- WEB_37. (2023). Coderspace.
<https://coderspace.io/sozluk/web3> (19.07.2023)

- WEB_38. (2023). Cointelegraph.
<https://tr.cointelegraph.com/learn/what-is-bitcoin-cash> (21.07.2023)
- WEB_39. (2023). Investopedia.
<https://www.investopedia.com/terms/b/bitcoin-cash.asp> (21.07.2023)
- WEB_40. (2018). Cointelegraph.
<https://cointelegraph.com/news/abc-vs-cv-assessing-the-consequences-of-the-bitcoin-cash-war> (21.07.2023)
- WEB_41. (2023). Ethereum.
<https://ethereum.org/en/dapps/#what-are-dapps> (22.07.2023)
- WEB_42. (2023). Ethereum.
<https://ethereum.org/en/developers/docs/consensus-mechanisms/pos/>
 (22.07.2023)
- WEB_43. (2023). Ethereum.
<https://ethereum.org/en/developers/docs/evm/> (22.07.2023)
- WEB_44. (2023). Ethereum.
<https://ethereum.org/en/defi/#borrowing-privacy> (22.07.2023)
- WEB_45. (2023). Ethereum.
<https://ethereum.org/en/foundation/#about-the-ethereum-foundation>
 (22.07.2023)
- WEB_46. (2023). Investopedia.
<https://www.investopedia.com/terms/e/ethereum-classic.asp> (23.07.2023)
- WEB_47. (2023). Ripple.
<https://ripple.com/ripplenet-committee/> (23.07.2023)
- WEB_48. (2022). Investopedia.
<https://www.investopedia.com/terms/i/interledger-protocol.asp> (25.07.2023)
- WEB_49. Litecoin.
<https://www.litecoin.net/litecoin-foundation> (25.07.2023)
- WEB_50. (2023). Wikipedia.
<https://en.wikipedia.org/wiki/Litecoin> (25.07.2023)
- WEB_51. (2022). İsternet.
<https://isternet.com/coin/24/litecoin> (27.07.2023)
- WEB_52. (2023). Stellar.
<https://stellar.org/learn/intro-to-stellar> (27.07.2023)
- WEB_53. (2022). Stellar.
<https://developers.stellar.org/docs/fundamentals-and-concepts/stellar-consensus-protocol> (27.07.2023)

- WEB_54. (2023). Stellar.
<https://stellar.org/learn/anchor-basics> (27.07.2023)
- WEB_55. (2022). Stellar.
<https://anchors.stellar.org/?> (27.07.2023)
- WEB_56. (2023)
<https://stellar.org/learn/store-and-send-lumens> (09.08.2023)
- WEB_57. (2022). Stellar.
<https://stellar.org/press/unhcr-launches-pilot-cash-based-intervention-using-blockchain-technology-for-humanitarian-payments-to-people-displaced-and-impacted-by-the-war-in-ukraine> (09.08.2023)
- WEB_58. (2023). Coin Rapor.
<https://www.coinrapor.com/dogecoin-nedir/> (10.08.2023)
- WEB_59. (2023). Kriptomat.
<https://kriptomat.io/tr/kripto-para-fiyatlari/dogecoin-doge-fiyati/> (10.08.2023)
- WEB_60. (2023). Wikipedia.
<https://tr.wikipedia.org/wiki/Monero> (12.08.2023)
- WEB_61. (2023). Kriptomat.
<https://kriptomat.io/tr/kripto-paralar/monero/monero-nedir> (12.08.2023)
- WEB_62. (2021). Bitcoinsistemi.
<https://www.bitcoinsistemi.com/bitcoin-ve-monero-ile-alisveris-yapilan-darkwebin-en-buyuk-yasadisi-pazari-kapatildi/> (12.08.2023)
- WEB_63. (2023). Getmonero.
<https://www.getmonero.org/resources/about/> (12.08.2023)
- WEB_64. (2023). Wikipedia.
[https://en.wikipedia.org/wiki/Tether_\(cryptocurrency\)](https://en.wikipedia.org/wiki/Tether_(cryptocurrency)) (12.08.2023)
- WEB_65. (2023). Cryptomus.
<https://cryptomus.com/tr/blog/understanding-usdt-crypto-the-tether-stablecoin-explained> (23.10.2023)
- WEB_66. (2023). Rain.
<https://www.rain.com/tr-tr/learn/tether-usdt-trc-20-vs-erc-20-explained> (23.10.2023)
- WEB_67. (2023). Wikipedia.
[https://en.wikipedia.org/wiki/Dash_\(cryptocurrency\)](https://en.wikipedia.org/wiki/Dash_(cryptocurrency)) (15.08.2023)
- WEB_68. (2022). Dash.
<https://www.dash.org/masternodes/> (15.08.2023)

- WEB_69. (2018). Dash.
<https://docs.dash.org/ko/0.13.0/wallets/dashcore/privatesend-instantsend.html>
(15.08.2023)
- WEB_70. (2019). Dash.
<https://docs.dash.org/en/stable/docs/user/wallets/dashcore/coinjoin-instantsend.html> (15.08.2023)
- WEB_71. (2023). CoinMarketCap.
<https://coinmarketcap.com/tr/currencies/zcash/> (18.08.2023)
- WEB_72. (2021). The Balance Money.
<https://www.thebalancemoney.com/zcash-explained-5190582> (19.08.2023)
- WEB_73. (2023). Zcash.
<https://z.cash/learn/what-are-zk-snarks/> (19.08.2023)
- WEB_74. (2018). Zcash.
<https://z.cash/upgrade/sapling/> (19.08.2023)
- WEB_75. (2023). Uzmancoin.
<https://uzmancoin.com/ada-coin-nedir-gelecegi-yorumlari-projesi/> (04.12.2023)
- WEB_76. (2022). Bitlo.
<https://www.bitlo.com/rehber/binance-coin-nedir> (04.12.2023)
- WEB_77. (2023). Blockchain Council.
<https://www.blockchain-council.org/blockchain/what-is-proof-of-history-and-how-does-it-work/> (04.12.2023)
- WEB_78. (2021). Mowgli Finans.
<https://mowglifinance.medium.com/features-of-cryptocurrency-55802435511e>
(20.08.2023)
- WEB_79. (2023). CNBC.
<https://www.cnbc.com/2023/11/25/ex-binance-ceo-zhao-urges-judge-to-allow-him-to-leave-us-before-sentencing.html> (25.11.2023)
- WEB_80. (2023). Worldcoin.
<https://worldcoin.org/articles/history-of-cryptocurrency> (21.08.2023)
- WEB_81. (2019). Quora.
<https://www.quora.com/Can-the-cap-of-21-million-bitcoins-be-changed-If-so-who-decides-If-it-cannot-be-changed-why/answer/David-Schwartz-9>
(21.08.2023)
- WEB_82. (2023). Wikipedia.
<https://en.wikipedia.org/wiki/Cypherpunk> (21.08.2023)
- WEB_83. (2022). DataTeam.
<https://datateam.com.tr/regulasyon-teknolojileri-regtech-nedir/> (22.08.2023)

- WEB_84. (2022). Twitter.
https://twitter.com/Blockworks_/status/1599731976159649794 (22.08.2023)
- WEB_85. (2023). Influencer MarketingHub.
<https://influencermarketinghub.com/crypto-fintech-companies/> (22.08.2023)
- WEB_86. (2020). Coinkolik.
<https://www.coinkolik.com/kripto-para-fiyat-endeksi-nedir/> (23.08.2023)
- WEB_87. (2023). Geeksforgeeks.
<https://www.geeksforgeeks.org/what-are-crypto-indices/> (23.08.2023)
- WEB_88. (2018). Comply Advantage.
<https://complyadvantage.com/insights/cryptocurrency-regulations-around-world/>
 (18.04.2022)
- WEB_89. (2022). Money.
<https://money.com/cryptocurrency-legal-status-by-country/> (24.08.2023)
- WEB_90. (2023). FATF.
<https://www.fatf-gafi.org/en/publications/High-risk-and-other-monitored-jurisdictions/Call-for-action-october-2023.html> (29.10.2023)
- WEB_91. (2023). Investing.
<https://tr.investing.com/news/cryptocurrency-news/cumhurbaskanlg-acklad-kripto-paralara-vergi-hazrlklar-basladi-2577767> (29.10.2023)
- WEB_92. (2020). Thomson Reuters.
<https://legal.thomsonreuters.com/en/insights/white-papers/combating-money-laundering-five-ways-to-help> (24.08.2023)
- WEB_93. (2023). Gelecek Bilimde Bilim İletişimi Platformu.
<https://gelecekbilimde.net/yapay-zeka-hakkinda-bilmeniz-gerekenler/>
 (18.10.2023)
- WEB_94. (2018). Medium.
<https://medium.com/@milimaudio/sibernetik-ve-yapay-zeka-uzerine-9084f0ac30e9> (27.08.2023)
- WEB_95. (2018). Github.
https://github.com/openai/spinningup/blob/master/docs/spinningup/rl_intro2.rst
 (28.08.2023)
- WEB_96. (2015). Slideplayer.
<https://slideplayer.biz.tr/slide/3202032/> (28.08.2023)
- WEB_97. (2017). Derin Öğrenme | Deep Learning.
<https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/> (01.09.2023)
- WEB_98. (2021). Towards Data Science.
<https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis-cb408ee93141> (01.09.2023)

- WEB_99. (2023). Altair HyperStudy.
https://help.altair.com/hwdesktop/hst/topics/design_exploration/method_radial_basis_function_r.htm (02.09.2023)
- WEB_100. (2018). Geeks For Geeks.
<https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/> (03.09.2023)
- WEB_101. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Long_short-term_memory (03.09.2023)
- WEB_102. (2020). Machine Learning Mastery.
<https://machinelearningmastery.com/gentle-introduction-backpropagation-time/> (04.09.2023)
- WEB_103. (2022). Dive into Deep Learning.
https://tr.d2l.ai/chapter_multilayer-perceptrons/dropout.html (04.09.2023)
- WEB_104. (2020). Medium.
<https://medium.com/@batincangurbuz/kohonen-ağı-kohonen-network-kn-c7a3ab2637bc> (05.09.2023)
- WEB_105. (2023). Wikipedia.
<https://en.wikipedia.org/wiki/ADALINE> (07.09.2023)
- WEB_106. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Capsule_neural_network (08.09.2023)
- WEB_107. (2020). Medium.
<https://medium.com/deep-learning-turkiye/kapsül-ağları-capsule-networks-bb7ff1e74843> (08.09.2023)
- WEB_108. (2023). Telecom Trainer.
<https://www.telecomtrainer.com/drl-deep-reinforcement-learning/> (09.09.2023)
- WEB_109. (2021). V7 Labs.
<https://www.v7labs.com/blog/deep-reinforcement-learning-guide> (09.09.2023)
- WEB_110. (2021). Medium.
<https://medium.com/analytics-vidhya/quantum-convolutional-neural-network-for-image-classification-using-tensorflow-334c6c2c73f0> (15.09.2023)
- WEB_111. (2023). Wikipedia.
[https://tr.wikipedia.org/wiki/Süperpozisyon_prensibi_\(fizik\)](https://tr.wikipedia.org/wiki/Süperpozisyon_prensibi_(fizik)) (15.09.2023)
- WEB_112. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Paralel_hesaplama (15.09.2023)
- WEB_113. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Quantum_neural_network (16.09.2023)

- WEB_114. (2023). Wikipedia.
<https://tr.wikipedia.org/wiki/Otokodlayıcı> (17.09.2023)
- WEB_115. (2020). Medium.
<https://medium.com/@batincangurbuz/derin-oto-kodlayıcılar-denoising-autoencoders-dae-ve-oto-kodlayıcılar-autoencoders-ae-bbd3b1389d60>
 (17.09.2023)
- WEB_116. (2023). Medium.
<https://medium.com/@tallaswapna9/types-of-autoencoders-in-deep-learning-383cfec4d0e> (17.09.2023)
- WEB_117. (2023). Deep Learning of Python.
<https://deeplearningofpython.blogspot.com/2023/05/Typesofautoencoders-implementation-keras.html#point3> (17.09.2023)
- WEB_118. (2023). Waywithwords.
<https://waywithwords.net/landing/new-algorithms-in-machine-learning-2/>
 (19.09.2023)
- WEB_119. (2022). Builtin.
<https://builtin.com/data-science/transfer-learning> (19.09.2023)
- WEB_120. (2018). Towards Data Science.
<https://towardsdatascience.com/residual-networks-resnets-cb474c7c834a>
 (21.09.2023)
- WEB_121. (2023). Keras.
<https://keras.io/2.15/api/applications/resnet/> (21.09.2023)
- WEB_122. (2023). Github.
https://github.com/keras-team/tf-keras/blob/v2.15.0/tf_keras/applications/resnet.py#L499 (21.09.2023)
- WEB_123. (2022). Dive into Deep Learning.
https://d2l.ai/chapter_convolutional-modern/resnet.html (21.09.2023)
- WEB_124. (2023). Token Metrics.
<https://www.tokenmetrics.com/blog/quantum-financial-system> (19.06.2023)
- WEB_125. (2023). Azo Quantum.
<https://www.azoquantum.com/article.aspx?ArticleID=455> (18.10.2023)
- WEB_126. (2023). BlueQubit.
<https://www.bluequbit.io/quantum-financial-system> (22.06.2023)
- WEB_127. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Residual_neural_network (21.09.2023)
- WEB_128. (2018). Medium.
<https://medium.com/nsistanbul/görüntü-tanıyan-mobil-uygulama-nasıl-geliştirilir-33760f7d827> (20.09.2023)

- WEB_129. (2023). Github.
https://github.com/monero-project/monero/blob/master/docs/ANONYMITY_NETWORKS.md
 (11.08.2023)
- WEB_130. (2018). Acm Digital Library.
<https://dl.acm.org/doi/pdf/10.1145/3292040.3219620> (07.07.2023)
- WEB_131. (2021). CoinMarketCap.
<https://coinmarketcap.com/indices/> (23.08.2023)
- WEB_132. (2021). Nasdaq.
<https://www.nasdaq.com/articles/an-overview-of-the-top-crypto-indexes-2021-06-23> (23.08.2023)
- WEB_133. (2023). Cmc Markets.
<https://www.cmcmarkets.com/en/cryptocurrencies/crypto-index> (23.08.2023)
- WEB_135. (2023). BlackRock.
<https://www.blackrock.com/institutions/en-zz/literature/whitepaper/bii-investment-perspectives-sustainability-november-2023.pdf> (02.12.2023)
- WEB_136. (2023). BlackRock.
https://content.blackrock.com/i/od4FeO55PLUSSIGNvPLUSSIGN8E84ojNmAlEj7elkvkgDA1__S5RuVSxBvBBNzCz4nWlxsewLJ2mc61FOE9O2sNpBF TMPLUSSIGNi9VYbVLmONQgDV7f20Am93avDJ6fdYg0tYJRPLUSSIGNV GfN0PLUSSIGNXA13DB (29.06.2023)
- WEB_137. (2023). Dataguess.
<https://www.dataguess.com/post/computer-vision-bilgisayarli-goru-vs-image-processing-goruntu-isleme> (02.08.2023)
- WEB_138. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Yapay_zeka (03.04.2023)
- WEB_139. (2018). Fikir Jeneratörü.
<https://fikirjeneratoru.com/cesitli-yapay-zeka-tekniklerinin-karsilastirilmesi/>
 (03.04.2023)
- WEB_140. (2022). Bulutistan.
<https://bulutistan.com/blog/yapay-zeka-ai-nedir/> (26.03.2023)
- WEB_141. (2023). World Economic Forum.
https://www3.weforum.org/docs/WEF_Global_Risks_Report_2023.pdf
 (21.03.2023)
- WEB_142. (2023). World Economic Forum.
https://www3.weforum.org/docs/WEF_Quantum_Readiness_Toolkit_2023.pdf
 (16.07.2023)

- WEB_143. (2022). World Economic Forum.
https://www3.weforum.org/docs/WEF_Transitioning%20to_a_Quantum_Secure_Economy_2022.pdf (07.05.2023)
- WEB_144. (2021). Cointelegraph.
<https://tr.cointelegraph.com/learn/btc-bch-differences> (21.07.2023)
- WEB_145. (2023). TradingView.
<https://tr.tradingview.com/news/coinotag:7b0bc6a83d9e8:0/> (07.10.2023)
- WEB_146. (2023). WallStreetMojo.
<https://www.wallstreetmojo.com/cryptocurrency-top/#h-features> (27.06.2023)
- WEB_147. (2023). Data Base Camp.
<https://databasecamp.de/en/ml/transfer-learning-en> (19.09.2023)
- WEB_148. (2023). Wikipedia.
<https://en.wikipedia.org/wiki/Autoencoder> (17.09.2023)
- WEB_149. (2022). Great Learning.
<https://www.mygreatlearning.com/blog/autoencoder/> (17.09.2023)
- WEB_150. (2020). Medium.
<https://medium.com/@batincangurbuz/derin-oto-kodlayıcılar-denoising-autoencoders-dae-ve-oto-kodlayıcılar-autoencoders-ae-bbd3b1389d60> (17.09.2023)
- WEB_151. (2023). Qiskit.
https://qiskit.org/ecosystem/machine-learning/locale/tr_TR/tutorials/01_neural_networks.html (14.09.2023)
- WEB_152. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Quantum_cognition (16.09.2023)
- WEB_153. (2021). Quantum Machine Learning Platform.
<https://qml.baidu.com/quick-start/quantum-neural-network.html> (14.09.2023)
- WEB_154. (2021). Medium.
<https://medium.com/analytics-vidhya/quantum-convolutional-neural-network-for-image-classification-using-tensorflow-334c6c2c73f0> (16.09.2023)
- WEB_155. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Kuantum_dolanıklık (14.09.2023)
- WEB_156. (2018). Google Research.
<https://blog.research.google/2018/12/exploring-quantum-neural-networks.html> (15.09.2023)
- WEB_157. (2020). Medium.
<https://medium.com/@batincangurbuz/n%C3%B6ral-turing-makinesi-neural-turing-machines-ntm-f36197fff2e4> (11.09.2023)

- WEB_158. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Neural_Turing_machine (11.09.2023)
- WEB_159. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Deep_reinforcement_learning (09.09.2023)
- WEB_160. (2022). Dataversity.
<https://www.dataversity.net/fundamentals-deep-reinforcement-learning/>
 (09.09.2023)
- WEB_161. (2023). SaturnCloud.
<https://saturncloud.io/glossary/capsnet/> (08.09.2023)
- WEB_162. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Deep_learning (08.09.2023)
- WEB_163. (2023). Analytics Vidhya.
<https://www.analyticsvidhya.com/blog/2021/03/basics-of-neural-network/>
 (08.09.2023)
- WEB_164. (2023). Amazon Web Services.
<https://aws.amazon.com/tr/what-is/deep-learning/> (08.09.2023)
- WEB_165. (2016). Scribd.
<https://www.scribd.com/presentation/328499473/ADALINE-ADaptive-LInear-Neuron-Network-and-Widrow-Hoff-Learning> (07.09.2023)
- WEB_166. (2023). MathWorks.
<https://in.mathworks.com/help/deeplearning/ug/adaptive-neural-network-filters.html> (07.09.2023)
- WEB_167. (2017). IBM Developer.
<https://developer.ibm.com/articles/cc-cognitive-recurrent-neural-networks/>
 (03.09.2023)
- WEB_168. (2020). Github.
<https://pabloinsente.github.io/the-recurrent-net> (03.09.2023)
- WEB_169. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Recurrent_neural_network (03.09.2023)
- WEB_170. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Self-organizing_map (05.09.2023)
- WEB_171. (2020). Medium.
<https://medium.com/@batincangurbuz/kohonen-ağı-kohonen-network-kn-c7a3ab2637bc> (05.09.2023)
- WEB_172. (2019). Towards Data Science.
<https://towardsdatascience.com/kohonen-self-organizing-maps-a29040d688da>
 (05.09.2023)

- WEB_173. (2023). Geeks for Geeks.
<https://www.geeksforgeeks.org/self-organising-maps-kohonen-maps/>
 (05.09.2023)
- WEB_174. (2021). Java T Point.
<https://www.javatpoint.com/artificial-neural-network-kohonen-self-rganizing-feature-map> (05.09.2023)
- WEB_175. (2023). Search.r-Project.
<https://search.r-project.org/CRAN/refmans/RSNNS/html/elman.html>
 (06.09.2023)
- WEB_176. (2023). Search.r-Project.
<https://search.r-project.org/CRAN/refmans/RSNNS/html/jordan.html>
 (06.09.2023)
- WEB_177. (2023). Ibm.
<https://www.ibm.com/topics/convolutional-neural-networks> (03.09.2023)
- WEB_178. (2020). Machine Learning Mastery.
<https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/> (03.09.2023)
- WEB_179. (2020). Baeldung.
<https://www.baeldung.com/cs/ml-relu-dropout-layers> (03.09.2023)
- WEB_180. (2020). Medium.
<https://medium.com/@mcvarer/rnn-lstm-ve-gru-modellerinin-inceleme-si-f59a73499edb> (03.09.2023)
- WEB_181. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Gated_recurrent_unit (03.09.2023)
- WEB_182. (2018). Towards Data Science
<https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21> (03.09.2023)
- WEB_183. (2020). Towards Data Science.
<https://towardsdatascience.com/lstm-networks-a-detailed-explanation-8fae6aefc7f9> (04.09.2023)
- WEB_184. (2022). Data Base Camp.
<https://databasecamp.de/en/ml/lstms> (04.09.2023)
- WEB_185. (2023). Stanford University.
<https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks> (03.09.2023)
- WEB_186. (2017). Towards Data Science.
<https://towardsdatascience.com/radial-basis-functions-neural-networks-all-we-need-to-know-9a88cc053448> (03.09.2023)

- WEB_187. (2023). Medium.
<https://medium.com/@monocosmo77/rise-of-radial-basis-functions-part3-machine-learning-93a704486501> (13.09.2023)
- WEB_188. (2023). Medium.
<https://medium.com/@monocosmo77/rise-of-radial-basis-functions-part2-machine-learning-bebb7521c28d> (13.09.2023)
- WEB_189. (2023). Medium.
<https://medium.com/@monocosmo77/rise-of-radial-basis-functions-part1-machine-learning-4b6e8474b3c9> (13.09.2023)
- WEB_190. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Radial_basis_function (02.09.2023)
- WEB_191. (2022). Medium.
<https://emreetiner.medium.com/generative-adversarial-networks-gans-54411916065e> (01.09.2023)
- WEB_192. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Generative_adversarial_network (01.09.2023)
- WEB_193. (2021). Medium.
<https://gnoguz.medium.com/gan-generative-adversarial-networks-75b0c1d0c658> (01.09.2023)
- WEB_194. (2023). Wikipedia.
https://en.wikipedia.org/wiki/Multilayer_perceptron (01.09.2023)
- WEB_195. (2023). Medium.
<https://medium.com/@HeCanThink/the-representation-power-of-perceptron-networks-mlp-1d189ad640bc> (01.09.2023)
- WEB_196. (2023). Neptune.ai.
<https://neptune.ai/blog/self-supervised-learning> (28.08.2023)
- WEB_197. (2023). Geeks for Geeks.
<https://www.geeksforgeeks.org/what-is-reinforcement-learning/> (28.08.2023)
- WEB_198. (2022). Altexsoft.
<https://www.altexsoft.com/blog/semi-supervised-learning/> (26.08.2023)
- WEB_199. (2023). Datacamp.
<https://www.datacamp.com/blog/introduction-to-unsupervised-learning> (26.08.2023)
- WEB_200. (2023). Ibm.
<https://www.ibm.com/topics/supervised-learning> (26.08.2023)
- WEB_201. (2020). Veri Bilimi Okulu.
<https://www.veribilimiokulu.com/makinelar-nasil-ogrenir/> (26.08.2023)

- WEB_202. (2020). Sap.
<https://www.sap.com/turkey/products/artificial-intelligence/what-is-machine-learning.html> (26.08.2023)
- WEB_203. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Genetik_algoritma (25.08.2023)
- WEB_204. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Genetik_programlama (25.08.2023)
- WEB_205. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Bilgisayarlı_görü (25.08.2023)
- WEB_206. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Doğal_dil_işleme (25.08.2023)
- WEB_207. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Örüntü_tanım (25.08.2023)
- WEB_208. (2023). Imf.
<https://www.imf.org/en/Blogs/Articles/2023/07/05/crypto-poses-significant-tax-problems-and-they-could-get-worse> (26.10.2023)
- WEB_209. (2019). HodlBlog.
<https://www.hodlbot.io/blog/ultimate-guide-on-cryptocurrency-indices> (23.08.2023)
- WEB_210. (2023). Investing.
<https://tr.investing.com/news/cryptocurrency-news/kripto-sektorunun-temelleri-kripto-ticaretinde-temel-terimler-nelerdir-2516859> (29.07.2023)
- WEB_211. (2020). Bitexen Research.
<https://research.bitexen.com/post/ico-ieo-sto-ido-nedir> (01.08.2023)
- WEB_212. (2023). Phemex.
<https://phemex.com/tr/academy/yield-farming-vs-staking-vs-likidite-madenciligi> (16.03.2023)
- WEB_213. (2021). Gate.io.
<https://www.gate.io/tr/article/22734> (16.03..2023)
- WEB_214. (2022). Coindesk.
<https://www.coindesk.com/consensus-magazine/2022/12/19/the-10-biggest-developments-in-bitcoin-in-2022/b> (22.03.2023)
- WEB_215. (2023). Wikipedia.
https://tr.wikipedia.org/wiki/Kripto_para (03.04.2023)
- WEB_216. (2023). Forbes.
<https://www.forbes.com/advisor/in/investing/cryptocurrency/advantages-of-cryptocurrency/> (20.08.2023)

- WEB_217. (2023). Investopedia.
<https://www.investopedia.com/terms/c/cryptocurrency.asp> (20.08.2023)
- WEB_218. (2023). Btcturk.
<https://www.btcturk.com/bilgi-platformu/sozluk/> (17.03.2023)
- WEB_219. (2023). Analytics Vidhya.
<https://www.analyticsvidhya.com/blog/2023/07/generative-ai-with-vaes-gans-transformers/> (20.03.2024)
- WEB_220. (2024). Wikipedia.
https://en.wikipedia.org/wiki/Variational_autoencoder (20.03.2024)
- WEB_221. (2020). Medium.
<https://medium.com/machine-learning-t%C3%BCrkiye/yapay-sinir-a%C4%9Flar%C4%B1nda-kullan%C4%B1lan-optimizasyon-algoritmalar%C4%B1-3e87cd738cb5> (21.03.2024)
- WEB_222. (2023). Analytics Vidhya.
<https://www.analyticsvidhya.com/blog/2023/09/what-is-adam-optimizer/#:~:text=Adam%20can%20be%20looked%20at,for%20many%20machine%20learning%20practitioners> (22.03.2024)
- WEB_223. (2022). Derin Öğrenme.
<https://dltr.asmaamir.com/0-nn-kavramlari/7-optimizasyon> (24.03.2024)
- WEB_224. (2020). DTA Mühendislik.
<https://blog.dta.com.tr/fourier-donusumu-nedir/> (25.03.2024)
- WEB_225. (2024). Trive.
<https://www.trive.com.tr/blog/bollinger-bandi> (28.03.2024)
- WEB_226. (2018). Medium.
<https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> (30.03.2024)
- WEB_227. (2023). Medium.
<https://medium.com/@marcodeipra/generative-adversarial-networks-dba10e1b4424> (02.04.2024)
- WEB_228. (2023). Yapay Zeka TR.
<https://www.yapayzekatr.com/2023/11/03/generative-adversarial-networks-gan-nedir/> (03.04.2024)
- WEB_229. (2024). Scientific Research.
<https://www.scirp.org/journal/paperinformation?paperid=131809> (7.04.2024)
- WEB_230. (2023). Tech Sciences Press.
<https://www.techscience.com/csse/v47n1/53044/html#:~:text=First%2C%20the%20GAN%20model%20can,used%20in%20the%20GAN%20network> (08.04.2024)

WEB_231. (2021). d2I AI.

https://d2l.ai/chapter_optimization/rmsprop.html (11.04.2024)

WEB_232. (2023). DeepAI.

<https://deepai.org/machine-learning-glossary-and-terms/rmsprop#:~:text=RMSProp%20addresses%20the%20issue%20of,allowing%20for%20more%20nuanced%20updates> (13.04.2024)

WEB_233. (2020). Medium.

<https://medium.com/machine-learning-t%C3%BCrkiye/yapay-sinir-a%C4%9Flar%C4%B1nda-kullan%C4%B1lan-optimizasyon-algoritmalar%C4%B1-3e87cd738cb5> (14.04.2024)