

**T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
İŞLETME BİLİM DALI**

**BİTCOİN FİYAT HAREKETLİLİĞİNİN MAKİNE
ÖĞRENMESİ İLE TAHMİN EDİLMESİ**

AHMET AKUSTA

DOKTORA TEZİ

**DANIŞMAN:
DOÇ. DR. MEHMET NURİ SALUR**

KONYA-2023



Bilimsel Etik Sayfası

Öğrencinin	Adı Soyadı	Ahmet AKUSTA		
	Numarası	18811101041		
	Ana Bilim / Bilim Dalı	İşletme/İşletme		
	Programı	Tezli Yüksek Lisans		
		Doktora	X	
	Tezin Adı	Bitcoin Fiyat Hareketliliğinin Makine Öğrenmesi ile Tahmin Edilmesi		

Bu tezin hazırlanmasında bilimsel etiğe ve akademik kurallara özenle riayet edildiğini, tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada başkalarının eserlerinden yararlanılması durumunda bilimsel kurallara uygun olarak atıf yapıldığını bildiririm.

Ahmet AKUSTA

ÖZET

Öğrencinin	Adı Soyadı	Ahmet AKUSTA		
	Numarası	18811101041		
	Ana Bilim / Bilim Dalı	İşletme/İşletme		
	Programı	Tezli Yüksek Lisans		
		Doktora	X	
	Tez Danışmanı	Doç. Dr. Mehmet Nuri SALUR		
	Tezin Adı	Bitcoin Fiyat Hareketliliğinin Makine Öğrenmesi ile Tahmin Edilmesi		

Bitcoin, dijital bir para birimi olarak finansal piyasalarda önemli bir yer edinmiştir. Ancak, Bitcoin'in belirgin bir özelliği olan yüksek volatilité problemi, hem yatırımcılar hem de akademisyenler için dikkat çekici bir konudur. Bitcoin'in fiyatında ani ve büyük ölçekli değişimler olabilmektedir. Bu durum, yatırımcıların karar alma süreçlerini etkileyebilir ve piyasa analizlerini daha zor hale getirebilir. Bu çalışma, Bitcoin'in fiyat hareketlerini etkileyen faktörleri belirleyerek Bitcoin fiyatını tahmin etmeyi amaçlamaktadır. Çalışma kapsamında, iki farklı kategoride veri kaynakları kullanılmıştır. Birincisi, kripto para sistemine ait olan ve Bitcoin ile diğer kripto paraları içeren 350 farklı değişkeni olan verilerdir. İkinci kategori ise dünya endekslerine ait olan ve 46 farklı değişkeni içeren verilerdir. Bu veriler, Tradingview ve Yahoo Finance gibi popüler finansal veri kaynaklarından elde edilmiştir. Kripto para sistemine ait veriler ağ bilgileri, kripto borsa işlemleri, adres verileri, fiyat verileri ve sosyal medya verileri gibi başlıklar altında toplanmıştır. Dünya endekslerine ait veriler ise tahvil endeksleri, dövizler, volatilité endeksi ve hisse senedi endeksleri gibi başlıklar altında sınıflandırılmıştır. Araştırma kapsamında, 2022-10 ile 2022-12 tarihleri arasındaki 90 günlük dönemi kapsayan veriler kullanılarak Bitcoin'in fiyatının tahmin edilmesi amacıyla makine öğrenimi algoritmaları kullanılmıştır. Bu veriler, %85'i eğitim ve %15'i test verisi olarak ayrılarak analiz edilmiştir. Eğitim aşamasının ardından, test verileri üzerinde yapılan tahminler görselleştirilerek sunulmuştur. Elde edilen sonuçlar, modelin 0.909 R² skoru ile genel anlamda başarılı bir performans sergilediğini ve tahminlerinin gerçek değerlere oldukça yakın olduğunu ortaya koymuştur. Bu bulgular, makine öğrenimi algoritmalarının Bitcoin fiyat tahmininde etkili bir araç olarak kullanılabilirliğini desteklemektedir.

Anahtar kelimeler: Bitcoin, Kripto Para, Fiyat Hareketliliği, Blokzincir, Makine Öğrenmesi



ABSTRACT

Author' s	Name and Surname	Ahmet AKUSTA		
	Student Number	18811101041		
	Department	İşletme/İşletme		
	Study Programme	Master's Degree (M.A.)		
		Doctoral Degree (Ph.D.)	X	
	Supervisor	Doç. Dr. Mehmet Nuri SALUR		
	Title of the Thesis/Dissertation	Bitcoin Price Volatility Prediction with Machine Learning		

As a digital currency, Bitcoin has gained significant prominence in financial markets. However, the high volatility issue, a prominent characteristic of Bitcoin, is an intriguing topic for investors and academics. It can lead to sudden and large-scale changes in the price of Bitcoin, affecting investors' decision-making processes and making market analysis more challenging. This study aims to predict the price of Bitcoin by identifying the factors that affect the price movements of Bitcoin. Two different categories of data sources were used in this study. The first category consists of data related to the cryptocurrency system, including 350 variables encompassing Bitcoin and other cryptocurrencies. The second category includes data related to global indices, encompassing 46 variables. These data were obtained from popular financial data sources such as Tradingview and Yahoo Finance. The data relating to the cryptocurrency system were collected under headings such as network information, cryptocurrency exchange transactions, address data, price data, and social media data. The data related to global indices were classified under headings such as bond indices, currencies, volatility indices, and stock indices. Within the scope of the research, machine learning algorithms were employed to predict the price of Bitcoin using data encompassing the 90 days between October 2022 and December 2022. These data were divided into an 85% training set and a 15% test set for analysis. Following the training phase, predictions on the test data were visualized and presented. The obtained results have demonstrated that the model exhibited a generally successful performance with an R^2 score of 0.909, indicating its predictions were notably close to actual values. These findings substantiate the utility of machine learning algorithms as an effective tool for Bitcoin price prediction.

Keywords: Bitcoin, Cryptocurrency, Price Volatility, Blockchain, Machine Learning

İÇİNDEKİLER

TABLolar LİSTESİ	iv
ŞEKİLLER LİSTESİ.....	v
GRAFİKLER LİSTESİ	vi
TEŞEKKÜR VE ÖNSÖZ	vii
GİRİŞ	1

BİRİNCİ BÖLÜM

PROBLEMİN TANIMLANMASI

1.1. Problemin Tanımlanması.....	3
1.2. Araştırmanın Faydaları.....	5
1.3. Literatür	5

İKİNCİ BÖLÜM

KAVRAMSAL ÇERÇEVE

2.1. Para.....	25
2.1.1. Paranın Tanımı	25
2.1.2. Paranın Klasik Fonksiyonları	26
2.1.3. Paranın Modern Fonksiyonları.....	27
2.2. Dijital Para Kavramı.....	29
2.3. Kriptografi Kavramı ve Blokzincir	29
2.4. Blokzincir Uzlaş Mekanizmaları.....	34
2.5. Blokzincir Teknolojilerinin Ortak Özellikleri	36
2.6. Kripto Sistemlerinde Güvenlik.....	37
2.7. Kripto Para Kavramı	40
2.8. Kripto Para Olarak Bitcoin.....	41
2.8.1. Bitcoin Arzı, Talebi ve Fiyatının Belirlenmesi	44
2.8.2. Bitcoin'in Ortaya Çıkış Süreci ve Tarihsel Gelişimi	45
2.8.3. Bitcoin ve Blokzincir'in Avantaj ve Dezavantajları.....	48
2.9. Altcoinler	51
2.9.1. Altcoin Tanımı.....	51
2.9.2. Stabil Coinler.....	51
2.9.3. Başlıca Altcoinler	54
2.9.4. Token.....	57
2.10. Araştırmanın Hipotezleri	58

ÜÇÜNCÜ BÖLÜM

BITCOİN FİYAT HAREKETLİLİĞİNİN MAKİNE ÖĞRENMESİ İLE TAHMİN EDİLMESİ

3.1.	Çalışmanın Amacı, Kapsamı ve Sınırları	61
3.2.	Veri Toplama ve Ön İşleme	62
3.3.	Veri Kaynakları	63
3.4.	Veri Ön İşleme	63
3.5.	Öznitelik Seçimi	65
3.5.1.	Düşük Varyansa Sahip Değişkenlerin Kaldırılması	65
3.5.2.	Aykırı Değerlerin Ayıklanması	66
3.5.3.	Çoklu Doğrusallığın Kaldırılması	67
3.5.4.	Boyut İndirgeme.....	68
3.5.5.	İndirgenmiş Veri Setinin Görselleştirilmesi	71
3.6.	Makine Öğrenimi Algoritmaları (Model Seçimi).....	74
3.7.	Makine Öğrenimi Modelinin Değerlendirilmesi	76
3.7.1.	Makine Öğrenimi Modeli İçin Tahmin Hatası	76
3.7.2.	Makine Öğrenimi Modeli İçin Artıkların İncelenmesi	77
3.7.3.	Makine Öğrenimi Modelinin Doğrulama Ve Öğrenme Eğrileri	79
3.8.	Makine Öğrenimi Modeli İçin Analiz Döneminin Değerlendirilmesi	83
3.9.	Tahmin Sonuçları	85
SONUÇ		87
KAYNAKÇA		91
EKLER		102

KISALTMALAR

Btc : Bitcoin

Cpu : İşlemci

Eba : Extreme Bounds Analysis (Uç Sınırlar Analizi)

Lda : Linear Discriminant Analysis (Doğrusal Diskriminant Analizi)

Pca : Temel Bileşen Analizi

PoS : Proof Of Stake (Hisse Kanıtı Mekanizması)

PoW : Proof Of Work (İş Kanıtı Mekanizması)

Vec : Vector Error Correction (Vektör Hata Düzeltme)



TABLolar LİSTESİ

Tablo 1.1 Bitcoin Fiyatının Yıllara Göre Değişimi.....	4
Tablo 2.1 Dijital Para Biçimlerinin Özellikleri	29
Tablo 2.2 Blokzincir Sistemlerinin Özellikleri	30
Tablo 2.3 Blokzincir Temel Bilgiler	33
Tablo 2.4 Pow Ve Pos Sistemlerinin Avantajları Ve Dezavantajları	36
Tablo 2.6 Çalınmış Kripto Paraların Kullanıldığı Yerler	40
Tablo 2.7 Kripto Paraların Özellikleri.....	41
Tablo 2.8 Bitcoin Kabul Eden 10 Uluslararası Şirket	42
Tablo 2.9 Bitcoin Arz İstatistikleri.....	44
Tablo 2.10 Bitcoin Yıllara Göre Getirisi.....	46
Tablo 3.1 Kategori 1 'de Kullanılan Değişkenler.....	62
Tablo 3.2 Kategori 2 'de Kullanılan Değişkenler.....	63
Tablo 3.3 Makine Öğrenmesi Algoritmalarının Kıyaslanması	75
Tablo 3.4 Seçilen Algoritmanın 10-Kat Çapraz Doğrulama Sonuçları.....	82

ŞEKİLLER LİSTESİ

Şekil 2.1 Merkezi, Merkeziyetsiz Ve Dağıtılmış Ağ Görünümü	32
Şekil 2.3 Hash Mekanizmasının İşleyişi	33
Şekil 3.1 Aykırı Değerlerin Belirlenmesi	67
Şekil 3.2 İndirgenmiş Verinin Kümülatif Varyans Açıklama Oranı	69
Şekil 3.3 İndirgenmiş Verinin İkili Karşılaştırılması	70
Şekil 3.4 İndirgenmiş Verinin Üç Boyutlu Görselleştirilmesi	72
Şekil 3.5 İndirgenmiş Verinin T-SNE Manifold Tekniği İle Görselleştirilmesi	73
Şekil 3.6 Tahmin Hata Eğrisi	77
Şekil 3.7 Model Artıklarının Görselleştirilmesi	78
Şekil 3.8 Bir Yıllık Period'a Ait Model İstatistikleri	83
Şekil 3.9 Altı Aylık Period'a Ait Model İstatistikler	84
Şekil 3.10 Üç Aylık Period'a Ait Model İstatistikler	84

GRAFİKLER LİSTESİ

Grafik 2.1 Bitcoin Fiyatı	45
Grafik 3.1 Modelin Öğrenme Eğrisi	80
Grafik 3.2 Modelin Doğrulama Eğrisi	81
Grafik 3.3 Model Tahmini Ve Gerçekleşen Günlük Kapanış	85



TEŞEKKÜR ve ÖNSÖZ

Öncelikle doktora çalışmamın her anında yanımda olan ve tecrübelerini paylaşan değerli danışman hocam Doç. Dr. Mehmet Nuri SALUR'a teşekkür ediyorum.

Beni yapay zekâ ile tanıştıran ve akademik hayatımda bana yeni ufuklar açan arkadaşım Özay OKUMUŞ'a şükran borçluyum.

Çalışmam sırasında çok büyük desteği olan ve daima yanımda olan canım aileme, özellikle kardeşim Dr. Emre AKUSTA'ya teşekkürlerimi sunuyorum.



GİRİŞ

Kripto para birimlerinin ortaya çıkışı, dijital para birimleri olarak adlandırılan varlıkların popülerlik kazanmasıyla başlamıştır. İlk kripto para birimi olan Bitcoin, 2009 yılında piyasaya sürülmüş ve o zamandan bu yana birçok kripto para birimi ortaya çıkmıştır. Kripto para birimleri, merkezi bir otoriteye veya bankaya bağlı olmadan, kullanıcılar arasında doğrudan ve güvenli bir şekilde transfer edilebilen sanal para birimleridir.

Kripto para birimleri ve blokzincir teknolojisi, hızla büyüyen bir endüstri haline gelmiş ve birçok birey ve kuruluş tarafından benimsenmiştir. Finansal sistemdeki teknolojik yenilikler, finansal sistemlerdeki geleneksel sınırlamaları aşma potansiyeline sahip oldukları için kullanıcılar tarafından büyük ilgi görmüştür. Blokzincir teknolojisi, işlemlerin kaydedilmesi ve doğrulanması için dağıtık bir ağ kullanır, bu da güvenlik ve şeffaflık sağlar. Aynı zamanda, finansal işlemlerin merkezi bir otoriteye veya aracıya ihtiyaç duymadan, düşük maliyetlerle ve hızlı bir şekilde finansal işlemlerin gerçekleştirilmesini mümkün kılar.

Kripto para birimlerinin popüleritesi ve kullanımı, beraberinde birçok sorunu getirmektedir. Kripto para birimlerinin en belirgin sorunlarından biri, aşırı fiyat volatilitesidir. Bitcoin gibi önde gelen kripto para birimleri, kısa bir süre içinde büyük fiyat dalgalanmaları gösterebilmektedir. Bu durum, yatırımcılar ve kullanıcılar için belirsizlik yaratır ve günlük kullanımda kripto para birimlerinin istikrarlı bir değer deposu veya değişim aracı olarak kullanılmasını zorlaştırmaktadır.

Kripto para birimlerinin volatilitesi, çeşitli faktörlerden etkilenmektedir. Bu faktörler arasında piyasa talebi, haberler ve duyurular, düzenleyici önlemler, teknolojik gelişmeler ve makroekonomik faktörler bulunmaktadır. Örneğin, olumlu bir haber veya büyük bir şirketin kripto para birimlerini kabul etmesi, fiyatların aniden yükselmesine neden olabilmektedir. Benzer şekilde, olumsuz bir duyuru veya düzenleyici kısıtlamalar, fiyatların hızla düşmesine yol açabilmektedir.

Bu fiyat dalgalanmaları, yatırımcılar ve tüccarlar için büyük fırsatlar sunarken aynı zamanda riskleri de beraberinde getirmektedir. Spekülatif ticaret ve kısa vadeli yatırımlar, volatiliteye dayalı stratejilerin kullanılmasına yol açabilir, ancak bu da piyasa manipülasyonunu artırabilir ve riski daha da artırabilir.

Ayrıca, kripto para birimlerinin düzenlenmesi gerekliliği de volatilitenin yakından ilişkilidir. Kripto para birimlerinin yasa dışı faaliyetlerde kullanımını engellemek, dolandırıcılık ve manipülasyonu önlemek, vergi kaçakçılığını önlemek ve bilgisayar korsanlığı, kara para aklama ve terörist faaliyetler için fon sağlama gibi eylemleri önlemek için düzenleyici tedbirler

alınması da gerekmektedir. Bu tür düzenlemeler, kripto para birimlerinin güvenilirliğini ve kabul edilebilirliğini artırabilir, ancak aynı zamanda piyasa üzerinde etkileri olduğu için fiyat volatilitelerini de etkileyecektir.

Bu çalışma, Bitcoin'in fiyat hareketlerini etkileyen faktörleri belirleyerek Bitcoin fiyatını tahmin etmeyi amaçlamaktadır. Çalışmanın, kripto para birimlerinin fiyat dalgalanmalarının nedenlerini ve etkilerini anlamamıza yardımcı olacak makine öğrenmesi yöntemleri kullanarak kripto para birimlerinin gelecekteki fiyat hareketlerini daha iyi anlamamıza ve daha etkili risk yönetimi stratejileri geliştirmemize yardımcı olabileceği düşünülmektedir.

Literatürde, Bitcoin'in fiyat hareketlerini tahmin etmeye yönelik makine öğrenmesi ve yapay zekâ tabanlı çalışmalara sıkça rastlanmaktadır. Ancak, bu çalışmalar genellikle farklı algoritmaların performansını yeterince karşılaştırmaktan yoksun kalmaktadır. Bu bağlamda, mevcut araştırmaların eksik kalan bu yönünü ele alarak, Bitcoin fiyat tahmini alanında algoritmalar arası performans karşılaştırmalarını gerçekleştiren bir çalışma sunuyoruz; bu da çalışmamızı özgün kılmaktadır.

Önceki çalışmalarda, Bitcoin fiyat tahmini için genellikle kripto ile ilgili değişkenler ve küresel ekonomik faktörler ayrı ayrı ele alınmıştır. Bizim çalışmamız ise bu iki değişken kategorisini aynı modele entegre ederek, Bitcoin fiyatını etkileyen faktörlerin daha kapsamlı bir perspektifini sunmayı amaçlamaktadır. Bu yaklaşım, literatüre, Bitcoin fiyat hareketlerini şekillendiren faktörlerin birbirleriyle etkileşimlerini daha gerçekçi bir şekilde yansıtmada konusunda yeni bir bakış açısı kazandırmaktadır.

Ayrıca, mevcut literatürde Bitcoin fiyat tahmini genellikle belirli bir zaman dilimi için gerçekleştirilmektedir. Çalışmamızda ise farklı zaman dilimleri (1 yıl, 6 ay, 3 ay) üzerinde yapılan analizler sonucunda en yüksek tahmin doğruluğuna sahip olan zaman dilimi seçilmiştir. Bu yaklaşım, literatüre sadece tek bir zaman dilimine odaklanmanın ötesinde, farklı dönemlerin performansını karşılaştırarak daha kapsamlı bir bakış açısı sunma konusunda önemli bir katkı sağlamaktadır.

BİRİNCİ BÖLÜM

PROBLEMİN TANIMLANMASI

Kripto para piyasası son yıllarda büyük bir yükseliş trendi yaşamış ve bu sektöre olan ilgi her geçen gün daha da artmaktadır. Özellikle Bitcoin, piyasa hacmi bakımından diğer kripto para birimlerine göre önemli bir yer tutmakta ve piyasa fiyat hareketleri sürekli olarak takip edilmektedir.

Ancak, bu kadar hızlı ve yüksek fiyat hareketleri, yatırımcılar için zorluklar da içermektedir. Sadece birkaç dakika içinde yaşanan fiyat değişimleri, yatırımcıların sağlıklı bir şekilde yatırım yapmalarını engelleyebilir ve hatta kayıplara sebep olabilir. Bu nedenle, piyasa hareketlerini anlamak ve doğru kararlar vermek için hem teknik hem de temel analiz araçları kullanılmaktadır.

Bitcoin, kripto para birimleri arasında en popüler olanıdır ve geniş çapta kullanılmaktadır. Ancak, Bitcoin'in fiyat hareketleri oldukça dalgalıdır ve bu hareketlerin belirlenmesi ve tahmin edilmesi zorlu bir görevdir. Bu nedenle, bu çalışma, Bitcoin fiyat hareketlerinin altında yatan faktörleri belirleyerek gelecekteki fiyat değişikliklerini tahmin etmek için bir analiz yapmayı amaçlamaktadır.

Bu çalışma, yatırımcıların doğru ve bilinçli kararlar vermelerine yardımcı olmakla sınırlı kalmayarak kripto para piyasasının genel dinamiklerine ilişkin daha kapsamlı bilgiler de sağlayacaktır. Bu nedenle, kripto para piyasasına ilgi duyan kişiler için bu çalışmanın önemli bir kaynak olabileceği düşünülmektedir.

1.1.Problemin Tanımlanması

Bitcoin'in fiyat oynaklığı, yatırımcılar, hissedarlar ve diğer kullanıcılar arasında tekrar eden bir endişe kaynağı olmuştur. Bu endişe, önemli derece öngörülemeyen ve yatırımcıların ciddi kayıplar yaşamasına yol açabilen sık ve hızlı fiyat dalgalanmalarıyla ilgilidir.

Tablo 1.1 Bitcoin'in bir önceki yılbaşına göre yıllık getirisini göstermektedir.

Tablo 1.1 Bitcoin Fiyatının Yıllara Göre Değişimi

Tarih	Bitcoin Fiyatı (\$)	Değişim (\$)	Yıllık Yüzde Değişim
1.01.2023	16625,08	-31061,73	-65,14
1.01.2022	47686,81	18312,66	62,34
1.01.2021	29374,15	22173,98	307,96
1.01.2020	7200,17	3356,65	87,33
1.01.2019	3843,52	-9813,68	-71,86
1.01.2018	13657,20	12658,88	1268,01
1.01.2017	998,33	563,99	129,85
1.01.2016	434,33	120,09	38,21
1.01.2015	314,25	-439,97	-58,33
1.01.2014	754,22	740,92	5569,07
1.01.2013	13,30	8,03	152,12
1.01.2012	5,28	4,98	1659,16
1.01.2011	0,30	0,21	249,45
1.01.2010	0,09	0,00	0

(Kaynak: www.in2013dollars.com, 2023)

Bitcoin'in merkezi olmayan doğası nedeniyle, fiyat oynaklığı sorununu daha da kötüleştiren piyasa manipülasyonlarına karşı hassas hale getirmektedir. Bu durum Bitcoin'in ana akım tarafından kabul edilmemesini kısmen haklı çıkarmıştır. Bitcoin, yaygın bir para birimi olarak kullanılmamaktadır ve çoğu düzenli tüketici ve tüccar, işlemler için Bitcoin'i kabul etmekte tereddüt etmektedir. Bu durum, talebin nispeten düşük kalarak arz-talep zincirinde bir dengesizlik yarattığı için fiyat oynaklığına katkıda bulunmaktadır.

Bununla birlikte, Bitcoin, yıllar boyunca güçlü bir büyüme ve dayanıklılık göstermiştir. Yatırımcılar arasında, özellikle yatırımlardan cazip getiri arayanlar arasında hala fazla bir ilgi görmektedir. Dahası, Bitcoin, geleneksel varlıklarla düşük korelasyon gösterdiği için benzersiz çeşitlendirme faydaları sunmaktadır.

Bitcoin'in bir para birimi ve yatırım aracı olarak daha geniş bir şekilde benimsenmesi için, fiyat oynaklığı sorununun ele alınması için acil bir ihtiyaç vardır. Bu sorunun çözülmesi, mali ve düzenleyici kurumların ortak çabalarını gerektirir ve bu sayede Bitcoin pazarına istikrar ve doğruluk getirilebilir. Bu başarıldığında, Bitcoin muhtemelen daha fazla yatırımcı çekecek ve bu, artan benimseme ve kullanım, istikrarlı fiyatlar ve daha büyük büyüme potansiyeline yol açacaktır.

1.2.Araştırmanın Faydaları

Bu tez çalışması, Bitcoin fiyat hareketliliğinin takibi ve fiyat tahmini yapmak için makine öğrenmesi kullanarak sıklıkla tercih edilen bir yöntemi Bitcoin fiyat hareketleri üzerinde uygulamaktadır. Bitcoin fiyat tahmininde kullanılan bu yöntemi hem teorik olarak hem de pratik olarak daha kapsamlı bir şekilde anlamak mümkün hale gelmektedir.

Ayrıca, bu çalışma, Bitcoin fiyat hareketleri üzerinde bir tahmin modeli oluşturmakta ve piyasa katılımcılarına doğru tahminler yapma imkânı sunmaktadır. Yatırımcıların daha bilinçli yatırım kararları alabilmeleri ve risklerini minimize edebilmeleri açısından bu tahminlerin önemi büyüktür. Bu yöntem, Bitcoin ve kripto para piyasalarındaki fiyat hareketliliğinin daha doğru ve başarılı bir şekilde takip edilmesine katkıda bulunmaktadır.

Ayrıca, bu tez çalışması finansal piyasalarda makine öğrenmesi kullanmanın Bitcoin fiyat tahmini için ne kadar etkili olduğunu göstermektedir. Makine öğrenmesi yöntemleri hakkındaki kapsamlı bir anlayış sağlanmaktadır ve bu yöntemlerin Bitcoin fiyat tahmini açısından ne kadar başarılı olduğu hakkında önemli bir bilgi paylaşılmaktadır.

Son olarak, Bitcoin ve kripto para piyasasını daha iyi anlamak için önemli bir adım olarak karşımıza çıkmaktadır. Özellikle, Bitcoin fiyat hareketlerini takip etmek ve tahmin etmek, piyasa oyuncularının daha doğru yatırım kararları alabilmeleri ve risklerini minimize edebilmeleri açısından büyük önem taşımaktadır. Bu nedenle, bu çalışmanın sonuçları, özellikle Bitcoin piyasasında bilinçli yatırımlar yapmak isteyen yatırımcılar, araştırmacılar ve akademisyenler için faydalı bir rehber niteliği taşımaktadır.

1.3.Literatür

Bitcoin'in volatilitesi ve fiyatındaki belirsizlikler, akademisyenlerin, finans profesyonellerinin ve yatırımcıların dikkatini çekmiş, bu da çeşitli araştırmaların ve çalışmaların bu alanda yoğunlaşmasına neden olmuştur. Bitcoin'in fiyatının belirlenmesi ve tahmin edilmesi, finansal piyasalardaki geleneksel varlık fiyatları analizlerinin ötesine geçen, yeni ve dinamik bir araştırma alanı sunmaktadır.

Çalışma, literatürdeki mevcut çalışmaları inceleyerek, Bitcoin fiyatının belirlenmesi ve tahmin edilmesi konusundaki akademik araştırmaların mevcut durumunu ve önemini sunmayı amaçlamaktadır.

Madan (2014) çalışmasında makine öğrenimi algoritmaları ile Bitcoin fiyatını tahmin etmeyi amaçlamıştır. Beş yıllık bir dönem boyunca Bitcoin fiyatı ve ödeme ağıyla ilgili 25'ten fazla özelliği içeren bir veri seti kullanmıştır. Bu bilgileri kullanarak, günlük fiyat değişimlerinin işaretini %98.7 doğrulukla tahmin etmiştir.

Kristoufek (2015) tarafından yapılan çalışmada, Bitcoin'in fiyat oluşumu ve gelişimi daha kapsamlı bir perspektifle ele alınmış ve fiyatları etkileyen en sık iddia edilen faktörler incelenmiştir. Araştırmada, Bitcoin'in uzun vadeli fiyat oluşumunda standart temel faktörlerin, özellikle ticaretteki kullanımı, para arzı ve fiyat seviyesinin rol oynadığı bulunmuş ve Bitcoin'in sadece spekülative bir varlık olarak değerlendirilmemesi gerektiği ortaya konmuştur. Bitcoin hem spekülative bir varlık özelliği gösterirken hem de geleneksel finansal bir varlık özelliği taşımaktadır.

Georgoula vd. (2015) Bitcoin fiyatları ile temel ekonomik değişkenler, teknolojik faktörler ve Twitter gönderilerinden türetilen kolektif ruh halleri ölçümleri arasındaki ilişkiyi zaman serisi analizi kullanarak incelemeyi amaçlamıştır. Güncel makine öğrenimi algoritmalarından biri olan Destek Vektör Makineleri (SVMs) kullanarak duygu analizini günlük bazda gerçekleştirmiştir. Bir seri kısa vadeli regresyon analizi, Twitter duygu oranının Bitcoin fiyatları ile pozitif bir ilişkiye sahip olduğunu göstermiştir. Ayrıca, kısa vadeli analizde, Bitcoin'e olan ilgiyi yansıtan Wikipedia arama sorgularının sayısı ve madencilik zorluğunu ölçen hash oranının Bitcoin fiyatları üzerinde pozitif bir etkiye sahip olduğunu bulmuştur. Uzun vadeli analiz, Bitcoin fiyatının (toplam para arzını temsil eden) dolaşımdaki Bitcoin sayısı ile pozitif bir ilişkiye, küresel ekonominin genel durumunu yansıtan SP 500 hisse senedi piyasa endeksi ile ise negatif bir ilişkiye sahip olduğunu göstermiştir.

Bouoiyour ve Selmi (2015) Günlük veriler ile optimal GARCH modelini kullanarak, Aralık 2010-Haziran 2015 ve Ocak 2015-Haziran 2015 dönemlerini karşılaştırmış Bitcoin fiyatlarındaki volatilitenin azaldığını tespit etmişlerdir. İlk dönemde, Eşik GARCH tahminleri, büyük bir süreklilik süresine işaret eder ve böylece uzun bir bellek sürecini takip etme eğilimindedir. İkinci dönem için seçilen model

(Üstel-GARCH), daha az volatilité sürekliliđi göstermektedir. Özellikle, Bitcoin, pozitif şoklar yerine negatif şoklar tarafından yönlendirilme eğilimindedir.

Greaves ve Au (2015) makalede, blokzincir ağı tabanlı özelliklerin Bitcoin'in gelecekteki fiyatını tahmin etme gücünü araştırmıştır. Blokzincir ağı tabanlı özellik mühendisliği ve makine öğrenimi optimizasyonu kullanarak, yukarı veya aşağı yönlü Bitcoin fiyat hareketini sınıflandırmada %55 civarında bir doğruluk oranı elde etmiştir.

Cheah ve Fry (2015) tarafından yapılan çalışmada, Bitcoin ve diğer kripto para piyasalarının artan ilgi ve yaygınlaşma durumuna rağmen akademik olarak yeterince keşfedilmediđi vurgulanmaktadır. Diğer varlık sınıflarıyla benzer şekilde, Bitcoin fiyatları spekülâtif balonlara eğilim göstermektedir. İkinci olarak, Bitcoin fiyatlarında balon bileşeninin önemi vurgulanmaktadır. Üçüncü olarak, Bitcoin'in temel değerinin sıfır olduđu belirtilmektedir. Bu nedenle, bu bulgular Bitcoin'in uzun vadeli sürdürülebilirliği ile ilgili geniş çaplı akademik ve genel endişeleri yansıtmaktadır. Bu çalışmadan elde edilen sonuçlar, kripto para piyasalarının diğer piyasalarla benzer şekilde stilize edilmiş gerçeklere sahip olduğunu, özellikle spekülâtif balonlara karşı hassas olduğunu göstermektedir.

Vockathaler (2015) tarafından yürütölen çalışma iki temel amaç taşımaktadır. İlk olarak, bu makale, önceki araştırmacıların çalışmalarını gözden geçirerek ve bulgularının geçerliliđini yeniden değerlendirerek yapılmıştır. İkinci olarak, Bitcoin fiyatını etkileyen uzun vadeli faktörleri araştırmak amaçlanmaktadır. Elde edilen bulgular, daha önce yayınlanan bazı sonuçların tekrar test edildiğinde önemli ölçüde farklı olduğunu göstermektedir.

Easwaran vd. (2015) tarafından yapılan çalışmada, yüksek frekanslı Bitcoin ticaret verileri (tek bir işlem etkinliğiyle ölçölen tick çözünürlüğü) analiz edilmiştir. Logaritmik getiriler açısından ölçölen fiyat dalgalanmalarının ağır kuyruđa sahip olduđu bulunmuştur. Bu, Bitcoin dalgalanmalarının çoğunun finansal ve emtia piyasalarında gözlenen ters kare yasasının aksine ters kübik yasayı takip ettiđini göstermektedir. Ayrıca, işlem boyutları ve ticaret hacmi dağılımlarının Levy kararlılığına sahip olduđu gözlemlenmiştir. Çok ölçekli analiz, piyasa davranışında uzun süreli bellek etkilerinin varlığını göstermektedir.

Ciaian vd. (2016) tarafından yapılan çalışma geleneksel para fiyatını belirleyen faktörlerin yanı sıra dijital para birimi özellikleri ve Bitcoin fiyatını etkileyen faktörler

arasındaki etkileşimleri de göz önünde bulundurarak Bitcoin fiyat oluşumunu analiz etmektedir. Makale, 2009-2015 dönemine ait günlük veriler üzerinde zaman serisi analiz mekanizmalarını kullanarak Bitcoin fiyat oluşum hipotezlerini test etmektedir. Araştırmanın sonuçları, Bitcoin arz-talep piyasası etkilerinin Bitcoin fiyatı üzerinde önemli bir etkiye sahip olduğunu doğrulamakta ve ayrıca online bilgi sorgularının da Bitcoin fiyatı üzerinde etkili olduğu sonucuna varmaktadır.

Bouoiyour vd. (2016) tarafından kaleme alınan makale, Bitcoin'in karmaşık doğasını dikkate alarak Bitcoin fiyat analizine yeni bir perspektif sunmayı hedeflemektedir. Makale, Bitcoin'in spekülasyon bir balon olduğu genel kanısına karşın, uzun vadeli temellerin (düşük frekans bileşeni) Bitcoin fiyat değişiminde önemli bir rol oynadığını iddia etmektedir. Kısa vadeli dalgalanmaların ise, Bitcoin'in yaratılışından bu yana büyük bir medya ilgisi ve spekülasyonlara konu olmasından kaynaklandığı belirtilmektedir. Bununla birlikte, makalede vurgulanan nokta, Bitcoin'in uzun vadede belirleyicilerinin arz-talep temelleri, para birimi döviz oranları, borsa endeksleri, döviz kurları, petrol fiyatları ve çıktı hacmi gibi diğer faktörlerin yanı sıra olduğudur.

Wang vd. (2016) Makale, öncelikle Bitcoin fiyat dalgalanmalarını incelemekte ve Bitcoin ile temsil edilen dijital para birimlerinin yatırım potansiyeline sahip olup olmadığını tartışmaktadır. Cointegration analizi ve VEC (Vector Error Correction) Model yöntemleri kullanılarak, hisse senedi fiyat endeksi, petrol fiyatı ve Bitcoin'in günlük işlem hacmi gibi değişkenler arasındaki ilişkiyi göstermek için analizler yapılmıştır. Ampirik araştırma, bu dört faktör arasında uzun vadeli denge ve kısa vadeli dinamik bir ilişkinin olduğunu göstermektedir. Kısa vadeli analiz, petrol fiyatı ve Bitcoin işlem hacminin Bitcoin fiyatı üzerinde sınırlı bir etkiye sahip olduğunu, hisse senedi fiyat endeksinin ise daha güçlü bir etkiye sahip olduğunu ortaya koymaktadır. Uzun vadede, hisse senedi fiyat endeksi ve petrol fiyatının Bitcoin fiyatına olumsuz bir etkisi olduğu belirtilmektedir. Bununla birlikte, Bitcoin değeri günlük işlem hacmi tarafından olumlu yönde etkilenmektedir.

Pryzmont (2016) tarafından yapılan çalışmanın bulgularına göre, olumsuz bir olayın gerçekleşmeden önce ve sonra ölçülen fiyat dalgalanması arasında istatistiksel olarak anlamlı bir yön ilişkisi olduğu gözlemlenmiştir. Bitcoin'e yönelik kamu dikkatinin artması, bu bağlamda olumsuz olayların etkilerini artırarak fiyat artışı veya

düşüşüne neden olabilmektedir. Ancak, Bitcoin fiyat verilerinin analiz sonuçları, olayların meydana gelmeden önce ve sonra ölçülen fiyat dalgalanması arasında gözlemlenebilir bir fark olmadığını göstermektedir.

Estrada (2017) tarafından yapılan çalışmada, Bitcoin'in fiyatı ve volatilitésinin analizi yapılmıştır. Özellikle, Bitcoin fiyatı ile SveP 500, Bitcoin fiyatı ile VIX (Volatility Index), Bitcoin gerçekleşen volatilitési ile SveP 500, ve Bitcoin gerçekleşen volatilitési ile VIX arasındaki Granger nedensellik ilişkileri incelenmiştir. Ayrıca, Bitcoin'in temel teknolojisi olan Blokzincir'e yönelik halkın ilgisinin Google Trends verileri kullanılarak ölçüldüğü, haftalık Bitcoin fiyatı ile Blokzincir Google Trend zaman serileri arasındaki Granger nedensellik ilişkileri de incelenmiştir. Sonuç olarak, VIX ve Bitcoin gerçekleşen volatilitési arasında %5 anlamlılık düzeyinde çift yönlü bir Granger nedensellik ilişkisi olduğu bulunmuştur.

Sin ve Wang (2017) tarafından ele alınan makale, Bitcoin'in özellikleri ile Bitcoin fiyatının bir sonraki gün değişimi arasındaki ilişkiyi araştırmak için Multi-Katmanlı Algılayıcı tabanlı sinir ağı topluluk yaklaşımını kullanmaktadır. Bu yaklaşım, Genetik Algoritma temelli Seçici Sinir Ağı Topluluğu adlı bir yapay sinir ağı modelini temel almaktadır. Gerçek dünya uygulamasının etkililiğini ve uygulanabilirliğini değerlendirmek amacıyla, yaklaşık 200 kripto para birimi özelliği kullanılarak Bitcoin fiyatının bir sonraki gün yönünü tahmin etmek için 2 yıllık bir veri kullanılmıştır. Geriye dönük testlerle 50 günlük bir süre boyunca, topluluğa dayalı bir ticaret stratejisi "önceki gün trendi takip" ticaret stratejisiyle karşılaştırılmıştır. İlk adımdaki ticaret stratejisi yaklaşık %85 getiri sağlarken, "önceki gün trendi takip" ticaret stratejisi yaklaşık %38 getiri sağlamış ve topluluktaki en iyi MLP modelini izleyen bir ticaret stratejisi ise yaklaşık %53 getiri sağlamıştır.

Bouoiyour ve Selmi (2017) tarafından yapılan çalışma, ekonomik ve jeopolitik kaos dönemlerinde Bitcoin fiyatını etkileyen faktörlere odaklanmaktadır. Araştırma, Bitcoin fiyatının belirleyicilerini en az etkili faktörlerden en etkili faktörlere kadar incelemeyi amaçlamaktadır. Makroekonomik, finansal, spekülative ve teknik belirleyicilere ek olarak, 2016 olaylarına da bakılarak Bitcoin fiyatının farklılık gösterdiği belirleyiciler incelenmiştir. Bayesian quantile regresyonu kullanılarak Bitcoin fiyatı ve belirleyicileri arasındaki bağımlılık yapısı, Bitcoin fiyat hareketlerinin tüm koşullu dağılımı boyunca nasıl değiştiği analiz edilmiştir. Bu

şekilde, üç grup belirleyici ortaya çıkarılmıştır. Bitcoin'in ticarete kullanımı ve Çin'in derinleşen yavaşlaması, Brexit ve Hindistan'daki para reformu gibi belirsizliklerin, piyasa iyileştiğinde Bitcoin fiyatına en potansiyel katkı sağlayan faktörler olduğu bulunmuştur. Dolaşımdaki Bitcoin hızı, altın fiyatı, Venezuela para reformu ve hash oranı ise piyasanın gerilemeye doğru ilerlediği durumlarda Bitcoin fiyatını etkileyen temel faktörler olarak belirlenmiştir.

Stenqvist ve Lönnö (2017) tarafından yapılan çalışma Bitcoin'in halk algısını analiz ederek, duygusal dalgalanmaların yakın gelecekte fiyat değişikliği sinyalleri verebileceği konusunu araştırmaktadır. Bu amaçla, Twitter üzerinde 2.27 milyon Bitcoin ile ilgili tweet analiz edilmektedir. Tahmin işlemi, tweet'lerin duygusallık seviyesine dayanarak, 5 dakika ile 4 saat arasında değişen zaman aralıkları için toplam duygusal değişim şiddeti üzerinden gerçekleştirilmektedir. Elde edilen tahminler daha sonra, BTC aralık zamanına karşılık gelen 1, 2, 3 veya 4 zaman aralığı için ileriye doğru kaydırılmaktadır. Tahmin modelinin değerlendirmesi, 30 dakikalık tweet duygusallıklarını toplama, 4 kaydırma ile öne doğru ve %2.2 duygu değişim eşiği kullanarak %79 doğruluk elde edildiğini göstermiştir.

Virk (2017) tarafından yapılan çalışma, on farklı kripto para biriminin verileri kullanılarak Bitcoin fiyatının yönünün ve doğruluğunun öngörülmesi amaçlanmaktadır. Bu amaçla, her bir kripto paranın kapanış fiyatlarından oluşturulan yeni bir veri seti kullanılmıştır. Öznitelik mühendisliği analizi sonucunda, tüm on kripto para birimi arasında güçlü bir ilişki olduğu belirlenmiştir. Veri madenciliği yöntemleri kullanılarak, sınıflandırma ve regresyon olmak üzere iki kategori altında çeşitli algoritmalar değerlendirilmiştir. Sınıflandırma kategorisinde, rastgele orman, destek vektör sınıflandırıcısı, gradyan arttırma sınıflandırıcısı ve sinir ağı sınıflandırıcısı gibi algoritmalar incelenmiştir. Destek vektör sınıflandırıcısı en yüksek başarıyı elde etmiş, %62.31 doğruluk oranı ve 0.77 hassasiyet değeriyle öne çıkmıştır. Regresyon kategorisinde ise doğrusal regresyon, tekrarlayan sinir ağı ve gradyan arttırma regresyonu gibi algoritmalar kullanılmıştır. Gradyan arttırma regresyonu, 0.99 R-kare değeriyle en yüksek performansı sergilemiştir.

Blau (2017) tarafından yapılan çalışma Bitcoin'in fiyat dinamikleriyle ilgili bazı önemli gerçekleri sunmayı ve spekülasyon işlemlerin Bitcoin'deki yüksek volatilité seviyesine katkıda bulunup bulunmadığını test etmeyi amaçlamaktadır. Bitcoin'in

değerinin birkaç kuruşla başlayıp 2013 sonunda 1.132,26 dolara yükseldiğini ve sonraki aylarda yaklaşık %60 oranında düştüğünü gösterilmektedir. Değerlenme ve düşüş, bir varlık balonunun varlığına işaret etse de yapılan testler, bu dönemde spekülasyon işlem yapmanın önemli ölçüde yüksek olmadığını ortaya koymuştur. Bitcoin'in volatilitesine spekülasyon işlem yapmanın katkıda bulunduğu fikrine karşın, tek veya çoklu değişkenli testlerimizde pozitif bir ilişki gözlenmemiştir.

Urquhart (2017) Bitcoin fiyat kümelemesini inceleyerek literatüre katkıda bulunmayı amaçlamıştır. Çalışmanın bulgularına göre, önemli ölçüde fiyat kümelemesinin belirgin kanıtları bulunmuştur, özellikle fiyatların %10'unun ondalık basamağı 00 ile sonlandığı tam sayılarda kümeleşmenin gözlemlendiği tespit edilmiştir. Bununla birlikte, ardışık getirilerde yuvarlak sayılardan sonra belirgin bir desen bulunmamaktadır. Ayrıca, fiyat ve hacim arasında tam sayı kümelemesiyle önemli bir pozitif ilişki tespit edilmiştir. Bu sonuçlar, finansal piyasalarda fiyat kümelemesinin var olduğunu ve çalışmanın bu konuya odaklanan ilk çalışma olduğunu göstermektedir. Özellikle %10'dan fazlası ondalık basamağı 00 olan tam sayılar etrafında önemli bir fiyat kümelemesi olduğu bulunmuştur.

Karalevicius (2018) tarafından kaleme alınan çalışmada, ilgili haber ve blog yayınlarından oluşan bir veri tabanı toplanmıştır. Her makale, içerdiği olumlu ve olumsuz kelimelere dayalı olarak bir duygu skoru almıştır. Bu çalışma, medya duyarlılığı ile Bitcoin fiyatı arasında bir etkileşim olduğunu ve yatırımcıların haberlere hızlı tepki gösterme eğiliminde olduklarını belirlemiştir. Araştırmada, Twitter gönderilerinin duygu analiziyle Bitcoin fiyatının tahmin edilmesine yönelik bir çalışma yapılmıştır. Bu çalışma, psiko-semantic sözlüklerin kullanılmadığı önceki çalışmalardan farklı olarak benzersiz bir yaklaşım sunmaktadır ve Bitcoin araştırmalarında yeni bir katkı sağlamaktadır.

Wu vd. (2019) tarafından yapılan çalışmada, uzun kısa vadeli bellek (LSTM) ağları, derin öğrenme alanında zaman serisi tahmini için kullanılan son teknolojidir. Ancak, özellikle kripto para tahmini alanında finansal zaman serilerine yönelik sınırlı çalışma bulunmaktadır. Bu nedenle, Bitcoin günlük fiyat tahmini için iki farklı LSTM modeliyle (geleneksel LSTM modeli ve LSTM AR(2) modeli) yeni bir tahmin çerçevesi önerilmektedir. Önerilen modellerin performansı, 2018/1/1 ile 2018/7/28 tarihleri arasında toplam 208 kayıt içeren Bitcoin günlük fiyat verileri kullanılarak

değerlendirilmiştir. Sonuçlar, önerilen modelin AR(2) ile mükemmel tahmin doğruluğunu doğrulamaktadır. Önerilen LSTM modeli, geleneksel LSTM modeline kıyasla daha başarılı sonuçlar elde etmiştir.

Roy vd. (2019) tarafından yapılan çalışma, istatistiksel analizleri kullanarak en iyi Bitcoin piyasa fiyatının tahmin edilmesi için uygun bir model önermektedir. Çalışma, 2013 ile 2017 yılları arasındaki dört yıllık Bitcoin verisine dayanmaktadır ve özellikle otoregresif entegre hareketli ortalama (ARIMA) modeline dayanan zaman serileri yaklaşımlarını kullanmaktadır. Elde edilen sonuçlar, Bitcoin'in ağırlıklı maliyetlerindeki kısa vadeli volatilitiyi belirlemede %90'lık bir doğruluk sağlandığını göstermektedir.

Kjaerland vd. (2018) tarafından yapılan çalışmanın amacı, Bitcoin'in fiyat dalgalanmalarını açıklayan faktörleri ortaya çıkarmaktır. Fiyat hareketlerini açıklamak için, Ordinary Least Squares regresyon yöntemi kullanılarak iki Otoregresif Dağıtılmış Gecikme modeli tahmin edilmiştir. Veri seti, 18.09.2011 ile 05.02.2017 tarihleri arasında 279 haftalık gözlemi içermektedir. Bağımlı değişken Bitcoin fiyatıdır ve analiz dokuz bağımsız değişkeni incelemektedir. Çalışma sonucundaki bulgular, politik olayların ve açıklamaların ("şokların") Bitcoin fiyatını önemli ölçüde etkilediğini göstermektedir. Ayrıca, Bitcoin hacmi ile Bitcoin fiyatı arasında anlamlı negatif bir ilişki tespit edilmiştir. Bitcoin'in Google aramaları ile ölçülen ilgisi, Bitcoin fiyatı ile pozitif ve anlamlı bir ilişkiye sahiptir. Bu çalışma, Bitcoin'in bir güvenli liman yatırımı olmadığına dair kanıt bulamamaktadır.

Ji vd. (2019) yaptıkları çalışmada, Bitcoin blokzincir verilerini kullanarak çeşitli derin öğrenme tabanlı Bitcoin fiyat tahmin modelleri geliştirilmiş ve karşılaştırılmıştır. LSTM, DNN, CNN ve ResNet modelleri test edilmiş ve regresyon ve sınıflandırma problemleri ele alınmıştır. Regresyon problemlerinde LSTM modelleri diğer modellere göre daha başarılı olurken, sınıflandırma problemlerinde DNN diğer modellere göre daha başarılı bulunmuştur. CNN ve ResNet modelleri ise Bitcoin fiyat tahmini için özellikle etkili olmamıştır. Ancak, derin öğrenme modelleri arasında net bir kazanan belirlenememiş ve tüm modellerin performansı birbirine yakın çıkmıştır. Ayrıca, bu modellerin sadece Bitcoin ticareti için yeterli olmadığı da belirtilmiştir.

Munim vd. (2019) tarafından yapılan çalışmada, ARIMA ve NNAR modelleri kullanılarak bir sonraki günün Bitcoin fiyatı tahmini yapılmıştır. Tahmin doğruluğunu değerlendirmek için RMSE, MAPE ve MASE gibi ölçütler kullanılmıştır. Sonuçlara göre, NNAR modelleri ilk eğitim örneğinde (500 gün) ARIMA modellerine göre daha iyi performans göstermişken, test örneğinde ARIMA modelleri daha başarılı olmuştur. Ayrıca, bu sonuçlarla uyumlu olarak, NNAR modellerinin düşük volatilité dönemlerinde daha iyi performans gösterdiği, ancak özellikle 2018 yılında Bitcoin fiyatındaki aşırı volatilité dönemlerinde ARIMA modellerinin daha başarılı olduğu söylenebilir. Daha fazla araştırma, kripto para birimlerinin getirilerinin modellenmesine odaklanması gerektiğini göstermektedir.

Azari (2019) tarafından yapılan çalışma, geleneksel otoregressif entegre hareketli ortalama (ARIMA) modelinin Bitcoin'in gelecekteki değerini tahmin etmedeki etkinliğini, 3 yıllık bir zaman diliminde fiyat zaman serilerini analiz ederek ortaya koymayı amaçlamaktadır. Empirik çalışmalar, bu basit modelin zaman serisinin davranışını neredeyse değiştirmeden kısa vadeli tahminler için özellikle etkili olduğunu göstermektedir. Ancak, farklı davranışlar sergileyen Bitcoin fiyatı için veya uzun vadeli tahminlerde büyük tahmin hataları olduğunu gözlemlenmiştir. Bu nedenle, daha doğru tahminler elde etmek için fiyatın yanı sıra daha fazla özellik çıkarılması ve kullanılması gerekmektedir. Bu çalışma, geniş bir veri kümesi üzerinde eğitilen ARIMA modelinin ve sınırlı bir test penceresinin (w) Bitcoin fiyat tahminine etkisini araştırmıştır. Araştırma, tahmin doğruluğunu, (p , q , d) seçimi ve pencere boyutu w arasındaki etkileşimi açıklayarak konuya ışık tutmaktadır.

Atsalakis vd. (2019) tarafından yapılan çalışma, Bitcoin'in günlük fiyat değişim yönünü öngörmek için bir hibrit Neuro-Fuzzy denetleyicisi olan PATSOS'u kullanarak bir bilgi işlem zekâsı tekniği önermektedir. Önerilen yöntem, daha basit bir nöro-fuzzy yaklaşımla geliştirilmiş birinci ve yapay sinir ağlarıyla geliştirilmiş ikinci bilgi işlem zekâsı modeline göre daha iyi performans göstermektedir. Ayrıca, önerilen modelin sinyallerine dayalı bir ticaret simülasyonu ile elde edilen yatırım getirileri, basit bir buy-and-hold stratejisiyle elde edilen getirilerin %71.21 daha yüksek olduğunu göstermektedir. PATSOS sistemi, diğer kripto para birimlerinin kullanımında da sağlam bir performans sergilemektedir.

Aggarwal vd. (2019) tarafından kaleme alınan makalede, Bitcoin fiyat tahminini etkileyen çeşitli parametreler üzerinde farklı derin öğrenme modellerinin karşılaştırmalı analizi RMSE değerlerine göre yapılmıştır. Elde edilen sonuçlar, çeşitli derin öğrenme modellerinin Bitcoin fiyat tahmininde etkili olduğunu göstermektedir. Bitcoin parametreleri fiyat tahmini için kullanıldığında, LSTM modelinin en düşük RMSE değerlerine sahip olduğu görülmüştür. Ancak, Bitcoin fiyat tahmini için altın fiyatının parametre olarak kullanıldığı durumda, LSTM modelinin altın fiyatı ile Bitcoin fiyatı arasında olumlu bir korelasyon göstermediği tespit edilmiştir. Bu durumda, gerçek ve tahmin edilen değerler arasında büyük bir sapma olduğu gözlemlenmiştir. Ayrıca, Twitter duyarlılık analizi kullanılarak yapılan Bitcoin fiyat tahminleri sonuçları, pozitif bir tweet yayınlandığında Bitcoin fiyatlarının artış gösterdiğini, Bitcoin ile ilgili negatif bir tweet atıldığında ise fiyatların etkilendiğini ve tweet atan kullanıcının popülaritesine bağlı olarak düştüğünü göstermiştir. Bu etkinin ölçülmesi için Twitter'da takipçi sayısı gibi ölçütler kullanılabilir.

Rizwan vd. (2019) tarafından yapılan çalışmanın temel amacı, Bitcoin'in dolar cinsinden fiyatının yakın zamandaki tahminini gerçekleştirmektir. Bitcoin fiyat endeksi verilerinden elde edilen değerli bilgiler kullanılarak, Bayes rekürrent hiyerarşik sinir ağı (RNN) ve uzun kısa vadeli bellek ağı (LSTM) kullanılmıştır. LSTM modeli, toplam doğruluk oranı olarak %52 ve RMSE (%8) değerleri elde etmiştir. Zaman serisi tahminleri için yaygın olarak kullanılan ARIMA yönteminin derin öğrenme modellerinin performansının gerisinde kaldığı gözlenmiştir. Bu nedenle, Bitcoin fiyat tahminlerini gerçekleştirmek için kilitli tekrarlayan ağ modeli (GRU) kullanılmıştır. Elde edilen sonuçlara göre, tüm derin öğrenme modelleri GPU eğitim sürelerine göre %94.70 gibi yüksek bir başarı oranına sahip olmuştur.

Dutta vd. (2020) tarafından yapılan çalışmada Bitcoin fiyat tahmini, finansal bağlantıları olan geniş bir özellik listesi temel alınarak incelenmektedir. Ayrıca, Bitcoin'in alternatif bir yatırım aracı olarak kullanılabilirliği de analiz edilmekte ve gelecekteki fiyat trendlerini öğrenmekte yardımcı olabilecek öncü değişkenler seçilmektedir. LSTM ve GRU gibi tekrarlayan sinir ağı modellerinin geleneksel makine öğrenmesi modellerine göre daha iyi performans sergilediği bulunmuştur. GRU modelinin, anında unutma ve güncelleme yeteneği sayesinde Bitcoin fiyat tahmininde başarılı olduğu gözlemlenmiştir. Yüksek boyutlu verilerde hesaplama

yükünü artırabilen derin modellerden ziyade, daha sığ öğrenme modellerinin daha etkili olabileceği belirtilmektedir. Bu çalışmanın bulgularına göre, özellikle nicel finans alanında önemli katkılar sağlayabileceği düşünülmektedir.

Chen vd. (2020) yaptıkları çalışmada Makine öğrenmesi tekniklerini kullanarak farklı frekanslarda Bitcoin fiyat tahmini yapabilmek için, öncelikle Bitcoin fiyatını günlük fiyat ve yüksek frekanslı fiyat olarak sınıflandırmışlardır. Bitcoin günlük fiyat tahmini için, işlem ve piyasa verileri, dikkat ve altın spot fiyatı gibi yüksek boyutlu özelliklerle birlikte temel işlem özelliklerini kullanmışlardır. Bitcoin fiyat tahmininde 5 dakikalık aralıklarla elde edilen kripto para borsası verileri ise kullanılmaktadır. Bitcoin günlük fiyat tahmini için, Yüksek Boyutlu Özelliklerle Lojistik Regresyon ve Lineer Diskriminant Analizi gibi istatistiksel yöntemler, daha karmaşık makine öğrenmesi algoritmalarını geride bırakarak %66 doğruluk oranı elde edilmiştir. 5 dakikalık aralık fiyat tahmini için ise Rastgele Orman, XGBoost, Kuadratik Diskriminant Analizi, Destek Vektör Makinesi ve Uzun Kısa Dönemli Hafıza gibi makine öğrenmesi modelleri, istatistiksel yöntemlere göre daha üstündür ve %67.2 doğruluk oranına ulaşır. Bitcoin fiyat tahmini çalışmamız, makine öğrenmesi tekniklerinde örnek boyutunun önemine dair bir pilot çalışma niteliği taşımaktadır.

Fantazzini ve Kolodin (2020) tarafından yapılan çalışmada sunulan kanıtlar, Aralık 2017'de düzenlenmiş vadeli piyasaların tanıtılmasının ardından Bitcoin piyasasının daha olgun ve verimli bir hale geldiğini göstermektedir. Önceden belirlenmiş teknik sürücüler (Bitcoin arzı ve talebi), çekicilik göstergeleri ve makroekonomik değişkenler artık Bitcoin fiyatının dinamiklerini açıklamak için gecikmeli göstergeler veya daha az önemli hale gelmiştir. Bu nedenle, kripto para birimleri için modern ampirik finans varlık fiyatlandırma modelleri ve teori temelli değerlendirme modellerini birleştirebilen "ikinci nesil değerlendirme ölçütleri"nin geliştirilmesi, daha fazla araştırma için çekici bir yöntem olarak kabul edilebilir.

Lamothe-Fernández vd. (2020) tarafında yapılan çalışma, Bitcoin fiyatını tahmin etmek için farklı metodolojilerin karşılaştırılmasını ve yeni bir modelin oluşturulmasını içermektedir. Çalışma, 2011 ile 2019 yılları arasındaki bir dönemi kapsamaktadır. Robust bir model elde etmek amacıyla derin tekrarlı evrişimli sinir ağı, derin sinir ağaçları ve derin destek vektör makineleri gibi derin öğrenme yöntemleri kullanılmıştır. DRCNN modeli en yüksek doğruluk seviyelerini elde etmiştir. Bu

araştırma, önceki çalışmalara kıyasla Bitcoin fiyatını tahmin etmek için modellerin performansını artırmayı önermektedir. Ayrıca, gelecekte bir ve iki yıllık dönemlerde tahmin yapmak için geliştirilen modellerde kararlılık sağlayan önemli değişkenlerin yeni bir setini tanımlamayı mümkün kılmıştır.

C. Chen vd. (2020) tarafından ele alınan makalede, koronavirüs pandemisi sırasında yatırımcıların korku duygusunun Bitcoin fiyat dinamiklerini nasıl etkilediği araştırılmaktadır. Yüksek frekanslı verileri kullanarak yatırımcıların koronavirüsle ilgili korkularını ölçmek için bir Google arama tabanlı korku duygu ölçüsü oluşturulmaktadır. Sonuçlar, pandemiye ilişkin arama ilgisindeki artışın finansal piyasalardaki belirsizlik artışıyla ilişkili olduğunu göstermektedir. Koronavirüs korkusunun artması, negatif Bitcoin getirilerine ve yüksek işlem hacmine neden olur ve bu da Bitcoin'in, geleneksel güvenli liman varlıklar olan altın gibi davranmak yerine diğer finansal varlıklara daha çok benzeyebileceğini göstermektedir. Araştırma, koronavirüs pandemisi sırasında riski azaltmak için yatırımcıların kaynaklarını Bitcoin'e yönlendirmenin istenmeyebileceğini düşündürmektedir, çünkü Bitcoin'in bir güvenli liman olarak hizmet etmeyebileceğini göstermektedir.

Kervanci ve Akay (2020) yaptığı çalışmaya göre merkezi olmayan ve dünyada en yaygın kabul gören kripto para birimidir olan Bitcoin yüksek oynaklığı, döviz kurunu tahminleme konusunda zorluk oluşturabilmektedir. Bu nedenle son yıllarda Bitcoin fiyat tahmini konusunda Makine Öğrenimi ve İstatistiksel Yöntemlerle birçok çalışma yapılmıştır. Bu çalışma, önceki çalışmaları gruplandırarak Bitcoin fiyatının daha iyi tahmin edilmesini amaçlamaktadır. Bu gruplar, istatistiksel ve makine öğrenimi yöntemleri, sosyal medya ve web arama motoru etkisi, zaman frekansı etkisi, nedensellik ve hiper parametre optimizasyonu yöntemleri olarak incelenmiştir. Genel olarak, makine öğrenimi yöntemleri daha iyi performans göstermektedir.

Albariqi ve Winarko (2020) tarafından kaleme alınan makale, Multilayer Perceptron (MLP) ve Recurrent Neural Networks (RNN) modelleri kullanarak kısa ve uzun vadeli Bitcoin fiyat değişimini belirlemek için temel sinir ağı modellerini kullanılmaktadır. Veriler, Ağustos 2010'dan Ekim 2017'ye kadar olan Bitcoin blok zincirlerinden elde edilen 1300 veri üzerinde 2 günlük dönemlerle oluşturulmuştur. Modeller, hem kısa vadeli hem de uzun vadeli fiyat değişim tahminleri yapmak için 2 ila 60 gün aralığında çalışmaktadır. Sonuçlar, uzun vadeli tahminin kısa vadeli

tahminden daha başarılı olduğunu göstermektedir. En yüksek doğruluk oranı, MLP modelinde 60 gün sonrası fiyat değişimini tahmin ederken elde edilirken, RNN modelinde ise 56 gün sonrası fiyat değişimini tahmin ederken elde edilmiştir. MLP, %81.3 doğruluk, %81 hassasiyet ve %94.7 hatırlama oranıyla RNN'i geride bırakmaktadır.

Cretarola ve Figà-Talamanca (2021) tarafından yapılan çalışmaya göre Empirik kanıtlar, 2009 yılında başlayan süreç boyunca Bitcoin fiyat dinamiklerinde balon etkilerinin varlığını göstermektedir. Önceki araştırmalar genellikle zaman içindeki balon davranışını tespit etmek için istatistiksel testlere odaklanmış ve bazı istisnalar, bu fenomeni tanımlayabilen belirli zaman serisi modelleri önermiştir. Bu çalışma, Bitcoin dinamikleri için sürekli bir zaman stokastik modelini dikkate alarak, literatüre katkıda bulunmaktadır ve balon altında artan bir piyasa dikkati faktörüne bağlı olan Bitcoin'e özgü dinamikleri ele almaktadır. Burada, özellikle, Bitcoin üzerindeki piyasa dikkati faktörü ile Bitcoin getirileri arasındaki korelasyonun, işaretlenmiş dikkatin Bitcoin fiyatları üzerinde etkisi olduğunda ve tersi durumunda bir kötü döngü yaratıldığında bir balonun varlığı ile ilişkisi kanıtlanmıştır.

Jana vd. (2021) tarafından yapılan çalışmada, altı farklı ileri tahmin model algoritması olan çok katmanlı algılayıcı sinir ağı, rastgele orman, uyarlanabilir sinir bulanık çıkarsama sistemi, tek başına SVR, çoklu uyarlanabilir regresyon spline ve en az mutlak büzülme ve seçim operatörü kullanılarak karşılaştırma yapılmaktadır. Son olarak, sayısal deneyler gerçekleştirilmiş ve bu deneylerde Monte Carlo analiziyle oluşturulan rastgele surrogat zaman serileri ve 10 Ocak 2013'ten 23 Şubat 2019'a kadar Bitcoin'in günlük kapanış fiyatları kullanılmıştır. Sonuçlar, önerilen regresyon çerçevesinin diğer tahmin modellerinden daha yüksek bir tahmin doğruluğuna sahip olduğunu göstermektedir.

Haffar ve Le Fur (2021) tarafından yapılan çalışmada, Ocak 2011'den Aralık 2019'a kadar gelişmekte olan ve gelişmiş ülkelerin finansal piyasalarının Bitcoin fiyatı üzerindeki etkisi yapısal vektör hata düzeltme modeli kullanılarak analiz edilmiştir. Elde edilen sonuçlar, seçilen süre ve bölgeye göre değişiklik göstermektedir. Kısa vadede, Bitcoin fiyatları Asya'daki gelişmekte olan ülkeler ve tüm ülke bölgeleri tarafından pozitif etkilenirken Kuzey Amerika tarafından negatif etkilenmektedir. Uzun vadede ise sadece Asya'da bulunan tüm ülkelerin Bitcoin fiyatına etki ettiği

görülmüştür, Pasifik bölgesi ise negatif etki yaparken Avrupa bölgesi pozitif etki yapmaktadır. Diğer bölgelerde ise süreye bağlı olarak Bitcoin fiyatına etki eden şoklar gözlenmemiştir. COVID-19'un sağlık şokunun analizi ve finansal piyasalardaki etkisi, elde edilen bulguları desteklemektedir.

Chkili (2021) tarafından kaleme alınan makalenin amacı, 2013-2020 dönemi için Bitcoin fiyatlarının volatilité dinamiklerini belirlemek için en iyi modeli tanımlamaktır. Bu amaçla, iki farklı model olan uzun hafıza modeli ve Markov geçiş modeli kullanılmıştır. Elde edilen sonuçlar, Bitcoin piyasasının volatilité dinamiklerinde uzun hafızanın varlığına işaret etmektedir. Ayrıca, özellikle uzun hafızayı hesaba katan FIGARCH modeli, diğer tüm modellere göre Bitcoin fiyatlarının volatilitésini daha başarılı bir şekilde modellemektedir. Bu bulgu, portföy çeşitlendirmesi, riskten korunma stratejileri ve Risk Değerini Atama (Value at Risk) değerlendirmesi için önemli sonuçlar ortaya koymaktadır.

Rathore vd. (2022) tarafından yapılan çalışmanın amacı, mevsimsellik nedeniyle tamamen geçmiş verilere dayanmayan bitcoin'in gelecekteki fiyatını tahmin etmek için Fbprophet modelini kullanmaktır. Bu model, LSTM ve ARIMA'nın karşılaştığı sorunları ortadan kaldırır. Çalışma, mevsimsellik sorununu çözen ve gerçek dünya kullanımları için faydalı olabilecek bir model geliştirmiştir. Daha az geçmiş veriye sahip olan ve desenlerin bulunmasının zor olduğu kripto para birimi durumlarında bu yöntem kolayca uygulanabilir. Tahmin edilen değerler ile gerçek değerler arasındaki fark, diğer tüm modellere kıyasla düşüktür.

Rajabi vd. (2022) tarafından kaleme alınan makale, birincil derin sinir ağını kullanarak önceki günlerde gözlemlenen Bitcoin fiyat trendlerine ve dalgalanmalara dayanan en iyi pencere boyutunu tahmin etmekte ve ardından tahmin edilen pencere boyutuna dayalı olarak Bitcoin fiyatını tahmin etmek için ikincil bir derin sinir ağı kullanmaktadır. Makalenin veri seti, Google, Blokzincir ve Bitcoin piyasası bilgilerini içermektedir. Yapılan değerlendirmeler, bu yöntemin, Tahmin Güçlük Faktörü (TGF) adı verilen ve tahmin zorluğunun derecesini tanımlamak için önerilen yeni bir kriter ile birlikte, İşlem Destek Vektörü Regresyonu ve ARIMA gibi iyi bilinen yöntemlere kıyasla normal bir durum altında minimum hata elde etme yeteneğine sahip olduğunu göstermektedir.

Ye vd. (2022) tarafından yapılan çalışma, Bitcoin'in bir sonraki 30 dakikalık fiyatlarını tahmin etmek için yeni bir birleşik derin öğrenme modeli önermektedir. Modelde, fiyat verileri, teknik göstergeler ve duygu endeksleri kullanılmaktadır. Önerilen modelde, uzun kısa süreli bellek (LSTM) ve kapı tekrarlayan birimi (GRU) gibi iki sinir ağı türü, yığın birleştirme tekniğiyle entegre edilmektedir. Sosyal medyada yapılan yorumların gerçek zamanlı güncellemeleri dikkate alınarak, haber siteleri yerine sosyal medya metinleri, kamuoyu görüşlerinin kaynak verisi olarak kullanılmaktadır. Modelin eğitimi ve değerlendirmesi için Eylül 2017 ile Ocak 2021 arasındaki gerçek veriler kullanılmaktadır. Deneysel sonuçlar, yakın gerçek zamanlı tahminin, günlük tahmine kıyasla ortalama mutlak hata (MAE) bakımından %88.74 daha iyi bir performans sergilediğini göstermektedir. Bu çalışmanın amacı, önerilen çözümü açıklamak ve ensemble yönteminin daha iyi performans sergilediğini ve diğer geleneksel modellere kıyasla yatırımcılara doğru yatırım kararları vermelerinde daha iyi yardımcı olabileceğini göstermektir.

Kubal ve Kristoufek (2022) tarafından yapılan çalışmada, bu sistemle ilgili çeşitli istatistiksel zorlukların kontrol edildiği ve karmaşık denklem sistemine odaklanılmıştır. Bu çalışma, bugüne kadar en sıkı ve karmaşık yaklaşımı sunarak Bitcoin sisteminin fiyat dinamiklerini açıklamayı hedeflemektedir. Elde edilen sonuçlar, tüm sistemin çok iyi yapılandırıldığını ve ekonomik ve mantıksal olarak sağlıklı sonuçlar sunduğunu göstermektedir. Bu da Bitcoin fiyat-hashrate etkileşimi çerçevesinde ağ güvenliğinin önemine işaret etmektedir.

Critien vd. (2022) tarafından kaleme alınan bu makalede, Twitter'daki duygusal durumun Bitcoin fiyatının artış veya azalışını tahmin etmede faydalı olduğu gösterilmiştir. Ancak, mevcut durum yalnızca fiyat yönünü değil, artış veya azalışın büyüklüğünü tahmin etmekle sınırlıdır. Bu çalışmada, tweet'lerden çıkarılan duygusal duruma ek olarak tweet hacmini kullanarak, mevcut durumu geliştirerek sadece yönü değil, artış veya azalışın büyüklüğünü tahmin etme amaçlanmıştır. Duygusal durum ve gelecekteki fiyat arasındaki ilişkiyi farklı zamansal kırımlarda keşfetmek için deney sonuçları sunulmaktadır. Deneysel sonuçlar, fiyat yönü tahmininin yanı sıra fiyat değişikliğinin büyüklüğünün de nispeten doğru bir şekilde (%63) tahmin edilebileceğini göstermektedir.

Gurrib ve Kamalov (2022) tarafından kaleme alınan makale, Bitcoin fiyatının yönünü tahmin etmek için doğrusal diskriminant analizi (LDA) ve duygu analizini birleştiren yeni bir yöntem önermektedir. Yazarlar, mevcut Bitcoin fiyat bilgisi ve Bitcoin haber duyurularının başlıklarını kullanarak, gelecek gün Bitcoin fiyatının yönünü tahmin etmek için bir LDA tabanlı sınıflandırıcı eğitimi gerçekleştirmektedir. LDA sonuçlarına göre, SVM modeli gelecek günün BTC fiyat hareketlerini tahmin etmede daha doğru sonuçlar vermektedir. Tüm modeller, kripto fiyatının düşmesini tahmin etmek yerine yarının BTC fiyatında bir artış tahmin etmek için daha iyi sonuçlar vermektedir. Haber duyusunun dahil edilmesi, test verilerinde en yüksek tahmin doğruluğuna (0,585) yol açmış ve rastgele tahmine göre daha iyidir.

Ahmed (2022) tarafından yapılan çalışma, ilgili literatürde dikkat çeken geniş bir aday belirleyici değişkenlerin sağlamlığını araştırmaktadır. Bu çalışma, model belirsizlik sorunlarını ele alabilen büyük ölçekli bir hassasiyet analizi olan 'extreme bounds analysis (EBA)' yöntemine dayanmaktadır. Bulgular, arz ve talep, halkın ilgisi ve ekonomik politika belirsizliği gibi kripto para piyasası kuvvetlerinin, tüm koşullandırma bilgi setinde olası her türlü değişikliğe dayanıklı olan tek değişkenler olduğunu göstermektedir. Elde edilen bulgular, Bitcoin fiyat hareketlerini açıklamada küresel makroekonomik ve finansal etmenlerden çok kripto para ile ilgili belirleyicilerin üstünlüğünü desteklemektedir.

Yaya vd. (2022) tarafından yazılan makale, Ocak 2018'den Temmuz 2020'ye kadar günlük veri setlerini kullanarak, fraksiyonel kalıcılık çerçevesini kullanarak Bitcoin piyasasından altın ve gümüş piyasalarına kalıcılık, getiri ve oynaklık sıçramalarını araştırmayı amaçlamaktadır. Sonuçlar, Bitcoin'in en yüksek oynaklık kalıcılığına sahip olduğunu, altının ise en düşük oynaklık kalıcılığına sahip olduğunu göstermektedir. CCC-VARMA-GARCH modeli ve diğer alt modellerin kullanılması sonucunda, Bitcoin ve altın (veya gümüş) piyasaları arasında getiri sıçraması olasılığının olmadığı, ancak iki yönlü oynaklık sıçramalarının olduğu görülmüştür. Makalenin sonunda uygun bir portföy yönetimi ve riskten korunma stratejileri için, yatırımcıların portföylerinde tam bir çeşitlilik avantajı sağlamak ve beklenen getirilerini azaltmadan riski en aza indirmek için daha fazla altın ve gümüş yatırımına ihtiyaç duydukları belirtilmektedir.

Aghashahi ve Bamdad (2022) tarafından yapılan çalışma, gecikmeli özellikler gibi teknik özelliklerin sinir ağlarının girdileri olarak kullanılmasıyla, tahmin yeteneklerinin artırılmasının doğrudan karlılık üzerindeki etkisini tartışmaktadır. Ampirik analiz için, www.coindesk.com'da 9 ay boyunca (1.1.2018 - 30.9.2018) Bitcoin fiyatı verileri kullanılmıştır. On katlı çapraz doğrulama yöntemi kullanılarak, her YSA için farklı eğitim fonksiyonlarına göre optimum gizli nöron sayısı, ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hata (MAPE) gibi hata ölçüleri temelinde belirlenmiştir. Ardından, Bitcoin fiyatı tahmin edilmiş ve sonuçlar, R miktarına göre hangi YSA'nın daha iyi tahmin verdiğini karşılaştırmak için kullanılmıştır. Sonuç olarak, bu çalışma Fitnet ağı trainlm fonksiyonu ve 30 gizli nöronla diğerlerinden daha iyi bir sonuç elde ettiği sonucuna varmıştır.

Bejan vd. (2022) tarafından yapılan çalışmaya göre, kripto para birimlerinin ekonomik değeri, ticaret için kullanıcı toplulukları tarafından dolaşıma sokulması ve kabul edilmesi ile kanıtlanmaktadır. Ancak, bu değeri belirlemek, literatürde tartışmalara neden olmaktadır. Bu makalenin araştırması, Bitcoin fiyatının evrimi ile madencilik için enerji tüketimi eğilimi arasında yeterince güçlü bir bağlantı olup olmadığını ve Bitcoin'in değerini etkileyip etkilemeyeceğini araştırır ve analiz eder. Araştırmada Ocak 2014 ile Temmuz 2021 tarihleri arasındaki kamu verileri kullanılmıştır. Yapay Sinir Ağı (YSA), Bitcoin fiyatı ve enerji tüketim eğilimini incelemek ve tahmin etmek için kullanılmıştır. Tahmin edilen eğilim ile gerçek eğilim (enerji tüketimi ve Bitcoin fiyatının evrimi) karşılaştırılmıştır. Araştırma, nicel bir çalışmayla başlamış ve nitel bir çalışmaya (eğilimlere) kadar uzanmıştır. Elde edilen sonuçlar, aylık BTC fiyatı ve madencilik için elektrik tüketimi ortalaması değerleri arasında niteliksel olarak iyi bir ilişki olduğunu göstermektedir.

Chen (2023) tarafından yazılan makalede, Bitcoin fiyatının bir sonraki günü tahmin etmek için kullanılan açıklayıcı değişkenler incelenmiştir. Bu değişkenler arasında (a) Bitcoin fiyat değişkenleri, (b) Bitcoin'in özel teknik özellikleri, (c) diğer kripto para birimleri, (d) emtia, (e) piyasa endeksi, (f) döviz kuru, (g) halkın dikkati ve (h) haftanın Dummy değişkenleri gibi sekiz kategoriye ait 47 değişken yer almaktadır. Araştırma sonucunda, rastgele orman regresyonunun LSTM'e göre daha iyi fiyat tahmini doğruluğuna sahip olduğu bulunmuştur. Araştırmanın sonuçları ayrıca farklı

dönemlerde Bitcoin fiyatını belirleyen açıklayıcı değişkenleri de göstermektedir. İlk fiyat balonu dönemi olan Nisan 2015'ten Ekim 2018'e kadar, Bitcoin'in önceki dönem fiyatının yanı sıra, ABD hisse senedi piyasası endeksi (NASDAQ, DJI ve S&P500), petrol fiyatı, ETH fiyatı ve Bitcoin bloklarını bulma zorluğu gibi madencilik zorluğu da önemli rol oynamıştır. İkinci fiyat balonu döneminde ise (Ekim 2018'den Nisan 2022'ye kadar), OHLC fiyatlarına ek olarak, önceki günün Bitcoin fiyatı, ETH ve Japonya'nın JP22 borsalarındaki fiyatları belirleyici olmuştur.

Cevik vd. (2023) tarafından yapılan çalışmaya göre, Bitcoin'in getirileri vadeli piyasanın başlangıcından etkilenirken, volatilité için böyle bir etki söz konusu değildir. COVID-19 pandemisinin Bitcoin'in getirileri veya volatilitesi üzerinde istatistiksel olarak anlamlı bir etkisi olduğu kanıtlanamamıştır. COVID-19, küresel ekonomi ve finansal piyasalar üzerinde benzersiz bir şok etkisi yaratmıştır, ancak sonuçlar, bu etkinin Bitcoin'in getirileri veya volatilitesi üzerinde herhangi bir etkisini doğrulayamamaktadır. Bu sonuç, Bitcoin fiyat hareketlerinin spekülâtif doğasına bağlı olabilir.

Toai vd. (2023) tarafından yapılan çalışmanın amacı, Bitcoin fiyat tahmini için AutoRegressive Integrated Moving Average (ARIMA), Support Vector Machines (SVM), hibrit ARIMA-SVM ve Long short-term memory (LSTM) gibi makine öğrenimi modellerini kullanarak bir bakış açısı geliştirmektir. Farklı veri türleri ve dönemlerine bağlı olarak, çeşitli modeller tahmin için kullanılmaktadır. Veri örnekleme süresine, tahmin süresine ve spesifik uygulama türüne bağlı olarak zaman serisi verilerinin tahmin edilmesi için tek bir model kullanmak uygun olmayabilir. Sonuç olarak, ARIMA modeli kısa tahmin süreleri veya küçük veri setleriyle daha iyi hata sonuçları üretebilirken, hibrit ARIMA-SVM modeli özellikle bu çalışmada kullanılan 7 ve 30 günlük tahmin süreleri için ARIMA modelinin performansını artırmaya yardımcı olacaktır.

Jia ve Li (2023) tarafından yapılan çalışmada, Bitcoin ekosisteminin madencilik piyasasının yapısına odaklanan basit bir model sunulmaktadır. Model, büyük bir madencilik havuzunun ağa zarar verme riski ile dağılmış madencilerden yeterli hash oranı delegasyonlarını çekme arasında bir tercih yapması gerektiğini göstermektedir. Bu nedenle, bir madencilik havuzu, piyasa gücüne bağlı olarak kendini sınırlı tutmanın en uygun olduğunu bulur, ancak denge durumunda ağa zarar

verme olasılığı pozitif kalmaktadır. Tahmin sonuçları tutarlı güçlü deneysel kanıtlar sunmaktadır. Elde edilen bulgular, madencilerin büyük bir madencilik havuzuna hash oranı delegasyonu yapmanın potansiyel riskinin, havuzun ağın istikrarını ve dolayısıyla karlılığını sağlamak için kendini sınırlama konusunda güçlü teşviklere sahip olduğunu göstermektedir.

Dumitrescu vd. (2023) tarafından yapılan çalışmada, Euro kullanılmayan dokuz Avrupa ülkesinde Bitcoin getirilerinin ulusal para birimi gelişimini etkileyip etkilemediği ve ulusal para birimlerindeki değişimlere bağlı olarak bu ilişkide heterojenlik olup olmadığı araştırılmıştır. Ulusal para birimlerinin gelişiminde iş güveni, enflasyon farkı, faiz oranı farkı gibi birçok kontrol değişkeni kullanılmış, ayrıca COVID-19 pandemisi dönemindeki vakalar da dikkate alınmıştır. Sonuçlar, normal piyasa koşullarında Bitcoin fiyatındaki artışın, örneklemimizdeki para birimlerinde değer artışına neden olduğunu gösterirken, COVID-19 pandemisi sırasında bu ilişkinin tersine döndüğünü göstermiştir. Ayrıca, nominal döviz kuru değişimlerine bağlı olarak ilişkide heterojenlik tespit edilmiştir.

Seifaddini ve Habibdoust (2023) tarafından yapılan çalışma, bir makine öğrenimi yönteminin tahmin edilebilirlik gücünü artırmayı amaçlamaktadır ve bu amaçla iki aşamalı bir tahmin yöntemi önermiştir. Özellik seçiminde kullanıcının rolünü ortadan kaldırmak için Grup Modelleme Veri İşleme (GMDH) tipi sinir ağı yöntemi kullanılmıştır. Bitcoin piyasasındaki son şokları dikkate almak için COVID-19 öncesi, COVID-19 sonrası ve Elon Musk'ın Twitter etkinliği sonrası olmak üzere üç dönemi dikkate alınmış, zaman ölçeği analizi kullanarak verileri farklı ölçeklere ayrılmıştır. Bulgular, daha kısa dönemde günlük fiyatların birinci, ikinci ve üçüncü gecikmeyle birlikte işlem hacminin değerli bilgiler ürettiğini ve yedi günlük gecikmenin daha uzun dönemde tahmin gücünü artırabileceğini göstermektedir. GMDH-sinir ağı yönteminin standart yöntemle göre daha iyi bir performans gösterdiğini ortaya koymaktadır. Bu, modellerin tahmin gücü üzerinde ticaret frekanslarının etkisinin önemini ortaya koymaktadır.

İKİNCİ BÖLÜM

KAVRAMSAL ÇERÇEVE

Kripto para piyasası, son yıllarda giderek artan bir şekilde gündemde yer almaktadır. Bu piyasada yer alan en öncü kripto para birimi olan Bitcoin, hem yatırımcıların hem de geniş kitlenin ilgisini çeken yüksek fiyat hareketliliği ile dikkatleri üzerine çekmektedir. Bu çalışma, Bitcoin'in fiyat hareketliliği dinamiklerine odaklanmakta ve bu dinamiklere dair bilgi sağlamak amacıyla Binance Borsası üzerinde bir uygulama geliştirilmektedir.

İkinci bölümde, çalışmanın kavramsal çerçevesi sunulmaktadır. Para, para birimleri, dijital para, kriptografi, blokzincir teknolojisi, kripto para ve altcoin kavramları, bu kavramsal çerçevenin temellerini oluşturmaktadır. Para, ekonomi dünyasında kullanılan bir değer sayım aracıdır ve ekonomik faaliyetlerin gerçekleştirilmesinde önemli bir rol oynamaktadır. Dijital para kavramı, geleneksel para birimlerinin yerini alan bir para birimi türüdür ve genellikle kripto para birimleri olarak adlandırılır.

Kriptografi teknolojisi, dijital para birimleri ve blokzincir teknolojilerinin temelini oluşturmaktadır. Kriptografi, gizli mesajlaşma, kimlik doğrulama ve veri güvenliği gibi konularda kullanılan bir teknolojidir. Blokzincir teknolojisi ise, bir ağ üzerinde kaydedilen verilerin merkezi olmayan bir şekilde depolanmasına olanak tanıyan bir veri yapısıdır.

Kripto para, dijital para türleri arasında yer alan bir para birimidir. Bitcoin, bu kripto para birimlerinin en bilinen örneği olarak tanınmaktadır. Bitcoin'in arzı, talebi ve fiyatı, piyasa hareketleri, arz talep dengesi, madencilik faaliyetleri ve regülasyonlar gibi faktörler tarafından belirlenmektedir. Bitcoin, finansal dünyadaki yenilikçi bir teknoloji ve ekonomik aktivitelerin artması için bir aracı olarak kullanılabilecek bir tür dijital para olarak tanımlanabilir.

Altcoinler ise diğer kripto para birimleri olarak adlandırılmaktadır. Stabil Coinler, dijital para birimleri arasında yer alan ve kararlı bir fiyat noktasına sahip olan para birimleridir. Tether, USD Coin ve Binance USD, bu kategoride yer alan stabil coinlerdir. Ethereum, kullanıcılarına birden fazla amaç için kullanılabilecek bir platform sağlayan kripto para birimi olarak dikkat çekmektedir.

Bu çalışma, Bitcoin'in fiyat hareketliliği dinamikleri üzerine odaklanarak Binance Borsası üzerinde bir uygulama geliştirerek bu dinamiklere dair yeni bilgiler sağlamayı amaçlamaktadır. İkinci bölümde ise, konuyla ilgili kavramsal çerçeveyi ele alarak, çalışmanın diğer bölümlerinde yer alacak konuların anlaşılması için gerekli temel bilgiler sunulmaktadır.

2.1.Para

Para denildiğinde mavi, yeşil banknotlar; çeşitli metal alaşımından yapılan yuvarlaklar ya da banka hesaplarında çok haneli dijital varlıklar akla gelip bunların satın alabileceği diğer varlıklarla değeri kıyas edilir. Çünkü para sosyal ve ekonomik hayatın içinde sürekli ihtiyaç duyulan bir araçtır.

Para ülke içi ticaretin en önemli unsurlarında biri olmasının yanında ülkeyi yöneten siyasi gücü tescil eden bir araç olarak kullanılmıştır. İmparatorluklarda hükümdar değiştiğinde yeni hükümdar para bastırarak yönetim gücünü pekiştirmiştir. Yönetime darbe yaparak el koyan yöneticiler bile para basmanın bu fonksiyonunu bildikleri için kendi paralarını bastırıp tedavüle koymuştur. İlerleyen dönemlerde parayı yönetme gücü profesyonel kurumlara bırakılmış, merkez bankaları para yönetiminde bir numaralı otorite olmuştur. (Çatlı ve Şimşek, 2021)

Parayı yönetme gücü ülke içinde merkez bankaları elinde tutarken küreselleşme adımlarının öncüleri olarak Uluslararası Para Fonu (IMF) ve Dünya Bankası (WB) gibi devletler üstü oluşturulan kurumlar uluslararası ekonominin en önemli aktörlerinden biri haline gelmiştir.

2.1.1. Paranın Tanımı

Para, mal ve hizmetlere ilişkin işlemlerde yaygın olarak kabul gören bir değişim aracı, bir hesap birimi ve bir değer saklama aracı olarak tanımlanabilir. Ekonomik işlemleri kolaylaştırmak için bir araç olarak hizmet eder ve modern ekonomilerin temel bir bileşenidir (Lea ve Webley, 2006).

Literatürde paranın bu üç fonksiyonundan çokça bahsedilmektedir. Sürekli değişen dünya ekonomik düzeninde para birtakım fonksiyonlar daha yüklenilmiştir. Bu işlevlere paranın modern fonksiyonları denilmektedir. Bunlar (Parasız, 2000);

- Paranın ekonomik faaliyetleri teşvik etme ya da köstekleme,
- Geliri yeniden dağılma
- Egemenlik işlevleridir.

2.1.2. Paranın Klasik Fonksiyonları

Literatürde para için çeşitli tanımla yapılmıştır. Bu tanımlar paranın fonksiyonlarından faydanılarak yapılmaktadır. Paranın fonksiyonları şunlardır:

i. Hesap Birimi Olarak Para

Hesap birimi, iki ögenin değerini karşılaştırmak veya varlıklarınızın toplam değerini hesaplamak için kullanabileceğiniz bir şey olduğu anlamına gelir (Lewis, 2018). Bu fonksiyon “değer ölçüsü”, “muhasabe birimi” olarak da adlandırılmaktadır (Parasız, 2000).

Paranın bu fonksiyonu sayesinde elinizdeki varlığın almak istediğiniz iki üründen hangisinin yettiğini hesaplayabilirsiniz. Ya da yapacağınız yatırımdan elde edeceğiniz getiriye bakarak yatırım yapmanın mantıklı olup olmadığına karar verirsiniz. Bütün mal varlığınızı elden çıkardıktan sonra yabancı bir ülkede nasıl bir hayat yaşayabileceğiniz kıyaslamaya izin veren yine paranın hesap birimi olması özelliğidir.

ii. Değişim Aracı Olarak Para

Değişim aracı, "ödeme mekanizması" anlamına gelir; bunu birine bir şey için ödeme yapmak veya bir borcu veya finansal yükümlülüğü kapatmak için kullanabilirsiniz. Uygun bir değişim aracının evrensel olarak kabul edilmesi gerekmez. Yine de kullanıldığı özel bağlamda geniş çapta kabul edilmelidir (Lewis, 2018).

Uygulamada kâğıt ve madeni paralar değişim aracı olarak kullanılmaktadır. Çek öncelikle borç ödeme aracı olarak kullanılırken değişim aracı olarak da kullanılabilen ancak bunun için aracı bir kurum olan bankalara ihtiyaç duyulmaktadır. Bütün bu işlemler paranın satın alma gücü sayesinde gerçekleşebilmektedir (Parasız, 2000).

iii. *Tasarruf Aracı Olarak Para*

Paranın bu fonksiyonu, yakın vadede paranızın bugünkü değeriyle aynı olacağı anlamına gelir. İyi bir değer deposu olmak için, paranızın size yarın, gelecek ay veya gelecek yıl aşağı yukarı aynı miktarda mal ve hizmet alacağından makul ölçüde emin olmanız gerekir (Lewis, 2018).

Enflasyonist dönemlerde parasının satın alma gücü aşındığı için tasarruf aracı olması da zayıflar. Bireyler tasarruflarının günden güne eridiğini gördüklerinde elde para tutmak yerine bir emtiaya bağlamayı daha mantıklı bulur. Örneğin yakın zamanda elindeki nakdi araba olarak sakladığında tasarrufunu koruyabilmiş olacaktır.

2.1.3. **Paranın Modern Fonksiyonları**

Küreselleşen ve değişen dünya ekonomik düzeninde kimi teoriler çürütülürken kimileri revize edilmektedir. Böyle bir ortamda para geleneksel fonksiyonlarının yanında ek olarak fonksiyonlar üstlenmiştir. Literatürde bu fonksiyonlara paranın modern fonksiyonları denilmekte ve üç başlıkta sınıflandırılmıştır. Başlıklar kısaca şu şekilde açıklanmıştır.

i. *Ekonomiyi Teşvik Edici ya da Engelleyici Fonksiyonu*

Ekonomiyi yöneten karar birimleri para politikası ile ekonomiye yol verir. Birçok para politikası aracı olmasının yanında bu politikalar, karar biriminin tercihi göre temelde iki amaç için kullanılır:

Para arzını daraltmak; Daraltıcı para politikası

Para arzını genişletmek; Genişletici para politikası

Ekonomiyi canlandırmak için geniş para politikası araçlarıyla müdahale gerçekleşirse, piyasaya para enjekte edilmiş olur. Diğer bir ifade ile ekonomi teşvik edilmiş olur.

Ekonominin fazla ısındığı dönemlerde, ki bunun sonu enflasyonist ortamdır ve karar birimleri bunu istemez, daraltıcı para politikası araçlarıyla piyasaya müdahale edilebilir. Bunun sonucunda piyasada likiditesi düşer ve ekonomi engellenmiş olur.

ii. Gelirleri Yeniden Dağıtma Fonksiyonu

Paranın geliri yeniden dağıtma fonksiyonu enflasyonist dönemlerde daha ön plana çıkar. Elinde sermayesi olanlar varlıklarının değerini koruyucu tedbirler alabilirler. Ancak bu imkânı olmayan bireyler enflasyon baskısı altında ezilirler.

Bankalar enflasyonist ortamlarda gelirin yeniden dağıtılmasına yardımcı olmada önemli bir rol üstlenirler. Elinde para olmayan bireyler kredibilitesi oranında kredi alarak ihtiyaçlarını anlık olarak karşılarlar. Kredinin geri ödeme vadesi geldiğinde ise ödeyecekleri miktar enflasyon karşısında erimiş olan bir borç haline gelmiştir. Paranın üstlendiği geliri yeniden dağıtma fonksiyonu sayesinde Mali gücüm yüksek bireyler ve kurumlar gibi, mali gücü zayıf olanlar da kendini korumuş olur (Parasız, 2000).

iii. Nüfuz Aracı Olma Fonksiyonu

Ekonomik dengelerin bozulduğu dönemlerde ekonomi yönetiminin para ve maliye politikaları yeterli olmayabilir. Böyle dönemlerde ülkeler dış borç almak isteyebilir. Para gücünü elinde tutanlar borçlanmak isteyen ülkeler üzerinde doğal bir nüfuz sahibi olacaktır. Tarihte bu nüfuzun örnekleri vardır ve günümüzde de benzer olaylar yaşanmaktadır (Özbilen, 2015).

Paranın nüfuz aracı olmasını daha makro düzeyde tartıştıktan sonra çerçeve daraltılabilir. Şirketlerin sermayesi güçlü olan şirketlerle iş yapması için taviz vermek zorunda kalması paranın nüfuz aracı olmasına örnek verilebilir.

2.2.Dijital Para Kavramı

Teknolojik gelişmeler sosyal hayatımızı etkilediği kadar ekonomik hayatımızı da etkilemiştir. Fiziksel banknot ve madeni para kullanımının yanında, para dijital olarak da kullanıma sunulmuştur. Tabii ki paranın dijitalleşmesinin sadece teknolojiye bağlamak doğru olmaz. Teknolojik gelişmelerin yanında küreselleşme ve diğer ticari ihtiyaçlar da dijital paranın hayatımıza girmesini hızlandırmıştır.

Tablo 2.1 Dijital para biçimlerinin özellikleri

Özellikler	Merkez bankası dijital para birimi	Kripto para	B-money	E-money	I-money
Tipi	Nesne	Nesne	Talepsel	Talepsel	Talepsel
Değer	Hesap birimi	Başka	Sabit değerli itfalar	Sabit değerli itfalar	Değişken değerli kullanımlar
Garantör	-	-	Devlet	Özel	-
Teknoloji	Merkezileştirilmiş ve blokzincir	Blokzincir	Merkezileştirilmiş ve blokzincir	Merkezileştirilmiş ve blokzincir	Blokzincir

Kaynak: (Adrian ve Mancini-Griffoli, 2021).

Bir ödeme aracını tanımlayan ilk nitelik, bir talepsel ya da bir nesnesel olmasıdır. Mesela kahve için ödeme yapmak için kullanılan nakit, nesne tabanlı bir ödeme aracının bir örneğidir. Taraflar nesneyi geçerli saydıkları sürece işlem derhal sonuçlandırılır. Bilgi alışverişi gerekli değildir. Diğer seçenek, başka bir yerde var olan değer üzerinde bir hak talebini devretmektir. Kahvenin kredi kartıyla ödendiği durum budur. Kredi kartını pos cihazından geçirmek ile banka varlıkları üzerindeki bir hak talebinin sahipliğini bir kişiden diğerine aktarmak için talimatlar verir. Hak talebine dayalı ödemeler işlemleri basitleştirir ancak karmaşık altyapı gerektirir (Adrian ve Mancini-Griffoli, 2021).

2.3.Kriptografi Kavramı ve Blokzincir

Kriptografi, özellikle bilgi güvenliğinin sağlanması açısından son yıllarda giderek artan bir öneme sahip olan bir konudur. Kriptografi, gizliliği ve bütünlüğü

sağlamak amacıyla kullanılan, matematiksel yöntemlerden oluşan bir teknolojik disiplindir.

Bu teknolojinin en önemli uygulama alanlarından biri de blokzincir teknolojisi ve kripto para birimleridir. Blokzincir teknolojisi, merkezi olmayan bir veri tabanı olan blokzincir yapısını kullanarak verilerin güvenli bir şekilde saklanması sağlamaktadır. Bu teknolojinin temelini ise kriptografi oluşturmaktadır.

Kriptografi, başta şifreleme olmak üzere, dijital imzalar, kimlik doğrulama ve açık anahtar altyapıları gibi birçok uygulama alanında kullanılmaktadır. Bu teknolojinin ana hedefi, mesajların sadece yetkili kişiler tarafından okunmasını ve verilerin istenmeyen kişiler tarafından değiştirilememesini sağlamaktır.

Bu bölümde, kriptografi teknolojisi ve blokzincir teknolojisi arasındaki ilişkiyi ele alınarak, blok zincir teknolojisinin temel prensipleri açıklanacaktır. Kriptografinin blokzincir teknolojisinde nasıl kullanıldığına ve blokzincir yapısının nasıl işlediğine dair ayrıntılı bilgiler sunulacaktır.

Tablo 2.2 Blokzincir sistemlerinin özellikleri

	Sistemin Özellikleri	Sistemin Avantajları	Sistemin Dezavantajları
Merkezi Sistemler	Küresel bir saatin varlığı: Tüm sistem bir merkezi düğümden (bir sunucu / bir yönetici) ve birçok istemci düğümden oluştuğundan, tüm istemci düğümleri küresel saatle çalışır. Tek bir merkezi birim: Sistemdeki diğer tüm düğümlere hizmet veren/koordinasyon sağlayan tek bir merkezi birim vardır. Bileşenlerin bağımlı hatası: Merkezi düğüm hatası, tüm sistemin başarısız olmasına neden olur. Bu mantıklıdır çünkü sunucu kapalıyken yanıt / istek gönderecek / alacak başka bir varlık yoktur.	Fiziksel olarak güvenli olması kolaydır. Pürüzsüz ve zarif kişisel deneyim- Bir müşterinin kullandığı özel bir sistemi Özel kaynaklar (bellek, CPU çekirdekleri vb.) kullanılır. Belirli bir sınıra kadar küçük sistemler için daha uygun maliyetlidir. Hızlı güncellemeler yapmak mümkündür.	Ağ bağlantısına son derece bağımlı – Yalnızca bir merkezi düğüm olduğu için düğümler bağlantıyı kaybederse sistem başarısız olabilir. Daha az veri yedekleme olasılığı. Sunucu yedekleme olmadan başarısız olursa, verileri hemen kaybedilebilir. Karmaşık sunucu bakımı – Yalnızca bir sunucu vardır ve kullanılabilirlik nedenleriyle sunucuyu bakım için kapatmak maliyetlidir.


Merkezi Olmayan Sistemler	Küresel bir saatin olmaması: Her düğüm birbirinden bağımsızdır ve bu nedenle çalıştırdıkları ve takip ettikleri farklı saatler vardır. Çoklu merkezi birimler (Bilgisayarlar/Düğüm/Sunucular): Diğer düğümlerden gelen bağlantıları dinleyebilen birden fazla merkezi birim vardır.	Minimum performans darboğazları sorunu – Tüm yük, tüm düğümlerde dengelenir ve minimum veya sıfır darboğaz durumlarına yol açar. Yüksek kullanılabilirlik – Bazı düğümler (bilgisayarlar, cep telefonları, sunucular) iş için her zaman kullanılabilir/çevrimiçidir, bu da kullanılabilirliğin artmasına neden olur. Kaynaklar üzerinde daha fazla özerklik ve kontrol – Her düğüm kendi davranışını kontrol ettiğinden, kaynaklar üzerinde daha fazla kontrole yol açan daha iyi bağımsızlığa sahiptir.	Büyük küresel görevleri başarmak için zordur. Hangi düğümün başarısız olduğunu bilmek zordur, probleme kolayca müdahale edilemez. Merkezi olmayan bir sistem bir talebe hizmet ettiğinde, istek sistemdeki düğümlerden biri tarafından yapılır, ancak hangi düğümün gerçekten talepte bulunduğunu bulmak zordur.
Dağıtılmış Sistemler	Bileşenlerin eşzamanlılığı: Düğümler, aynı komutlar üzerinde anlaşmak için fikir birliği protokolleri uygular. Küresel bir saatin olmaması: Tüm düğümler saatini korur.	Merkezi bir sistemden daha düşük gecikme yaşanır. Dağıtılmış sistemler, yüksek coğrafi yayılım nedeniyle düşük gecikme süresine sahiptir, bu nedenle yanıt almak için daha az zamana yol açar.	Fikir birliğine varmak zordur. Olayları meydana geldikleri mutlak zamana göre kaydetmenin geleneksel yolu burada mümkün değildir.

(Kaynak:www.GeeksforGeeks.com, 2023)

Abadi ve Brunnermeier (2018)'e göre bir blokzincir yani hiçbir defter, herhangi bir kayıt tutma sisteminin tüm ideal nitelikleri olan doğruluk, ademi merkeziyetçilik ve maliyet verimliliği aynı anda karşılayan bir üçlü çıkmaz olarak tanımlanmaktadır. Yine de bir blokzincir, merkezi olarak yönetilen geleneksel bir defterden daha verimlidir. Bir blokzincir birçok şekilde uygulanabilir, ancak çoğu birkaç standart özelliği paylaşır.

Bir blokzincir istisnai bir veri tabanı olarak düşünebiliriz. Bir blokzincir yapısı, merkezileştirilmek yerine paylaşılr veya dağıtılır ve bu nedenle genellikle dağıtılmış defter teknolojisi olarak adlandırılır. Bu ağ belirli bir düzeyde güvenlik sağlar, çünkü veri tabanının her kopyasına bir saldırı başlatılması pek olası değildir. Çünkü saldırının dağıtılmış durumda olan bütün defterlerin hepsini değiştirecek kadar güçlü olması ve sonucunun maliyetine değer olması gerekir (Härdle vd., 2020).

Şekil 2.1 Merkezi, merkeziyetsiz ve dağıtılmış ağ görünümü



Bitcoin teknolojisinin merkezinde, SHA-256 hash işleviyle Bitcoin adresleri oluşturan, işlemleri imzalayan ve ödemeleri doğrulayan açık anahtarlı şifreleme bulunur. Açık anahtar kriptografisi, dijital imzalar kullanılarak Bitcoin işlemlerinin gerçekliğinin belirlenmesinde güven verir. İki ayrı ancak asimetrik olarak bağlantılı genel ve özel anahtar üreten asimetrik bir algoritma kullanır. Genel anahtar özel anahtardan türetildiği için anahtarlar asimetriktir. Bir genel anahtardan özel bir anahtar elde etmek hesaplama açısından imkansızdır. Böyle bir sistemde, genel anahtar işlemlerdeki dijital imzaları doğrulamak amacıyla kullanılırken, özel anahtar bu çok dijital imzaları üretmek ve işlemleri imzalamak için kullanılır. Genel anahtar herkese açıktır; Bitcoin'de, ödemelerin gönderildiği ve gönderildiği Bitcoin adresi olarak kullanılır. Öte yandan, özel anahtar gizli ve güvenli tutulmalıdır. Böyle bir sistemin güzelliği, işlemleri imzalamak için kullanılan özel anahtarı paylaşmadan genel anahtar kullanılarak işlemlerin kolayca doğrulanabilmesidir (Chuen, 2015).

Bir blok zinciri değiştiremeyecek bazı bilgiler içerir. Bu bilgiler Tablo 2.3'te kısaca açıklanmıştır.


Tablo 2.3 Blokzincir temel bilgiler

Başlık	Açıklama
Bloklar	Blokzincir ağlarıyla ilgili verilerin kalıcı olarak kaydedildiği dosyalardır. İşlemlerin çoğunu kaydeder.
Versiyon	Bloğun mevcut sürüm bilgisini depolar.
Hash Değeri	Belirli bir algoritma tarafından hesaplanan girdi verilerinin sabit boyutlu bir diziye dönüştürülmesini ifade eder.
Merkle Kök Ağacı	Bloktaki işlemlerin kriptografik olarak karma değerlerinin depolandığı bir veri yapısı.
Zaman	Bloğun oluşturulduğu zaman damgasını içerir.
İşlem	Para transferi, alım-satım veya borçlanma gibi finansal işlemlere konu olan verileri içerir.

Kaynak: (www.learn.bybit.com, 2022).

Şekil 2.3'te gösterildiği üzere Blokzincir, her bir bloğun önceki bloğunun hash değeriyle başladığı ve içerdiği bilgilerle bir sonraki bloğun hash değerini oluşturarak ardışık bir yapı oluşturduğu bir teknoloji olarak öne çıkar. Bu yapı, her bir bloğun bir önceki bloğun verilerine ve hash değerine dayandığı için, bütünlüğü ve geçerliliği sağlamaktadır.

Şekil 2.3 Hash mekanizmasının işleyişi



(Kaynak: <https://blokzincirsentry.com>, 2023)

2.4.Blokszincir Uzlaşı Mekanizmaları

Blok zincirlerindeki konsensus mekanizması sistemin temelini oluşturur. Bir blokszincir ağındaki herhangi bir kullanıcı blokszincire yeni bilgiler eklemeyi önerebilir. Bu veri eklenmesinin meşru olup olmadığını doğrulamak için kullanıcıların bir tür anlaşmaya varması gerekir. Bu anlaşma olmazsa bilim kurgu filmlerindeki alternatif zaman tünelleri gibi, her biri kendisinin meşru olduğunu iddia eden alternatif blok zincirleri ortaya çıkar, ki bu da kaos demektir.

Tek bir meşru blokszincir oluşması için aksi iddia edilemez bir “uzlaşma mekanizması” gerekir. Konsensus mekanizması, blokszincirdeki işlemlerin doğru bir şekilde sıralanmasını sağlayan önceden tanımlanmış kriptografik bir doğrulama yöntemidir. Transferler merkezi olarak kaydedilmediği ve kontrol edilmediği takdirde, aynı ödeme aracı veya varlık birden fazla kez transferi ile sonuçlanan mükerrer işlem problemi ortaya çıkar (Houben ve Snyers, 2018).

Bir konsensus mekanizması çeşitli şekillerde yapılandırılabilir. Blokszincir altyapısını kullanan kripto para birimlerinin en sık kullandığı konsensus mekanizmaları aşağıda açıklandığı üzere İşlem Kanıtı - Proof of Work (“PoW”) mekanizması ve Hisse kanıtı - Proof of Stake (“PoS”) mekanizmasıdır.

i. *Proof of Work (PoW)*

PoW, ilk olarak Bitcoin tarafından kullanılan orijinal kripto konsensus mekanizmasıdır. PoW yani “iş kanıtı” ve madencilik yakından ilişkili konseptlerdir. Kripto işlemlerinin kaydedildiği blokszincir çok yüksek işlemci gücü gerektirdiği için “iş kanıtı” olarak adlandırılmıştır (www.coinbase.com, 2022).

Madencilik süreci, bilgisayarların maksimum kapasitede çalışmasını ve önemli miktarda elektrik tüketmesini gerektirir. Bu durum, (PoW) adı verilen kaynak yoğun bir konsensus protokolü olmasına neden olur; zaman ve enerji için yapıldığını kanıtlar. 2014 yılında Bitcoin ağıının elektrik tüketimi İrlanda'nınkine eşdeğerdir. Ancak, başlangıçta spekülasyon bir varlık olan Bitcoin'i yönetmek için tasarlanmadığından, bu protokolün geleceği belirsizliğini korumaktadır. (Seang ve Torre, 2018).

ii. *Proof of Stake (PoS)*

Proof of Stake, hisse kanıtı olarak dilimize çevrilmiştir. Ayrıntılar projeye göre değişmekle beraber gerçekleştirilen işlemlerin kanıtlanması kendi kriptolarına katkıda bulunan veya "paylaşan" bir "doğrulayıcılar" ağı kullanılır. Rekabetçi bir doğrulama sistemiyle kazanan en son işlem bloğunu doğruladıktan sonra, diğer doğrulayıcılar bloğun doğru olduğunu onaylayabilir. Bir eşik sayıda doğrulama yapıldığında, ağ blozinciri günceller. Katılan tüm doğrulayıcılar, genellikle ağ tarafından her doğrulayıcının hissesiyle orantılı olarak dağıtılan yerel kripto para biriminde bir ödül alır (www.coinbase.com, 2022).

PoS, PoW sisteminin karşılaştığı enerji sorununu çözse de çözülmeyi bekleyen noktaları bulunmaktadır. Bu sorunlardan biri de bir doğrulayıcının birden fazla bloğa oy vermesinin hiçbir maliyeti olmamasıdır. Bu sorun, doğrulayıcıların yalnızca bir kez oy kullanmasına izin vererek ve birden fazla zincire oy verirlerse onları ağır şekilde cezalandırarak çözülebilir. Pratikte, doğrulayıcıların ofset zincir bilgilerini almasına neden olabilecek ağ gecikmeleri nedeniyle bunun uygulanması daha karmaşıktır (Seang ve Torre, 2018).

Tablo 2.4 PoW ve PoS sistemlerinin avantajları ve dezavantajları

	PoW	PoS
Artıları	• Rekabet: Blok kazanma rekabeti, hızı ve verimliliği teşvik eder.	• Verimlilik: PoS, bir blokzincir güvenceye almak için çok az enerji kullanır.
	• Yenilenebilir kaynaklara geçiş: Madenciler maliyetlerini düşürmek için mümkün olan en ucuz enerji türlerini ararlar. Yenilenebilir enerji, hızla en uygun fiyatlı enerji biçimi olarak teşvik edilmiş olur.	• Artan verim: Karmaşık Bilgisayar sorunları olmadan işlem hızları artırılabilir.
	• Âtıl enerjinin kullanılması: Uzak yerlerde, aksi takdirde kullanılmayacak olan enerji, internet bağlantısı ve donanım ile değere dönüştürülebilir.	• Sansür direnci: Büyük enerji tüketimi olmadan, bir PoS Sisteminde katılımcı doğrulayıcıları belirlemek ve durdurmak neredeyse imkansızdır.
	• Güvenlik: Donanımın peşin maliyeti ve devam eden enerji maliyetleri iki katmanlı güvenlik sağlar.	• Daha düşük giriş engeli: PoS Sisteminde ödül kazanmak özel donanım gerektirmez. Tek maliyet kripto para satın almaktır.
Eksileri	• Enerji tüketimi: Proof-of-work muazzam miktarda enerji kullanır.	• Büyük ölçekte kanıtlanmamıştır: Ethereum veya Bitcoin'in boyutuna ve güvenliğine ulaşmak için henüz bir PoS Sistemi yoktur.
	• E-atık: Elektronik atık, çip hızı ve verimliliğindeki yenilik eski çipleri hızla işe yaramaz hale getirdiği için kripto madenciliğinde öne çıkan bir sorundur.	• Madeni Para Konsolidasyonu: PoS, merkezileşmeye yol açabilecek madeni paraların istiflenmesini teşvik eder.
	• Tekeller: Madencilik endüstrisinde hem ASIC yonga üreticileri hem de madencilik şirketleri arasında tekel oluşturabilir.	• Daha az sağlam güvenlik: PoS Sisteminde bir ağ katılımcısı olmak, çok az veya hiç devam eden maliyet olmadan tek bir peşin maliyet gerektirir. Proof-of-work sisteminde devam eden maliyetler
	• İzlenebilirlik: Yüksek enerji kullanımı izlenebilir, bu da yetkililere madencilik tesislerini bulma ve kapatma olanağı verir.	

(Kaynak: www.blockworks.co, 2023)

2.5. Blokzincir Teknolojilerinin Ortak Özellikleri

Blokzincir teknolojisi hayatımıza giren yeni bir teknoloji olmasının yanında, çok hızlı değişen ve gelişen teknolojilerden biridir. Bununla birlikte mevcut blokzincir'ler aynı temeller üzerine kurulmuştur. Blok zincirleri genellikle şu konseptleri içerir (Lewis, 2018):

1. Verilerdeki deęişiklikleri kaydeden bir veri deposu (veri tabanı): Şimdiye kadar, bunlar en yaygın olarak finansal işlemlerdi, ancak herhangi bir verideki deęişiklikleri bir blokzincirde saklanabilmektedir.

2. Şeffaf ve yarı şeffaf blok zincirleri: Bitcoin ve Ethereum gibi "yayın" blok zincirleri, tüm verilerin tüm katılımcılara gönderilmesini sağlar; herkes her şeyi görür. Bazıları, bilginin nereye iletildeęi konusunda daha seçicidir.

3. İstemci-sunucu aę mimarisi yerine 'eşler arası' mimarisi: Veri, altın veri kaynaęı olarak görev yapan tek bir koordinatör tarafından yayınlanmak yerine komşulara 'dedikodu' yapılabilmektedir. İşlemlerin doęruluęunu garanti eden madencilerin yanı sıra bütün son kullanıcılar zincir verisinin tek bir veri tabanından deęil bu madencilerin konsensus oluşturduduęu veri üzerinden alır.

4. Dijital imzalar gibi kriptografik yöntemler, sahiplik ve özgünlüęü, referanslar için karmaları kanıtlar ve bazen yazma erişimini yönetir. Genel ve özel anahtarın sahibi kripto varlıęın da sahibidir. Bu sahiplik bütün zincir kullanıcılarının şahit olduęu ve hiçbirinin aksini iddia edemedięi bir sahiptir.(Lewis, 2018).

2.6.Kripto sistemlerinde güvenlik

Blokzincir, şimdiye kadar yürütölen tüm Bitcoin işlemlerinin halka açık bir defteridir. Kaydedildikten sonra, herhangi bir bloktaki veriler, aę çoęunluęunun iş birlięini gerektiren sonraki tüm blokları deęiştirmeden geriye dönük olarak deęiştirilemez. Blokzincir veri tabanı, aędaki tüm bilgisayarlar tarafından paylaşılr ve gerçek zamanlı olarak güncellenir. Blokzincir merkezi olmayan doęası, herhangi bir bilgisayarın onu kontrol etmesini imkânsız kılar, yani kapatılamaz veya deęiştirilemez.

Kriptografi güvenli bir gezegen olmasına raęmen, birçok kripto borsası siber suçlular tarafından saldırıya uğramıştır. Saldırıları sonucunda milyon dolarlık servet el deęiştirmiştir. Kripto para borsalarının bu şekilde soyulması Bitcoin temelinde kripto para konseptinin güvenli olup olmadıęı sorusunu akıllara getirmektedir.

Kripto varlıklarının tamamı siber soyguncuların saldırısına açık deęildir. Borsalardaki sıcak cüzdanda tutulan varlıkların deęerinin çok fazla olması sebebiyle, yapılacak saldırının maliyetinin, getirisinin çok altında kalmaktadır. Bu da yapılacak olan siber saldırıyı cazip kılmaktadır.

Kripto cüzdanları genel yani halka açık anahtar ve sadece sahibinin bildiği özel anahtar prensibi ile çalışmaktadır. Genel anahtar, cüzdanın para transfer işlemlerinde tanınmasını sağlayan adres görevi görür. Özel anahtar ise işlemin cüzdan sahibinin doğrulamak işlevi görmektedir. Bu iki anahtara sahip herkes, cüzdanın içinde tuttuğu değer üzerinde söz sahibi olur.

Kripto paraları internete bağlı şekilde saklayan cüzdanlar sıcak cüzdan olarak tanımlanırken, telefon ya da bilgisayara yükleme suretiyle genel ve özel anahtar üreten uygulamalar da soğuk cüzdan olarak bilinir. Donanım cüzdan ise işlemin onaylanmasının fiziksel bir cihaz sayesinde mümkün olduğu, diğer bir deyişle fiziksel donanım olmadan transfer işleminin yapılamayacağı cüzdanlardır.

Kripto borsalarının kripto paraları sakladıkları cüzdanlar sıcak cüzdanlardır. Büyük vurgunlarda sıcak cüzdanlara yani borsalara daha yaygın yapılmakta başarılı olursa daha büyük skandallara neden olmaktadır.

Tablo 2.5 Kripto para borsalarına yapılmış olan bilinen siber saldırılar

Tarih	Borsa	Hack Nedeni	Çalınan Miktar (USD)
2022, 17 Ocak	Crypto.com	Bilinmeyen	34 milyon dolar
2021, 11 Aralık	AscendEX	Sıcak cüzdana erişim sağlandı	80 milyon dolar
2021, 5 Aralık	BitMart	Sıcak cüzdana erişim sağlandı	150 milyon dolar
2021, 19 Ağustos	Liquid	Sıcak cüzdana erişim sağlandı	97 milyon dolar
2021, 29 Nisan	Hotbit	Sıcak cüzdana erişim sağlandı	Sıfır
2020, 23 Aralık	Livecoin	Güvenliği ihlal edilmiş sunucular	Bilinmeyen
2020, 21 Aralık	EXMO	Sıcak cüzdana erişim sağlandı	4 milyon dolar
2020, 1 Aralık	BTC Markets	Dahili personel hatası	270.000 kullanıcı bilgisi
2020, 25 Eylül	KuCoin	Veri sızıntısı	275 milyon dolar
2020, 11 Temmuz	Cashaa	Kötü amaçlı yazılım	3,1 milyon dolar
2020, 29 Haziran	Balancer	Protokoldeki güvenlik açığı	500.000\$
2020, Nisan 19	Lendf.me	Hatalar ve Yeniden giriş saldırısı	24.5 milyon dolar
2020, Nisan 19	Uniswap	Hatalar ve Yeniden giriş saldırısı	500.000\$
2020, 5 Şubat	Altsbit	Sıcak cüzdana erişim sağlandı	70.000\$
2019, 19 Aralık	Yobit	Sıcak cüzdana erişim sağlandı	Bilinmeyen
2019, 26 Kasım	Upbit	Sıcak cüzdana erişim sağlandı	49 milyon dolar
2019, 5 Kasım	Vindax	Bilinmeyen	500.000\$
2019, 11 Temmuz	Bitpoint	Güvenliği ihlal edilmiş sunucular	32 milyon dolar
2019, 27 Haziran	Bittrue	Güvenliği ihlal edilmiş sunucular	4,5 milyon dolar
2019, 6 Haziran	Gatehub	Bilinmeyen	9,5 milyon dolar
2019, 7 Mayıs	Binance	Sıcak cüzdana erişim sağlandı	40 milyon dolar
2019, 29 Mart	Bithumb	Bilinmeyen	29 milyon dolar

2019, 25 Mart	Coinbene	Şüpheli iç kullanıcı	40 milyon dolar
2019, 24 Mart	DragonEX	Bilinmeyen	1 milyon dolar
2019, 15 Şubat	Coinmama	Veri sızıntısı	450.000 kullanıcı bilgisi
2019, 1 Şubat	Cryptopia	Bilinmeyen	16 milyon dolar
2019, 26 Ocak	LocalBitcoins	Sahte sitede kimlik avı verileri	27.000 \$
2018, 28 Ekim	Maplechange	Şüpheli iç kullanıcı	51.000 \$
2018, 14 Eylül	Zaif	Sıcak cüzdana erişim sağlandı	60 milyon dolar
2018, 18 Haziran	Bithumb	Bilinmeyen	31 milyon dolar
2018, 10 Haziran	Coinrail	Bilinmeyen	40 milyon dolar
2018, 13 Nisan	CoinSecure	Şüpheli iç kullanıcı	3.5 milyon dolar
2018, 10 Şubat	Bitgrail	Şüpheli iç kullanıcı	146 milyon dolar
2018, 27 Ocak	CoinCheck	Bilinmeyen	560 milyon dolar
2017, 20 Aralık	EtherDelta	Güvenliği ihlal edilmiş DNS	1.4 milyon dolar
2017, 5 Temmuz	Bithumb	Bilinmeyen	7 milyon dolar
2017, 22 Nisan	Yapizon	Sıcak cüzdana erişim sağlandı	5,3 milyon dolar
2016, 2 Ağustos	Bitfinex	Bilinmeyen	623 milyon dolar
2016, 9 Mayıs	Gatecoin	Sıcak cüzdana erişim sağlandı	2,14 milyon dolar
2016, 7-9 Nisan	Shapeshift	Şüpheli iç kullanıcı	230.000\$
2016, 16 Şubat	BTER	Bilinmeyen	1,75 milyon dolar
2015, 11 Aralık	Bitstamp	Kötü amaçlı yazılım	5 milyon dolar
2015, 15 Ağustos	BTER	Şüpheli iç kullanıcı	1,65 milyon dolar
2014, 13 Temmuz	Mintpal	Sıcak cüzdana erişim sağlandı	2 milyon dolar
2014, 4 Mart	Poloniex	Sıcak cüzdana erişim sağlandı	50.000\$
2014, Şubat	Mt. Gox	Çeşitli metodlar	460 milyon dolar
2013, 11 Kasım	Bitcash	Güvenliği ihlal edilmiş sunucular	100.000\$
2012, 12 Eylül	Bitfloor	Güvenliği ihlal edilmiş sunucular	250.000\$
2012, 1 Mart	Bitcoinica	Güvenliği ihlal edilmiş sunucular	\$87.000

(Kaynak: www.hedgewithcrypto.com, 2023)

Kripto varlıklar bir şekilde ele geçirildikten sonra gerçek hayatta harcanabilmesi için mevcut finansal sisteme dahil edilmeleri gerekmektedir. Genellikle yine kripto borsaları aracılığıyla banka hesabına aktarılmaktadır. Kripto kabul eden pazar yerlerinin yaygınlaşması ile alışverişte de kullanılmaktadır. İzinin sürülmesinin zor olması nedeniyle Darknet'te kanun dışı işlemlerin finansmanı için kullanılması da anlaşılması kolay bir kullanımdır.

Tablo 2.6 Çalınmış kripto paraların kullanıldığı yerler

Kullanılan alanlar	%
Sahte borsalar	48%
Kimlik Doğrulaması gereksinimleri olmayan borsalar	37%
Kimlik Doğrulaması gereksinimleri olan borsalar	4%
Mikserler	4%
Diğer*	3%
Çevrimiçi cüzdanlar	2%
Darknet Pazar yerleri	1%
Ödeme işlemcileri	1%
* %1'den daha az alan varlık türlerini içermektedir (Kumar hizmetleri, ATM'ler, Dolandırıcılık, Çevrimiçi pazar yerleri, Madencilik şirketleri, Darknet hizmetleri, Fidyeye yazılımı dağıtıcıları)	

(Kaynak: www.cointelegraph.com, 2023)

2.7.Kripto Para Kavramı

Kripto paralar merkezi otorite ve banka vb. kurumlar gibi aracı olmadan, kullanıcıların transfer işlemlerini gerçekleştirilebildiği fiziksel olmayan paralar şeklinde tanımlanabilir. Sistemin güvenliği sağlayan kullanıcılar o para birimi ile ödüllendirilir.

Kripto paralar en başından beri para olarak adlandırılrsa da paranın değişim aracı olması özelliğini yakın zamana kadar sağlayamamıştır. Kripto paraların en büyüğü ve ilk olan Bitcoin ve ikinci sırayı paylaşan Ethereum artık ticarete ödeme aracı olarak kullanılmaya başlamıştır. Bu yönüyle kripto paralar geleneksel anlamda para kavramına yaklaşmıştır.

Tablo 2.7 Kripto Paraların Özellikleri

Türler	Özellikler	Fonksiyonlar
Operasyonel Özellikler	İşlem geri çekilemez.	İşlem onaylanırsa iptal edilemez.
	Kimlik gerektirmez.	Operatörlerin iş akışları tespit edilirken kimlik bilgilerine ulaşamaz.
	Hızlı ve küreseldir.	Kripto para birimlerindeki işlemler anında dağıtılır ve birkaç dakika içinde onaylanır.
	Güvenlidir.	Kripto para birimleri, sistem sahibi tarafından özel bir şifreleme ile korunmaktadır.
	Daha az bürokrasi vardır.	Kripto para almak ve göndermek için herhangi bir izin süreci gerekmemektedir.
Finansal Özellikler	Arzı sınırlanabilir.	Kripto para arzı belli bir noktaya kadar sınırlanabilir.
	Borçlanma Özelliği Yoktur.	Şirketlerin şu anda kripto para ile borç almadıkları belirlendi.
	Parasal işlevi vardır.	Fonksiyonel olarak para kabul edilmemektedir.
Finansal Olmayan Özellikler	Garanti ve garantör yoktur.	Kripto para birimleri merkezi olmayan bir şekilde dağıtıldığından, hükümet veya kuruluşlar bu işlemlerden sorumlu değildir.
	Dijital cüzdanı vardır.	Kripto para birimleri bir Sanal hesap aracılığıyla alınıp satılmaktadır.
	Volatilite var.	Değerleri talebe bağlı olarak artabilir ve değişkenlikleri risk ile ilişkilidir.
	Maddi olmayan bir varlıktır.	Talebe göre değerleri artabilir, değişkenlikleri riskle ilişkilidir.

Kaynak: (Demirkan vd., 2021)

2.8.Kripto Para Olarak Bitcoin

Geleneksel para birimlerinin aksine, Bitcoin tamamen sanaldır. Kendi başına fiziksel paralar ve hatta dijital paralar yoktur. Kripto paralar, göndericiden alıcıya değer aktaran işlemlerin konusunu teşkil eder. Bitcoin sahipleri, Bitcoin ağındaki Bitcoin'in sahipliğini kanıtlamalarına izin veren genel ve özel anahtarlar sahiptir. Bu anahtarlar ile isterlerse sanal değeri diğer kullanıcılara devredebilir.

Bitcoin kendi başına değer taşımadığı için Bitcoin'in finansal sistemde yerinin olması için kullanıcılar tarafından sürekli desteklenmesi gerekir, sürekli popüler olması gerekir. Çünkü Bitcoin'in mevcut piyasa değeri sadece onu değerli görenlerin sisteme koyduğu değerler ile mümkün olabilmektedir. Geleneksel para birimlerinde ise durum böyle değildir. Örneğin Amerikan dolarının değerinin koruyucusu

Amerikan Merkez Bankası, garantörü ise Amerikan ekonomisinin kendisidir. Amerikan ekonomisi güçlü olduğu müddetçe Amerikan dolarının dünyada geçerliliği olacaktır. Tarihte güçlü devletlerin güç gösterisi olarak altın para bastıkları görülmektedir. Bazıları gümüş, bazı devletler ise diğer alışimlardan madeni para basmışlardır. Basılan bu paraların arasında değer farkı sadece basımında kullanılan alışımın değerinden kaynaklanmaz. Onu basan devletin ekonomisinin gücü paranın satın alma gücünü etkiler.

Kripto paraların en ilki ve en büyüğü olan Bitcoin'in piyasa değerinin bir garantörü yoktur. Aksine bu para gücünü merkeziyetsiz olmasından almaktadır. Bitcoin sisteminin en önemli koruyucusu matematik ve bu matematiği çalışmasını sağlayacak işlemci gücünü tedarik eden madencilerdir. Bu madenciler de dünyanın herhangi bir yerinde yeterli donanım, elektrik ve internet ile bu görevi yerine getirmektedir.

Kripto para olan Bitcoin geleneksel para tanımına en yakın olana kripto değerdir. Kripto para dünyasında paranın fonksiyonlarını yerine getirmeye en yatkındır. *Paranın değişim aracı olması fonksiyonunu* kısmen sağlamaktadır. Artık birçok büyük şirket Bitcoin'i ödeme aracı olarak kabul etmektedir. Paypal gibi bir ödeme sisteminin Bitcoin'i kabul etmesi, Paypal kullanan onlarca ülkede Bitcoin ile alışveriş imkanını ortaya koymuştur.

Tablo 2.8 Bitcoin Kabul Eden 10 Uluslararası Şirket

1	Microsoft
2	Twitch
3	Rakuten
4	PayPal
5	Overstock
6	Whole Foods
7	Etsy
8	Starbucks
9	Newegg
10	Home Depot

Kaynak: (www.finance.yahoo.com, 2022)

Bitcoin bazı yenilikçi şirketler tarafından ödeme aracı olarak kabul edilmesinin yanında, Bitcoin sektörel anlamda da alışverişte kullanılmaktadır. Kripto para ile ticaretin yaygın olduğu sektörler şunlardır(Gürsoy, 2021):

- Finans Sektörü
- Gayrimenkul endüstrisi
- Sağlık sektörü
- Devlet kurumları
- Muhasebe
- Eğitim sektörü
- Tedarik Zincirleri

Bitcoin fiyat hareketliliğinin çok olması yani volatilitesini yüksek olması sebebiyle *paranın ölçü birimi olması fonksiyonunu* yerine getirme zorlanmaktadır. Çünkü alışverişte alınan ürün/hizmet karşılığında ödenmesi gereken Bitcoin miktarı sürekli değişmektedir. Dolayısıyla elde tutulan Bitcoin miktarı ile alınabilecek ürün miktarı sürekli farklı olmaktadır.

Yine Bitcoin volatilitesinin yüksek olması *sebebiyle paranın değer saklama aracı olması fonksiyonunu* yerine getirmesi zorlaşmaktadır. Ancak kripto paraların popülaritesinin sürekli artması, kullanımını yaygınlaşması sonucunda şu anki Bitcoin satın alma gücünü gelecekte de sağlayabileceği akla yatkındır. Sonuç olarak bu fonksiyonu kısmen sağladığı söylenebilir.

Bitcoin merkez bankaları tarafından basılan diğer para birimlerinden ayıran temel özellikler arasında şunlar sayılmaktadır (Teker vd., 2020):

- Bitcoin Merkezi değildir
- Hesap açma işlemleri kolaydır
- Bitcoin anonimdir
- Bitcoin işlemleri herkese açıktır, şeffaftır.
- İşlem ücretleri önemsiz derecede düşüktür
- Transfer işlemleri hızlıdır. Saniyeler içinde uluslararası para transferi mümkündür.

2.8.1. Bitcoin Arzı, Talebi ve Fiyatının Belirlenmesi

Sanal para olarak Bitcoin'i bir başka birime göndermek isteyen kullanıcı ya da kurum bu işlemi devlet otoritesinden ve garantisinden bağımsız olarak gerçekleştirir. Bu transfer işlemine hiçbir kamu birimi dahil olmadığı için garantör olarak güvenilecek en kuvvetli konsept matematiktir. Sanal paranın üretilmesi, gönderilmesi ve saklanması blokzincir teknolojisi ile birlikte mümkündür. Yani işlem altyapısını hazırlayan blokzincir sisteminin kendine has kuralları sürekli olarak işlemektedir.

Yerel para birimlerinin arzı ülke yöneticileri tarafından sağlanmaktadır. Yeni para basılması ya da kredilerin teşvik edilmesi sonucu para arzının genişletilmesi ekonomi yönetiminin elindedir. Mikro ve makro hedefler doğrultusunda istenildiği kadar para basılabilmesi, bazı durumlarda tasarruf sahipleri için tehdit oluşturmaktadır. Her basılan yeni para ile paranın satın alma gücü zayıflar ve tasarruflar aynı ölçüde erimektedir.

Tablo 2.9 Bitcoin arz istatistikleri

Mevcut Toplam BTC	19,195,400
Çıkarılacak Bitcoinler	1,804,600.0
Çıkarılan Bitcoinlerin Yüzdesi	91,41%
Günlük çıkarılan Yeni Bitcoin	900
Çıkarılmış Bitcoin Blokları	761,264

Kaynak: www.buybitcoinworldwide.com, 2022

Kripto paralarda anlatılan durum benzer olmakla birlikte, kripto para arzı tamamen kısıtlanabilmektedir. Bitcoin'in maksimum para arzı 21 milyon BTC olarak sınırlandırılmıştır. Kasım 2022 itibariyle yaklaşık Bitcoin arzı 19 milyon 195 bin BTC'dir.

Bitcoin'in mevcut arzı, maksimum arzı ve henüz çıkarılmamış olan arzı basit bir matematik olmasının yanında çoğu çevrelerce tam anlaşılamamaktadır. Bitcoin ağında bulunan Bitcoinlerin sayısı yazıldığı kod ile en başında 21 milyon BTC olarak sınırlandırılmıştır. Ancak bu miktarın tamamı henüz dolaşımda değildir. Dolaşımdaki miktarı kullanıcılar tarafından birbirlerine kolaylıkla gönderilmekte iken, henüz kullanımda olmayan kısım para transferinin güvenliğini ve geçerliliğini sağlayan madencilere ödül olarak dağıtılmaktadır. Dolaşımda olmayan kısım madenciler marifetiyle çıkarılıp kullanıma girmektedir.

Bitcoin'in arzının sınırlı olması uzun vadede değerinin artması için tasarlanmış bir mekanizmadır. Bu yönüyle altına benzetilebilir. Bitcoin'den sonra çıkan altkoinlerde de benzer bir mekanizma işler. Bazılarında arz belirli bir miktar ile kısıtlanmış, bazılarında ise kısıtlı olan miktar koinlerin yakılması diğer bir ifadeyle kullanılmayacak bir duruma getirilmesi sayesinde değerinin artırılması planlanmıştır.

Bitcoin özelinde kripto paraların fiyatı diğer bütün mallarda olduğu gibi arz ve talebin birbiriyle buluştuğu noktada ortaya çıkar. Ancak Bitcoin'in arzının sınırlı olduğuna göre, diğer bir ifade ile alınmak istenildiği takdirde 21 milyon BTC'den daha fazla alınamadığı bilindiğine göre; Bitcoin'in fiyatını talep belirler demek yanlış olmaz.

2.8.2. Bitcoin'in Ortaya Çıkış Süreci ve Tarihsel Gelişimi

Bitcoin (BTC) kavramı, ilk olarak 2008 yılında Satoshi Nakamoto tarafından ortaya atılmış, takip eden yılda, yani 2009 yılında hayata geçirilmiştir. İlk zamanlarında, yalnızca meraklı bir grup tarafından konuşulan 1 BTC'nin değeri, sıfır dolara yakın bir seviyededir. Ancak, 13 yılın ardından Bitcoin, finans piyasaları haricindeki insanlar tarafından dahi tanınır hale gelmiştir.

Grafik 2.1 Bitcoin fiyatı



(Kaynak: <https://www.barchart.com>,2023)

Grafik 2.1'e bakıldığında, Aralık 2022'de yaklaşık 16.500 dolar değeri ile Bitcoin, başlangıç değeri ile karşılaştırıldığında 18 milyon kat değer kazanmıştır. Eğer, değerinin tarihi zirvesinde hesaplanması yapılabilseydi, 4 kat daha değerli olurdu.

Tablo 2.10 Bitcoin Yıllara Göre Getirisi

Tarih	Bitcoin Fiyatı (\$)	Değişim (\$)	Yıllık Yüzde Getiri
1.01.2023	16625,08	-31061,73	-65,14
1.01.2022	47686,81	18312,66	62,34
1.01.2021	29374,15	22173,98	307,96
1.01.2020	7200,17	3356,65	87,33
1.01.2019	3843,52	-9813,68	-71,86
1.01.2018	13657,20	12658,88	1268,01
1.01.2017	998,33	563,99	129,85
1.01.2016	434,33	120,09	38,21
1.01.2015	314,25	-439,97	-58,33
1.01.2014	754,22	740,92	5569,07
1.01.2013	13,30	8,03	152,12
1.01.2012	5,28	4,98	1659,16
1.01.2011	0,30	0,21	249,45
1.01.2010	0,09	0,00	0

(Kaynak: www.in2013dollars.com, 2023)

Bitcoin 70 Milyon kat değer kazandığı zaman dilimini grafik 2.1'deki fiyat hareketlerine göre 3 bölümde özetleyebiliriz.

2009-2016 Yılları

2009 yılı, Bitcoin'in doğuş yılı olarak kabul edilir. Bitcoin, blokzincir teknolojisiyle birlikte ortaya çıkmış ve tarihte ilk olarak kabul görmüştür. Bitcoin'in ilk fiyatı sıfır olarak belirlenmiştir. Kurucusu, Satoshi Nakamoto olarak bilinen, bitcoin beyaz kitabını yayınlamıştır.

2010 yılı, Bitcoin'in ilk "büyük" atlamasını gerçekleştirmiştir. Fiyat, nisan ayında birkaç santimden yaz aylarında \$0.09'a yükselmiştir. Çok az insan, özellikle nicel teknoloji uzmanları ve finans hayranları, Bitcoin hakkında yeterli bilgiye sahip olduğu için para almıştır. Ekim ayında, fiyat yaklaşık \$0.10 olarak belirlenmiştir.

2011 yılında, Bitcoin \$1'ı aşmıştır ve ilk mini "boğa koşusu"na girmiştir. 3 ay içerisinde yaklaşık %3,000 artmış ve haziran ayında \$29-\$32 arasında zirve yapmıştır.

Kasım ayında, fiyat tekrar \$2'ye düşmüştür. İlk yılın geri kalanı, Bitcoin için önemli bir gelişme olmamıştır. 2012 yılı, \$13-\$14 arasında tamamlanmıştır.

2013 yılı, Bitcoin için önemli bir yıl olarak kabul edilir. Yılı \$13.28 seviyelerinde başlamış ve ilk çeyrekte \$30 aralığına yükselmiştir. Mart ayının son haftasında hızlı bir şekilde yükselişe geçmiş ve Nisan ayında \$100'ü aşmıştır. Bu yükseliş, online forumlar aracılığıyla para hayranları ve teknoloji profesyonellerinin ilgisini çekmiştir. Kasım ayında, Bitcoin \$1,000'ı aşmıştır ancak Aralık ayında \$530 seviyelerine düşmüştür. Bu yıl, Bitcoin'in potansiyelini ve volatilitelerini göstermiştir (www.time.com, 2022).

2014-2016 yılları, Bitcoin için genellikle fiyatların durgun olduğu yıllar olarak kabul edilir. Bu yıllar arasında, Bitcoin fiyatları \$1,000 seviyelerine ulaşamamıştır. Bu dönem boyunca, Nelson Merchan gibi Bitcoin yatırımcıları için sabır gerektirmiştir. Bitcoin fiyatları \$100-\$900 arasında dalgalanmış ve yatırımcılar ne olacağını bilememişlerdir. 2017 yılında, Bitcoin \$1,000 seviyelerine tekrar ulaşmıştır ve bu bir boğa koşusunun başlangıcı olarak kabul edilmiştir (https://www.forbes.com, 2023).

2017- 2020 Yılları

2017-2019 yılları, Bitcoin için fiyatların hızla yükseldiği ve önemli bir popülerite kazandığı yıllar olarak kabul edilir. 2017 yılının başlarında, Bitcoin \$1,000 seviyelerine tekrar ulaşmıştır ve bu bir boğa koşusunun başlangıcı olarak kabul edilmiştir. Bu yıllar arasında, Bitcoin fiyatları hızla yükselmiş ve \$20,000 seviyelerine kadar ulaşmıştır. Bu dönemde, Bitcoin yatırımcılarının yanı sıra, bireyler ve kurumlar tarafından da ilgi görmeye başlamıştır. Ayrıca, bu yıllar arasında, Blokzincir teknolojisi ve diğer kripto paralar için de ilgi hızla artmıştır. Bu dönem, Bitcoin ve diğer kripto paraların geleceği hakkında çok fazla spekülasyon yapılmıştır (https://www.forbes.com, 2023).

2020 yılı, COVID-19 pandemisi nedeniyle ekonomik incinmelerin olduğu, yatırımcıların endişeli olduğu, ancak aynı zamanda kripto paralar için önemli bir yıl olarak kabul edilir. Bu yıl, Bitcoin fiyatları önceki yıllarda görülen hızlı yükselişten daha yavaş bir şekilde yükselmiştir. Ayrıca, bu yılın başlarında, Bitcoin halving olayı

gerçekleşmiştir. Halving olayı, Bitcoin madencilerinin ödülünün yarıya düşürülmesi olayıdır ve bu olayın etkisi fiyatlar üzerinde bazı spekülasyonlar yaratmıştır. Bu yıl, ayrıca, kripto paralar için daha fazla yasal düzenlemelerin gerçekleştiği bir yıl olmuştur. Ayrıca, kripto paraların kullanım alanlarının genişlemesiyle birlikte, kurumsal yatırımcıların dahil olması da hızlanmıştır (www.zebpay.com, 2023).

2021 ve Sonrası

2021 yılının başlarında, Bitcoin 2020 yılındaki fiyat rekorunu kırmıştır ve 7 Ocak 2021 tarihinde 40,000 dolar seviyelerine ulaşmıştır. Nisan ortasına kadar Bitcoin fiyatları yeni zirve seviyelerine ulaşmıştır ve 60,000 doların üzerine çıkmıştır. Bu arada kripto paraların ticaretini yapan Coinbase, borsaya açılmıştır. Kurumsal ilgi fiyatları daha da yukarı taşımıştır ve Bitcoin 12 Nisan 2021'de 63,558 dolar seviyelerine ulaşmıştır. Yaz aylarına gelindiğinde fiyatlar yüzde 50 düşmüştür ve 19 Temmuz'da 29,796 dolar seviyelerine gerilemiştir. Eylül aylarında fiyatlar tekrar yükselmiştir ve 52,693 dolar seviyelerine yükselmiştir ancak iki hafta sonra 40,710 dolar seviyelerine gerilemiştir. Kasım ayında Bitcoin tekrar tüm zamanların rekorunu kırmıştır ve 68,789 dolar seviyelerine ulaşmıştır. Aralık ayında fiyatlar 46,164 dolar seviyelerine gerilemiştir. Ocak 2022 ile Mayıs 2022 arasında Bitcoin fiyatları yavaş yavaş düşmüştür ve Mart ayı sonunda 47,445 dolar seviyelerine gerilemiştir ve Mayıs ayının 11'inde 28,305 dolar seviyelerine düşmüştür. Bu, Temmuz 2021'den beri Bitcoin'in 30,000 dolar seviyelerinin altına düştüğü ilk kez olmuştur. Haziran ayında kripto paraların fiyatları düşmüştür ve Bitcoin 13 Haziran'da 23,000 dolar seviyelerinin altına gerilemiştir. Kasım 2021'den 2022 yılı sonuna kadar 20,000 dolar seviyelerinin altına gerilemiştir (https://www.investopedia.com, 2022).

2.8.3. Bitcoin ve Blokzincir'in Avantaj ve Dezavantajları

Kripto paralar ve özellikle Bitcoin hakkında farklı görüşler vardır. Bitcoinin bir avantajı bakış açısına bağlı olarak dezavantaj da sayılabilir. Bitcoin'in avantajları arasında kolayca para transferi yapılabilmesi, güvenli olması, anonim olması ve dünya çapında kabul görmesi sayılabilir. Ancak, dezavantajları arasında fiyatının volatil olması, yasadışı faaliyetlerle ilişkilendirilmesi ve merkezi bir otoritenin olmaması yer

alır. Bu nedenle Bitcoin ve diğer kripto paraların geleceği hakkında endişeler devam etmektedir.

Bitcoinin en temel avantajlarından bazıları şunlardır (Bunjaku vd., 2017):

i. *Bitcoin Güvenliği*

Bitcoin işlemleri, madenciler tarafından gerçekleştirilen matematiksel işlemler kullanılarak doğrulanır. Bu, işlemlerin yürütülmesini sağlamak için gereken enerji miktarını artırır ve böylece işlemlerin dolandırıcılıktan korunmasını sağlar. Ayrıca, Bitcoin cüzdanları, kullanıcıların kripto para birimlerini saklamaları için güvenli bir yerdir.

ii. *Anonimlik*

Bitcoin işlemleri, kullanıcıların kişisel bilgilerini gerektirmez. Kullanıcılar, cüzdanlarının adreslerini kullanarak işlem gerçekleştirir. Bu nedenle, işlemler isimsizdir ve kişisel bilgilerin ifşa edilmesi gerekmez.

iii. *İşlem hızı*

Bitcoin işlemleri bankalar veya başka kurumlar aracılığıyla yapılmadığı için işlemler çok hızlı gerçekleşmektedir. Genellikle işlemler 10-15 dakika içinde gerçekleşir. Ayrıca Bitcoin işlemleri herhangi bir saat ve gün sınırlaması olmaksızın gerçekleştirilebilir.

iv. *Merkezi olmayan yapı*

Bitcoin ağının merkezi bir otorite tarafından denetlenmediği anlamına gelir. Ağda tüm işlemleri yöneten ve kontrol eden merkezi bir sunucu yoktur. Bunun yerine, tüm işlemler yüzlerce veya binlerce dağıtılmış sunucu tarafından gerçekleştirilir. Bu sunucular, ağın bir parçası olarak katılımcılar tarafından yönetilir ve herhangi bir kuruluşun ağın işleyişini etkileyemeyeceği veya manipüle edemeyeceği garanti edilir. Bu yapı, Bitcoin sahiplerinin kural koyma yetkisi olmadığı anlamına gelir ve ağın bir kısmı çalışmasa bile ödeme sistemi stabil bir şekilde çalışmaya devam eder.

v. *Enflasyon olmaması*

Enflasyon bir ekonomide para biriminin zaman içinde değerinin düşmesi ve mal ve hizmet fiyatlarının artmasıdır. Bitcoin sistemi 21 milyon Bitcoin ile sınırlıdır ve bu düzeni değiştirebilecek hiçbir siyasi güç veya örgüt yoktur. Dolayısıyla sistemde enflasyon söz konusu değildir. Bu özellik, Bitcoin'in diğer itibari para birimlerine

kıyasla daha güvenli bir yatırım aracı olarak kullanılmasını sağlar. Bu sınırlı arz, Bitcoin fiyatının yükselmesine ve yatırımcıları çekmesine neden olmaktadır.

Bitcoin kullanımına bağlı olarak dezavantajları da şu şekilde sıralanabilir (cs.stanford.edu, 2023):

i. *Bitcoin'in yaygınlaşması*

Bitcoin yalnızca az sayıda çevrimiçi mağaza tarafından kabul edilmektedir. Bunun sonucu olarak, Bitcoin'i bütün finansal işlemlerde kullanmak mümkün değildir. Ayrıca, hükümetler kullanıcı işlemlerinin izlenebilmesi için mağazaların Bitcoin kullanımını yasaklayabilirler.

ii. *Volatilite*

Bitcoin'in değeri talebe bağlı olarak sürekli değişmektedir. Bu sürekli dalgalanma, Bitcoin kabul eden sitelerin fiyatlarını sürekli değiştirmesine neden olabilecektir. Ayrıca, geri ödeme talebinin karşılanması da zorlaşabilir.

iii. *Alıcı korumasının bulunmaması*

Satıcı tarafından taahhüt edilen malların gönderilmemesi durumunda, Bitcoin ile satın alınan ürünler geri alınamaz.

iv. *Deflasyon*

21 milyon Bitcoin ile sınırlı olduğu için deflasyon oluşacaktır. Toplam Bitcoin sayısı azaldıkça her bir Bitcoin daha değerli hale gelecektir. Bu sistem erken benimseyenleri ödüllendirmek için tasarlanmıştır. Her geçen gün daha da kullanışlı hale gelen Bitcoin'in ne zaman harcanacağı konusu elzem hale geliyor. Bu, harcama artışlarına neden olabilir ve Bitcoin ekonomisini hızlı ve öngörülemez bir şekilde değişken hale getirebilir.

v. *Güvenlik Riskleri*

Bitcoin sistemi siber saldırılara ve hilelere karşı daha savunmasız olduğundan, güvenliği sağlamak kullanıcının sorumluluğundadır. Cüzdan şifresini kaybeden veya cüzdan bilgilerini sızdıran kullanıcılar, Bitcoin'lerini kaybedebilir. Ayrıca, Bitcoin madencilerinin saldırılarının %51'i sistemi manipüle edebilir ve kullanıcıların Bitcoin'lerini kaybetmelerine neden olabilir.

vi. *Regülasyon Riskleri*

Bitcoin, hükümetlerin kontrol etmediği bir para birimi olduğundan, hükümetler tarafından yasaklanma riski taşır. Ayrıca hükümetler, Bitcoin kullanılarak yapılan işlemleri izlemek için mahremiyet ve anonimliği ortadan kaldırabilecek yasal mekanizmalar oluşturabilir.

Sonuç olarak, Bitcoin kullanmanın avantajları ve dezavantajları vardır. Kullanıcılar kendilerine en uygun olanı seçmeli ve dikkatli olmalıdır. Bitcoin'in gelecekte benimsenmesi, hükümetlerin ve kuruluşların politikalarına, güvenliğini artırmaya ve yasal mekanizmalar oluşturmaya bağlı olacaktır.

2.9. Altcoinler

Altcoinler, Bitcoin dışındaki dijital para birimleridir. Bunlar, Bitcoin'in yerini alabilecek veya Bitcoin'in özelliklerini geliştirerek farklı özellikler sunabilecek dijital para birimleridir. Altcoin'ler, Bitcoin'in kullanımını ve işlevlerini genişletmek için tasarlanmıştır ve genellikle merkezi değildir. Örnekler arasında Ethereum, Litecoin, Ripple, Bitcoin Cash gibi popüler altcoinler yer almaktadır.

2.9.1. Altcoin tanımı

Altcoin, "alternatif" ve "coin" kelimelerinin birleşiminden oluşur. Bu terim genellikle Bitcoin dışındaki tüm dijital para birimlerini kapsar. Altcoinler, özellikle onlar için tasarlanmış olan blok zincirlerine aittir. Birçokları, Bitcoin ve Ethereum gibi diğer blok zincirlerinden ayrılmıştır. Bu ayrılmalar genellikle farklı nedenlerle gerçekleşir. Çoğu zaman, geliştiriciler arasında anlaşmazlıklar çıkar ve kendi dijital para birimlerini oluşturmak için ayrılırlar (www.investopedia.com, 2023).

2.9.2. Stabil Coinler

Stabilcoin'lerin ortaya çıkması çeşitli faktörler tarafından tetiklenmiş olup finansal sistemin farklı yönleri üzerinde etkileri bulunmaktadır. Stabilcoin'ler, volatilitiyi azaltma potansiyeli ve alternatif bir yatırım aracı sunma özellikleri nedeniyle popülerlik kazanmışlardır. Bitcoin ve Ethereum gibi geleneksel kripto

paralara kıyasla daha istikrarlı bir değer sunarak, dalgalanmalardan daha az etkilenmek isteyen yatırımcılar için cazip bir varlık haline gelmişlerdir (Kyosev vd., 2022).

Stabilcoin, genellikle belirli bir varlık veya bir varlık sepetine bağlı olarak istikrarlı bir değere sahip olacak şekilde tasarlanmış bir kripto para birimidir. Stabilcoin'lerin temel amacı, Bitcoin ve Ethereum gibi popüler kripto paralarla sıklıkla ilişkilendirilen fiyat dalgalanması sorununa çözüm getirmektir (Trotter vd., 2020).

Ancak, stabilcoin'lerin istikrarı konusunda bazı endişeler bulunmaktadır. Bazı akademisyenler, stabilcoin'lerin sürekli olarak belirli bir aralıkta bir değer sürdürebilme yeteneğini sorgulamaktadır. Merkez bankası gibi bir merkezi otoriteden bağımsız olmaları, stabilcoin'lerin uzun vadede istikrarlarını koruma konusunda şüpheler doğurmaktadır. Merkez bankası dijital para birimi şeklinde stabilcoin'lerin çıkarılması, daha güvenilir ve istikrarlı bir değer sağlayabileceği iddia edilmektedir (Hairudin vd., 2020).

Regenerate responseStablecoinler genellikle faizsiz olduğu için sahiplerine bir fayda sağlamazlar. Ancak kripto dünyasındaki volatiliteden kısa süreli olarak sakınmak için kullanılmaktadırlar.

2.9.2.1. Tether (USDT)

Tether, sabit değerli bir dijital varlıktır ve ABD dolarının fiyatına sabitlenmiştir. Amacı, Tether'in her zaman sabitlenen değerle aynı değere sahip olmasıdır. Sürekli olarak 1 Tether 1 Dolar'a eşittir.

Tether, kripto piyasasının volatilitelerinden kaçınmak isteyen yatırımcılar için popüler bir seçenek olarak kabul edilmektedir. Bu sebeple, Tether, kripto para borsalarında yaygın olarak işlem görmekte ve diğer kripto paralarla takas edilebilmektedir. Tether'in diğer önemli özelliklerinden biri de, gerçek dünya paraları ile bağlantılı olarak işleyebilmesi ve gerçek dünya işlemlerinde kullanılmasına olanak tanımasıdır. Bu, Tether'in kullanım alanlarını genişletir ve daha fazla kişinin kullanmasına olanak tanır. Özetle, Tether, sabit değerli dijital varlık olarak tasarlanmıştır ve kripto piyasasının volatilitelerinden kaçınmak isteyen tüccarlar ve yatırımcılar için popüler bir seçenektir. Tether, gerçek dünya paraları ile bağlantılı

olarak işleyebilir ve kripto para borsalarında yaygın olarak işlem görmektedir (www.forbes.com, 2023).

2.9.2.2.USD Coin (USDC)

USD Coin (USDC), tamamen rezerve edilmiş bir stablecoin'dir ve ABD doları ile değer eşitliğini sağlamak için yaratılmıştır. USDC, fiat-collateralized bir stablecoin'dir ve bir merkeziyetsiz dijital varlıktır. (www.investopedia.com, 2023)

Muhasebe şirketi Grant Thornton bu ayrılmış hesapları denetler ve aylık onay raporları sunar. USDC ile ABD doları arasındaki 1:1 sabitlik nasıl sağlanır? Eğer bir USD Coin satın almak için fiat parayı kullanırsanız, o zaman o fiat paraya yatırılır ve 1 ABD doları olarak depolanır ve yeni USDC çıkarılır. Eğer bir USD Coin'i fiat para karşılığında satarsanız, o zaman fiat para hesabınıza geri transfer edildiğinde USDC yok edilir. USDC, Ethereum, Algorand, Solana, Stellar ve TRON gibi birçok blokzincir ile uyumludur (www.investopedia.com, 2023).

2.9.2.3.Binance USD (BUSD)

BUSD, Paxos ve Binance tarafından oluşturulan ve rezervde tutulan ABD doları ile desteklenen bir stablecoin'dir. New York State Department of Financial Services tarafından düzenlenir ve belirteç arzı ile Paxos tarafından tutulan rezervler arasında 1:1 oranını korumak için tasarlanmıştır. BUSD tokenlerinin oluşturulması ve yakılması, yasa dışı faaliyet durumunda hesapların dondurulması ve fonların kaldırılması ve Tröste bağlılık dahil olmak üzere New York Eyaleti Mali Hizmetler Departmanı tarafından uygulanan özel düzenlemelere tabidir (www.binance.com, 2023).

BUSD, tamamen teminatlandırılmış, tamamen denetlenebilir ve token arzı ile Paxos'un rezervleri arasında 1:1 oranında çalışan, düzenlenmiş bir stablecoin'dir. Paxos'un sağladığı düzenli denetimler ve şeffaflık, BUSD'yi piyasadaki diğer stablecoin'lerden ayırır (www.binance.com, 2023).

2.9.3. Başlıca Altcoinler

Bitcoin haricindeki diğer bütün bütün kripto paralar olarak tanımlayabileceğimiz altcoinlerin başlıcaları şunlardır.

2.9.3.1.Ethereum (ETH)

Ethereum, 2015 yılında piyasaya sürülen bir kripto para ve blokzincir platformudur. Bitcoin'in temel ilkelerini benimsemesine rağmen, önemli farklılıkları vardır. Her ikisi de dijital para kullanmanıza olanak tanır ve bankalar veya ödeme sağlayıcılarına ihtiyaç duymaz. Ancak Ethereum, programlanabilir olduğu için merkezsiz uygulamaların inşasına ve yayınlamasına olanak tanır. Ethereum'un programlanabilirliği, blokzincir'i veri saklamak veya uygulamanızın yapabileceklerini kontrol etmek için kullanabileceğiniz uygulamalar yaratmanıza olanak tanır. Ethereum'un yapabilecekleri için sınır yoktur, bu nedenle Ethereum ağı üzerinde büyük bir yenilik potansiyeli vardır. Bitcoin sadece bir ödeme ağıdır, Ethereum ise gizliliğinizi ve sansürlenemezliğinizi koruyan finansal hizmetler, oyunlar, sosyal ağlar ve diğer uygulamaların bir pazar yeridir. Ethereum'un yapabilecekleri arasında herkes için bankacılık, daha gizli bir internet, eşten eşe bir ağ, sansürlenemezlik ve sözleşmelerde güvence yer almaktadır (www.ethereum.org, 2022).

2.9.3.2.BNB (BNB)

BUSD, Paxos ve Binance tarafından kurulan bir stablecoin'dir. Paxos, blokzincir teknolojisini kullanarak Stablecoin hizmetlerini dış şirketlere sunmaktadır. BUSD tokenlerinin oluşturulması ve yakılması, yasa dışı faaliyet durumunda hesapların dondurulması ve fonların kaldırılması ve Tröste bağlılık dahil olmak üzere New York Eyaleti Mali Hizmetler Departmanı tarafından uygulanan özel düzenlemelere tabidir (www.binance.com, 2022).

BUSD, tamamen teminatlandırılmış, tamamen denetlenebilir ve token arzı ile Paxos'un rezervleri arasında 1:1 oranında çalışan, düzenlenmiş bir stablecoin'dir. Paxos'un sağladığı düzenli denetimler ve şeffaflık, BUSD'yi piyasadaki diğer stablecoin'lerden ayırır (www.binance.com, 2022).

2.9.3.3.Terra (LUNA)

Luna, Terraform Labs tarafından geliştirilen Terra blokzincir'in doğal token'ıdır. \$32 milyon özel satış yoluyla toplanmıştır ve yatırımlar Binance, Huobi ve OKEx gibi merkezileşmiş kaynaklardan gelmektedir. Kurucu ekip Daniel Shin tarafından yönetilmektedir ve fintech portföy şirketi HOF'u kurmuştur. Luna 2019 yılında lansman yapmış ve bir süre decentralize finans coin'lerinden biri olarak başarılı olmuştur. Ancak son zamanlardaki düşüşle birlikte, 1 Haziran 2022 itibariyle 214. sırada yer almaktadır.

Terra LUNA'nın amacı, kripto paraların serbestliği ile fiat paraların istikrarını birleştirmek için stablecoin'ler yaratmaktır ve staking veya protocol token olarak tanımlanmıştır. Blokzincir, UST ve LUNA arasında çift token sistemi uygulamıştır ve UST, LUNA yakarak üretilir ve ayrıca LUNA ile değiştirilebilir. LUNA coin'i yakma, dinamikte önemli rol oynamakta ve kullanıcıları LUNA'nın değerini ve, teoride UST'nin istikrarını vermektedir. Mayıs 2022 krizi öncesinde LUNA coin'in dolaşımda olmasına izin verilen miktar 1 milyardı ve bu sayı aşıldığında LUNA yakılıyordu. 1 Haziran 2022 itibariyle, orjinal LUNA, şimdi CoinMarketCap'e göre dolaşımda olan 6.5 trilyon adet LUNC olarak yeniden adlandırılmıştır (www.currency.com, 2023).

2.9.3.4.Solana (SOL)

Solana, Ethereum ile benzerlikler taşıyan hızlı büyüyen bir blokzincir'dir. Sıklıkla "Ethereum killer" olarak adlandırılır. SOL token çoğu büyük borsada satın alınabilir ve gerçek değeri Solana ağında işlem yapmaktır. Solana blokzincir'i, proof-of-history consensus mekanizmasını kullanır. Bu algoritma, Solana zincirinin sonraki bloğunu tanımlamak için zaman damgalarını kullanır. Solana, Ethereum co-founder Vitalik Buterin tarafından belirlenen ölçekleme, güvenlik ve merkeziyetsizlik üçgeninde iki sorunu çözmeye odaklanmıştır. Solana, proof-of-history ve delegated PoS algoritmalarının benzersiz bir kombinasyonu ile Ethereum ve Cardano (ADA) gibi rakiplerinden önemli ölçüde daha hızlı işlem hızlarını ve daha az maliyetleri

sunmaktadır. Bu, Solana'nın öne çıkan özelliklerinden biridir ve rakiplerinden ayrılmasını sağlamaktadır (www.forbes.com, 2022).

2.9.3.5.Cardano (ADA)

Cardano, ADA ile çalışan bir blokzincir'dir. Ethereum blokzincir'i ile bazı yönlerde benzerdir. Bitcoin'i Crypto 1.0 olarak düşünün. Temel olarak dijital altındır ancak sistem ölçekleme sorunları ile sıkışmıştır. Daha sonra Ethereum var, sıklıkla Crypto 2.0 olarak adlandırılır. Cardano, 2017 yılında lansman yaptı ve amacı Ethereum'un başlangıçta eksik olan işlevselliği geliştirmektir. Cardano'yu kurucusu Charles Hoskinson'dur ve aynı zamanda Ethereum'un ortak kurucusudur. Hoskinson, 2014 yılında Ethereum projesinin ticari olup olmayacağı konusunda ortak kurucu Vitalik Buterin ile anlaşmazlık nedeniyle Ethereum ekibi ile arasına açıldı. Hoskinson, Bitcoin ve Ethereum'u geliştirmek amacıyla daha ölçeklenebilir, uyumlu ve sürdürülebilir bir blokzincir olan Cardano'yu lansman yaptı. Cardano, 'Ethereum Killer' olarak tanımlanan destekçiler tarafından desteklenmektedir ve Cardano Vakfı ve IOHK araştırma enstitüsü tarafından geliştirilmektedir (www.forbes.com, 2022).

2.9.3.6.Avalanche (AVAX)

Avalanche, dijital dünyada çok zincirli yapıların ve uygulamaların oluşmasını ve işletilmesini sağlamak için tasarlanmış bir blokzincir platformudur. Bu platform, çok zincirli yapıların ve uygulamaların oluşması ve işletilmesi için gerekli olan araçları ve teknolojileri sunar. AVAX adlı yerli kripto para birimi, Avalanche ağının işletilmesi için gerekli olan enerji kaynağıdır. Bu token, ağda işlem yapmak veya ağın belirli bölümlerine erişmek için kullanılabilir.

Avalanche, Ethereum ile tamamen uyumlu olduğu için, Ethereum smart contract'larının aynı kod ile Avalanche üzerinde deploy edilebildiği gibi, Ethereum token'larının da Avalanche Bridge aracılığıyla taşınabildiği özellikleri ile öne çıkmaktadır. Bu sayede, Avalanche, Ethereum'daki ölçekleme sorunlarını çözmeye çalışmaktadır. Aynı zamanda, Avalanche, güvenli, hızlı ve enerji verimli olması amaçlanan kendine özgü bir konsensus mekanizması olan Avalanche consensus'u kullanmaktadır. Bu mekanizma sayesinde, Avalanche ağı, dünya çapındaki

kullanıcılar tarafından kullanılabilir ve ölçeklenebilir hale getirilmiştir (www.fool.com, 2023).

2.9.3.7.Dogecoin (DOGE)

Dogecoin, 2013 yılının sonlarında Billy Marcus ve Jackson Palmer tarafından kodu yazılmış bir kripto para birimidir. Dogecoin'in logosu, o zamanlar popüler olan bir meme'i kullanarak markalaştırılmıştır. İlk günlerinde, Dogecoin'in profilini yükseltmek için tanıtım gösterileri düzenlenmiştir. 2021 yılının başlarında Reddit'in WallStreetBets mesaj panosunda popüler hale gelmiştir. Dogecoin, 2021 yılının başlarında bir kuruşun biraz altındaki bir değere kıyasla 0,68 dolara yükselmiştir. Dogecoin, kendi özel blokzincirde çalışır ve madenciler tarafından işlemleri işlemek için kullanılır. Ancak, Dogecoin'in sınırsız sayıda yaratılması nedeniyle, yani Dogecoin'lerin sınırsız sayıda üretilebildiği için kripto paranın tasarım olarak oldukça enflasyonist bir yapıya sahiptir (www.forbes.com, 2023).

2.9.4. Token

Tokenler, genellikle blok zincirlerinde kayıt girdileri olarak var olan, maden edilemeyen değerli dijital birimlerdir. Tokenler fonksiyonlarına göre kullanılabilirlik tokenleri ve güvenlik tokenleri olarak sınıflandırılır. Kullanılabilirlik tokenleri genellikle bir hizmete erişimin temsilcisi olur veya bir ekosistem içinde para birimi olarak çalışabilir. Güvenlik tokenleri ise finansal varlıkları temsil eder. Örneğin, bir şirket ICO sırasında tokenize hisse senetleri yayımlayabilir ve sahibine sahiplik hakları ve temettüler verir. Yasal açıdan, bu geleneksel olarak dağıtılan hisse senetlerine benzerdir (www.academy.binance.com, 2023).

Kripto tokenlar, blokzincir teknolojisi ile birlikte dünya genelinde hızla yayılan dijital varlıklardır. Bu tokenlar, bir nesneyi, gerçek bir varlığı veya bir hizmeti temsil edebilirler. Kripto tokenlar, bazı özelliklerine göre sınıflandırılabilir. Bu sınıflandırmaların başında, değer tokenları, kullanım tokenları ve güvenlik tokenları gelir (www.forbes.com, 2023).

Değer tokenları, bir sanat eseri, müzik veya bir başka dijital varlık gibi bir değer nesnesinin temsilcisidir. Değer tokenları, NFT'lerin en yaygın örneğidir.

NFT'ler, blokzincirdeki benzersiz bir koda sahip ve bu kod, bir kripto tokenin bütünlüğünü sağlar. Değer tokenları, bir varlık gibi değerlidirler ve sahiplerine sahip oldukları nesnenin mülkiyet hakkını verirler (www.forbes.com, 2023).

Kullanım tokenları, blokzincirde birtakım işlemlerin gerçekleştirilmesi için kullanılır. Bu tokenlar, blokzincirdeki ağın ve merkezi olmayan uygulamaların verimli bir şekilde çalışmasını sağlamaya yardımcı olurlar. Fayda tokenları, bir hizmetin kullanımı için gerekli olan hakları sağlarlar. Örneğin, bir araç paylaşım uygulaması için bir fayda tokenı satın alırsanız, uygulamanın kullanım hakkına sahip olursunuz (www.forbes.com, 2023).

Güvenlik tokenları, bir varlığın sahipliğini temsil ederler. Şirketler, sermaye artırmak için özkaynak tokenları satarak güvenlik tokenlarını kullanabilirler. Güvenlik tokenları, bir finansal güvenliğin sahipliğini temsil ederler ve bu nedenle Menkul Kıymetler ve Borsa Komisyonu (SEC) tarafından düzenlenirler. Bu tokenlar, diğer tokenlar gibi benzersiz değildirler, bu nedenle homojendirler. Güvenlik tokenları, bir finansal araç olarak hizmet verirler ve sahiplerine bir varlığın sahipliğini temsil etme hakkını verirler. Bu nedenle, güvenlik tokenları, diğer kripto tokenlardan farklı bir varlık sınıfı olarak kabul edilirler (www.forbes.com, 2023).

2.10. Araştırmanın Hipotezleri

Bu çalışma, Bitcoin fiyat hareketliliğinin öngörülebilirliği üzerine odaklanmaktadır. Bu bağlamda, hipotezimiz şu şekildedir:

H0: Bitcoin fiyat hareketliliği, kripto para sistemine ait verilerin yanı sıra dünya endekslerine ait verilerin de incelenmesiyle öngörülebilir ve makine öğrenmesi algoritmaları ile doğru bir şekilde tahmin edilemez.

H1: Bitcoin fiyat hareketliliği, kripto para sistemine ait verilerin yanı sıra dünya endekslerine ait verilerin de incelenmesiyle öngörülebilir ve makine öğrenmesi algoritmaları ile doğru bir şekilde tahmin edilebilir.

Bu hipotezi test etmek için, öncelikle Bitcoin fiyat hareketliliğinin nasıl öngörülebileceği araştırılacak ve bir veri seti oluşturulacaktır. Veri seti, kripto para sistemine ait verilerin yanı sıra dünya endekslerine ait verileri de içerecektir. Daha

sonra, makine öğrenmesi algoritmaları kullanılarak Bitcoin fiyat hareketliliğinin doğru bir şekilde tahmin edilip edilemeyeceği test edilecektir.

Bu araştırmanın sonuçları, Bitcoin fiyat hareketliliğinin öngörülebilirliği üzerine daha iyi anlayış sağlayabilir ve finansal karar vericilerine Bitcoin yatırımları hakkında daha bilinçli kararlar vermelerine yardımcı olabilir.



ÜÇÜNCÜ BÖLÜM

BİTCOİN FİYAT HAREKETLİLİĞİNİN MAKİNE ÖĞRENMESİ İLE TAHMİN EDİLMESİ

Makine öğrenimi, büyük miktardaki veriyi analiz etme ve desenleri ile trendleri belirleme yeteneği sayesinde fiyat tahmini için güçlü bir araçtır. Bitcoin gibi kripto paraların fiyatlarını tahmin etmede makine öğrenimi modellerinin etkinliğini gösteren çalışmalar bulunmaktadır.

Bitcoin gibi kripto paraların merkezi olmayan yapısı ve doğal fiyat oynaklığı, onları makine öğrenimi teknikleri kullanarak çalışmak ve modellemek için ideal adaylar haline getirir (Mudassir vd., 2020). Makine öğrenimi, Bitcoin fiyatlarının durağan olmayan davranışını etkili bir şekilde yakalayabilir; burada verinin istatistiksel dağılımı zaman içinde değişmektedir.

Wang ve Yan'ın (2023) yaptığı başka bir çalışma, Bitcoin'in nicel ticareti için geleneksel makine öğrenmesi modellerinin uygulanmasına odaklanmıştır. Çalışma sonucu, 30 günlük hisse fiyatı değişikliklerinin eğilimini tahmin ederken makine öğrenmesi sınıflandırma modellerinin, Bitcoin'in günlük ve yüksek frekanslı ticaret fiyat değişikliklerini tahmin etmede istatistiksel yöntemleri geride bıraktığını göstermektedir.

Bitcoin'in günlük ve yüksek frekanslı ticaret fiyat değişikliklerini öngörmek amacıyla istatistiksel yöntemleri geride bıraktığı ortaya konulmuştur. Bu sebep ile Bitcoin'in fiyat hareketliliğinin etkileyen faktörlerini tahlil etmek ve bu faktörlerin fiyat üzerindeki etkisini tespit ederek fiyat tahmini yapabilmek adına makine öğrenimi yaklaşımı tercih edilmiştir. Bu hedef doğrultusunda, iki ayrı veri kategorisi kullanılmıştır. Kripto para sistemine özgü 350 farklı değişken ile uluslararası düzeyde etkili olan 46 farklı değişken, veri kaynakları olarak seçilmiştir.

Başlangıçta, 2022 yılının tamamının analize dahil edilmesi amaçlanmıştır. Ancak, Bitcoin gibi volatilitesi yüksek bir enstrüman için 1 yılın çok uzun bir süre olduğu düşünüldüğünden, araştırmada kullanılan zaman aralığı daraltılmıştır. Araştırmada 2022-10/2022-12 arasındaki tarihi kapsayan günlük veriler kullanılmıştır. Veriler %85 eğitim, %15 test verisi olarak ikiye bölünmüştür. Eğitim sonrasında test verisi tahminleri görselleştirilmiştir.

Makine öğrenmesi algoritmaları kullanılarak seçilen algoritma ile test verileri tahmin edilmiş ve gerçek sonuçlarla karşılaştırılmıştır. Bu çalışmanın metodolojisi, veri kaynaklarının seçimi, verilerin toplanması, verilerin işlenmesi ve analizi, makine öğrenmesi algoritmalarının değerlendirilmesi ve sonuçların görselleştirilmesi adımlarından oluşmaktadır.

3.1.Çalışmanın Amacı, Kapsamı ve Sınırları

Bu çalışmanın temel amacı, Bitcoin'in fiyat hareketlerini tahmin etmek amacıyla kullanılan makine öğrenmesi yöntemlerini kullanarak, Bitcoin fiyatını etkileyen faktörleri tespit etmektir. Bu çerçevede, kripto para birimlerinin fiyat değişikliklerine neden olan faktörlerin analizi, gelecekteki fiyat hareketlerini anlamayı artırmak ve daha etkili risk yönetimi stratejileri geliştirmeyi hedeflemektedir.

Bu araştırma, Bitcoin fiyat tahmini yapmak amacıyla makine öğrenmesi modellerini kullanmaktadır. Makine öğrenmesi, istatistiksel analizler yoluyla verilere dayanarak gelecekteki olayları tahmin edebilme yeteneğine sahip bir sistemdir. Finansal piyasalardaki hızlı ve ani değişiklikler göz önüne alındığında, kısa vadeli verilerin kullanılması gerekliliği vurgulanmıştır. Çalışmada, hem kripto para ekosistemi hem de küresel ekonomik değişkenlerin Bitcoin fiyatını etkileyebileceği öngörülmektedir.

Bu çalışma, belirli sınırlılıklar çerçevesinde yürütülmüştür. Öncelikle, Bitcoin fiyat hareketlerini etkileyen tüm faktörlerin analiz edilmesi her zaman mümkün olmayabilir. Ayrıca, kripto para piyasasının yüksek volatilitesi nedeniyle, veri toplama süreci sırasında dar bir zaman aralığı seçilmiştir. Bu, uzun vadeli eğilimlerin göz ardı edilmesine yol açabilir. Bununla birlikte, kullanılan makine öğrenmesi algoritmalarının başarısı, algoritma seçimi kadar veri setinin kalitesi ve işlenmesi gibi faktörlere de bağlıdır. Son olarak, bu çalışmanın sonuçları, kullanılan veri setinin ve algoritmaların özelliklerine dayanmakta olup, gelecekteki piyasa koşullarına dair kesin tahminler sunma amacı taşımamaktadır.

3.2. Veri Toplama ve Ön İşleme

Araştırmada kullanılan veriler iki temel kategori altında toplanabilir. **Kategori 1'de** bulunan Kripto para sistemine ait verilerin tamamı Bitcoin ve diğer kripto paralar ile ilgilidir ve 350 farklı değişkenden oluşmaktadır. Verilerin ana başlıklar altında sınıflandırılması Tablo 3.1'de, kullanıların verilerin tanımları EK1'de gösterilmiştir.

Tablo 3.1 Kategori 1 'de kullanılan değişkenler

Ağ Bilgileri	Network Hashrate (kod blokundaki bir işlemin tamamlanma hızı)
	Miner Outflows (Madenci Çıkışları)
	Miner Reserves (Madenci Rezervleri)
Kripto Borsa İşlemleri	Borsaya giriş yapılan toplam işlem hacmi (USD)
	Belirli bir kripto para biriminin borsaya giriş yapılan işlem hacmi (USD)
	Belirli bir kripto para biriminin borsadan çıkış yapılan işlem hacmi (USD)
	100.000 USD veya daha büyük işlem hacmi (USD)
	Ortalama işlem değeri (USD)
Adres Verileri	Toplam adres sayısı
	Hodler (kripto parayı elde tutan) adres sayısı
	Büyük sahiplerin (en az %0.1) giriş ve çıkışları
	Gerçekleşmiş karlar ve zararlar
	Belirli bir kripto para biriminin belirli bir günde bir veya daha fazla on-chain işlem yapan adres sayısı
Fiyat verileri	Belirli bir kripto para biriminin belirli bir dönemdeki long pozisyon oranı
	Belirli bir kripto para biriminin belirli bir dönemdeki short pozisyon oranı
	Belirli bir kripto para biriminin spot fiyatı
	60 günlük fiyat değişim oranı
Sosyal Medya Verileri	Twitter'da belirli bir kripto para birimi hakkında olumsuz söylemler içeren mesaj sayısı
	Twitter'da belirli bir kripto para birimi hakkında olumlu söylemler içeren mesaj sayısı

Kategori 2'de yer alan önemli Dünya Endekslerine ait 46 farklı değişkenden oluşmaktadır. Verilerin ana başlıklar altında sınıflandırılması Tablo 3.2'de, kullanıların verilerin tanımları EK2'de gösterilmiştir.

Tablo 3.2 Kategori 2 'de kullanılan değişkenler

Tahvil Endeksleri	Devlet tahvillerinin faiz oranlarını gösteren endekslerdir ve ekonomik eğilimleri tahmin etmek için kullanılırlar.
Enerji Endeksleri	Petrol ve doğalgaz gibi enerji kaynaklarının fiyat performansını gösteren ve enerji sektörüne yatırım yapanların takip ettiği endekslerdir.
Dövizler	Dünya para birimlerinin birbirleri karşısındaki değerini gösteren ve döviz yatırımcıları tarafından takip edilen endekslerdir.
Volatilité Endeksi	Piyasadaki belirsizlik düzeyini gösteren ve risk yönetimi stratejilerinde kullanılan endekslerdir.
Hisse Senedi Endeksleri	Şirketlerin borsa performansını gösteren endekslerdir ve borsa yatırımcıları tarafından takip edilir.

3.3. Veri Kaynakları

Bu araştırmada, iki farklı veri kaynağı kullanılmıştır. Kategori 1'de bulunan Bitcoin ve altcoinlerin fiyat ve hacim bilgileri Tradingview vasıtasıyla Binance Borsası'ndan, ağ bilgileri ise Tradingview kanalı ile alt borsalardan elde edilmiştir. Bu veriler, kripto para piyasasının genel performansını ve kripto para birimlerinin fiyat hareketlerini yansıtmaktadır.

Kategori 2'deki veriler ise Yahoo Finance'den elde edilmiştir. Bu veri kaynağı, DOW Jones, S&P 500 ve NASDAQ gibi dünya endekslerini içermektedir. Bu veriler, geleneksel finans piyasalarının genel performansını yansıtmaktadır.

Veri toplama sürecinde, her iki veri kaynağından toplam 396 değişken elde edilmiştir. Bu değişkenler, araştırmacıların finansal piyasaların genel performansını ve kripto para birimlerinin fiyat hareketlerini incelemelerine olanak tanımaktadır.

3.4. Veri Ön İşleme

Veri ön işleme teknikleri, verilerden anlamlı bilgi çıkarmak için önemlidir. Veri temizleme, verilerdeki gürültüyü gidermek ve tutarsızlıkları düzeltmek için kullanılır. Veri birleştirme, farklı kaynaklardan gelen verileri uygun bir veri tabanında birleştirir. Veri dönüştürme yöntemleri, verileri normalleştirerek veya indirgeyerek veri madenciliği için hazırlar. Bu teknikler veri madenciliği için kaliteli sonuçlar elde etmek ve zaman kazanmak için uygulanır (Oğuzlar, 2003).

Veri temizleme ve dönüştürme işlemleri, araştırmacıların elde ettikleri verileri analiz etmek için kullanılabilecek şekilde hazırlamalarına yardımcı olur. Bu işlemler, verilerin doğruluğunu ve güvenilirliğini artırmak için önemlidir. Bu bölümde,

araştırmada kullanılan verilerin temizleme ve dönüştürme işlemleri ayrıntılı olarak açıklanmaktadır.

Eksik değerlerin doldurulması, belirli bağlama ve veri türüne bağlı olarak çeşitli yöntemlerin kullanılabileceği önemli bir veri işleme sürecidir. Araştırmacılar ve veri analistleri, eksik verilerin etkili bir şekilde ele alınması için çeşitli yöntemleri kullanmışlardır.

Basit tamamlama teknikleri yaygın şekilde kullanılmıştır. Bu tekniğe göre eksik veriler sıfır, ortalama, medyan veya rastgele değerler gibi istatistiksel değerler ile doldurulmaktadır (Anggraeny vd., 2018).

Bazı durumlarda, bir yerel komşu ortalaması yöntemi kullanılabilir. Bu yaklaşım, eksik değerlerin önceki ve sonraki komşularının ortalamasının alınarak eksik değeri hesaplanmasını baz almaktadır. Ek olarak, komşular arasındaki farka bağlı olarak eksik değerlerin hesaplanmasını ayırt etmek için bir eşik parametresi kullanılabilir (Flores vd., 2019).

Eksik değerleri doldurmak için geriye doldurma yaklaşımı kullanılabilir. Bu yöntem, eksik değerleri veri setindeki en yakın mevcut değerle değiştirme işlemi içermektedir (Agca ve Mansi, 2008).

Bu yöntemler, eksik değerleri önceki değer veya komşu değerlerin bir kombinasyonunu kullanarak veri setinde doldurma yöntemlerini mümkün kılmaktadır. Bu teknikler kullanılarak eksik değerlerin yerine konması, daha eksiksiz ve doğru veri analizine imkân sağlamaktadır.

Eksik değerleri silmek, örnekleri azaltacak, bilgi kaybına neden olacak ve deneysel sonuçları etkileyecektir (Q.-M. Zhou ve Xiping, 2019). Veri setindeki özniteliklerin tamamını analize dahil etmek için eksik veriler silinmemiştir. Çalışmada kripto borsalarının hafta sonu açık olması nedeniyle, diğer borsalar kapalı olduğu için eksik veriler bir önceki verinin kopyalanması şeklinde doldurulmuştur. Kapalı borsalardaki en son fiyatın sabit olduğu ve kripto borsalarında veri akışının sürekli olduğu durumda, literatürde de sıkça kullanılan geriye dönük eksik veri doldurma işlemi gerçeğe daha yakındır.

Bitcoin fiyatı, volatilitesi yüksek olduğu için makine öğrenmesi algoritmalarının en ufak fiyat değişikliğine tepki vermemesi için bin dolar olarak ifade edilmiştir.

İstatistikte, z-puanı, belirli bir ölçümün bir popülasyon ortalamasının üzerinde veya altında kaç tane standart sapma olduğunu açıklayan bir ölçüdür. Verileri standardize etmek ve bireysel gözlemleri bir popülasyonla karşılaştırmak için kullanılmaktadır (Curtis vd., 2016). Analizde kullanılan veriler z-score yöntemi kullanılarak normalleştirilmiştir. Bu işlem, verilerin farklı ölçeklerde olması durumunda etkili sonuçlar elde etmek için önemlidir. Bu sayede, verilerin arasındaki farklılıkların neden olduğu yanlış yorumlama ve hatalar en aza indirgenmiştir.

Verilerin öncelikle temizlenmesi gerekmektedir. Bu kapsamda, araştırmada kullanılan veri setinde eksik verilerin çıkarılması işlemi gerçekleştirilmiştir. Kategori 1'deki 350 değişkenin tamamı kullanılmamış, eksik verisi bulunan değişkenlerin veri setinden çıkarılmasıyla sadece 73 değişken seçilerek analiz için kullanılmıştır. Kategori 2'deki 46 değişken de benzer şekilde, eksik verisi bulunan değişkenlerin veri setinden çıkarılmasıyla sadece 32 değişken analiz için kullanılmıştır. Bu sayede, verilerin daha anlamlı ve kullanışlı olması sağlanmıştır.

Bu işlemler, verilerin araştırmacılar tarafından doğru bir şekilde yorumlanmasına ve sonuçların güvenilirliğinin artmasına yardımcı olur. Veri temizleme ve dönüştürme işlemlerinin ayrıntılı olarak açıklanması, araştırmacının okuyucuları tarafından daha iyi anlaşılmasını sağlar. Ayrıca, gelecekteki araştırmalar için de bir rehber niteliği taşır.

3.5.Öznitelik Seçimi

Makine öğrenmesi modellerinin doğru ve genellenebilir tahminlerde bulunabilmesi için kullandığı değişkenlerin analizdeki rolünün belirlenmesini içerir. Bu değişkenler öncelikle titizlikle seçilmelidir, çünkü modelin performansı doğrudan bu seçilmiş özniteliklere bağlı olacaktır. Modelde yapılan öznitelik seçimi adımları sırasıyla açıklanmıştır.

3.5.1. Düşük Varyansa Sahip değişkenlerin kaldırılması

Doğru tahminler veya sınıflandırmalar yapmada etkili olarak öğrenme sürecine katkıda bulunacak özelliklerin modelleme için seçilmesini sağlamak için veri setini dikkatlice değerlendirmek ve önışlemek son derece önemlidir. Bir veri seti birden fazla

seviyeye sahip bir öznitelik içerdiğinde, bu seviyelerin dağılımı dengesiz olabilir ve diğerlerine göre belirli bir seviyenin belirgin şekilde daha baskın olması mümkündür. Sonuç olarak, bu özellik veri setine çok fazla varyans veya değerli bilgi katkısı sağlamamaktadır.


Makine öğrenmesi modelleri bağlamında, her bir özelliğin ilgisi ve önemi dikkate alınması önemlidir. Bu durumda, çeşitlilik eksikliği ve bir seviyenin ezici baskınlığı nedeniyle, bu kategorik özelliğin modele dahil edilmesi, önemli ölçüde ek bilgi sağlamayabilir. Sonuç olarak, bu özelliğin modelleme sürecinden çıkarılması mümkün ve mantıklı hale gelir. Bu özelliğin çıkarılmasıyla model, diğer daha bilgilendirici özelliklere odaklanabilir, performansını artırabilir ve dağılım dengesizliğinden kaynaklanabilecek olası önyargıları veya aşırı uyumu önleyebilir (Pycaret Documentation, 2023).

Çalışmada, düşük varyansa sahip öznitelikleri olarak tespit edilerek model oluşturma sürecinden kaldırılmıştır. Bu sayede, modelin performansı artırılmış ve daha etkili bir öznitelik seçimi sağlanmıştır.

3.5.2. Aykırı değerlerin ayıklanması

İstatistikte, aykırı değer olarak adlandırılan gözlem verisi, diğer tüm verilere sayısal olarak uzak olan bir gözlem değeridir. Örneğin, bir örneklemden diğer üyelerden önemli ölçüde sapma gösteren bir gözlem değeri ise aykırı bir değer olarak tanımlanabilir. Aykırı değerler genellikle hata veya gürültü olarak görülmelerine rağmen, önemli bilgiler de taşıyabilirler. Aykırı değerlerin varlığı çoğunlukla bir model uyum sorunu veya ölçüm hatası gibi bir soruna işaret ettiği için, etkili bir analiz için öncelikle tespit edilmeleri önemlidir (Oyeyemi vd., 2015).

Şekil 3.1 Aykırı değerlerin belirlenmesi



Araştırmada aykırı değerleri belirlemek için Şekil 3.1 yardımıyla 0.07 değeri kullanılmış ve bu değer üzerindeki veriler aykırı kabul edilerek modelden kaldırılmıştır. Bu işlem, modelin daha doğru sonuçlar üretmesine yardımcı olmuştur.

3.5.3. Çoklu doğrusallığın kaldırılması

Çoklu doğrusal regresyon analizinde, çoklu doğrusallık terimi, bağımsız değişkenler arasında yüksek derecede korelasyon olduğu durumu ifade eder. Bu durum, bağımsız değişkenlerin yalnızca bağımlı değişkenle değil, birbirleriyle de anlamlı şekilde ilişkili olduğunda ortaya çıkarmaktadır. Bu korelasyon, bazı önemli değişkenlerin istatistiksel olarak anlamsız hale gelmesi gibi regresyon analizinde sorunlara yol açabilir (Shrestha, 2020).

Yakob vd. (2012) konvansiyonel hayat sigortacıları ve takafil işletmelerinin ödeme gücü belirleyicileri üzerine yaptıkları analizde, bağımsız değişkenler arasındaki çoklu doğrusallık sorununu ele almıştır. Bağımsız değişkenler arasında istatistiksel olarak anlamlı korelasyonlar olduğuna dikkat çekerek, çoklu doğrusallık nedeniyle katsayıların yorumlanması konusunda endişelerin olduğunu vurgulamıştır.

Li vd. (2020) bir kamu-özel ortaklık projesinin değerlendirmesinde indeksler arasındaki çoklu doğrusallığı azaltmak ve etkisi az olan faktörleri ortadan kaldırmak

için açıklayıcı faktör analizi (AFA) yöntemini kullanmıştır. AFA, boyutları azaltmaya ve çoklu doğrusallık sorununu çözmeye yardımcı olmuştur.

Bu çalışmalar, çoklu doğrusallık sorununun regresyon analizinde karşılaşılan önemli bir zorluk olduğunu ve bu sorunu ele almak için istatistiksel yöntemlerin kullanılabileceğini göstermektedir. Araştırmacılar, bu tür sorunları tespit etmek ve etkisini azaltmak için istatistiksel yöntemlerin yanı sıra uygun değişken seçimi ve modelleme tekniklerini de dikkate almaktadırlar (Li vd., 2020; Shrestha, 2020; Yakob vd., 2012).

Çalışmada, öznelilikler arasındaki 0.9 üstü kolineerlik, tam kolineerliği sayılmış ve bunlar veri setinden kaldırılmıştır.

Öznelilik seçimi aşamasında veri setindeki gereksiz özneliliklerin çıkarılması, aykırı değerlerin ayıklanması ve kolineer özneliliklerin kaldırılması gibi teknikler kullanılarak veri seti daha sade ve daha anlamlı hale getirilmiştir. Bu işlemlerin sonucunda, model performansı artırılmış ve gereksiz özneliliklerin etkisi azaltılmıştır.

3.5.4. Boyut İndirgeme

Temel Bileşen Analizi (PCA), yüksek boyutlu verilerin analizinde boyut azaltma için yaygın olarak kullanılan istatistiksel bir araçtır (Hung vd., 2012). Verilerin keşfedilmesinde önemli bir araç olan Temel Bileşen Analizi (PCA), büyük varyanslara sahip yapıları tercih eden bir çözüm sunan geleneksel bir yaklaşıma dayanmaktadır. Bu yaklaşım, aykırı değerlere hassas olabilir ve ilgi çekici alt yapıları belirsizleştirebilir (Akinduko ve Gorban, 2014).

PCA, sofistike matematiksel prensipleri kullanarak bir dizi olası korele değişkeni, temel bileşenler adı verilen daha az sayıda değişkene dönüştüren bir teknik için genel bir terimdir. Genel olarak PCA, büyük veri setlerinin boyutunu azaltmak için bir vektör uzayı dönüşümü kullanır. Matematiksel projeksiyon yardımıyla, birçok değişkeni içeren orijinal veri seti, genellikle sadece birkaç değişkenle (temel bileşenler) yorumlanabilir hale gelmektedir. Bu nedenle, azaltılmış boyutlu veri setinin incelenmesi, kullanıcının verilerdeki trendleri, desenleri ve aykırı değerleri, temel bileşen analizi yapmadan önce mümkün olandan çok daha kolay bir şekilde belirlemesini sağlamaktadır (Richardson, 2009).


PCA, veri setindeki değişkenlerin birbirleriyle olan ilişkilerini göz önünde bulundurarak, değişkenler arasındaki bağımlılıkları en aza indirgeyerek veri setindeki boyutu azaltır. Bu yöntemle, veri setindeki değişkenlerin varyansının büyük bir bölümünü koruyarak, boyut azaltma işlemi gerçekleştirilir. Bu, verilerin daha anlaşılabilir ve daha az boyutlu hale getirilmesine olanak tanır. Bu çalışmada, PCA algoritması ile veriler 3 boyuta indirgenmiştir.

PCA algoritması sonucunda elde edilen veri setindeki boyutların önem derecesi ölçülebilir. PCA algoritması, verilerin boyutunu azaltırken, verilerin varyansını da hesaba katmaktadır. Bu nedenle, her bir bileşenin varyansı, veri setinin özellikleri hakkında bilgi sağlamaktadır. Örneğin, ilk bileşenin varyansı, veri setindeki en yüksek varyansa sahiptir ve veri setindeki en önemli özneliği temsil etmektedir.

Verilen bilgiye göre, PCA algoritması sonucunda 3 boyuta indirilen veri setinin yüzde olarak varyans açıklama oranları şu şekildedir:

- İlk bileşenin varyansı: 39.43692323
- İkinci bileşenin varyansı: 18.72248772
- Üçüncü bileşenin varyansı: 9.95660597

Şekil 3.2 İndirgenmiş verinin kümülatif varyans açıklama oranı




Bu sonuçlar, her bir bileşenin veri setindeki toplam değişkenliğin ne kadarını açıkladığını göstermektedir. Örneğin, ilk bileşenin varyansı, veri setindeki toplam değişkenliğin %39,43'ünü açıklamaktadır. İkinci bileşenin varyansı ise, veri setindeki

toplam deęişkenlięin %18,72'sini açıklamaktadır. Şekil 3.2'de, toplamda açıklanan %68,11'lik bir varyans oranı gösterilmektedir.

Bu bilgi, her bir bileşenin veri setinin özellikleri hakkında ne kadar bilgi sağladığını göstermektedir. Örneğin, ilk bileşenin varyansı, veri setindeki en yüksek varyansa sahip olduğundan, veri setindeki en önemli öznitelikleri temsil etmektedir. Diğer bileşenlerin varyansı ise, veri setindeki diğer özellikler hakkında bilgi sağlamaktadır.

Şekil 3.3 İndirgenmiş verinin ikili karşılaştırılması



Şekil 3.3 öznitelik seçimi için önemli bir araçtır. Grafik, verilerin boyutsallığını azaltmak için PCA algoritmasının kullanılması sonucu ortaya çıkan deęişkenlerin ikili olarak birbirleriyle olan ilişkisini görselleştirmek için kullanılmıştır. Grafikte, her

özellik bir eksen üzerinde temsil edilir ve her bir nokta, veri setindeki bir gözlemi temsil etmektedir.

Bu grafiğin genel olarak, bileşenler arasındaki ilişkiyi açıklayan bir yorum yapmak zordur çünkü bileşenler orijinal değişkenlere karşılık gelir ve bunların ne olduğu bilinmediği için, hangi ilişkilerin anlamlı olduğu belirsizdir. Ancak, grafikteki alt grafiklerdeki noktaların yayılması, değişkenler arasında bir ilişki olup olmadığını gösterir. Örneğin, bazı alt grafiklerde noktaların düzenli bir şekilde dağıldığı görülebilir, bu da o değişkenler arasında bir ilişki olduğunu söyleyebiliriz.

Köşegen grafiği, her değişkenin histogramını göstermektedir. Grafiğe bakarak dağılımın kabaca simetrik olduğunu söyleyebiliriz. Ancak son değişkenin (Boyut 3) hafifçe çarpık olduğu görülmektedir.


İkili grafiği incelediğimizde, değişkenler arasında güçlü bir doğrusal ilişki olmadığını görüyoruz. Bununla birlikte, bazı dağılım grafiklerinde, özellikle Boyut 1 içeren çizimlerde bazı nokta kümeleri oluştuğu görülmektedir. Bu, Boyut 1'in diğerlerinden bariz şekilde ayrıştığını gösterir. Boyut 2 ve Boyut 3 arasında pozitif bir ilişkinin olduğunu söyleyebiliriz.

Genel olarak, PCA algoritmasının, verilerin boyutunu azaltırken temel yapının bir kısmını koruduğunu göstermektedir. Bu nedenle, öznetelik seçiminde kullanılan önemli bir araçtır ve veri setindeki değişkenlerin ilişkisini anlamak için kullanılabilir.

3.5.5. İndirgenmiş veri setinin görselleştirilmesi

PCA algoritması sonucu 3 boyuta indirgenen verinin 3 boyutlu görselinde, X eksenini Boyut 1, Y eksenini Boyut 2 ve Z eksenini Boyut 3'ü temsil eder. Her nokta, üç boyutta birleştirilen orijinal veriden üretilir ve renk kodlu bir sınıflandırma sonucuna göre gösterilir. Bu veri setinde, farklı renkler farklı grupları temsil eder. Noktaların üç farklı eksen üzerinde dağıtıldığı, farklı grupların farklı yüksekliklerde yoğunlaştığı bir veri seti olduğu gözlemlenmektedir.

Şekil 3.4 İndirgenmiş verinin üç boyutlu görselleştirilmesi



Çalışmada, 105 değişken incelenmiş ve yapılan analiz sonucunda sadece 3 ana değişkene indirgenmiştir. Ancak, bu indirgeme sonucu elde edilen üç boyutlu görselleştirme, yorumlanması oldukça zor olabilmektedir. Daha kapsamlı bir veri analizi ve anlaşılabilir bir yorumlama için daha ileri görselleştirme yöntemleri kullanmak gerekebilir. Bu nedenle, elde edilen verilerin daha net ve anlaşılır bir şekilde yorumlanabilmesi için uygun yöntemlerin kullanımı önemlidir.

T-distributed Stochastic Neighbor Embedding (t-SNE), veri görselleştirmesi ve kümeleme için yaygın olarak kullanılan bir tekniktir. Amaç, veri noktalarının daha düşük boyutlu gömlemelerini bulmak, yerel yapıyı korumak ve komşu veri noktaları arasındaki uzaklıklarda bozulmaları minimize etmektir (Y. Zhou ve Sharpee, 2018).

Bu teknikle t-SNE, orijinal Stochastic Neighbor Embedding (SNE) algoritmasına göre daha hızlı ve daha istikrarlı bir öğrenme sağlamaktadır (Kimura, 2021).

t-SNE'nin güçlü yönlerinden biri, özellik çıkarımı sırasında hem global hem de lokal veri yapılarını koruyabilme yeteneğidir (Gu ve Wang, 2022). Özellikle yüksek boyutlu verileri daha düşük boyutlu bir uzayda görselleştirmede etkilidir, böylece karmaşık veri setlerinin daha iyi anlaşılmasına ve yorumlanmasına olanak sağlamaktadır (Zhang vd., 2020). Tek hücreli transkriptomik ve sitometri alanında, t-SNE, benzer hücrelerin birbirine yakın konumlandırıldığı 2B dağılım grafiğinde bireysel hücreleri noktalar olarak görselleştirmek için yaygın olarak kullanılan bir analiz aracı haline gelmiştir (Kobak ve Linderman, 2021).

t-SNE algoritması iki ana aşamadan oluşmaktadır. İlk olarak, t-SNE benzer objelerin daha yüksek olasılıkla atanacağı bir olasılık dağılımı oluşturur. İkinci olarak ise t-SNE oluşturduğu bu olasılık dağılımını görelî olarak daha az boyutta olan harita üzerinde yeniden oluşturur ve iki dağılımın birbirine görelî olarak yakın olması amaçlanır. Yöntem, benzerlik ölçüsü olarak başlangıçta öklid uzaklığını kullanırken, bunu uygulayacağı veri türüne uygun olarak değiştirme imkânı sunar (Katubi vd., 2023).

Şekil 3.5 indirgenmiş verinin t-SNE manifold tekniği ile görselleştirilmesi



Şekil 3.5 bir t-SNE manifold grafiğini göstermektedir. Bu grafiğin oluşturulmasındaki farklılık, verilerin manifold olarak adlandırılan bir yüzeyde yer almış gibi gösterilmesidir. Bu, verilerin daha iyi bir şekilde ayırt edilmesini sağlar.

Şekil 3.5'te her nokta bir veri noktasını temsil etmektedir. Renkler, her veri noktasının veri setindeki ait olduğu sınıfı temsil etmektedir. Örneğin, veri setindeki kırmızı noktalar bir başka sınıfa ve mavi noktalar bir başka sınıfa aittir.

Dikkat çeken bir diğer nokta, benzer veri noktalarının yakın bir şekilde gruplandırıldığıdır. Örneğin, mavi noktalar birbirine oldukça yakinken, kırmızı noktalar daha uzakta kalmaktadır. PCA algoritması sonrasında 3 boyuta indirgenmiş ve ikili ilişki grafiğinde Boyut 1 diğer iki boyuttan bariz şekilde ayrılmaktadır. Boyut 1 tSNE grafiğinde kırmızı noktalarla temsil edildiğini rahatlıkla söyleyebiliriz. Boyut 2 ve Boyut 3 her ikisi de mavi renkte ve birbirlerine yakın olması verilerin birbirine olan benzerliğini anlatmaktadır.

3.6.Makine Öğrenimi Algoritmaları (Model Seçimi)

Regresyon analizinde, modelin kalitesini ölçmek için birçok istatistiksel yöntem kullanılmaktadır. Bu yöntemlerden biri, bağımlı değişkendeki değişimlerin bağımsız değişkenlerdeki değişimlerle ne kadar iyi tahmin edilebildiğini ölçen R^2 'dir. Belirleme katsayısı, R-kare (R^2) olarak da bilinen, regresyon modelinde bağımlı değişkendeki değişkenliğin bağımsız değişkenler tarafından açıklanan oranını gösteren bir istatistiki ölçüdür (Farida ve diğerleri, 2022).

Belirleme katsayısı (R^2), 0 ile 1 arasında bir sayıdır ve 1'e yakın bir değer daha yüksek bir doğruluk oranı ve daha iyi bir uyum sağlayan bir modeli gösterirken, 0'a yakın bir değer daha az doğru tahminleri ve daha kötü bir uyumu gösterir (American Institute of Certified Public Accountants, 2022).

Tablo 3.3 Makine Öğrenmesi Algoritmalarının Kıyaslanması

Model	MAE	MSE	RMSE	R ²	RMSLE	MAPE	TT (Sec)
K Neighbors Regressor	0,4244	0,3502	0,5231	0,8538	0,0271	0,0233	0,136
Extra Trees Regressor	0,5406	0,5679	0,6723	0,7648	0,0352	0,0301	0,306
Random Forest Regressor	0,5135	0,6473	0,6451	0,7468	0,0336	0,0286	0,573
Extreme Gradient Boosting	0,5341	0,7194	0,6926	0,7269	0,0368	0,0301	0,171
Gradient Boosting Regressor	0,5459	0,8454	0,7162	0,6767	0,0374	0,0304	0,197
AdaBoost Regressor	0,6159	0,9775	0,7996	0,6269	0,0417	0,0343	0,199
Decision Tree Regressor	0,5553	0,9041	0,7627	0,6246	0,04	0,0309	0,133
Bayesian Ridge	0,7444	0,7866	0,8618	0,624	0,0453	0,0411	0,134
Ridge Regression	0,7428	0,7886	0,8627	0,6212	0,0454	0,041	0,694
Least Angle Regression	0,7425	0,7897	0,8632	0,6203	0,0455	0,041	0,349
Linear Regression	0,7425	0,7897	0,8632	0,6203	0,0455	0,041	1,547
Huber Regressor	0,7383	0,819	0,878	0,6063	0,0464	0,0409	0,14
Light Gradient Boosting Machine	0,8265	1,1052	0,9916	0,5211	0,0515	0,0453	0,466
Orthogonal Matching Pursuit	0,9967	1,5383	1,155	0,2991	0,0585	0,0534	0,42
Elastic Net	0,9904	1,3366	1,1126	0,2413	0,0578	0,0539	0,383
Lasso Regression	1,0357	1,4508	1,1641	0,19	0,0605	0,0564	0,385
Lasso Least Angle Regression	1,0357	1,4508	1,1641	0,19	0,0605	0,0564	0,485
Passive Aggressive Regressor	1,089	1,9991	1,3091	-0,3522	0,0714	0,0596	0,133
Dummy Regressor	1,5527	2,9241	1,6832	-0,3867	0,0869	0,0856	0,134

Tablo 3.3’deki “TT (Sec)”, her bir algoritmanın çalıştırılmak için geçirdiği süreyi ifade etmektedir. Tablo 3.3’deki “TT (Sec)” değerlerine bakıldığında, bazı algoritmaların diğerlerine göre daha hızlı çalıştığı, bazılarının ise daha yavaş olduğu görülmektedir. Örneğin, K Neighbors Regressor, en hızlı çalışan algoritma olarak görülmektedir. Buna karşılık, Linear Regression, Lasso Regression ve Dummy Regressor gibi algoritmalar daha yavaş çalışmaktadır. Ancak, bu ölçüte göre sadece bir algoritmanın seçilmesi yeterli değildir, diğer performans ölçütleri ile değerlendirme yapılmalıdır.

Çalışmada, R² ölçütü baz alınarak 18 farklı algoritmanın performanslarının karşılaştırılmıştır. Tablo incelendiğinde, K Komşu Regressor ve Extra Trees Regressor algoritmalarının en yüksek R² değerlerine sahip olduğu görülmektedir. Bu durum, bu algoritmaların diğer algoritmalarla göre daha iyi performans gösterdiğini ortaya koymaktadır. Bununla birlikte, Lasso Regression, Lasso Least Angle Regression, Dummy Regressor ve Passive Aggressive Regressor algoritmalarının ise en düşük

performansı gösterdiği tespit edilmiştir. Çalışmanın dikkate aldığı diğer performans ölçütleri de bu sonucu destekleyerek, bu algoritmaların performans açısından diğerlerine kıyasla daha zayıf olduklarını göstermektedir. Ancak, bu sonuçların elde edilmesinde çalışma süresinin önemsiz kabul edilmesi gerektiğine dikkat çekmek gerekir. Bu noktanın göz ardı edilmemesi, algoritmaların gerçek hayatta uygulanabilirliği açısından önem taşımaktadır.


3.7. Makine Öğrenimi Modelinin Değerlendirilmesi

Makine öğrenimi modelinin etkinliğini değerlendirmek için, kullanılan algoritmanın yaptığı tahminlere ait kapsamlı veri analizleri gerçekleştirildi. Bu analizler, modelin doğruluk, hassasiyet ve özgünlük gibi performans ölçütleri üzerindeki performansını ortaya koymayı amaçlamaktadır.

3.7.1. Makine öğrenimi modeli için tahmin hatası

Grafik seçilen makine öğrenimi algoritmasının performansını değerlendirmek için kullanılan bir diğer araç olan tahmin hata grafiğini göstermektedir. Bir tahmin hata grafiği, model tarafından oluşturulan tahmin değerlerini, veri setinden elde edilen gerçek hedef değerleriyle karşılaştırarak modeldeki değişkenliği görmemizi sağlar (Yellowbrick documentation, 2023). Diğer bir ifadeyle tahmin hata grafiği, gerçek ve tahmin edilen değerler arasındaki farkları ve dolayısıyla modelin ne kadar doğru tahmin yaptığını gösterir.

Şekil 3.6 Tahmin hata eğrisi



Şekil 3.6’da Gözlemlenebileceği gibi, grafikteki noktaların çoğu çizginin etrafında yer almaktadır. Bu da modelin genel olarak iyi bir performans sergilediğini ve tahminlerinin gerçek değerlere oldukça yakın olduğunu göstermektedir. R^2 skoru da 0.909 olarak verilmiştir, bu da modelin ne kadar iyi bir uyum sağladığını ölçer ve 1’e ne kadar yakınsa, o kadar iyi bir uyum sağladığı anlamına gelir. Yüksek bir R^2 skoru, modelin verilere iyi uyum sağladığını ve tahminlerinin doğru olduğunu göstermektedir.

3.7.2. Makine öğrenimi modeli için artıkların incelenmesi

Artıklar, makine öğrenme algoritmasının tahmin ettiği hedef değişkenin gözlenen değerleri ile arasındaki farkları ifade eder. Artık grafiği ise bu hataları tahmin edilen değerlere karşı gösteren bir grafikdir (Stat 462 Course, 2023). Diğer bir ifadeyle artıklar (residuals), modelin bir adım önceden tahmin edilen çıktısı ile doğrulama veri setinden elde edilen ölçülen çıktı arasındaki farklardır. Dolayısıyla, artıklar model tarafından açıklanamayan doğrulama verisinin bir kısmını temsil eder (Matlab Documentation, 2023).


Seçilen makine öğrenme algoritmasının performansını ölçmek için kullanılan bir araç olan artık grafiklerinde, noktalar gerçek ve tahmini değerler arasındaki farkı

gösterir. Eğer bir model mükemmel tahminler yapıyorsa, tüm noktalar sıfır olacaktır. Ancak, herhangi bir sapma varsa, noktalar grafikteki bir çizginin etrafında dağılmış olacaktır. Bu durumda, sapma ne kadar büyükse, noktalar o kadar uzak olacaktır (Stat 462 Course, 2023).

Artıkların grafiklerini yorumlarken, artıkların büyüklüğü ve yönünü dikkate almak önemlidir. Pozitif artıklar, gözlemlenen değerlerin tahmin edilen değerlerden daha yüksek olduğunu, negatif artıklar ise gözlemlenen değerlerin tahmin edilen değerlerden daha düşük olduğunu gösterir (Grosinger et al., 2021). Sıfıra yakın artıklar, model ile veri arasında iyi bir uyum olduğunu gösterirken, daha büyük artıklar uyumsuzluğu veya sistemsel hataları işaret edebilir.

Artık grafiklerini yorumlamak, modelin uyumunun değerlendirilmesi, verideki anormallikleri veya desenleri tespit etme ve farklı modelleri karşılaştırma amacıyla artıkların desenlerini, büyüklüklerini ve yönlerini analiz etmeyi içerir. Bu, araştırmacıların istatistiksel modellerinin doğruluğu ve geçerliliği hakkında bilgi edinmelerine yardımcı olan veri analizinde kritik bir adımdır.

Şekil 3.7 Model artıklarının görselleştirilmesi



Şekil 3.7’de artıkların sıfır çizgisi etrafında rastgele dağıldığı görülmektedir. Bu iyi davranışlı bir artık grafiğinin arzu edilen bir özelliğidir. Bu durum, öngörücü değişkenler ile hedef değişken arasındaki ilişkinin doğrusal olduğunu ve doğrusal ilişki varsayımının makul olduğunu düşündürür.

Grafik ayrıca, seçilen makine öğrenme algoritmasının gerçek değerlerle tahminleri arasında nispeten az bir sapma olduğunu göstermektedir. Noktaların çoğu grafikteki bir çizgiye çok yakın dağılmıştır, bu da modelin genel olarak iyi bir performans sergilediğini göstermektedir.

Grafikte ayrıca, eğitim ve test R^2 skorları da verilmiştir. R^2 skoru, bir modelin ne kadar iyi bir uyum sağladığını ölçer ve 1'e ne kadar yakınsa, o kadar iyi bir uyum sağladığı anlamına gelir. Train R^2 skoru, modelin eğitim verilerine ne kadar iyi uyum sağladığını gösterirken, test R^2 skoru, modelin yeni verilerde ne kadar iyi performans göstereceğini tahmin etmektedir. Test R^2 skoru, modelin yeni verilerde de iyi bir performans sergileme olasılığının yüksek olduğunu göstermektedir.

3.7.3. Makine öğrenimi modelinin doğrulama ve öğrenme eğrileri

Makine öğrenimi modelinin doğrulama ve öğrenme eğrileri, modelin performansını değerlendirmek ve eğitim sürecini anlamak için önemli araçlardır. Modelin performansını değerlendirmek amacıyla bu eğriler incelenmiştir.

3.7.3.1. Makine öğrenimi modelinin öğrenme eğrisi


Öğrenme eğrisi, öğrenme ve deneyim sonucunda zaman içinde performansta veya verimlilikte kaydedilen gelişmeyi ifade eder. Genellikle bir eğri olarak çizilen öğrenme ve performans arasındaki ilişkinin grafiksel bir temsidir (Raja, 2008). Bu eğri, makine öğrenmesi modelinin öğrenme davranışını temsil eden bir grafikdir ve makine öğrenmesi modeli için sağlanan ek verilerin eğitim amaçlı iyi olup olmadığını gösterir. Eğitim puanı ve çapraz doğrulama puanını içerir.

Şekilde “K Neighbors Regressor” için bir öğrenme eğrisi gösterilmektedir. Bu eğri, y-ekseninde puanı, x-ekseninde eğitim örneğini içerir. Çizimde gölgeli alan, standart sapmayı gösterir. Eğitim puanı, eğitim seti için hassasiyet puanını, çapraz doğrulama puanı ise test seti için hassasiyet puanını temsil eder. Eğer bu iki puan, yani

eğitim ve çapraz doğrulama puanı birbirine keserse, bu durum kullanılan verilerin makine öğrenme modeli eğitimi için iyi olmadığı anlamına gelir (Katubi vd., 2023).

Şekil’de görüldüğü gibi eğitim puanı ve çapraz doğrulama puanı kesişmemiş, bu da verinin makine öğrenme modeli eğitimi için yararlı olduğunu gösterir. Eğitim puanı, çapraz doğrulama puanından daha yüksek olduğu için bu, modelin daha fazla eğitim verisine ihtiyaç duyduğunu gösterir.

Grafik 3.1 Modelin öğrenme eğrisi




Grafik 3.1 seçilen makine öğrenimi algoritmasının öğrenme eğrisini göstermektedir. X ekseninde, eğitim örneklerinin sayısı ve y ekseninde, elde edilen skorları gösterir. Grafikte, eğitim örneklerinin sayısı arttıkça, eğitim skoru azalırken doğrulama skoru artar. Başlangıçta, her iki skor da düşüktür ve daha fazla veri örneği kullanıldıkça hem eğitim hem de doğrulama skorları artar. Ancak, daha fazla veri eklemek, performansı artırmak için bir noktadan sonra yeterli olmaz ve doğrulama skoru bir noktada neredeyse sabit kalır. Modelimizde eğitim skoru ve doğrulama skorunun sabit seyretmeye başlayınca çapraz doğrulama sonlandırılmıştır.

3.7.3.2. Makine öğrenimi modelinin doğrulama eğrisi

Bir modelin doğruluğunu ölçmek için, öngörülere göre bir puanlama işlevi kullanmak gereklidir. Hiper parametrelerin bu puanlama işlevine göre optimize edilmesi, genelleme için güvenilir bir tahmin olmaktan çıkar ve önyargılı hale gelir. Doğru bir genelleme tahmini için, test verilerinin kullanılması gereklidir. Ancak,

bazen tek bir hiper parametrenin eğitim puanına ve doğrulama puanına etkisini görselleştirmek, hiper parametre değerlerinin aşırı uygun veya uygun olmayan olup olmadığını belirlemede faydalı olabilir.

Düşük eğitim puanı ve yüksek test puanı, genellikle mümkün değildir. Tahminci, eğitim ve doğrulama puanları düşük olduğunda, az uyumlu olurken, eğitim puanı yüksek ve doğrulama puanı düşük olduğunda, aşırı uyumlu olabilir. Dolayısıyla, hiper parametrelerin optimize edilmesi için uygun bir denge, doğru bir genelleme tahmini elde etmek için gerekli olan bir faktördür (Validation curves: scikit-learn documentation, 2023).



Bu makine öğrenimi algoritması için doğrulama eğrisi, belirli bir hiper parametrenin değerleri ile model doğruluğu arasındaki ilişkiyi göstermektedir. Eksenler arasındaki ilişki şu şekildedir: X eksenini, hiper parametrenin farklı değerlerini temsil ederken, y eksenini, modelin çapraz doğrulama puanlarını temsil etmektedir.

Grafik 3.2 belirli bir hiper parametrenin değerinin model doğruluğu üzerindeki etkisini görselleştirerek en uygun hiper parametre değerini belirlememize yardımcı olmaktadır. Grafiğin incelenmesiyle, hiper parametrenin değeri düşükken başlangıçta modelin yetersiz kaldığı anlaşılmaktadır. Ancak hiper parametrenin değerini

artırdıkça, model eğitim verilerine daha iyi uyum sağlamaya başlar, ancak doğrulama puanı düşer. Bu durum, modelin verilere fazla uydurduğunu göstermektedir.

3.7.3.3.10 kat çapraz doğrulama için makine öğrenimi modelinin performansı

Tablo 3.4 Seçilen algoritmanın 10-kat çapraz doğrulama sonuçları

Fold	MAE	MSE	RMSE	R²	RMSLE	MAPE
0	0,1973	0,0802	0,2832	0,9095	0,015	0,0106
1	0,2096	0,0544	0,2332	0,9628	0,0126	0,0119
2	0,2309	0,0997	0,3157	0,8919	0,0162	0,0123
3	0,3561	0,1736	0,4166	0,9194	0,0209	0,019
4	0,283	0,0983	0,3135	0,9616	0,0151	0,0145
5	0,6791	0,677	0,8228	0,7792	0,0427	0,0357
6	0,3122	0,1165	0,3414	0,9648	0,0188	0,0181
7	0,7035	0,7007	0,8371	0,6307	0,0449	0,0391
8	0,7501	1,1441	1,0696	0,6307	0,0539	0,043
9	0,5223	0,3579	0,5982	0,8877	0,0306	0,0285
Mean	0,4244	0,3502	0,5231	0,8538	0,0271	0,0233
Std	0,2076	0,3511	0,2767	0,1229	0,0142	0,0116

Makine öğrenimi algoritmalarının performansını objektif bir şekilde değerlendirmek için, genellikle verilerin bir kısmı test verisi olarak ayrılır ve öğrenme algoritması bu test verisi üzerinde değerlendirilir. Ancak, bu yöntem bazen aşırı uydurma (overfitting) problemini çözmek için yeterli olmayabilir (Cross-validation: evaluating estimator performance, 2023).

Bu nedenle, makine öğrenimi modellerinin performansını daha doğru bir şekilde değerlendirmek için 10-kat çapraz doğrulama (cross-validation) yöntemi kullanılır. Bu yöntem, veri kümesini 10 farklı parçaya ayırır ve her seferinde farklı bir parça kullanılarak öğrenme modeli eğitilir ve test edilir. Bu sayede, modelin genelleme performansı daha objektif bir şekilde ölçülebilir.

Cross-validation, modelin performansının ölçüldüğü bir tekniktir. Bu tabloda, 10 kez cross-validation yapılmıştır. Her katmanın mutlak hatanın ortalaması (MAE), hata kareler ortalaması (MSE), hata kareler ortalamasının karekökü (RMSE), belirleme katsayısı (R^2), hata kareler ortalamasının karekökü logaritması (RMSLE) ve ortalama mutlak yüzde hata (MAPE) değerleri belirtilmiştir. Ortalama MAE, 0.4244 olarak hesaplanmıştır, bu da tahminlerin ortalama olarak 0.4244 birim kadar gerçek

değerden sapma gösterdiği anlamına gelir. R^2 değeri 0.8538'dir, bu da modelin açıklama gücünün yüksek olduğunu gösterir.

3.8.Makine Öğrenimi Modeli İçin Analiz Döneminin Değerlendirilmesi

Makine öğrenimi modellerinin etkili kullanımı, analiz döneminin seçimine bağlıdır. Bu noktada, belirlenen periyodun özenle seçilmesi büyük bir öneme sahiptir. Bu çalışma bağlamında, ilk aşamada 1 yıllık bir veri periyodu tercih edilmiştir. Fakat literatürdeki önceki çalışmaların incelenmesi sonucunda, kullanılan analiz döneminin daraltılmasının, modelin performansını artırabileceği düşünülmüştür.

Veri ön işleme sürecinin ardından, Öznitelik Seçimi, Makine Öğrenimi Modeli Seçimi ve Makine Öğrenimi Modeli Değerlendirmesi aşamaları, hem 365 günlük, hem de daha kısa süreli olan 180 günlük ve 90 günlük periyotlar için aynı titizlikle uygulanmıştır.


Sonuç olarak, söz konusu üç farklı analiz periyodunun karşılaştırılması aşağıda detaylandırılmıştır.

i. 1 Yıllık Periyod

Model seçimi aşamasında bütün dönemler için en yüksek R^2 değeri veren model seçilmiştir. 1 Yıllık periyotta en yüksek R^2 değerini veren algoritma 0.71 değeri ile Orthogonal Matching Pursuit algoritmasıdır. Eğitim veri setindeki doğruluk oranı 0.81 iken, bu oran test veri setinde 0.73'e gerilemiştir.

Şekil 3.8 Bir Yıllık Periyod'a ait Model İstatistikleri

Bu modelin genele uygun tahmin yapamadığını göstermektedir. Şekil xx'de görüleceği üzere Tahmin hata grafiğinde en uygun regresyon doğrusu ile tahmin arasında uyumsuzluk vardır.



1 Yıllık Periyod

ii. 6 Aylık Periyod

Altı aylık analiz döneminde en yüksek R^2 değerini veren algoritma 0.61 değeri ile K Neighbors Regressor algoritmasıdır. Eğitim veri setindeki doğruluk oranı 0.87 iken, bu oran test veri setinde 0.74'e gerilemiştir.

Şekil 3.9 Altı Aylık Periyod'a ait Model İstatistikler

Model Statistics for K Neighbors Regressor	
Model	K Neighbors Regressor
MAE	0.8364
MSE	13.685
RMSE	11.194
R2	0.6119
RMSLE	0.0534
MAPE	0.0421
TT (Sec)	0.4120



6 Aylık Periyod


Bu modelin genele uygun tahmin yapamadığını göstermektedir. Şekil xx'de görüleceği üzere Tahmin hata grafiğinde en uygun regresyon doğrusu ile tahmin arasında uyumsuzluk vardır.

iii. 3 Aylık Periyod

Üç aylık analiz döneminde en yüksek R^2 değerini veren algoritma 0.85 değeri ile K Neighbors Regressor algoritmasıdır. Eğitim veri setindeki doğruluk oranı 0.92 iken, bu oran test veri setinde 0.90 düzeyindedir. Bu modelin genele uygun tahmin yapabildiğini göstermektedir. Şekil xx'de görüleceği üzere Tahmin hata grafiğinde en uygun regresyon doğrusu ile tahmin arasındaki uyumsuzluk minimum düzeydedir.

Şekil 3.10 Üç Aylık Periyod'a ait Model İstatistikler

Model Statistics for K Neighbors Regressor	
Model	K Neighbors Regressor
MAE	0.4244
MSE	0.3502
RMSE	0.5231
R2	0.8538
RMSLE	0.0271
MAPE	0.0233
TT (Sec)	0.1500



3 Aylık Periyod


Üç farklı dönem verileri analiz edilince en yüksek doğruluk oranı üç aylık periyotta K Neighbors Regressor algoritmasıyla yakalanmıştır. Üç aylık period en uygun dönem olarak seçilmiş, eğitilen model ile yapılan tahmin sonuçları test veri seti ile sonraki bölümde karşılaştırılmıştır.

3.9. Tahmin Sonuçları

Bu çalışma, Bitcoin fiyat hareketliliğinin faktörlerini incelemeyi ve bu faktörlerin fiyat üzerindeki etkisini belirlemeyi amaçlamaktadır. Bu doğrultuda, Bitcoin Günlük Kapanış Verilerini Tahmin Etme konusunu ele almaktadır. İki farklı kategoride veri kaynakları kullanılarak veriler toplanmış ve 2022 yılının tamamının analize dahil edilmesi öngörülmüştü. Ancak, Bitcoin'in volatilitesi yüksek bir enstrüman olduğu düşünüldüğünde, zaman aralığını daraltarak araştırmada 2022-10/2022-12 arasındaki 90 günlük veri kullanılmıştır. Veriler %85 eğitim, %15 test verisi olarak ikiye bölünmüştür.

Analiz için gerekli veriler toplanıp ön işlendikten sonra, makine öğrenmesi algoritmalarının performans değerlendirilmesi sonucunda seçilen algoritma eğitilmiştir. Test verileri, makine öğrenimi algoritmaları kullanılarak tahmin edilmiş ve gerçek sonuçlarla karşılaştırılmıştır.

Grafik 3.3 Model tahmini ve gerçekleşen günlük kapanış



Grafik, K Neighbors Regressor algoritmasının kullanılarak Bitcoin 2022-10/2022-12 arasındaki 90 günlük veriyle eğitilen modelin yapmış olduğu 13 günlük tahmin ve gerçekleşen günlük kapanış fiyatlarını göstermektedir. Grafikte mavi renkteki çizgi, gerçek Bitcoin kapanış fiyatlarını temsil etmektedir. Kırmızı renkteki

çizgi ise, bir model veya algoritma kullanılarak tahmin edilen Bitcoin kapanış fiyatlarını göstermektedir.

Gözlemlenebileceği gibi, Bitcoin'in kapanış fiyatları oldukça değişken ve volatil bir şekilde seyretmektedir. Model tarafından tahmin edilen kapanış fiyatları, gerçek fiyatlardan belirgin şekilde farklılık göstermektedir. Bitcoin fiyatlarının gelecekteki eğilimlerini anlamaya yönelik olarak kullanabileceğimiz bu grafikteki çizgilerin arasındaki boşluk, gerçek ve tahmini fiyatlar arasındaki farkın büyüklüğü olduğunu göstermektedir.

Modelin tahminleri ile gerçek günlük kapanış fiyatları arasında fark modelin başarısını tek başına ortaya koymaya yetmez. İncelendiğinde iki çizgi arasında yüksek bir korelasyonun varlığı göze çarpmaktadır. Görüntülenen tahminler arasında, algoritmanın 13 kere tahmin yapmış olduğu ve bunların 10 tanesinin fiyatların yönü bağlamında doğru olduğu ortaya çıkmıştır. Dikkatli bir bakış ise modelin ani ve yüksek artış ya da azalışları daha yüksek doğrulukla tahmin ettiği gerçeğini kolayca yakalar.

SONUÇ

Bu çalışma, Bitcoin'in fiyat hareketlerini etkileyen faktörleri belirleyerek Bitcoin fiyatını tahmin etmeyi amaçlamaktadır. Bitcoin fiyat tahmini yapmak için kullanılan makine öğrenmesi modelleri, gelecekteki olayları tahmin etmek üzere veriler üzerinde istatistiksel analizler yapabilen bir sistemdir. Ancak hızlı hareketlerin ve anlık değişimlerin yaşandığı finansal piyasalar, kısa vadeli verilerin kullanılmasını gerektirmektedir.

Ayrıca, uzun süreli verilerin bazı problemleri de vardır. Örneğin, finansal verilerde fiyatlarda uzun dönemli trendler oluşabilir. Bu uzun dönemli trendler, makine öğrenmesi algoritmalarının eğitim sırasında veri setinden öğrenmesi gereken bilgiyi sınırlı hale getirebilir. Bu da, modelin doğru tahminler yapmasını engelleyebilir.

Veri kaynakları, iki farklı kategoriye ait olacak şekilde toplanmış ve analiz için başlangıçta 2022 yılı boyunca tüm verilerin kullanılması planlanmıştı. Ancak, Bitcoin'in yüksek volatilitesi nedeniyle, zaman aralığı daraltılmıştır. Bu kararı destekleyen literatür örnekleri şunlardır:

Ye vd. (2022) tarafından yapılan bir bu fikri desteklemektedir. Çalışmada, önerilen topluluk derin öğrenme modelinin, günlük tahmin modellerine kıyasla %88,74'lük gelişmiş bir doğrulukla Bitcoin'in sonraki 30 dakikalık girafkte fiyatı tahmin edebildiği bulunmuştur. Benzer şekilde, Azari (2019) ise Bitcoin fiyat tahmininde kullanılan modellerin uzun vadeli tahminlerde veya ani fiyat değişiklikleri sırasında keskin dalgalanmaları yakalayamayarak büyük tahmin hatalarına neden olabileceğini belirtmişlerdir. Ayrıca, çalışmaları test penceresinin boyutunun artmasıyla birlikte tahmin hatasının ortalama kare hatasının azaldığını göstermiştir.

Kripto fiyat hareketlerini etkileyen uzayın mümkün olduğunca en büyük kısmını analize dahil edilmeye çalışılmıştır. Analizde kullanılan değişkenler kripto ekosistemi değişkenleri ve küresel değişkenler olmak üzere iki ana kategoride toplanmıştır.

Kripto para ekosistemi, alternatif bir finansal sisteme doğru hızla ilerlemektedir. Bitcoin ve diğer alternatif koinlerin işlemleri hakkında yüzlerce çeşit veri akışı sağlayan temel kripto borsaları ve alt borsalar, ekosistemin içinde bulunan ve Bitcoin fiyatının yönüne etkisi olduğu düşünülen değişkenleri analize dahil etmiştir.

Bu fikir Sovbetov (2018) tarihli çalışmasında desteklenmektedir. Yazarlar, Bitcoin, Ethereum, Dash, Litecoin ve Monero gibi beş popüler kripto para biriminin fiyatını etkileyen faktörleri analiz etmiş ve toplam piyasa fiyatları, işlem hacmi ve oynaklık gibi faktörlerin uzun ve kısa vadede beş kripto para birimi üzerinde önemli etkileri olduğunu bulmuşlardır.

Georgoula vd. (2015), Aggarwal vd. (2019) ve Critien vd. (2022) temel ekonomik değişkenler ve Twitter gönderilerinden sentiment analizi ile Bitcoin fiyatları arasındaki ilişkiyi araştırmıştır.

Birinci kategoride bulunan kripto para sistemine ait verilerin tamamı Bitcoin ile ilgilidir ve 350 farklı değişkenden oluşmaktadır. Bu değişkenler ağ bilgileri, kripto borsa işlemleri, adres verileri, fiyat verileri ve sosyal medya verileri ana başlıkları altında toplanabilir.

Bitcoin küresel finans sistemi içerisindeki hacminin artması, dünya ekonomisinden gün geçtikçe daha fazla etkilenmesine neden olmaktadır. Bitcoin fiyat tahmini yapılacaksa, analizde önemli dünya endekslerinin yer alması mutlak bir gerekliliktir.

Bouoiyour vd. (2016) çalışmasında Bitcoin fiyatını para birimi döviz oranları, borsa endeksleri, döviz kurları, petrol fiyatları gibi verilerle tahmin etmeye çalışmıştır. Wang vd. (2016) kısa vadeli analiz, petrol fiyatı ve Bitcoin işlem hacminin Bitcoin fiyatı üzerinde sınırlı bir etkiye sahip olduğunu, hisse senedi fiyat endeksinin ise daha güçlü bir etkiye sahip olduğunu ortaya koymaktadır. J. Chen (2023) ABD hisse senedi piyasası endeksi (NASDAQ, DJI ve S&P500), petrol fiyatı, ETH fiyatı ve Bitcoin fiyat balonunda etkisi olduğunu savunmaktadır.

Bu araştırmada, sınırlı bir şekilde ele alınan konulardan biri olan Bitcoin ile global endeksler arasındaki ilişki incelenmiştir. Analiz için dünya çapında önemli olan 46 farklı değişken kullanılmıştır. Bu değişkenler, tahvil ve hisse senedi endeksleri, enerji endeksleri, döviz kurları ve volatilité endeksleri gibi ana başlıklar altında toplanabilir. Benzer çalışmaların aksine, bu çalışmada daha kapsamlı bir analiz için geniş bir değişken seti kullanılmıştır. Bu şekilde, global endeksler ile Bitcoin fiyatları arasındaki ilişkinin daha doğru bir şekilde tahmin edilmesi amaçlanmıştır.

Kripto uzayının mümkün olduğunca çok bölümünün analize dahil edilmesi, daha doğru tahminler yapmaya olanak sağlayacaktır. Bu nedenle, kullanılacak yapay zekâ modelinin mümkün olduğunca geniş bir veri setiyle eğitilmesi gerektiği düşünülmektedir. Bu fikir, doğru model seçimi sorusunu ortaya çıkarmış ve makine öğrenmesi algoritmalarının daha kesin tahminler yapabileceği öngörülmüştür.

Birden fazla çalışma, makine öğrenmesine dayalı modellerin, geleneksel istatistiksel modellere göre Bitcoin fiyatlarını tahmin etmede daha başarılı olduğunu göstermiştir. Örneğin Mudassir vd. (2020) kısa ve orta vadeli Bitcoin fiyat hareketlerini ve fiyatlarını tahmin etmek için yüksek performanslı makine öğrenmesine dayalı sınıflandırma ve regresyon modelleri göstermiştir. Ji vd. (2019) fiyat artışları ve düşüşleri tahmininde (sınıflandırma) en iyi sonuçları derin sinir ağı (DNN) temelli modellerin verdiğini, Bitcoin fiyat tahmini için ise hafıza içeren uzun kısa vadeli hafıza (LSTM) temelli modellerin diğer tahmin modellerini biraz geride

bıraktığını bulmuştur (Dhande vd., 2022). Bitcoin fiyat tahmini için doğrusal regresyon, gradyan inişi, Random forest ve sınıflandırılmış derin öğrenme algoritmaları gibi algoritmaları kullanmıştır. Kervanci ve Akay (2020) tarafından yapılan çalışma, Bitcoin fiyat tahmini için makine öğrenimi yöntemlerinin genel olarak daha iyi bir performans sergilediğini vurgulamaktadır.

Makine öğrenimi ile verilerin önceden belirlenmiş bir model kullanarak analizi gerçekleştirilir ve gelecekteki olayların tahmini yapılabilir. Ancak, veri analizi sürecinde kullanılan algoritmanın doğruluğu oldukça önemlidir. Bu nedenle, en doğru tahmini sağlayacak makine öğrenimi algoritmasının seçilmesi için daha ileri düzeyde çalışmalar gerçekleştirilmiştir.

Bu çalışmaların ilk adımı, verilerin %85'inin eğitim verisi olarak, %15'inin ise test verisi olarak ayrılmasıdır. Daha sonra, 19 farklı makine öğrenimi algoritması kullanılarak, test verileri üzerinde tahminler yapılmıştır. Bu algoritmalar arasında, en yüksek doğruluk oranına sahip olan K Yakın Komşu Regresyonu algoritması seçilmiştir.

Makine öğrenimi algoritmalarının kullanımı ile elde edilen sonuçlar, birçok farklı alanda kullanılan veri analizi yöntemleri arasında oldukça etkili bir seçenektir. Ancak, algoritmanın doğruluğunun artırılması için uygun yöntemlerin kullanılması gerekmektedir.

Elde edilen sonuçlar oldukça başarılıdır. Test verilerinin doğru tahmin oranı %90 seviyesindedir. Bu sonuçlar, literatürde de çokça kullanılan ve analizde yer alan değişkenlerin doğru seçildiği ve işlendiğini ve algoritma parametrelerinin de optimize edildiğini göstermektedir.

Bitcoin fiyat hareketlerini daha iyi anlamak için ileride yapılacak araştırmalar, belirli konulara odaklanarak değerli bilgiler sunabilir. Bitcoin'in yaygınlığına erişemese de alternatif kripto para birimlerinin fiyat hareketlerini ve Bitcoin ile olan ilişkilerinin yönü ve derecesiyle birlikte yıllar içindeki değişimlerini incelemek, Bitcoin'in volatilitesi anlama konusunda bize yardımcı olabilir.

Bitcoin'in volatilitesinin makroekonomik faktörlerle ilişkisini araştırmak büyük önem taşımaktadır. Çalışmamızda, Bitcoin fiyatını etkileyen küresel endeksler altında ele alınan makroekonomik faktörlere dikkat çekilmiştir. Bu faktörler daha da genişletilebilir. Örneğin, ekonomik krizler, faiz oranları, enflasyon gibi faktörlerin Bitcoin volatilitesi üzerindeki etkilerini incelemek, piyasa dinamiklerini anlamamıza katkı sağlayabilir.

Düzenleyici önlemlerin ve regülasyonun Bitcoin volatilitesi üzerindeki etkisini araştırmak da önemlidir. Farklı ülkelerdeki regülasyon yaklaşımlarını ve düzenleyici

çerçevelerin Bitcoin volatilitesi üzerindeki etkilerini karşılaştırmak, regülasyonun piyasa istikrarına etkisini anlamamıza yardımcı olabilir.

Yatırımcı davranışı ve psikolojik faktörlerin Bitcoin volatilitesi yönlendirmedeki rolünü anlamak, daha fazla araştırmayı hak eden bir alandır. Gelecekte yapılacak çalışmalar, risk iştahı, piyasa duyarlılığı, sürü davranışı veya önemli piyasa katılımcılarının etkisi gibi faktörlerin Bitcoin volatilitesi nasıl etkilediğini inceleyebilir. Çalışma alanının bu yönde genişletilmesi Bitcoin'in fiyat karakteristiğini anlamamızda yarar sağlayacaktır.



KAYNAKÇA

- Abadi, J., & Brunnermeier, M. (2018). *Blockchain economics* (No. w25407). National Bureau of Economic Research.
- Adrian, T., & Mancini-Griffoli, T. (2021). *The Rise of Digital Money*. <https://doi.org/10.1146/annurev-financial-101620>
- Agca, S., & Mansi, S. (2008). Managerial Ownership, Takeover Defenses, and Debt Financing. *The Journal of Financial Research*. <https://doi.org/10.1111/j.1475-6803.2008.00233.x>
- Aggarwal, A., Gupta, I., Garg, N., & Goel, A. (2019). Deep Learning Approach to Determine the Impact of Socio Economic Factors on Bitcoin Price Prediction. *2019 12th International Conference on Contemporary Computing, IC3 2019*. <https://doi.org/10.1109/IC3.2019.8844928>
- Aghashahi, M., & Bamdad, S. (2022). Analysis of different artificial neural networks for Bitcoin price prediction. <https://doi.org/10.1080/17509653.2022.2032442>, 18(2), 126-133. <https://doi.org/10.1080/17509653.2022.2032442>
- Ahmed, W. M. A. (2022). Robust drivers of Bitcoin price movements: An extreme bounds analysis. *The North American Journal of Economics and Finance*, 62, 101728. <https://doi.org/10.1016/J.NAJEF.2022.101728>
- Albariqi, R., & Winarko, E. (2020). Prediction of Bitcoin Price Change using Neural Networks. *Proceeding - ICoSTA 2020: 2020 International Conference on Smart Technology and Applications: Empowering Industrial IoT by Implementing Green Technology for Sustainable Development*. <https://doi.org/10.1109/ICOSTA48221.2020.1570610936>
- Altcoin Explained: Pros and Cons, Types, and Future., <https://www.investopedia.com/terms/a/altcoin.asp>, Erişim Tarihi: 18 Ocak 2023
- American Institute of Certified Public Accountants. *Audit guide : analytical procedures.*, https://books.google.com/books/about/Audit_Guide.html?hl=tr&id=0vlotgEACAAJ, Erişim Tarihi: 08 Mart 2023
- Anggraeny, F. T., Purbasari, I. Y., Munir, M. S., Muttaqin, F., Mandyarta, E. P., & Akbar, F. A. (2018). *Analysis of Simple Data Imputation in Disease Dataset*. <https://doi.org/10.2991/icst-18.2018.98>
- Atsalakis, G. S., Atsalaki, I. G., Pasiouras, F., & Zopounidis, C. (2019). Bitcoin price forecasting with neuro-fuzzy techniques. *European Journal of Operational Research*, 276(2), 770-780. <https://doi.org/10.1016/J.EJOR.2019.01.040>

- Azari, A. (2019). *Bitcoin Price Prediction: An ARIMA Approach*. <https://doi.org/10.48550/arxiv.1904.05315>
- Bejan, C. A., Bucerzan, D., & Crăciun, M. D. (2022). Bitcoin price evolution versus energy consumption; trend analysis., 55(13), 1497-1511. <https://doi.org/10.1080/00036846.2022.2097194>
- Bitcoin Price Chart and Tables | Finance Reference.*, <https://www.in2013dollars.com/bitcoin-price>, Erişim Tarihi: 17 Mayıs 2023
- Bitcoin Price History 2009-2022 | NextAdvisor with TIME., <https://time.com/nextadvisor/investing/cryptocurrency/bitcoin-price-history/>, Erişim Tarihi: 17 Ocak 2023
- Bitcoin's Price History., <https://www.investopedia.com/articles/forex/121815/bitcoins-price-history.asp>, Erişim Tarihi: 18 Ocak 2023
- Blau, B. M. (2017). Price dynamics and speculative trading in bitcoin. *Research in International Business and Finance*, 41, 493-499. <https://doi.org/10.1016/J.RIBAF.2017.05.010>
- BNB- What is BNB and What Is It Used For?, <https://www.binance.com/en/bnb>, Erişim Tarihi: 16 Mayıs 2023
- Bouoiyour, J., & Selmi, R. (2015). *Bitcoin Price: Is it really that New Round of Volatility can be on way?*
- Bouoiyour, J., & Selmi, R. (2017). *The Bitcoin price formation: Beyond the fundamental sources*. <https://arxiv.org/abs/1707.01284v1>
- Bouoiyour, J., Selmi, R., Tiwari, A. K., & Olayeni, O. R. (2016). What drives Bitcoin price? *Economics Bulletin*, 36(2), 843-850. <https://ideas.repec.org/a/ebl/ecbull/eb-16-00311.html>
- Btcusd - Bitcoin - USD Cryptocurrency Interactive Chart - Barchart.com., <https://www.barchart.com/crypto/quotes/%5EBTCUSD/interactive-chart>, Erişim Tarihi: 17 Mayıs 2023
- Bunjaku, F., Gjorgieva-Trajkovska, O., & Miteva-Kacarski, E. (2017). Cryptocurrencies – Advantages And Disadvantages. *Journal of Economics*, 2, 31-39.
- Cevik, E. I., Gunay, S., Dibooglu, S., & Yıldırım, D. Ç. (2023). The impact of expected and unexpected events on Bitcoin price development: Introduction of futures market and COVID-19. *Finance Research Letters*, 54, 103768. <https://doi.org/10.1016/J.FRL.2023.103768>
- Cheah, E. T., & Fry, J. (2015). Speculative bubbles in Bitcoin markets? An empirical investigation into the fundamental value of Bitcoin. *Economics Letters*, 130, 32-36. <https://doi.org/10.1016/J.ECONLET.2015.02.029>

- Chen, C., Liu, L., & Zhao, N. (2020). Fear Sentiment, Uncertainty, and Bitcoin Price Dynamics: The Case of COVID-19. *https://doi.org/10.1080/1540496X.2020.1787150*, 56(10), 2298-2309. <https://doi.org/10.1080/1540496X.2020.1787150>
- Chen, J. (2023). Analysis of Bitcoin Price Prediction Using Machine Learning. *Journal of Risk and Financial Management* 2023, Vol. 16, Page 51, 16(1), 51. <https://doi.org/10.3390/JRFM16010051>
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395. <https://doi.org/10.1016/J.CAM.2019.112395>
- Chkili, W. (2021). Modeling Bitcoin price volatility: long memory vs Markov switching. *Eurasian Economic Review*, 11(3), 433-448. <https://doi.org/10.1007/S40822-021-00180-7/TABLES/5>
- Chuen, D. (2015). *Handbook of Digital Currency: Bitcoin, Innovation, Financial Instruments, and Big Data*.
- Ciaian, P., Rajcaniova, M., & Kancs, d'Artis. (2016). The economics of BitCoin price formation. *Applied Economics*, 48(19), 1799-1815. <https://doi.org/10.1080/00036846.2015.1109038>
- Comparison - Centralized, Decentralized and Distributed Systems - GeeksforGeeks., <https://www.geeksforgeeks.org/comparison-centralized-decentralized-and-distributed-systems/>, Erişim Tarihi: 30 Eylül 2022
- Cretarola, A., & Figà-Talamanca, G. (2021). Detecting bubbles in Bitcoin price dynamics via market exuberance. *Annals of Operations Research*, 299(1-2), 459-479. <https://doi.org/10.1007/S10479-019-03321-Z/TABLES/6>
- Critien, J. V., Gatt, A., & Ellul, J. (2022). Bitcoin price change and trend prediction through twitter sentiment and data volume. *Financial Innovation*, 8(1), 1-20. <https://doi.org/10.1186/S40854-022-00352-7/TABLES/6>
- Cross-validation: evaluating estimator performance — scikit-learn 1.2.2 documentation., https://scikit-learn.org/stable/modules/cross_validation.html, Erişim Tarihi: 08 Mart 2023
- Crypto Hacks: Crypto Exchange Hacks & Cryptocurrency Hackers., <https://cointelegraph.com/magazine/crypto-exchange-hacks/>, Erişim Tarihi: 11 Ekim 2022
- Curtis, A., Smith, T. A., Ziganshin, B. A., & Eleftheriades, J. A. (2016). The Mystery of the Z-Score. *Aorta*. <https://doi.org/10.12945/j.aorta.2016.16.014>
- Çatlı, M., & Şimşek, S. (2021). Dijital Para ve Egemenlik. *Türkiye Adalet Akademisi Dergisi*, 151-184. <https://doi.org/10.54049/TAAD.1009216>

- Demirkan, S., Baskan, T. D., Türk, M., Güngör, S., Vergili, Gizem., & vd. (2021). *Crypto Assets Conceptual Framework And Empirical Evidences*. Gazi Kitabevi.
- Dhande, A., Dhani, S., Parnami, S., & Vijayakumar, K. P. (2022). Cryptocurrency Price Prediction Using Linear Regression and Long Short-Term Memory (LSTM). *International Journal for Research in Applied Science and Engineering Technology*. <https://doi.org/10.22214/ijraset.2022.48286>
- Different Types of Cryptocurrencies – Forbes Advisor., <https://www.forbes.com/advisor/investing/cryptocurrency/different-types-of-cryptocurrencies/>, Erişim Tarihi: 04 Mayıs 2023
- Disadvantages of Bitcoin., <https://cs.stanford.edu/people/eroberts/cs181/projects/2010-11/DigitalCurrencies/disadvantages/index.html>, Erişim Tarihi: 18 Ocak 2023
- Dumitrescu, B. A., Obreja, C., Leonida, I., Mihai, D. G., & Trifu, L. C. (2023). The Link between Bitcoin Price Changes and the Exchange Rates in European Countries with Non-Euro Currencies. *Journal of Risk and Financial Management 2023*, Vol. 16, Page 232, 16(4), 232. <https://doi.org/10.3390/JRFM16040232>
- Dutta, A., Kumar, S., & Basu, M. (2020). A gated recurrent unit approach to bitcoin price prediction. *Journal of risk and financial management*, 13(2), 23.
- Easwaran, S., Dixit, M., & Sinha, S. (2015). Bitcoin Dynamics: The Inverse Square Law of Price Fluctuations and Other Stylized Facts. *New Economic Windows*, 121-128. https://doi.org/10.1007/978-3-319-08473-2_4
- Estrada, J. C. S. (2017). Analyzing bitcoin price volatility. *University of California, Berkeley*.
- Fantazzini, D., & Kolodin, N. (2020). Does the Hashrate Affect the Bitcoin Price? *Journal of Risk and Financial Management 2020*, Vol. 13, Page 263, 13(11), 263. <https://doi.org/10.3390/JRFM13110263>
- Flores, A., Tito, H., & Silva, C. A. (2019). Local Average of Nearest Neighbors: Univariate Time Series Imputation. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2019.0100807>
- Georgoula, I., Pournarakis, D., Bilanakos, C., Sotiropoulos, D. N., & Giaglis, G. M. (2015). Using Time-Series and Sentiment Analysis to Detect the Determinants of Bitcoin Prices. *SSRN Electronic Journal*. <https://doi.org/10.2139/SSRN.2607167>
- Greaves, A., & Au, B. (2015). *Using the Bitcoin Transaction Graph to Predict the Price of Bitcoin*.
- Gu, H., & Wang, L. (2022). Modified T-Distribution Stochastic Neighbor Embedding Using Augmented Kernel Mahalanobis-Distance for Dynamic Multimode Chemical Process Monitoring. *International Journal of Chemical Engineering*. <https://doi.org/10.1155/2022/8460463>

- Gurrib, I., & Kamalov, F. (2022). Predicting bitcoin price movements using sentiment analysis: a machine learning approach. *Studies in Economics and Finance*, 39(3), 347-364. <https://doi.org/10.1108/SEF-07-2021-0293/FULL/PDF>
- Gürsoy, S. (2021). The Relationship Of Blockchain Technology, Crypto Money And Foreign Trade. *Journal of Business in The Digital Age*. <https://doi.org/10.46238/JOBDA.982879>
- Haffar, A., & Le Fur, E. (2021). Structural vector error correction modelling of Bitcoin price. *The Quarterly Review of Economics and Finance*, 80, 170-178. <https://doi.org/10.1016/J.QREF.2021.02.010>
- Hairudin, A., Sifat, I. M., Mohamad, A., & Yusof, Y. (2020). Cryptocurrencies: A Survey on Acceptance, Governance and Market Dynamics. *International Journal of Finance & Economics*. <https://doi.org/10.1002/ijfe.2392>
- Härdle, W. K., Harvey, C. R., & Reule, R. C. G. (2020). Understanding Cryptocurrencies. *Journal of Financial Econometrics*, 18(2), 181-208. <https://doi.org/10.1093/JJFINEC/NBZ033>
- Hashing in Blockchain?, <https://blockchainsentry.com/blog/ hashing-in-blockchain/>, Erişim Tarihi: 17 Mayıs 2023
- History Of Bitcoin Bear Market: Explained | ZebPay., <https://zebpay.com/blog/history-of-bitcoin-bear-market>, Erişim Tarihi: 17 Ocak 2023
- Houben, R., & Snyers, A. (2018). *Cryptocurrencies and blockchain: Legal context and implications for financial crime, money laundering and tax evasion*.
- How Many Bitcoins Are There? (Circulating Supply - Live)., <https://buybitcoinworldwide.com/how-many-bitcoins-are-there/>, Erişim Tarihi: 01 Kasım 2022
- Jana, R. K., Ghosh, I., & Das, D. (2021). A differential evolution-based regression framework for forecasting Bitcoin price. *Annals of Operations Research*, 306(1-2), 295-320. <https://doi.org/10.1007/S10479-021-04000-8/TABLES/8>
- Ji, S., Kim, J., & Im, H. (2019a). A Comparative Study of Bitcoin Price Prediction Using Deep Learning. *Mathematics* 2019, Vol. 7, Page 898, 7(10), 898. <https://doi.org/10.3390/MATH7100898>
- Ji, S., Kim, J., & Im, H. (2019b). A Comparative Study of Bitcoin Price Prediction Using Deep Learning. *Mathematics* 2019, Vol. 7, Page 898, 7(10), 898. <https://doi.org/10.3390/MATH7100898>
- Jia, D., & Li, Y. (2023). Bounded pool mining and the bounded Bitcoin price. *Finance Research Letters*, 52, 103529. <https://doi.org/10.1016/J.FRL.2022.103529>

- Karalevicius, V. (2018). Using sentiment analysis to predict interday Bitcoin price movements. *Journal of Risk Finance*, 19(1), 56-75. <https://doi.org/10.1108/JRF-06-2017-0092/FULL/PDF>
- Katubi, K. M., Saqib, M., Maryam, M., Mubashir, T., Tahir, M. H., Sulaman, M., Alrowaili, Z. A., & Al-Buriahi, M. S. (2023). Machine learning assisted designing of organic semiconductors for organic solar cells: High-throughput screening and reorganization energy prediction. *Inorganic Chemistry Communications*, 151, 110610. <https://doi.org/10.1016/J.INOCHE.2023.110610>
- Kervanci I Sibel, & Fatih Akay, M. (2020). Review on Bitcoin Price Prediction Using Machine Learning and Statistical Methods. *Sakarya University Journal of Computer and Information Sciences*, 3(3), 272-282. <https://doi.org/10.35377/SAUCIS.03.03.774276>
- Kimura, M. (2021). Generalized T-Sne Through the Lens of Information Geometry. *Ieee Access*. <https://doi.org/10.1109/access.2021.3113397>
- Kjaerland, F., Meland, M., Oust, A., & Øyen, V. (2018). How can Bitcoin Price Fluctuations be Explained? 323-332, 8(3), 323-332. <https://ntnuopen.ntnu.no/ntnu-xmlui/handle/11250/2500190>
- Kobak, D., & Linderman, G. C. (2021). Initialization Is Critical for Preserving Global Data Structure in Both T-Sne and UMAP. *Nature Biotechnology*. <https://doi.org/10.1038/s41587-020-00809-z>
- Kristoufek, L. (2015). What Are the Main Drivers of the Bitcoin Price? Evidence from Wavelet Coherence Analysis. *PLOS ONE*, 10(4), e0123923. <https://doi.org/10.1371/JOURNAL.PONE.0123923>
- Kubal, J., & Kristoufek, L. (2022). Exploring the relationship between Bitcoin price and network's hashrate within endogenous system. *International Review of Financial Analysis*, 84, 102375. <https://doi.org/10.1016/J.IRFA.2022.102375>
- Kyosev, D., Anastasovski, D., Kikovic, M., & Voutyras, O. (2022). *Terra Luna and the Future of Internet Investments: Towards a Framework for Investors' Protections*. <https://doi.org/10.20944/preprints202210.0027.v1>
- Lamothe-Fernández, P., Alaminos, D., Lamothe-López, P., & Fernández-Gámez, M. A. (2020). Deep Learning Methods for Modeling Bitcoin Price. *Mathematics 2020*, Vol. 8, Page 1245, 8(8), 1245. <https://doi.org/10.3390/MATH8081245>
- Lea, S. E. G., & Webley, P. A. (2006). Money as Tool, Money as Drug: The Biological Psychology of a Strong Incentive. *Behavioral and Brain Sciences*. <https://doi.org/10.1017/s0140525x06009046>
- Lewis, A. (2018). *The basics of bitcoins and blockchains : an introduction to cryptocurrencies and the technology that powers them.*

- https://books.google.com/books/about/The_Basics_of_Bitcoins_and_Blockchains.html?hl=tr&id=7R4uswEACAAJ
- Li, H., Li, W., Wang, L., & Lv, L. (2020). Public Satisfaction Evaluation of Urban Water Environment Treatment Public-Private Partnership Project. *International Journal of Building Pathology and Adaptation*. <https://doi.org/10.1108/ijbpa-10-2019-0089>
- Madan, I. (2014). *Automated Bitcoin Trading via Machine Learning Algorithms*.
- Major Companies That Accept Bitcoin as Payment., <https://finance.yahoo.com/news/15-major-companies-accept-bitcoin-155558584.html>, Erişim Tarihi: 16 Mayıs 2023
- Mudassir, M., Bennbaia, S., Unal, D., & Hammoudeh, M. (2020). Time-Series Forecasting of Bitcoin Prices Using High-Dimensional Features: A Machine Learning Approach. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-020-05129-6>
- Munim, Z. H., Shakil, M. H., & Alon, I. (2019). Next-Day Bitcoin Price Forecast. *Journal of Risk and Financial Management* 2019, Vol. 12, Page 103, 12(2), 103. <https://doi.org/10.3390/JRFM12020103>
- Oğuzlar, A. (2003). Veri Ön İşleme. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21, 67-76. <https://dergipark.org.tr/tr/pub/erciyesiibd/issue/5878/77794>
- Oyeyemi, G., Bukoye, A., & Imam, A. (2015). Comparison of Outlier Detection Procedures in Multiple Linear Regressions. *American Journal of Mathematics and Statistics*, 2015, 37-41. <https://doi.org/10.5923/j.ajms.20150501.06>
- Özbilen, Ş. (2015). *Para Teorisi*. <https://www.turcademy.com/tr/kitap/para-teori-si-9786053442400>
- Parasiz, I. (2000). Para Banka ve Finansal Piyasalar. *Ezgi Kitabevi Yayınları*, 7.
- Proof-of-Work vs. Proof-of-Stake: Which Is Better? - Blockworks., <https://blockworks.co/news/proof-of-work-vs-proof-of-stake-whats-the-difference>, Erişim Tarihi: 16 Mayıs 2023
- Pryzmont, P. (2016). *An empirical study of how Bitcoin related incidents impact its price volatility*.
- Pycaret Documentation - Feature Selection., <https://pycaret.gitbook.io/docs/get-started/preprocessing/feature-selection#ignore-low-variance>, Erişim Tarihi: 22 Haziran 2023
- Raja, R. J. (2008). The Impact of the Learning Curve in Laparoscopic Surgery. *World Journal of Laparoscopic Surgery With DVD*. <https://doi.org/10.5005/jp-journals-10007-1048>
- Rajabi, S., Roozkhosh, P., & Farimani, N. M. (2022). MLP-based Learnable Window Size for Bitcoin price prediction. *Applied Soft Computing*, 129, 109584. <https://doi.org/10.1016/J.ASOC.2022.109584>

- Rathore, R. K., Mishra, D., Mehra, P. S., Pal, O., HASHIM, A. S., Shapi'i, A., Ciano, T., & Shutaywi, M. (2022). Real-world model for bitcoin price prediction. *Information Processing & Management*, 59(4), 102968. <https://doi.org/10.1016/J.IPM.2022.102968>
- Richardson, M. (2009). Principal component analysis. URL: <http://people.maths.ox.ac.uk/richardsonm/SignalProcPCA.pdf> (last access: 3.5. 2013). Aleš Hladnik Dr., Ass. Prof., Chair of Information and Graphic Arts Technology, Faculty of Natural Sciences and Engineering, University of Ljubljana, Slovenia ales.hladnik@ntf.uni-lj.si, 6(16), 4.
- Rizwan, M., Narejo, S., & Javed, M. (2019). Bitcoin price prediction using Deep Learning Algorithm. *MACS 2019 - 13th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics, Proceedings*. <https://doi.org/10.1109/MACS48846.2019.9024772>
- Roy, S., Nanjiba, S., & Chakrabarty, A. (2019). Bitcoin Price Forecasting Using Time Series Analysis. *2018 21st International Conference of Computer and Information Technology, ICCIT 2018*. <https://doi.org/10.1109/ICCITECHN.2018.8631923>
- Seang, S., & Torre, D. (2018). Proof of Work and Proof of Stake consensus protocols: a blockchain application for local complementary currencies. *France: Universite Cote d'Azur-GREDEG-CNRS. Str*, 3(4).
- Seifaddini, M., & Habibdoust, A. (2023). Improving Bitcoin price prediction power by time-scale decomposition and GMDH-type neural network: A comparison of different periods and features. *Journal of Mathematical Modeling*, 11(1), 1-17. <https://doi.org/10.22124/jmm.2022.22638.2003>
- Shrestha, N. (2020). Detecting Multicollinearity in Regression Analysis. *American Journal of Applied Mathematics and Statistics*. <https://doi.org/10.12691/ajams-8-2-1>
- Sin, E., & Wang, L. (2018). Bitcoin price prediction using ensembles of neural networks. *ICNC-FSKD 2017 - 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery*, 666-671. <https://doi.org/10.1109/FSKD.2017.8393351>
- Short History Of Bitcoin And Crypto Currency Everyone Should Read., <https://www.forbes.com/sites/bernardmarr/2017/12/06/a-short-history-of-bitcoin-and-crypto-currency-everyone-should-read/?sh=4b880b823f27>, Erişim Tarihi: 17 Ocak 2023
- Sovbetov, Y. (2018). *Factors Influencing Cryptocurrency Prices: Evidence from Bitcoin, Ethereum, Dash, Litecoin, and Monero*. <https://papers.ssrn.com/abstract=3125347>
- Stat 462 by PennState Science. <https://online.stat.psu.edu/stat462/node/117/>, Erişim Tarihi: 07 Mart 2023,
- Stenqvist, E., & Lönnö, J. (2017). Predicting Bitcoin price fluctuation with Twitter sentiment analysis. *Degree Project Technology*. <https://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-209191>

- Teker, T., Konuşkan, A., Ömürbek, V., & Bekçi, İ. (2020). Bitcoin Ve Kripto Paralar Hakkında Çıkan Haberlerin Bitcoin Fiyatları Üzerine Etkisi. *İçinde Maliye ve Finans Yazıları*. <https://doi.org/10.33203/mfy.567989>
- Toai, T. K., Senkerik, R., Zelinka, I., Ulrich, A., Hanh, V. T. X., & Huan, V. M. (2023). ARIMA for Short-Term and LSTM for Long-Term in Daily Bitcoin Price Prediction. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13588 LNAI, 131-143. https://doi.org/10.1007/978-3-031-23492-7_12/COVER
- Token - Binance Academy., <https://academy.binance.com/en/glossary/token>, Erişim Tarihi: 19 Ocak 2023
- Trotter, L., Harding, M., Shaw, P. J., Davies, N., Elsdon, C., Speed, C., Vines, J., Abadi, A., & Hallwright, J. (2020). *Smart Donations: Event-Driven Conditional Donations Using Smart Contracts on the Blockchain*. <https://doi.org/10.1145/3441000.3441014>
- Urquhart, A. (2017). Price clustering in Bitcoin. *Economics Letters*, 159, 145-148. <https://doi.org/10.1016/J.ECONLET.2017.07.035>
- USD Coin (USDC): Definition, How It Works in Currency, and Value., <https://www.investopedia.com/usd-coin-5210435>, Erişim Tarihi: 18 Ocak 2023
- Validation curves: plotting scores to evaluate models — scikit-learn 1.2.2 documentation., https://scikit-learn.org/stable/modules/learning_curve.html, Erişim Tarihi: 16 Mayıs 2023
- Virk, D. S. (2017). *Prediction of bitcoin price using data mining* (Doctoral dissertation, Dublin, National College of Ireland).
- Vockathaler, B. (2015). *The Bitcoin Boom: An In Depth Analysis Of The Price Of Bitcoins*. <http://ruor.uottawa.ca/handle/10393/32888>
- Wang, J., Xue, Y., & Liu, M. (2016). *An Analysis of Bitcoin Price Based on VEC Model*. 180-186. <https://doi.org/10.2991/ICEMI-16.2016.36>
- What Is Dogecoin? How Does It Work? – Forbes Advisor., <https://www.forbes.com/advisor/investing/cryptocurrency/what-is-dogecoin/>, Erişim Tarihi: 16 Mayıs 2023
- What Is Solana? How Does It Work? – Forbes Advisor., <https://www.forbes.com/advisor/investing/cryptocurrency/what-is-solana/>, Erişim Tarihi: 16 Mayıs 2023
- What Is Tether? How Does It Work? – Forbes Advisor INDIA., <https://www.forbes.com/advisor/in/investing/cryptocurrency/what-is-tether-usdt/>, Erişim Tarihi: 18 Ocak 2023

- What is Avalanche (AVAX)? | The Motley Fool., <https://www.fool.com/investing/stock-market/market-sectors/financials/cryptocurrency-stocks/avalanche-crypto/>, Erişim Tarihi: 16 Mayıs 2023
- What Is BUSD? | Binance Academy., <https://academy.binance.com/en/articles/what-is-busd>, Erişim Tarihi: 18 Ocak 2023
- What is Ethereum? | ethereum.org., <https://ethereum.org/en/what-is-ethereum/>, Erişim Tarihi: 18 Ocak 2023
- What is “proof of work” or “proof of stake”? | Coinbase., <https://www.coinbase.com/th/learn/crypto-basics/what-is-proof-of-work-or-proof-of-stake>, Erişim Tarihi: 05 Ekim 2022
- What Is Terra LUNA? | LUNA Coin Explained., <https://currency.com/what-is-terra-luna-your-ultimate-guide>, Erişim Tarihi: 16 Mayıs 2023
- Why decentralization? – Part I - IOTA News., <https://iota-news.com/why-decentralization-part-i/>, Erişim Tarihi: 17 Mayıs 2023
- Wu, C. H., Lu, C. C., Ma, Y. F., & Lu, R. S. (2019). A new forecasting framework for bitcoin price with LSTM. *IEEE International Conference on Data Mining Workshops, ICDMW, 2018-November*, 168-175. <https://doi.org/10.1109/ICDMW.2018.00032>
- Yakob, R., Yusop, Z., Radam, A., & Ismail, N. (2012). Solvency Determinants of Conventional Life Insurers and Takaful Operators. *Asia-Pacific Journal of Risk and Insurance*. <https://doi.org/10.1515/2153-3792.1143>
- Yaya, O. O. S., Lukman, A. F., & Vo, X. V. (2022). Persistence and volatility spillovers of bitcoin price to gold and silver prices. *Resources Policy*, 79, 103011. <https://doi.org/10.1016/J.RESOURPOL.2022.103011>
- Ye, Z., Wu, Y., Chen, H., Pan, Y., & Jiang, Q. (2022a). A Stacking Ensemble Deep Learning Model for Bitcoin Price Prediction Using Twitter Comments on Bitcoin. *Mathematics* 2022, Vol. 10, Page 1307, 10(8), 1307. <https://doi.org/10.3390/MATH10081307>
- Ye, Z., Wu, Y., Chen, H., Pan, Y., & Jiang, Q. (2022b). A Stacking Ensemble Deep Learning Model for Bitcoin Price Prediction Using Twitter Comments on Bitcoin. *Mathematics* 2022, Vol. 10, Page 1307, 10(8), 1307. <https://doi.org/10.3390/MATH10081307>
- Yellowbrick documentation Prediction Error, <https://www.scikit-yb.org/en/latest/api/regressor/peplot.html>, Erişim Tarihi: 21 Haziran 2023
- Zhang, H., Wang, P., Gao, X., Qi, Y., & Gao, H. (2020). Out-of-Sample Data Visualization Using Bi-Kernel T-Sne. *Information Visualization*. <https://doi.org/10.1177/1473871620978209>
- Zhou, Q.-M., & Xiping, H. (2019). Broad Learning Model Based on Enhanced Features Learning. *Ieee Access*. <https://doi.org/10.1109/access.2019.2905528>

Zhou, Y., & Sharpee, T. O. (2018). *Using Global T-Sne to Preserve Inter-Cluster Data Structure*. <https://doi.org/10.1101/331611>



EKLER

EK1 - Kategori 1'de Kullanılan Değişkenler

BTC_HASHRATE	Bitcoin Hash Oranı
ETH_TXVOLUME	Ethereum İşlem Hacmi
BTC_RETAIL	Bitcoin Perakende Katılımı
BTC_TXVOLUMEUSD	Bitcoin İşlem Hacmi (USD cinsinden)
BTC_INOUTMONEYIN	Giren Bitcoin Değeri
ETH_RETAIL	Ethereum Perakende Katılımı
ETH_HODLERS	Ethereum Tutucu Sayısı
BTC_INFLOWTXVOLUME	Giren Bitcoin İşlem Hacmi
BTC_MINERRESERVES	Bitcoin Madenci Rezervleri
BTC_HODLERSBALANCE	Bitcoin Tutucu Bakiyeleri
ETH_WHALESASSETS	Ethereum Balina Varlıkları
BTC_INFLOWTXVOLUMEUSD	Giren Bitcoin İşlem Hacmi (USD cinsinden)
BTC_LOSSESADDRESSESPERCENTAGE	Bitcoin Kaybedilen Adreslerin Yüzdesi
BTC_LARGETXVOLUMEUSD	Büyük Bitcoin İşlem Hacmi (USD cinsinden)
BTC_BULLSVOLUME	Boğa Piyasası Bitcoin İşlem Hacmi
BTC_MINERINFLOWS	Bitcoin Madenci Girişleri
BTC_MINEROUTFLOWS	Bitcoin Madenci Çıkışları
BTC_TXVOLUME	Bitcoin İşlem Hacmi
BTC_LARGETXVOLUME	Büyük Bitcoin İşlem Hacmi
BTC_LARGEHOLDERSINFLOWS	Büyük Bitcoin Tutucuların Girişleri
BTC_LARGEHOLDERSNETFLOWS	Büyük Bitcoin Tutucuların Net Akışları
BTC_D	Bitcoin Dominansı
TOTAL	Toplam Kripto Piyasa Değeri
TOTAL2	Toplam Kripto Piyasa Değeri 2
TOTAL3	Toplam Kripto Piyasa Değeri 3
ETH_D	Ethereum Dominansı
OTHERS_D	Diğer Kripto Paraların Dominansı
TOTALDEFI	Toplam DeFi Piyasa Değeri
ETH	Ethereum
XRP	Ripple
DEFIETH	DeFi / Ethereum Oranı
BNB	Binance Coin
OTHERS	Diğer Kripto Paralar
LTC	Litecoin
BTCUSD	Bitcoin / ABD Doları Kuru
ETHBTC	Ethereum / Bitcoin Oranı
LTCBTC	Litecoin / Bitcoin Oranı
XRPBTC	Ripple / Bitcoin Oranı
XBTUSD	XBT / ABD Doları Kuru
XBT	XBT (Bitcoin)
BVOL24H	24 Saatlik Volatilite

BVOL7D	7 Günlük Volatilite
BXBT	XBT Endeksi
XBTUSDPI	XBT / ABD Doları Kuru (Perpetual Swap)
BTC_NEWADDRESSES	Yeni Bitcoin Adresleri
BTC_MARKETCAP	Bitcoin Piyasa Değeri
BTC_ACTIVE1Y	1 Yıl İçinde Hareket Eden Bitcoin
BTC_ATHDRAWDOWN	Bitcoin Tüm Zaman En Yüksekten Düşüş
BTC_ACTIVEADDRESSES	Hareket Eden Bitcoin Adresleri
BTC_SUPPLY	Bitcoin Arzı
BTC_SOPR	Bitcoin SOPR (Yeniden Harcanan Coin Geliri Oranı)
BTC_TOTALVOLUMEUSD	Toplam Bitcoin İşlem Hacmi (USD cinsinden)
ETH_MARKETCAP	Ethereum Piyasa Değeri
BTC_TXS	Bitcoin İşlem Sayısı
BTC_SENDINGADDRESSES	Bitcoin Gönderen Adresler
BTC_RECEIVINGADDRESSES	Bitcoin Alıcı Adresler
BTC_TOTALTXFEESUSD	Toplam Bitcoin İşlem Ücreti (USD cinsinden)
BTC_TOTALTXSIZE	Toplam Bitcoin İşlem Boyutu
ETH_TOTALTXFEES	Toplam Ethereum İşlem Ücreti
BTC_MEANVOLUME	Ortalama Bitcoin İşlem Hacmi
ETH_ACTIVEADDRESSES	Hareket Eden Ethereum Adresleri
BTC_MEANTXFEESUSD	Ortalama Bitcoin İşlem Ücreti (USD cinsinden)
BTC_TOTALVOLUME	Toplam Bitcoin İşlem Hacmi
ETH_MEANTXGASPRICEUSD	Ortalama Ethereum Gaz Ücreti (USD cinsinden)
BTC_BLOCKMEANINTERVAL	Ortalama Bitcoin Blok Aralığı
ETH_SOPR	Ethereum SOPR (Yeniden Harcanan Coin Geliri Oranı)
BTC_DIFFICULTY	Bitcoin Zorluk Seviyesi
BTC_TXSPS	Bitcoin İşlem Hızı (İşlem Başına Saniye)
LTC_NEWADDRESSES	Yeni Litecoin Adresleri
ETH_NEWADDRESSES	Yeni Ethereum Adresleri
BTC_BLOCKS	Bitcoin Blokları
ETH_ADDRESSES	Ethereum Adresleri
LTC_SUPPLY	Litecoin Arzı

EK2 - Kategori 2'de Kullanılan Değişkenler

^GSPC	S&P 500 Endeksi
^NYA	NYSE Kompozit Endeksi
^VIX	CBOE Volatilite Endeksi
CL=F	Ham Petrol
^DJI	Dow Jones Endüstriyel Ortalama
EURUSD=X	EUR/USD Döviz Kuru
FANIX	Fidelity Advisor Energy Fund
FNRCX	Fidelity Advisor Energy Fund Class C
FAGNX	Fidelity Advisor Energy Fund Class M
FSENX	Fidelity Select Energy Index
GBPUSD=X	GBP/USD Döviz Kuru
GC=F	Altın
KMKNX	Kinetics Market Opportunities Fund (KMKNX)
KMKYX	Kinetics Market Opportunities Fund (KMKYX)
KNPYX	Kinetics Mutual Fds
KNPCX	Kinetics Paradigm Fund
KSCOX	Kinetics Small Cap Opportunities Fund
LSHEX	Kinetics Spin-Off and Corporate Restructuring Fund
LSHAX	Kinetics Spin-off and Corporate Restructuring Fund - Advisor Class A
MISMX	Matthews Gelişmekte Olan Piyasalar Küçük Şirketler Fonu
^IXIC	NASDAQ Kompozit Endeksi
NESGX	Needham Küçük Piyasa Büyüme Fonu (NESGX)
NESIX	Needham Küçük Piyasa Büyüme Fonu (NESIX)
^XAX	NYSE AMEX Kompozit Endeksi
ENPSX	ProFunds UltraSector Petrol ve Gaz Fonu
^GSPTSE	S&P/TSX Kompozit Endeksi (Kanada)
SI=F	Gümüş
KMKAX	The Market Opportunities Fund Advisor Class A
^TNX	10 Yıl Hazine Tahvili Getirisi
^TYX	30 Yıl Hazine Tahvili Getirisi
^FVX	5 Yıl Hazine Tahvili Getirisi
JPY=X	USD/JPY Döviz Kuru